

Universidad Católica de Santa María
Facultad de Ciencias e Ingenierías Físicas y Formales
Escuela Profesional de Ingeniería de Sistemas



Clasificación de bofedales en imágenes satelitales multiespectrales
de la región Arequipa mediante algoritmos de inteligencia artificial

Tesis presentada por las Bachilleres:

Cornejo Paredes, Andrea Sofía

ORCID: 0000-0001-6918-3616

Paja Medina, Aremi Isabel

ORCID: 0000-0002-6899-5046

para optar el Título Profesional de Ingeniero de Sistemas

Asesora:

Dra. Rosas Paredes, Karina

ORCID: 0000-0003-4650-7432

Arequipa - Perú

2024

UCSM-ERP

UNIVERSIDAD CATÓLICA DE SANTA MARÍA

INGENIERIA DE SISTEMAS

TITULACIÓN CON TESIS

DICTAMEN APROBACIÓN DE BORRADOR

Arequipa, 21 de Agosto del 2024

Dictamen: 012184-C-EPIS-2024

Visto el borrador del expediente 012184, presentado por:

2019802852 - CORNEJO PAREDES ANDREA SOFIA

2019205292 - PAJA MEDINA AREMI ISABEL

Titulado:

**CLASIFICACIÓN DE BOFEDALES EN IMÁGENES SATELITALES MULTIESPECTRALES DE LA
REGIÓN AREQUIPA MEDIANTE ALGORITMOS DE INTELIGENCIA ARTIFICIAL**

Nuestro dictamen es:

APROBADO

Título Profesional/Título de Segunda Especialidad/Grado Académico a optar:

INGENIERO DE SISTEMAS

**29643112 - GUEVARA PUENTE DE LA VEGA KARIM
DICTAMINADOR**



**29612305 - SULLA TORRES JOSE ALFREDO
DICTAMINADOR**



**71132586 - ANGULO OSORIO JAVIER FERNANDO
DICTAMINADOR**



Clasificación de bofedales en imágenes satelitales multiespectrales de la región Arequipa mediante algoritmos de inteligencia artificial

INFORME DE ORIGINALIDAD

17%

INDICE DE SIMILITUD

15%

FUENTES DE INTERNET

6%

PUBLICACIONES

5%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1

dblp.org

Fuente de Internet

<1%

2

Submitted to Universidad Internacional de la Rioja

Trabajo del estudiante

<1%

3

Submitted to Universidad Católica de Santa María

Trabajo del estudiante

<1%

4

www.journaltocs.ac.uk

Fuente de Internet

<1%

5

hdl.handle.net

Fuente de Internet

<1%

6

Submitted to Colegio de Estudios Superiores de Administración, CESA

Trabajo del estudiante

<1%

7

www.theibfr.com

Fuente de Internet

<1%

Dedicatoria

En agradecimiento a mis padres quienes me apoyan siempre a pesar de la distancia, especialmente a mi papá por ser mi todo y cuidar de mí en mis aventuras desde que nació. Gracias a cada una de las personas que pusieron una pieza en mi mosaico, sobretodo a mis mejores amigos. Este un gran paso en el presente, pero un pequeño paso para mi yo futuro.

Yrms

Andrea Sofia Cornejo Paredes

Dedico este trabajo primeramente a mi familia, de quienes tuve el apoyo de seguir lo que quise estudiar dándome tantos años de cariño, principalmente a mi hermana que siempre me apoyó a pesar de todo siendo la mayor de las dos, animándome en cada paso del camino y enseñándome lecciones valiosas, a mi madre que siempre quiso lo mejor para mí, llevándome a salir de mis límites sin temor para estar preparada para el futuro, y a mi padre que se aseguraba de que no me faltara la comida para seguir adelante, porque sé que nunca perdieron la fe en mí. A mis amigos que hice en esta etapa de mi vida, que sé que puedo confiar en ellos como ellos en mi. También dedico este trabajo a mi querido Balú, que descansa en paz, ya que me dio la motivación de nunca rendirme. A mis acompañantes actuales, que siempre me sacan una sonrisa, de verdad espero que todos estén orgullosos de este logro.

Aremi Isabel Paja Medina

Agradecimientos

La presente investigación se realizó gracias al apoyo de los docentes de la Universidad Católica de Santa María y personas que pusieron una pieza en el mosaico de nuestra formación profesional.

Un agradecimiento especial a nuestros padres por su inmensurable apoyo incondicional. A todos los docentes y mentores que contribuyeron a nuestra formación, especialmente al Dr. José Sulla Torres, a la Dra. Karina Rosas Paredes, al Dr. Manuel Mariano Zuñiga Carnero, a la Dra. Gwendolyn Peyre y al Mg. Enrique Manuel Zúñiga Portilla, quienes nos ofrecieron la gran oportunidad de participar en esta investigación. Además, agradecemos cordialmente al Vicerrectorado de Investigación y a la Universidad Católica de Santa María por haber apoyado y patrocinado el proyecto. Finalmente, agradecemos a Alexander, Beatrice y Maria Belen por su apoyo y amistad.



RESUMEN

Los bofedales, ecosistemas de vital importancia a nivel mundial, desempeñan un papel crucial en la sostenibilidad ambiental y en el bienestar de las comunidades. A pesar de su relevancia, mayormente han sido subestimados y carecen de la atención necesaria en términos de estudios detallados y monitoreo. Esta falta de análisis ha generado una brecha en la comprensión de la importancia y la dinámica de estos ecosistemas, lo que resulta en una escasez de información para la toma de decisiones informadas sobre su conservación y gestión. En este contexto, la presente investigación tiene como objetivo principal clasificar bofedales en imágenes satelitales multiespectrales de la región Arequipa mediante la aplicación de algoritmos de aprendizaje supervisado. Además, se busca aportar al corpus del conocimiento científico y apoyar la toma de decisiones en la preservación de este crucial ecosistema.

Los objetivos específicos de esta investigación incluyen realizar una investigación exhaustiva acerca del análisis de los bofedales en imágenes satelitales, seleccionar la fuente adecuada de datos de imágenes satelitales multiespectrales, diseñar y entrenar algoritmos para la clasificación de imágenes, y validar los resultados obtenidos. Como resultado esta investigación demuestra la viabilidad y la eficacia de utilizar algoritmos de Inteligencia Artificial, como las Redes Neuronales Convolucionales (CNN), Random Forest y K-Nearest Neighbors (KNN), para la clasificación de imágenes satelitales multiespectrales en el monitoreo de los bofedales en Arequipa. Los resultados obtenidos muestran que la CNN tuvo la mayor precisión con un 70 %, seguida por Random Forest con un 59 % y KNN con un 58 % .

Palabras claves

Redes neuronales; Análisis de imagen; Bofedales; Imágenes satelitales.

ABSTRACT

Wetlands, ecosystems of vital importance worldwide, play a crucial role in environmental sustainability and community well-being. Despite their relevance, they have been largely underestimated and lack the necessary attention in terms of detailed studies and monitoring. This lack of analysis has generated a gap in the understanding of the importance and dynamics of these ecosystems, resulting in a paucity of information for informed decision-making on their conservation and management.

In this context, the main objective of the present research is to classify bofedales in multispectral satellite images of the Arequipa region by means of the application of supervised learning algorithms. It also seeks to contribute to the corpus of scientific knowledge and support decision making in the preservation of this crucial ecosystem.

The specific objectives of this research include conducting a comprehensive investigation of the analysis of wetlands in satellite images, selecting the appropriate source of multispectral satellite image data, designing and training algorithms for image classification, and validating the results obtained. As a result, this research has demonstrated the feasibility and effectiveness of using Artificial Intelligence algorithms, such as Convolutional Neural Networks (CNN), Random Forest and K-Nearest Neighbors (KNN), for the classification of multispectral satellite images in the monitoring of wetlands in Arequipa. The results obtained show that CNN had the highest accuracy with 70 %, followed by Random Forest with 59 % and KNN with 58 %.

Key Words Neural networks; Image analysis; Wetlands; Satellite images

ÍNDICE

DEDICATORIA

AGRADECIMIENTOS

RESUMEN

ABSTRACT

INTRODUCCIÓN 1

CAPÍTULO I 3

1. Planteamiento de Investigación 4

1.1 El Problema 4

1.1.1 Planteamiento del problema 4

1.2 Objetivos de la investigación 6

1.2.1 Objetivo general 6

1.2.2 Objetivos específicos 6

1.2.3 Preguntas de Investigación 7

1.3 Justificación e Importancia 7

1.4 Variables e hipótesis 8

1.4.1 Hipótesis 8

1.4.2 Variables 8

1.5 Estructura del documento 8

CAPÍTULO II 10

2. Fundamentos Teóricos 11

2.1 Antecedentes de investigación 11

2.2 Estado del Arte 17

2.3 Bases teóricas de la investigación	31
2.3.1 Análisis de imágenes satelitales	31
2.3.2 Inteligencia Artificial	34
2.3.3 Arequipa	36
2.3.4 Land Use Land Cover(LULC)	37
2.4 Consideraciones finales	38
CAPÍTULO III	40
3. Marco Metodológico	41
3.1 Alcances y Limitaciones	41
3.2 Tipo, Nivel y Diseño de Investigación	41
3.3 Universo y Muestra	42
3.4 Técnicas y Herramientas	43
3.4.1 Técnicas de recolección de datos	43
3.4.2 Instrumentos de recolección de datos	43
3.4.3 Herramientas para el procesamiento de datos	43
3.5 Metodología	45
Consideraciones finales	46
CAPÍTULO IV	47
4. Desarrollo de la Propuesta	48
4.1 Planificación del Proyecto SCRUM	52
4.2 Backlog del Proyecto	53
4.3 Entendimiento del Negocio	54
4.3.1 Análisis Estadístico Descriptivo de los Datos de Entrada	54
4.4 Sprint 2: Entendimiento de Datos	60
4.5 Proceso de división del conjunto de datos	60

4.5.1 Recolección y Preparación de los Datos	60
4.5.2 Método de División del Conjunto de Datos	60
4.6 Modelos de Clasificación	61
4.6.1 Modelos utilizados	61
4.6.2 Implementación	64
4.6.3 Proceso de Entrenamiento	64
4.6.4 Proceso de Validación Cruzada	65
4.7 Afinamiento de los hiperparámetros	65
4.7.1 Redes Neuronales Convolucionales	65
4.7.2 K-Nearest Neighbors	66
4.7.3 Random Forest	66
4.8 Pruebas comparativas	66
4.9 Proceso del despliegue	67
4.10 Aprendizajes y Conclusiones SCRUM	67
CAPÍTULO V	69
5. Pruebas y Resultados	70
5.1 Análisis Estadístico Inferencial de los Datos de Salida	70
5.2 Resultados de la Clasificación y Evaluación de Modelos	72
5.3 Gráficas de Resultados	74
5.4 Discusión	76
Conclusiones y Recomendaciones	80
Conclusiones	80
Recomendaciones	82
Trabajos Futuros	83
Referencias	85

Anexos	95
Anexo A.	95



Índice de figuras

1	Unidades resultantes	50
2	Ejemplo de ROIs	51
3	Mapa de Arquitectura	52
4	Distribución de Lat 1	57
5	Distribución de Long 1	57
6	Distribución de Lat 2	58
7	Distribución de Long 2	58
8	Distribución por país	58
9	Distribuciones facetadas Lat 1	58
10	Distribuciones facetadas Long 1	59
11	Distribuciones facetadas Lat 2	59
12	Distribuciones facetadas Long 2	59
13	Nivel de precisión	75

Índice de tablas

1	Resultados del análisis de la estadística descriptiva	57
2	Resultados del análisis de la estadística inferencial	72
3	Resultados del análisis de la estadística inferencial	72
4	Resultados del análisis de la estadística inferencial	73
5	Compilación de resultados de los algoritmos	73
6	Resultados de las iteraciones del modelo CNN	74



INTRODUCCIÓN

En la región de Arequipa, un proyecto cobra vida con una visión clara y un propósito definido: la clasificación precisa de bofedales mediante el empleo de algoritmos de inteligencia artificial (IA) aplicados a imágenes satelitales multispectrales. En un contexto global donde la necesidad de contar con una cartografía de los bofedales ha adquirido relevancia debido a su papel fundamental en la sostenibilidad ambiental y el bienestar de las comunidades. Esta exigencia encuentra respaldo en las palabras de Penghai, quien destaca las incertidumbres introducidas por las evaluaciones puntuales y anuales en la comprensión de la evolución espacio-temporal de los humedales (Wu, Zhan, Cheng, Yang, y Wu, 2021).

En el contexto latinoamericano, los bofedales emergen como ecosistemas de vital importancia, pero estos enfrentan desafíos socioambientales, como se ve en el estudio de Doumet (Chilán, 2020). En la región de Arequipa, esta se destaca por sus singulares bofedales, fundamentales para la sostenibilidad ambiental y el bienestar de las comunidades.

A pesar de su importancia, estos ecosistemas han recibido poca atención y se enfrentan a varias amenazas, como puede ser los impactos del cambio climático, según evidencian estudios locales Villasante Benavides (2021). Ante este panorama, surge la necesidad de desarrollar un proyecto de clasificación que permita cartografiar y monitorear la cobertura del suelo en los bofedales de la región.

La relevancia de esta investigación se fortalece al considerar la falta de propuestas locales para el monitoreo de estos ecosistemas vitales. Al abordar esta problemática, el proyecto se propone utilizar algoritmos de inteligencia artificial para lograr una clasificación precisa. Inspirado por la iniciativa de Edwin Pizarro en los Andes centrales del Perú Pizarro, Pricope, Vargas-Machuca, Huanca, y Ñaupari (2022), este estudio tiene como objetivo contribuir al conocimiento científico con una mejor comprensión de la distribución de los bofedales.

En este contexto, se diseña e implementa la propuesta de un proyecto que utiliza algoritmos semiautomáticos para la clasificación de bofedales, facilitando el seguimiento continuo

de estos ecosistemas en la región de Arequipa.

A continuación, este documento presenta el plan de investigación, los fundamentos teóricos, el marco metodológico, el desarrollo de la investigación, y finalmente, una discusión de las conclusiones obtenidas.





CAPÍTULO I

1. Planteamiento de Investigación

1.1 El Problema

1.1.1 Planteamiento del problema

A nivel mundial, existe una necesidad de la existencia de contar con una cartografía precisa de los bofedales, ecosistemas fundamentales que desempeñan un papel crucial en la sostenibilidad ambiental y en el bienestar de las comunidades. Esta necesidad abarca diversas aplicaciones, desde la conservación de la biodiversidad hasta la gestión sostenible de recursos hídricos. Penghai (2021) respalda esta necesidad en su estudio sobre humedales, destacando que, a pesar de su significativa contribución, las evaluaciones de riesgos ecológicos del paisaje de humedales a largo plazo han dependido en gran medida de evaluaciones puntuales y anuales, introduciendo incertidumbres en la comprensión de la evolución espacio-temporal. (Wu y cols., 2021)

Los bofedales enfrentan varios desafíos críticos a nivel mundial, siendo los más importantes el cambio climático y la sobreexplotación de recursos hídricos. El retroceso de los glaciares y las temperaturas extremas afectan la disponibilidad de agua y la vegetación, mientras que el uso intensivo del agua para agricultura y ganadería drena y degrada estos ecosistemas vitales. Además, las actividades mineras y el desarrollo urbano contaminan y destruyen los bofedales, poniendo en riesgo su capacidad para sostener la biodiversidad y las comunidades locales. (Edwin, 2016)

En América Latina los bofedales se encuentran entre los ecosistemas de vital importancia, especialmente en el contexto de la abundante biodiversidad que caracteriza a la región. Sin embargo, a pesar de ser parte importante de la cadena montañosa de los Andes, la más extensa del mundo, estos humedales han sido subestudiados históricamente. La falta de atención no los exime de las preocupaciones ambientales que afectan a los ecosistemas de montaña de la región. Según el estudio de (Chilán, 2020), los humedales en América Latina enfrentan numerosos desafíos, incluidos problemas socioambientales causados por intereses económicos particulares, una falta de sensibilidad hacia su importancia ambiental y una es-

casa valoración social en muchos territorios.

En los Andes centrales del Perú en el año 2022, se identificó la necesidad de cartografiar y monitorear la cobertura del suelo en ecosistemas montañosos con topografía diversa y tipos de vegetación muy mezclados, Por ello, el artículo de Edwin Pizarro destaca la importancia de los ecosistemas altoandinos, fundamentales para la biodiversidad y los servicios ecosistémicos en Perú (Pizarro y cols., 2022).

A nivel local, los bofedales en la región de Arequipa se revelan como ecosistemas sumamente susceptibles a los impactos del cambio climático, como demuestra el estudio detallado de (Villasante Benavides, 2021) en donde evaluaron estos cambios en dos bofedales distintos y significativos. Esta investigación destaca la vulnerabilidad de los bofedales altoandinos locales al cambio climático y la importancia de implementar un modelo de monitoreo continuo para comprender y administrar las variaciones en el área y la salud de estos ecosistemas a nivel local.

A partir de lo presentado anteriormente, se ha llegado a la conclusión de que la falta de análisis de los bofedales, donde se considera como área de estudio la integridad de la región de Arequipa, Perú, es un problema que plantea la necesidad de estudiar y comprender los cambios en la distribución y densidad de los bofedales en relación a las condiciones climáticas y temporales.

Entre las causas de esta problemática hemos identificado que no se cuenta con conocimientos en la literatura actual sobre las tecnologías de análisis de imágenes satelitales (Huanca, 2019). Adicionalmente la disponibilidad de tecnologías avanzadas, equipos especializados y personal capacitado necesarios para llevar a cabo estudios exhaustivos y monitoreos regulares a estos ecosistemas está limitada por la falta de inversión adecuada. Por otro lado, existen múltiples amenazas ambientales causadas por las interacciones entre población humana y naturaleza. Y no se tiene una noción clara de la evolución por lo que no se puedan tomar decisiones de forma oportuna para el cuidado de un espacio tan importante (MINAM, 2019) (Gonzales, 2015)

Esta insuficiencia ocasiona diversos problemas como la falta de propuestas de investigación para el análisis de los bofedales, lo que puede limitar la capacidad de los investigadores para comprender los patrones de deforestación y degradación de estos ecosistemas andinos, lo cual obstaculiza la implementación de medidas efectivas para mitigar estas problemáticas (Stahl y cols., 2023). Además, ocurre una gran pérdida de la biodiversidad en los bofedales arequipeños, afectando a especies endémicas y aquellas en peligro de extinción que dependen de este hábitat particular (Gonda, 2020), y como efectos adversos que ponen en riesgo el equilibrio socio-ecológico andino, se tiene a la deforestación (Christmann y cols., 2023), las actividades humanas de las sociedades altoandinas, la contaminación hídrica, crecimiento de especies invasoras e incluso al cambio climático (Arlitt Lozano-Povis, 2021) (Jennifer Calderón-Caro, 2021). Las dificultades mencionadas tienen un impacto directo en la biodiversidad y los servicios ecosistémicos de los bofedales de Arequipa, lo que daña la calidad de vida de las comunidades locales que dependen de estos recursos vitales. (Botero, 2015).

Esta investigación tiene como aporte poder contribuir al conocimiento científico con una mejor comprensión de la distribución de los bofedales. Apoyando al análisis y la toma de decisiones a través del uso de redes neuronales. Además se cuenta con la publicación de un artículo científico indexado en Scopus el cual muestra la aplicación de este algoritmo y sus resultados principales.

1.2 Objetivos de la investigación

1.2.1 Objetivo general

Clasificar bofedales en imágenes satelitales multiespectrales de la región Arequipa mediante la aplicación de algoritmos de aprendizaje supervisado.

1.2.2 Objetivos específicos

1. Realizar una investigación exhaustiva acerca del análisis de los bofedales en imágenes satelitales.
2. Elegir la fuente de datos adecuada de imágenes satelitales multiespectrales.

3. Diseñar y entrenar algoritmos de aprendizaje supervisado, como redes neuronales, para llevar a cabo la clasificación precisa de los bofedales en las imágenes satelitales seleccionadas.
4. Validar los resultados con por lo menos 3 modelos diferentes con su respectiva comparación de resultados.

1.2.3 Preguntas de Investigación

1. ¿Es posible realizar una investigación exhaustiva acerca del análisis de los bofedales en imágenes satelitales?
2. ¿Se puede elegir la fuente de datos adecuada de imágenes satelitales multiespectrales?
3. ¿Es viable diseñar y entrenar algoritmos de aprendizaje supervisado, como redes neuronales, para clasificar con precisión los bofedales en las imágenes satelitales seleccionadas?
4. ¿Se pueden validar los resultados utilizando al menos tres modelos diferentes y compilar los resultados obtenidos?

1.3 Justificación e Importancia

Los bofedales son uno de los hábitats más importantes para los seres humanos y son ecosistemas multifuncionales ricos en biodiversidad. Estos tienen múltiples funciones, como mantener la biodiversidad, secuestrar carbono, circular el agua, purificar los cuerpos de agua y regular el clima local (Fonkén, 2015). Además, los bofedales también tienen importantes valores de patrimonio cultural e histórico y de desarrollo económico y social sostenible (Zhipeng, Jiang, Peng, Deng, y Wang, 2023). Asimismo, los bofedales, que son ecosistemas altiplánicos de gran importancia, juegan un papel importante en la ecología de la región de Arequipa, Perú. La diversidad biológica y la integridad del hábitat local se mantienen gracias a su preservación, que también contribuye significativamente a la regulación del ciclo hidrológico y al mantenimiento de servicios ecosistémicos importantes (Amani, Brisco, y cols., 2021).

Además de su función ecológica, los bofedales tienen un impacto socioeconómico significativo en las comunidades locales, ya que proporcionan pastizales para la ganadería y mantienen la forma de vida tradicional. Sin embargo, varios factores, como el cambio climático y las prácticas humanas no sostenibles, pueden poner en peligro esta delicada interacción entre el ecosistema y las actividades humanas. A partir de esto la propuesta busca analizar detalladamente los bofedales para evaluar su estado actual y para proporcionar información útil para la planificación e implementación de estrategias para la conservación y uso sostenible de estos ecosistemas cruciales en la región de Arequipa.

1.4 Variables e hipótesis

1.4.1 Hipótesis

Será posible que los algoritmos de aprendizaje supervisado sean capaces de clasificar de forma precisa y eficiente los bofedales de otras coberturas de suelo con una alta exactitud, aprovechando las características espectrales distintivas de los ecosistemas en las bandas multiespectrales.

1.4.2 Variables

La variable dependiente de este proyecto es la siguiente:

- **La clasificación de Bofedales:** Su indicador es: Porcentaje de precisión del modelo de clasificación y sensibilidad del modelo en la identificación de bofedales.

Las variables independientes del proyecto son las siguientes:

- **Algoritmos de inteligencia Artificial (Aprendizaje supervisado):** Sus indicadores son: nivel de exactitud y tamaño del conjunto de datos.

1.5 Estructura del documento

El presente trabajo de investigación está organizado con los siguientes capítulos:

En el Capítulo I donde se explica el planteamiento del problema, la justificación del proyecto, sus objetivos, su hipótesis y sus variables. En el Capítulo II en donde se presentará

el marco metodológico, detallando el estado del arte, los antecedentes y las bases teóricas del proyecto. En el Capítulo III se presentará la metodología, explicando el propósito, alcance, limitaciones y los requerimientos. En el Capítulo IV se desarrollará la solución, mostrando la muestra obtenida, la clasificación de las imágenes con los 3 algoritmos y se dará la prueba de hipótesis. En el Capítulo V se presentarán los resultados, teniendo una discusión de los datos obtenidos. Finalmente, de enumera las conclusiones y recomendaciones propuestos.





2. Fundamentos Teóricos

2.1 Antecedentes de investigación

En el artículo de investigación denominado **Global Land-Cover Mapping With Weak Supervision: Outcome of the 2020 IEEE GRSS Data Fusion Contest** (Robinson y cols., 2021) se presentan los resultados del Data Fusion Contest del 2020 organizado por la IEEE Geoscience and Remote Sensing Society. Donde se tuvo como objetivo poder aportar al monitoreo de forestal de zonas de difícil acceso empleando algoritmos de Inteligencia Artificial. Por lo que se propuso:

- Emplear imágenes procesadas de satélites como Sentinel-1 y Sentinel-2.
- Analizar los diferentes algoritmos más precisos para el análisis de imágenes.

Los resultados fueron exitosos. Nos permiten considerar la oportunidad de entrenar Inteligencia Artificial a pesar de contar con labels de baja resolución.

En el artículo de investigación denominado **Deep Learning Model Development for Detecting Coffee Tree Changes Based on Sentinel-2 Imagery in Vietnam** (Le y cols., 2022) se muestran los resultados de una red neuronal que permite la clasificación de café empleando imágenes remotas. A fin de poder monitorear el estado de las plantaciones de difícil acceso. Por lo que se propuso:

- Emplear clases de objetos para la manipulación de imágenes.
- Hacer uso de técnicas como Augmento de datos para permitir de nuestros datos sean más amplios y complejos.

Los resultados demostraron un 95 % de exactitud incluso en las zonas de difícil visibilidad.

En el artículo de investigación denominado **Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review** (Amani y cols., 2020) se busca explorar diferentes aspectos de la plataforma GEE,

incluyendo sus datasets, funcionalidades, ventajas/limitaciones. Para lo cual se hizo una revisión de 450 publicaciones donde se hace uso de la herramienta para clasificación de imágenes satelitales. Por lo que se propuso:

- Hacer uso de la herramienta Google Earth Engine Cloud Computing Plataform para poder realizar la segmentación del espacio de estudio.
- Crear un mapa de visualización que permita seleccionar las diferentes clases de área de acuerdo al interés.

Los resultados resaltan el uso efectivo de la herramienta, describiendo su aplicación como una ventaja para cualquier investigación.

En el artículo de investigación denominado **Sentinel-1 InSAR Coherence for Land Cover Mapping: A Comparison of Multiple Feature-Based Classifiers** (Jacob y cols., 2020) demuestra la idoneidad de usar imágenes satelitales para el mapeo de vegetación. Por lo que se evalúan 7 flujos de clasificación en diferentes zonas de Europa considerando entre 9 a 15 clases. Por lo que se propuso:

- Realizar la clasificación de acuerdo a colores principales para su rápido entendimiento.
- Emplear imágenes de los últimos 10 años, realizar un análisis de clases de tipo y profundidad.

Como resultado se destaca una mejora del 75 % a comparación de propuestas similares.

En el artículo denominado **Anomaly Detection Based on Tree Topology for Hyperspectral Images** (Sun y cols., 2023), comparte un nuevo enfoque denominado Tree Topology based Anomaly Detection (TTAD) para detectar anomalías en imágenes hiperespectrales, analizando datos en lugar de suposiciones específicas. Por lo que se propuso:

- El método emplea la topología matemática para extraer características de la cobertura terrestre y evaluar cada componente.

- Mejorar la separabilidad entre las anomalías y el fondo para evaluar el grado de anomalía.

Como resultado de los experimentos se comprueba que la propuesta tiene una excelente precisión de clasificación de imágenes además de eficiencia computacional en escenarios complejos.

En el artículo titulado **Sparse Pixel Training of Convolutional Neural Networks for Land Cover Classification** (Laban, Abdellatif, Ebeid, Shedeed, y Tolba, 2021), se aborda la problemática de la escasez de datos de entrenamiento en el campo de la teledetección para la clasificación de la cubierta terrestre mediante Inteligencia Artificial convolucionales. Por lo que se propuso:

- Un entrenamiento basado en píxeles dispersos de redes neuronales convolucionales U-Net para la clasificación de la cubierta terrestre.
- Reconstruir las imágenes de entrenamiento a partir de la colección de puntos de forma aleatoria y se utilizan como entrada para las redes convolucionales.
- Utilizar este método para reproducir la cantidad de datos de entrenamiento a partir de las diferentes señales espectrales para cada cobertura del suelo.
- Establecer los puntos recogidos en más de una forma, ya sea una simple imagen de tablero de ajedrez, un tablero de ajedrez de varios tamaños o utilizando una imagen similar a una plantilla, para utilizarlos posteriormente en el proceso de entrenamiento de U-Net.

Se obtuvo el siguiente resultado, el método propuesto mostró una notable superioridad en la clasificación de la imagen de satélite Sentinel-2 para la gobernación de Fayoum en Egipto, superando a otros métodos en precisión total en aproximadamente un 2%, y al mismo tiempo mejoró la clasificación de categorías relacionadas como trébol y trigo o suelo urbano y desnudo.

En el artículo denominado **Weakly Supervised Learning for Land Cover Mapping of Satellite Image Time Series via Attention-Based CNN** (Ienco, Gbodjo, Gaetano, y Interdonato, 2020), se presenta la restricción de información de las etiquetas relacionadas a la cartografía al usar imágenes satelitales, lo que genera un débil conocimiento que afecta a distintos procesos de análisis de datos. Por lo que se propuso:

- Un nuevo marco de aprendizaje profundo, llamado TASSEL, para la cartografía de la cubierta terrestre de las series cronológicas de imágenes de satélite (SITS) basado en objetos.
- Abordar la débil supervisión proporcionada por las etiquetas de granularidad gruesa y explota la información polifacética que transmite la representación basada en objetos.
- Identificar los diferentes componentes de los objetos mediante un análisis de conglomerados y adoptar un bloque CNN para extraer una representación interna de cada uno de ellos.

Se obtuvieron los siguientes resultados, primero que TASSEL supera a los enfoques competidores en términos de rendimiento predictivo y produce valiosa información adicional que puede explotarse en la práctica para interpretar las decisiones del modelo. Además, el análisis cualitativo muestra cómo el marco extrae conocimientos que pueden relacionarse directamente con su decisión y ayudar a la interpretación espacial de la clasificación obtenida, por ello, se destaca la eficacia de TASSEL en términos de métricas de clasificación frente a los enfoques más avanzados de la competencia y se sugiere la posibilidad de mejorar y ampliar el codificador CNN de acuerdo con estudios recientes que investigan el uso de enfoques de aprendizaje profundo para el análisis general de datos de series temporales.

En el artículo denominado **Application of Convolutional Neural Networks With Object-Based Image Analysis for Land Cover and Land Use Mapping in Coastal Areas: A Case Study in Ain Témouchent, Algeria**(Zaabar, Niculescu, y Kamel, 2022), se presenta la falta de detección y cartografía de la ocupación y uso del suelo en

la zona costera de Ain Témouchent, Argelia. Por lo que se propuso:

- Uso de un modelo de aprendizaje profundo de red neuronal convolucional (CNN) en combinación con el análisis de imágenes basado en objetos (OBIA)
- Mapear LULC en la zona costera de Ain Témouchent, al oeste de Argelia, utilizando datos de imágenes centinela-2 y Pléiades
- Construir el modelo CNN basado en capas de convolución, ocultas y de agrupación máxima.
- Optimizar los parámetros de la arquitectura de la CNN para mejorar el modelo de cara a su posterior procesamiento.

Se obtuvieron los siguientes resultados, en donde, primero se construyó un modelo CNN basado en capas de convolución, ocultas y de agrupación máxima., luego se logró optimizar los parámetros de la arquitectura de la CNN para mejorar el modelo de cara a su posterior procesamiento, se aplicó el OBIA para clasificar los objetos segmentados y detectar las características LULC, por último, el método propuesto alcanzó una alta precisión global (93,5 %) utilizando imágenes Pléiades, revelando mejoras significativas en comparación con otras técnicas de aprendizaje automático. Se concluyó que el método aquí propuesto es útil para la detección de LULC y puede aplicarse a escalas mayores en zonas costeras.

En el artículo titulado **Natural Forest Mapping in the Andes (Peru): A Comparison of the Performance of Machine-Learning Algorithms**(Isuhuaylas, Hirata, Santos, y Torobeo, 2018), se aborda el tema de la identificación de las condiciones de los bosques de montaña en los Andes para su conservación además de la clasificación de los bosques de montaña es difícil debido al ruido en los datos de reflectancia dentro de las clases de cobertura terrestre. Por lo que se propuso:

- Realizar un análisis comparativo no paramétrico del rendimiento de varios clasificadores producidos por tres algoritmos de aprendizaje automático supervisado.

- Seleccionar un método de clasificación óptimo para obtener resultados precisos en la identificación de las condiciones de los bosques de montaña de los Andes para su conservación en zonas donde la clasificación es difícil debido al ruido en los datos de reflectancia dentro de las clases de cobertura terrestre.
- Utilizar los métodos SVM y RF para separar las clases de cobertura del suelo de bosque montano y matorral de los Andes, y comparar sus mejores clasificadores con los del método kNN.
- Evaluar la precisión de clasificación de cada método y determinar cuál produce el mayor rendimiento de clasificación.
- Utilizar datos del satélite Landsat 8 OLI y datos de la cubierta terrestre para llevar a cabo el análisis estadístico comparativo.

Los resultados obtenidos indican que los métodos SVM (Máquinas de Vectores de Soporte) y RF (Bosques Aleatorios) no difirieron significativamente en su capacidad para distinguir entre las clases de cobertura del suelo de bosque montano y matorral de los Andes. Sin embargo, los clasificadores SVM y RF superaron de manera significativa al método kNN (Vecinos más Cercanos) en términos de precisión de clasificación, con valores AUC de 0,81 y 0,79, respectivamente, en comparación con el valor AUC de 0,75 obtenido por kNN. Esto se debió a que el método kNN fue más sensible a datos de entrenamiento ruidosos. En consecuencia, se concluyó que el mejor rendimiento de clasificación se logró utilizando un modelo de clasificación SVM, empleando los valores de reflectancia de las bandas 2 a 7, NDVI (Índice de Vegetación de Diferencia Normalizada), MSAVI (Índice de Vegetación Simple Modificado) y variables topográficas como la elevación y el aspecto.

En el artículo denominado **Improved Mapping Results of 10 m Resolution Land Cover Classification in Guangdong, China Using Multisource Remote Sensing Data With Google Earth Engine**(Y. Tu y cols., 2020), se presentó un estudio en el que se desarrolló un marco robusto para mejorar los resultados cartográficos de la clasifica-

ción de la cobertura del suelo de 10 m de resolución en la provincia de Guangdong, China, utilizando múltiples fuentes de datos de teledetección, algoritmos de aprendizaje automático y la plataforma gratuita basada en la nube de Google Earth Engine. Para lograr este objetivo, se llevaron a cabo las siguientes acciones:

- Se recolectaron miles de muestras de forma manual.
- Se utilizaron datos de teledetección de múltiples fuentes, incluyendo Sentinel-1, Sentinel-2 y LuoJia-1.
- Se emplearon algoritmos de aprendizaje automático, incluyendo modelos de bosque aleatorio, árboles de clasificación y regresión, distancia mínima y máquina de vectores de soporte.
- Se evaluaron los resultados obtenidos mediante la comparación con otros productos de cobertura del suelo existentes.

Los resultados obtenidos indicaron que se logró una precisión general del 86,12% y un coeficiente Kappa de 0,84 para la clasificación de la cobertura del suelo en Guangdong para 2019. También se encontró que los modelos de bosque aleatorio obtuvieron un mejor rendimiento que los modelos de árboles de clasificación y regresión, distancia mínima y máquina de vectores de soporte. Asimismo, se determinó que las características derivadas de los datos de Sentinel-1 y los índices espectrales de Sentinel-2 contribuyeron en gran medida al proceso de clasificación, mientras que la característica de los datos de LuoJia-1 no fue tan importante como otras configuraciones.

2.2 Estado del Arte

A continuación se presentan diferentes investigaciones desde el campo internacional y nacional relacionadas con el problema de investigación de falta de conocimiento de los movimientos de los bofedales y su clasificación de imágenes satelitales con el uso de Inteligencia Artificial como categorías principales del presente estudio.

(Gidey y cols., 2023) En el estudio llevado a cabo en Raya Valley, en el sur de Ti-gray, Etiopía, se abordó la modelación de los factores determinantes de los cambios en el uso y cobertura de la tierra (LULCC, por sus siglas en inglés), considerando tanto influencias naturales como socioeconómicas. Para ello, la investigación empleó un enfoque de muestreo multietapa, recolectando datos de 246 hogares distribuidos en diversas zonas agroclimatológicas, que abarcaron las tierras bajas, las tierras medias, las tierras altas y las subalpinas. Los datos de campo se analizaron mediante estadísticas descriptivas y un modelo de regresión logística. Los resultados del estudio identificaron la expansión de tierras agrícolas, la extracción de leña, la deforestación, el sobrepastoreo y la expansión de infraestructura como las causas inmediatas de los cambios en el uso y cobertura de la tierra en la zona de estudio. Específicamente, se destacó que la expansión de tierras agrícolas y la extracción de madera para la producción de combustible y carbón vegetal fueron factores prominentes en estos cambios. Además, se identificaron factores subyacentes como la persistente sequía, el crecimiento rápido de la población y la variabilidad climática como impulsores clave de los cambios en el uso y cobertura de la tierra. En última instancia, el estudio enfatiza la importancia de considerar y abordar estos determinantes para la formulación de políticas de uso de la tierra sostenibles, especialmente en el contexto de pequeños agricultores, y destaca su relevancia para el diseño e implementación de estrategias de gestión de tierras basadas en la evidencia científica por parte de los responsables de la formulación de políticas y gestores de tierras.

(Peyre, Osorio, François, y Anthelme, 2021) realizaron la investigación Mapping the páramo land-cover in the Northern Andes, y tuvo como objetivo principal clasificar la cobertura del páramo, estimar su extensión total y distribución entre los países andinos, y analizar la posición y la influencia antropogénica de su límite arbóreo. Para ello, se utilizaron imágenes Landsat 8 y se realizaron clasificaciones híbridas manuales-automatizadas con los algoritmos Maximum Likelihood y Random Forest. Los resultados obtenidos indicaron que la extensión del páramo era de 24.301 km², distribuidos principalmente en Ecuador (47%) y Colombia

(43%), seguidos de Venezuela (8%) y Perú (2%). Las clases de cobertura dominantes fueron los matorrales, las comunidades de plantas en roseta y los pastizales, mientras que las clases que reflejaban un uso intenso de la tierra ocupaban un porcentaje menor. Además, se encontró que el límite arbóreo promedio estaba bordeado en un 16% por clases antropogénicas de ocupación del suelo. En conclusión, la extensión del páramo es menor de lo sugerido previamente, y se observa una expansión de cultivos y pastizales hacia zonas elevadas, lo que plantea preocupaciones para la sostenibilidad a largo plazo. Estos hallazgos son relevantes para la predicción de cambios en el sistema terrestre y la identificación de áreas prioritarias para la conservación. La investigación es relevante para el estudio propuesto, ya que, los datos obtenidos en este estudio podrían complementar la información sobre la cobertura del suelo y el límite arbóreo en el páramo andino, brindando una base sólida para el desarrollo de modelos predictivos y estrategias de gestión ambiental en la región.

(Morata y cols., 2023) realizaron la investigación Neural Network Emulation of Synthetic Hyperspectral Sentinel-2-Like Imagery With Uncertainty, el objetivo del estudio fue generar imágenes hiperespectrales sintéticas por satélite que cubran potencialmente cualquier región, explorando la posibilidad de aplicar el aprendizaje estadístico, es decir, la emulación. La metodología consistió en probar el papel de diferentes algoritmos de regresión de aprendizaje automático y variar el tamaño del conjunto de datos de entrenamiento extraídos de la imagen. Los resultados demostraron que la red neuronal tuvo un rendimiento superior a los otros algoritmos cuando se entrenó con grandes conjuntos de datos (hasta 100,000 muestras). Además, la incertidumbre epistémica se obtiene utilizando la técnica del dropout, revelando la fidelidad espacial de la escena emulada. La conclusión del estudio es que la emulación puede utilizarse para producir imágenes sintéticas hiperespectrales S2 basadas en datos de entrada multiespectrales, con la provisión de estimación de incertidumbre, y de que al utilizar modelos de IA, ocurre un mejor rendimiento a diferencia de otros algoritmos de aprendizaje automático.

(Liu, Qian, y Yue, 2020) realizaron la investigación Combined Sentinel-1A With

Sentinel-2A to Estimate Soil Moisture in Farmland, el objetivo de este estudio fue comparar diferentes algoritmos de filtrado y técnicas de teledetección para estimar la humedad del suelo en zonas agrícolas utilizando imágenes satelitales de Sentinel-1A y Sentinel-2A. La metodología incluyó el uso de diferentes modelos de estimación de humedad del suelo, como el modelo de nubes de agua, el índice modificado de monitorización de la humedad del suelo y el índice perpendicular de sequía modificado, así como algoritmos de regresión, como la red neuronal de regresión generalizada, la regresión de vector de soporte, la regresión de bosque aleatorio y la red neuronal profunda. Los resultados mostraron que el método de filtrado Lee sigma fue el más adecuado para estimar la humedad del suelo en diferentes tipos de cobertura del suelo, y que los coeficientes de retrodispersión del radar después de la eliminación de la influencia de la vegetación mediante el modelo de nubes de agua fueron los más precisos para estimar la humedad del suelo en zonas cubiertas de vegetación. Además, la precisión de la estimación de la humedad del suelo mediante algoritmos de regresión fue superior a la de los modelos semiempíricos SAR y ópticos, y la precisión de la red neuronal profunda fue la más alta entre los algoritmos de regresión evaluados. En conclusión, el artículo demuestra que la combinación de imágenes de Sentinel-1A y Sentinel-2A con técnicas de teledetección y algoritmos de regresión puede ser útil para estimar la humedad del suelo en zonas agrícolas.

(Du, Li, Xu, y Zhou, 2023) realizaron la investigación An Ensemble Learning Approach for Land Use/Land Cover Classification of Arid Regions for Climate Simulation: A Case Study of Xinjiang, Northwest China, fue realizada en Xinjiang, al noroeste de China. El objetivo de la investigación era mejorar la precisión de la clasificación del uso y la cubierta del suelo en regiones áridas para analizar los cambios climáticos. La metodología utilizada se basó en el uso de conjuntos de datos geográficos de múltiples fuentes y la elección de cinco algoritmos de aprendizaje automático para desarrollar diferentes estrategias de aprendizaje de conjunto según las características climáticas y topográficas de cada subregión. Se utilizó un muestreo aleatorio estratificado para obtener muestras de entrenamiento y parámetros óptimos para cada algoritmo de aprendizaje automático. La conclusión de la investigación

fue que el enfoque de aprendizaje conjunto propuesto mejoró en 6,85 % mayor a la precisión de la clasificación LULC en comparación con los algoritmos de aprendizaje automático individuales. La investigación es relevante para el estudio propuesto, ya que ambas abordan la clasificación de imágenes satelitales para el análisis de los cambios en el uso del suelo y la cubierta vegetal, aunque la investigación mencionada se enfoca en regiones áridas mientras que la otra se enfoca en la cordillera de los Andes.

(Li, Lei, Sun, Li, y Kuang, 2020) realizaron la investigación Multimodal Bilinear Fusion Network With Second-Order Attention-Based Channel Selection for Land Cover Classification, el objetivo de la investigación fue proponer una nueva red de fusión bilineal multimodal (MBFNet) que pudiera fusionar características ópticas y de radar de apertura sintética (SAR) para mejorar la clasificación de la cubierta terrestre. La metodología utilizada consistió en la extracción de mapas de características semánticas profundas de imágenes ópticas y SAR a través de una red neuronal convolucional pseudosiamesa (CNN). Luego se utilizó un módulo de selección de canales de segundo orden basado en la atención (SACSM) para obtener mapas finos de atención al canal con estadísticas de segundo orden y seleccionar los canales importantes para mejorar la representación de las redes. Por último, se utilizó el pooling bilineal para fusionar eficazmente diferentes mapas de características compactas modales y obtener características de fusión bilineal para la clasificación de la cubierta terrestre. Los resultados experimentales demostraron que la MBFNet propuesta superó a los métodos más avanzados en la clasificación de la cubierta terrestre. La relación con el estudio propuesto es que ambas investigaciones utilizan IA para la clasificación de imágenes y la fusión de diferentes tipos de datos para mejorar la precisión de la clasificación.

(Cai, Chen, Niu, y Plaza, 2021) realizaron la investigación Landslide Detection Using Densely Connected Convolutional Networks and Environmental Conditions, el objetivo principal de la investigación es mejorar la precisión del modelo de detección de corrimientos de tierras mediante la combinación de factores ambientales y DenseNetse, por ello propone el uso de redes convolucionales densas (DenseNets) y su técnica modificada para resolver los

problemas de aplicación insuficiente, escasez de muestras y poca eficiencia en el reconocimiento de deslizamientos de tierra. La metodología se basa en la creación de una biblioteca de muestras de deslizamientos de tierra con la superposición de 12 factores geológicos, topográficos, hidrológicos y de ocupación del suelo que pueden reflejar directa o indirectamente el desprendimiento de tierras. Luego, se llevó a cabo la detección de corrimientos de tierras en la zona del embalse de las Tres Gargantas, en China, para comprobar el rendimiento del método mejorado. Los resultados muestran que el método propuesto tiene una aplicabilidad prometedora en escenarios de identificación de deslizamientos de grandes áreas. En relación con el estudio propuesto, ambas investigaciones utilizan IA para la detección de fenómenos naturales en imágenes satelitales, pero se enfocan en fenómenos diferentes y utilizan técnicas distintas para mejorar la precisión del modelo de detección.

(Huang, Pu, Li, y Duan, 2020) realizaron la investigación Adaptive Residual Convolutional Neural Network for Hyperspectral Image Classification, la cual presenta una metodología basada en una red neuronal convolucional residual adaptativa (ARCNN) para la clasificación de la cubierta terrestre utilizando cubos de imágenes hiperespectrales (HSI) sin procesar como datos de entrada. La ARCNN propuesta explora bloques de extracción de características espectrales y espaciales para aprender características discriminativas a partir de abundante información espectral y contextos espaciales en las HSI. Además, se utilizan un mecanismo de atención y un bloque de fusión de características para mejorar el rendimiento de la ARCNN y se imponen algunas estrategias, normalización por lotes y abandono, en cada capa convolucional para regularizar el proceso de aprendizaje. La metodología se evaluó en tres conjuntos de datos públicos de HSI y se comparó con otros métodos, como SVM tradicional, SAE, 3-D CNN y SSRN, donde los resultados experimentales muestran la eficacia de la ARCNN propuesta frente a algunos de los métodos más avanzados. Esta investigación se relaciona con la presente ya que ambos trabajos se relacionan con la clasificación de imágenes utilizando algoritmos de aprendizaje automático, lo que los convierte en ejemplos relevantes de la aplicación de la inteligencia artificial en el procesamiento de imágenes, esta nos ayuda

a identificar un modelo de aprendizaje automático que sea directamente útil con el tipo de imágenes a utilizar

(Amani, Mahdavi, y cols., 2021) realizaron la investigación *Wetland Change Analysis in Alberta, Canada Using Four Decades of Landsat Imagery* en Alberta, Canadá, utilizando imágenes de satélite Landsat. El objetivo de la investigación fue analizar las tendencias de los humedales de Alberta en las últimas cuatro décadas para producir información actualizada sobre los cambios en los humedales y evitar una mayor degradación de estos valiosos recursos naturales. La metodología utilizada para elaborar los mapas de humedales se basó en la utilización del motor Google Earth (GEE) y la precisión visual de los mapas fue evaluada. Los resultados del análisis mostraron que el 18% de la provincia había sufrido cambios y se observó una tendencia a la baja en las clases de aguas poco profundas y pantanos y una tendencia al alza en las clases de pantanos y marismas. La pérdida de humedales fue de aproximadamente 22,000 km², mientras que la ganancia de humedales fue de aproximadamente 24,000 km². La investigación concluyó que los resultados proporcionan la primera información exhaustiva sobre las tendencias de los humedales de Alberta en los últimos 37 años y ayudarán a los responsables políticos a ajustar las políticas necesarias/establecidas para mitigar los posibles cambios en los humedales debidos a actividades antropogénicas y a fenómenos relacionados con el clima. La relación con el estudio propuesto es que ambos estudios utilizan técnicas de análisis de imágenes satelitales para analizar la evolución de los ecosistemas naturales a lo largo del tiempo, lo que demuestra el valor de la tecnología satelital en el monitoreo y la conservación del medio ambiente.

(Soylu y Bras, 2022) realizaron la investigación *Global Shallow Groundwater Patterns From Soil Moisture Satellite Retrievals*, la cual se realizó para estimar las distribuciones espaciales y temporales de las zonas influenciadas por aguas subterráneas poco profundas a escala global utilizando un algoritmo de aprendizaje automático conjunto. La metodología utilizada incluyó el entrenamiento del modelo EML usando características estadísticas de los datos SMAP y se encontró que el rendimiento del modelo EML estimaba satisfactoriamente

el estado de GW superficial tras el entrenamiento del modelo con aproximadamente 1,19 millones de puntos de datos obtenidos de las simulaciones Hydrus-1D. Los resultados mostraron que el 19% de la cubierta terrestre había estado influenciada por aguas subterráneas poco profundas en algún momento durante el período de interés (2015-2018). La conclusión de la investigación es que las observaciones del SMAP podrían utilizarse para estimar las aguas subterráneas poco profundas con una alta resolución espaciotemporal a escala mundial, lo que podría proporcionar datos muy valiosos para la modelización y los estudios de vigilancia ambiental. En relación con la propuesta, ambas investigaciones se enfocan en el uso de tecnología satelital para analizar el medio ambiente y sus patrones. Sin embargo, la investigación de "Global Shallow Groundwater Patterns" se enfoca en la estimación de las distribuciones espaciales y temporales de las zonas influenciadas por aguas subterráneas poco profundas, mientras que la propuesta se enfoca en la clasificación de las imágenes satelitales para analizar la dinámica de los bofedales en la región Arequipa.

(Arndt y Lunga, 2021) realizaron la investigación Large-Scale Classification of Urban Structural Units From Remote Sensing Imagery, se realizó con el objetivo de proponer un esquema de categorización de unidades estructurales urbanas y demostrar su utilidad en 13 ciudades mediante el uso de IA. La metodología se basó en experimentos de clasificación en las ciudades y comparación con un método de referencia de características de imagen multiescala y máquinas de vectores de soporte. Los resultados mostraron que las IA lograron una alta precisión global en la clasificación de tipos de unidades estructurales urbanas en diversas regiones geográficas y en colecciones heterogéneas de imágenes de satélite. La conclusión de la investigación destaca la eficacia del enfoque de aprendizaje profundo propuesto en comparación con los métodos de referencia, y se sugiere que pueden realizarse más pruebas comparativas para determinar de forma concluyente si la IA ofrece siempre un aumento del rendimiento en relación con los métodos de referencia compuestos por características de imagen elaboradas a mano y otras clasificaciones. La relación con la investigación propuesta es que ambas investigaciones se centran en la clasificación de imágenes de satélite mediante el

uso de IA, aunque la primera se enfoca en la clasificación de unidades estructurales urbanas.

(Shao, Li, Ding, Zhuang, y Chen, 2020) realizaron la investigación Land Use Classification Using High-Resolution Remote Sensing Images Based on Structural Topic Model. El objetivo del estudio es mejorar la precisión de la clasificación del uso del suelo utilizando un modelo temático estructural (STM) con un modelo de asignación de Dirichlet latente (LDA). La metodología del estudio implica el uso de segmentación multiescala para construir representaciones de bolsa de palabras (BoW) de imágenes de alta resolución y luego utilizar un modelo LDA para la extracción secundaria de características de bajo nivel. Los parches de imagen segmentados se utilizaron como documentos, mientras que las características de bajo nivel de su interior se utilizaron como palabras visuales. El STM se propuso para fusionar la información espacial de los documentos de imagen. Se introdujeron dos tipos de conocimiento previo en el modelo LDA estándar en forma de covariables para simular los efectos de las regiones en las composiciones de temas de los documentos y de palabras de los temas. Los resultados demuestran que el uso de STM para la extracción de características secundarias a partir de documentos de imágenes produce resultados de clasificación más precisos que la adopción de modelos BoW o el uso directo de características de bajo nivel. La conclusión del estudio es que el método propuesto mejora eficazmente la precisión de la clasificación. La relación con la investigación propuesta es el estudio del uso del suelo a través de imágenes de teledetección y técnicas de aprendizaje automático como tema relevante en ambas investigaciones.

(B. Tu, Ren, Zhou, Chen, y He, 2021) realizaron la investigación Feature Extraction Using Multidimensional Spectral Regression Whitening for Hyperspectral Image Classification, con el objetivo de proponer un nuevo método de extracción de características para imágenes hiperespectrales (HSI) basado en blanqueamiento por regresión espectral multidimensional (M-SRW). La metodología consistió en la segmentación por tasa de entropía de la HSI, la realización de SRW en cada bloque de superpíxeles para reducir la dimensión de cada bloque a una dimensión diferente, la combinación de los bloques de superpíxeles de la

misma dimensión para obtener la HSI reconstruida, y la utilización de la máquina de vectores de soporte para clasificar el HSI reconstruido de diferentes dimensiones, y la fusión de decisiones por mayoría de votos para obtener el mapa final de resultados de la clasificación. Los resultados experimentales demostraron que el método M-SRW propuesto es superior a varios enfoques de extracción de características del estado del arte en términos de precisión de la clasificación. En conclusión, el método propuesto presentaba dos ventajas y el desarrollo futuro del artículo incluye explorar la posibilidad de considerar el grado de correlación entre bandas de frecuencia adyacentes en el método DR. La relación con la investigación propuesta es que ambos trabajos tratan de la clasificación de imágenes mediante técnicas de reducción de dimensionalidad y la extracción de características.

(Chen, Chen, Fang, Wang, y Wang, 2021) desarrolló la investigación Class-Aware Domain Adaptation for Coastal Land Cover Mapping Using Optical Remote Sensing Imagery donde se encuentra como objetivo principal facilitar el mapeo de la superficie de la tierra el cual es muy complicado cuando se usa una segmentación a nivel de píxeles. Por lo que, en respuesta, se presenta un método nuevo de adaptación de dominio para la segmentación de píxeles para poder realizar un análisis de cobertura terrestre costera, abordando los problemas principales de cambio de dominio, variación entre clases y desequilibrio. Se usa un enfoque de adaptación adversarial global y local conjunto, un discriminador sensible a las clases y la minimización de entropía a fin de producir unas predicciones mucho más objetivas. Además, se utiliza una ponderación exhaustiva en la pérdida de segmentación supervisada para abordar el problema del desequilibrio de clases. Los resultados de los experimentos demuestran que el método propuesto logra una alineación exitosa de las distribuciones condicionales marginales y de clase mediante la aplicación de transformaciones y la realización de adaptación adversarial global y local de manera separada. Además, la minimización de la entropía es exitosa en generar predicciones con alta confianza para imágenes objetivo sin necesidad de una referencia previa. Se concluye que el método propuesto tiene un rendimiento excelente y competitivo en la cartografía de la cobertura terrestre costera entre dominios. La

relación con la investigación propuesta es que se trabaja con imágenes que tienen dificultad de segmentación a nivel de píxeles debido al estado actual de la cordillera.

(Tombe y Viriri, 2021) en el artículo Adaptive deep co-occurrence feature learning based on classifier-fusion for remote sensing scene classification comparte un método de aprendizaje de características para la clasificación de imágenes satelitales que emplea una red neuronal convolucional para la extracción de características espaciales y un bosque multigrano para el aprendizaje de características y clasificación mediante votos con clasificadores de conjunto. Los resultados experimentales en dos conjuntos de datos públicos demuestran que el método propuesto (ADCFL) supera significativamente a otros métodos de clasificación de última generación en términos de precisión. Como conclusión se confirma esto además de reafirmarlo gracias a la literatura reciente, la cual muestra que la IA es efectiva en la extracción de características para la clasificación de escenas de teledetección, y que la fusión de clasificadores logra resultados superiores que los clasificadores individuales, lo que respalda el enfoque propuesto en este artículo. Esta investigación se relaciona con la presente ya que se emplean algoritmos para la extracción de características especiales, sin embargo, a diferencia de esta, se tendrá en cuenta aspectos de profundidad.

(Fan y cols., 2022) en el artículo Land Cover Classification of Resources Survey Remote Sensing Images Based on Segmentation Model aborda como objetivo la clasificación rápida y precisa de grandes áreas de uso y cobertura de suelo a partir de datos de teledetección. Se compararon métodos de clasificación de aprendizaje automático tradicionales y modelos de segmentación semántica de aprendizaje profundo para encontrar el modelo óptimo de extracción de características. Se utilizó el conjunto de datos de resolución media de Tonghe para la clasificación de recursos de tierra. Los resultados indican que el modelo U-Net es más preciso y eficaz que los métodos de aprendizaje automático tradicionales y otros modelos de segmentación semántica. Este estudio proporciona como conclusión una demostración para la investigación de grandes áreas de cobertura de suelo utilizando imágenes de baja y media resolución de teledetección. En relación a nuestra investigación, el estudio sugiere que los

modelos de aprendizaje profundo pueden ser una herramienta valiosa para la clasificación de grandes áreas de cobertura de suelo a partir de datos de teledetección.

(Sebastianelli, Zaidenberg, Spiller, Saux, y Ullo, 2022) presentó el artículo *On Circuit-Based Hybrid Quantum Neural Networks for Remote Sensing Imagery Classification*, el cual tiene como objetivo investigar cómo las redes neuronales híbridas de convolución cuántica basadas en circuitos pueden emplearse con éxito como clasificadores de imágenes en el contexto de la teledetección. Los QCNN híbridos enriquecen la arquitectura clásica de las redes neuronales convolucionales al introducir una capa cuántica dentro de una red neuronal estándar. Como solución propuesta se aplica a la clasificación de uso y cobertura del suelo, en el caso de uso de observación de la Tierra, y se prueba en el conjunto de datos EuroSAT utilizado como referencia de benchmark. La idea es investigar cómo los QCNN pueden mejorar el rendimiento de los clasificadores de imágenes en el contexto de la teledetección. Los resultados de la clasificación multiclase demuestran la efectividad del enfoque presentado al demostrar que el rendimiento de los QCNN es superior al de los clasificadores clásicos. Además, la investigación de diversos circuitos cuánticos muestra que aquellos que explotan el entrelazamiento cuántico logran las mejores puntuaciones de clasificación. Como conclusión sabemos que este estudio destaca las posibilidades de aplicar la computación cuántica a un estudio de caso de observación de la Tierra y proporciona los antecedentes teóricos y experimentales para futuras investigaciones. Los resultados demuestran que la introducción de una capa cuántica dentro de una red neuronal convolucional puede mejorar significativamente el rendimiento de los clasificadores de imágenes, lo que abre nuevas posibilidades en el campo de la teledetección. Esta investigación está relacionada a nuestro artículo ya que es una tecnología emergente muy importante, la cual exploraremos teóricamente.

(Unal, 2020) en el artículo *Smart Farming Becomes even Smarter with Deep Learning - A Bibliographical Analysis*, se centra como objetivo en la exploración de las ventajas del uso de técnicas de aprendizaje profundo en la agricultura. Para ello, se ha realizado una revisión bibliográfica de 120 artículos publicados entre 2016 y 2019 en 39 revistas científicas.

cas del Science Citation Index. Estos estudios se clasifican en diferentes categorías, como la detección de enfermedades, clasificación de plantas, identificación de la cobertura del suelo, agricultura de precisión, reconocimiento de plagas, reconocimiento de objetos, riego inteligente, fenotipado y detección de malezas. Los resultados muestran que las técnicas de aprendizaje profundo pueden mejorar significativamente la eficiencia y precisión de los sistemas de agricultura inteligente, y se espera que sean cada vez más populares en la agricultura práctica. En conclusión, los estudios sugieren que el uso de técnicas de aprendizaje profundo tiene el potencial de reducir los costos de producción y mejorar la calidad y cantidad de los productos agrícolas.

(Bosco, Wang, y Hategekimana, 2021) presenta el artículo denominado Learning Multi-Granularity Neural Network Encoding Image Classification Using DCNNs for Easter Africa Community Countries, una propuesta para mejorar la clasificación de escenas en teledetección utilizando una arquitectura de codificación de IA de multi-granularidad basada en InceptionV3, InceptionResNetV2, VGG16 y DenseNet201. El objetivo es mejorar el rendimiento y solucionar la variación intraclase para problemas de escena de múltiples clases en conjunto de datos de teledetección. Se utilizó un enfoque de aprendizaje profundo y se aplicó la función de activación y el aprendizaje por ensamble para mejorar la precisión. Los resultados obtenidos muestran que el modelo propuesto produce mejores resultados en el conjunto de pruebas que el modelo InceptionResNetV2, logrando una precisión del 97,84%. Además, se utilizó el promedio de ensamble de redes neuronales convolucionales profundas (DCNN) para mejorar aún más la precisión, obteniendo un resultado del 97,36%, mientras que el promedio ponderado del ensamble logró una precisión del 99,10%. Los experimentos se llevaron a cabo en dos conjuntos de datos públicos, UCM y SIRI-WHU, y uno recopilado a través de Google Earth Engine de los países de la Comunidad del Este de África (EACC), lo que indica como conclusión que la propuesta puede aumentar la precisión con pocas épocas de ajuste y menos tiempo computacional.

(Zafari, Zurita-Milla, y Izquierdo-Verdiguier, 2020) en la publicación A Multiscale

Random Forest Kernel for Land Cover Classification, se exploran nuevos diseños de RFKs (RF kernel) para la clasificación de imágenes de teledetección utilizando SVM. Se utilizan diferentes parámetros y características estructurales de RF para generar varios RFKs, incluyendo la profundidad, el número de ramas y las probabilidades de clase. Se proponen dos tipos de kernel basados en la profundidad: uno en la profundidad óptima y otro multiscale creado mediante la combinación de varios RFKs a diferentes profundidades. Los resultados muestran que los nuevos RFK propuestos superan al kernel RBF en experimentos con un alto número de características. Además, en comparación con el RF estándar, los RFKs propuestos generalmente tienen un mejor rendimiento en SVM. En general, se concluye que el RFK óptimo en profundidad proporciona los mejores resultados.

(Xu y cols., 2019) comparte en *Advanced multi-sensor optical remote sensing for urban land use and land cover classification: Outcome of the 2018 ieee grss data fusion contest*, los resultados científicos del Concurso de Fusión de Datos 2018, organizado por el Comité Técnico de Análisis de Imágenes y Fusión de Datos de la Sociedad de Geociencias y Teledetección de IEEE. El concurso de 2018 se centró en el problema de la observación y monitoreo urbano con teledetección óptica avanzada de múltiples fuentes (LiDAR multiespectral, imágenes hiperespectrales y de muy alta resolución). La competencia se basó en la clasificación de uso y cobertura de la tierra urbana, con el objetivo de distinguir entre clases muy diversas y detalladas de objetos urbanos, materiales y vegetación. Además de la fusión de datos, también se cuantificó los activos respectivos de los nuevos sensores utilizados para recopilar los datos. Los participantes propusieron enfoques elaborados basados en teledetección, aprendizaje automático y visión por computadora para aprovechar al máximo los datos disponibles. Los enfoques ganadores combinan IA con la sutil experiencia del científico de datos de teledetección.

(Zerrouki, Harrou, Zerrouki, Dairi, y Sun, 2021) en *Desertification Detection Using an Improved Variational Autoencoder-Based Approach through ETM-Landsat Satellite Data*, se presenta un enfoque efectivo para detectar regiones desérticas utilizando imágenes de

Landsat y el modelo de autoencoder variacional (VAE). El objetivo principal es mejorar la detección del cambio en la cobertura del suelo para analizar dinámicas del paisaje y mitigar problemas de desertificación. Se extrajeron características de las imágenes multitemporales, incluyendo información multiespectral, mediante el modelo VAE, el cual se ha destacado por su capacidad para extraer características y modelar datos de manera no lineal. El estudio se realizó en la región árida alrededor de Biskra, en Argelia, y se comparó el rendimiento del modelo VAE con otras técnicas, como máquinas de Boltzmann restringidas, modelos de aprendizaje profundo y algoritmos de agrupamiento binario. Los resultados comparativos muestran que el modelo VAE superó consistentemente a los demás modelos para detectar cambios en la cobertura del suelo, principalmente en regiones desérticas. Se concluye que el enfoque propuesto utilizando VAE es más efectivo que las técnicas de detección de cambios del estado del arte.

De acuerdo al análisis realizado del estado, la IA puede ser utilizada para la clasificación de imágenes satelitales de los bofedales en la región Arequipa, puesto que ellas ofrecen maneras de manejar grandes cantidades de datos, aprendiendo patrones complejos de maneras eficientes, además se pueden utilizar para trabajar con imágenes multiespectrales e imágenes satelitales, siendo que son capaces de adaptarse a distintos escenarios, con un gran grado de precisión. El uso de IA, específicamente, en el LULC(Land Use Land Cover), es una propuesta que ha ido tomando relevancia entre varios autores para solucionar problemas similares al propuesto en el presente estudio.

2.3 Bases teóricas de la investigación

2.3.1 Análisis de imágenes satelitales

El análisis de imágenes es un proceso complejo que involucra la interpretación de imágenes y la extracción de información temática de los objetos presentes en ellas. Esta extracción se realiza mediante la síntesis, el análisis y la inducción, basados en el reconocimiento y la medición de imágenes. En otras palabras, se trata de un análisis cualitativo y cuantitativo de información diversa que permite obtener características específicas de las

imágenes. Existen diferentes tipos de extracción de características temáticas que se pueden realizar a través del análisis de imágenes (Alayo Ontón, 2021). Algunos de ellos son:

- Extracción de objetos y estados del suelo específicos: Esta técnica se utiliza para evaluar la situación de un desastre natural, como un terremoto, a través del monitoreo del hundimiento del suelo y su combinación con la estructura geológica local.
- Extracción de indicadores: En este caso, se utilizan diversas operaciones numéricas para obtener índices de vegetación a partir de las imágenes.
- Extracción de cantidades físicas: Esta técnica permite obtener datos de elevación a partir de pares estéreo y calcular una serie de factores del terreno, como la pendiente y la rugosidad.
- Detección de cambios: Esta técnica se utiliza para analizar los cambios en la cobertura del suelo en un área determinada a partir de imágenes tomadas en diferentes fases de tiempo.

El proceso de combinar diferentes conjuntos de datos en un solo análisis implica una serie de actividades importantes (Berdugo Muñoz y Relaes Lopez, 2016), entre las que destacan:

- Transformar todas las imágenes en un sistema de coordenadas coherente para poder compararlas adecuadamente.
- Realizar la corrección atmosférica para eliminar los efectos atmosféricos que pueden afectar la calidad de las imágenes.
- Ajustar el rango dinámico para mejorar el contraste y la visualización de los detalles de las imágenes.
- Dividir las imágenes en mosaicos y sincronizarlos entre conjuntos de datos para facilitar su análisis.

- Realizar un análisis paralelo de bloques para procesar un gran número de imágenes de manera rápida y eficiente.
- Desarrollar transformaciones de registro conjuntas para cada bloque en el conjunto de análisis, lo que ayuda a alinear las imágenes de manera precisa.
- Entrenar redes neuronales artificiales (ANN) para reconocer objetos o patrones de interés.
- Ejecutar las ANN entrenadas en datos combinados para reconocer objetos o patrones.
- Aplicar sistemas expertos para obtener información de los resultados.
- Crear un archivo GeoJSON con los resultados del análisis, lo que permite visualizar y compartir los datos obtenidos de manera efectiva.

Imágenes multiespectrales.

La imagen multiespectral es una técnica avanzada de captura de imágenes que adquiere imágenes donde cada píxel contiene un espectro (intensidad en función de la longitud de onda) de la luz recopilada en ese lugar, en lugar de los típicos tres puntos de datos (rojo, verde y azul) que se encuentran en las imágenes RGB convencionales. Esta técnica se caracteriza generalmente por su enfoque basado en hardware y, en esta revisión, no nos centraremos en los aspectos específicos de esta implementación tecnológica. (Berdugo Muñoz y Relaes Lopez, 2016)

Además, es importante destacar que la imagen multiespectral es ampliamente utilizada en una variedad de aplicaciones debido a su capacidad para proporcionar información más rica y detallada que va más allá de la percepción visual humana. Este enfoque permite el análisis de diversas características y propiedades de los objetos y las superficies, lo que la convierte en una herramienta valiosa en campos como la agricultura de precisión, la monitorización ambiental, la detección de enfermedades de cultivos, la cartografía y la exploración espacial, entre otros. La imagen multiespectral desvela una ventana de conocimiento que

amplía nuestra comprensión y posibilidades en la adquisición de datos visuales y el análisis de nuestro mundo y el universo circundante. (Orozco, Cardenas, Meneses, Sanchez, y Núñez, 2023)

2.3.2 Inteligencia Artificial

La inteligencia artificial (IA) es un campo fascinante que ha capturado la imaginación de la humanidad desde hace varias décadas. En esencia, la IA se refiere a la ciencia y la ingeniería de crear máquinas y programas informáticos inteligentes que sean capaces de realizar tareas que, de otra manera, requerirían la intervención humana (IBM, 2023).

A lo largo de los años, se han presentado varias definiciones de la IA, pero una de las más influyentes es la propuesta por John McCarthy en 2004 (McCarthy, 2007), quien la describió como la ciencia y la ingeniería de hacer máquinas inteligentes, especialmente programas informáticos inteligentes. De acuerdo con McCarthy, la IA no se limita a métodos que sean biológicamente observables.

Sin embargo, la historia de la IA se remonta mucho más allá, a 1950, cuando Alan Turing (Turing, 1950), uno de los padres fundadores de la informática, publicó un trabajo seminal titulado "Computing Machinery and Intelligence", en el que planteó la pregunta: ¿pueden las máquinas pensar? En su trabajo, Turing propuso la famosa prueba de Turing, en la que un interrogador humano trata de distinguir entre las respuestas de texto de una computadora y las de un humano. Aunque esta prueba ha sido objeto de mucha crítica, sigue siendo un concepto importante en la filosofía, especialmente en la lingüística.

Stuart Russell y Peter Norvig, por otro lado, en su libro *Artificial Intelligence: A Modern Approach* (Russell y Norvig, 2010), proponen cuatro posibles objetivos o definiciones de la IA, que diferencian a los sistemas según si piensan o actúan como humanos o de manera racional.

La IA implica el uso de datos y algoritmos de aprendizaje automático y aprendizaje profundo para resolver problemas y crear sistemas expertos que hacen predicciones y clasificaciones basadas en datos de entrada. Aunque ha experimentado ciclos de expectativa

exagerada, en la actualidad, la IA se encuentra en un punto de inflexión, gracias a los avances en el procesamiento del lenguaje natural y la generación de modelos.

Estos avances tienen aplicaciones emocionantes y cada vez más importantes en diferentes campos. Sin embargo, es necesario tener en cuenta las preocupaciones éticas y legales relacionadas con el uso de la IA en los negocios y en otros ámbitos. En consecuencia, las conversaciones sobre ética y responsabilidad deben ser parte integral de la discusión sobre la IA en la actualidad y en el futuro.

Machine Learning.

El aprendizaje automático es una rama de la inteligencia artificial y la informática que se centra en el uso de datos y algoritmos para imitar la forma en que los humanos aprenden, mejorando gradualmente su precisión. Arthur Samuel (Arthur L. Samuel, 2023), acreditado por acuñar el término "aprendizaje automático" con su investigación sobre el juego de las damas. A lo largo de las últimas décadas, los avances tecnológicos en almacenamiento y potencia de procesamiento han permitido la creación de productos innovadores basados en el aprendizaje automático, como el motor de recomendaciones de Netflix y los vehículos autónomos.

El aprendizaje automático es una parte esencial del creciente campo de la ciencia de datos. A través del uso de métodos estadísticos, se entrenan algoritmos para realizar clasificaciones o predicciones, y para descubrir conocimientos clave en proyectos de minería de datos. Estos conocimientos impulsan la toma de decisiones en aplicaciones y negocios, lo que idealmente afecta a las métricas clave de crecimiento. Con el continuo aumento de los datos masivos, la demanda del mercado para los científicos de datos aumentará, ya que se requerirán para ayudar a identificar las preguntas empresariales más relevantes y los datos para responder a ellas (IBM, 2023).

Los algoritmos de aprendizaje automático se crean típicamente utilizando marcos que aceleran el desarrollo de soluciones, como TensorFlow y PyTorch. En resumen, el aprendizaje automático es una tecnología poderosa y en constante evolución que tiene aplicaciones en

una amplia variedad de campos, desde la ciencia de datos hasta la conducción autónoma, y está impulsando la toma de decisiones informadas y precisas en todo el mundo.

Deep Learning.

El aprendizaje profundo es una técnica de aprendizaje automático que se encuentra dentro del ámbito de la inteligencia artificial. Utiliza redes neuronales artificiales para procesar grandes volúmenes de datos y aprender de ellos de forma autónoma, y se considera una de las técnicas más avanzadas en el campo del aprendizaje automático. A través de la aplicación de complejas operaciones matemáticas en capas sucesivas de nodos, las redes neuronales son capaces de reconocer patrones en los datos de entrada y realizar tareas de clasificación, predicción y generación de contenido (*Deep Learning - MATLAB & Simulink*, 2023).

El aprendizaje profundo es considerado uno de los mayores avances en la inteligencia artificial de los últimos tiempos, debido a su capacidad para lograr resultados de alta precisión en tareas como la visión artificial, el procesamiento de lenguaje natural y la comprensión de voz. Además, el aprendizaje profundo se ha vuelto cada vez más accesible gracias a herramientas y marcos de trabajo de código abierto como TensorFlow, PyTorch y Keras (*¿Qué es el aprendizaje profundo?*, fecha de acceso: 2023). Comparado con otros algoritmos de aprendizaje automático, el aprendizaje profundo permite que las redes neuronales aprendan de manera más precisa y eficiente.

2.3.3 Arequipa

Arequipa, ubicada en el sur de Perú, es una región de gran diversidad geográfica que alberga ecosistemas únicos, entre ellos los bofedales, humedales de alta montaña que desempeñan un papel importante en la regulación hídrica y la biodiversidad local. Los bofedales en la región de Arequipa se desarrollan a lo largo de la cadena montañosa occidental de Perú, abarcando aproximadamente 133,434.8 hectáreas, lo que constituye el 2.11 % de la extensión total de su territorio. Esta ubicación posiciona a Arequipa en el segundo lugar entre los 19 departamentos a nivel nacional con mayor presencia de bofedales. El bofedal más extenso abarca una superficie estimada de 3,232.7 hectáreas, mientras que el más pequeño

se extiende sobre 0.09 hectáreas. Estos ecosistemas constituyen una fuente vital de alimento para el ganado y sirven como reservorios hídricos, incluso durante períodos de sequía. En el actual escenario de cambio climático, adquieren una importancia estratégica al almacenar considerables cantidades de carbono y agua. Además, desempeñan una función crucial en la gestión del agua al proteger contra inundaciones y sustentar la diversidad biológica. El análisis de bofedales en Arequipa se ha convertido en un tema relevante para la investigación, ya que estos ecosistemas sensibles están experimentando cambios significativos debido a factores como el cambio climático y actividades humanas. La comprensión detallada de la estructura y ubicación de los bofedales es esencial para evaluar su vulnerabilidad y tomar decisiones informadas sobre su conservación. Además, el análisis de bofedales en Arequipa puede proporcionar información valiosa sobre la gestión sostenible de los recursos hídricos, la preservación de la biodiversidad y la mitigación de impactos ambientales en una región de gran importancia tanto cultural como ambiental. (Minam, 2023)

2.3.4 Land Use Land Cover (LULC)

Los datos de LULC (Uso de la tierra y cobertura de la tierra) incluyen información sobre áreas urbanas y construidas, tierras de cultivo, pastizales, bosques, agua, humedales, terrenos baldíos, tundra y áreas de nieve o hielo perenne. Los datos relacionados con LULC incluyen:

- Unidad de distrito político
- Unidad hidrológica
- Propiedad de tierras federales
- División de censo a nivel de condado.

La recopilación de datos sobre uso y cobertura de la tierra incluye conjuntos de datos globales y regionales relacionados con la forma y el uso de la tierra, ya sea natural o influenciado por humanos. Algunos conjuntos de datos proporcionan indicadores de posibles

amenazas al desarrollo para establecer prioridades de conservación. Otros conjuntos de datos contienen información sobre la modificación humana de la tierra a través de la expansión urbana u otros factores de estrés antropogénicos. También se incluyen un conjunto de datos de cobertura terrestre de manglares y un conjunto de datos de vegetación mesoamericana derivados de imágenes de Landsat, así como tipos de cobertura terrestre basados en imágenes de radiómetro avanzado de muy alta resolución (AVHRR). El conjunto de datos Global Human Alteration of Terrestrial Systems se basa en el modelado de los impactos estimados de la extensión física de 13 estresores antropogénicos y su uso a partir de un conjunto de datos global espacialmente explícito, mientras que el conjunto de datos del Índice de potencial de desarrollo global proporciona información relacionada con la energía renovable. datos para 13 sectores Energía, Combustibles Fósiles, Minería y Agricultura. El conjunto de datos del Índice de Amenazas para el Desarrollo es un mapa global de las amenazas para el desarrollo terrestre producido al agregar amenazas para hábitats individuales, como la expansión agrícola, la expansión urbana, la minería y el desarrollo energético (petróleo y gas, carbón, biocombustibles, energía solar y eólica). El mapa de manglares fue desarrollado por Chandra Giri y sus colegas y representa una línea de base de la distribución de manglares alrededor del año 2000. Investigadores de la Universidad de Yale y la Universidad de Texas A&M produjeron una cuadrícula global de expansión urbana, que ayuda a comprender las áreas de crecimiento urbano potencial futuro y la pérdida de tierras agrícolas o naturales. El Proyecto de Mapeo de la Cobertura Terrestre Mesoamericana evaluó hasta qué punto las redes de áreas protegidas terrestres existentes y propuestas protegen/protegerán la biodiversidad a nivel de paisaje expresada como tipos de vegetación delineados a partir de imágenes de teledetección. (Data y (sedac), 2023)

2.4 Consideraciones finales

En el capítulo, se ha llevado a cabo un análisis exhaustivo que respalda de manera sólida la viabilidad de emplear la Inteligencia Artificial en la clasificación de imágenes satelitales relacionadas con la identificación de bofedales en la región de Arequipa. La capacidad

inherente de la IA para gestionar grandes volúmenes de datos y discernir patrones complejos eficientemente ha demostrado ser una herramienta valiosa. Además, su capacidad de adaptación a diversos escenarios y su precisión en la clasificación de Land Use Land Cover (LULC) ofrecen un enfoque prometedor para abordar problemáticas similares a las propuestas en este estudio. El uso de imágenes multiespectrales y satelitales en conjunto con la IA se ha revelado como una combinación efectiva para obtener resultados de alta calidad. Este enfoque representa una base sólida para futuras investigaciones en el campo de la monitorización y clasificación del uso de tierras en entornos geográficos diversos.





3. Marco Metodológico

3.1 Alcances y Limitaciones

Para establecer los alcances y limitaciones de la presente investigación se consideró lo siguiente:

- **Viabilidad:** La propuesta es completamente viable debido a que se cuenta con acceso a la fuente de datos, que en este caso son las imágenes satelitales Sentinel 2, las cuales representan un componente principal. Del mismo modo, la mayor parte de los recursos utilizados para su tratamiento son de uso libre y cuentan con una documentación amplia que nos permite entender su uso.
- **Lugar o espacio:** La investigación se centra principalmente en el análisis de Arequipa.
- **Tiempo:** El tiempo previsto es de un año..
- **Financiamiento:** Se cuenta con un financiamiento y apoyo por parte del Vicerrectorado de Investigación que nos permite cubrir cualquier necesidad que se pueda presentar.

3.2 Tipo, Nivel y Diseño de Investigación

El área de la tesis presentada pertenece a la línea de investigación de Inteligencia Artificial y Sub línea de Inteligencia artificial y computacional. El tipo y nivel de investigación del proyecto son los siguientes:

- **Tipo:** *Correlacional*, porque la investigación tiene como finalidad mejorar la situación de clasificación de bofedales en la ciudad de Arequipa, es decir, que buscamos mejorar una situación concreta, con el fin de que se genere conozca el estado actual de estos 35 ecosistemas, donde se proporciona una utilidad práctica ayudando a la toma de decisiones informadas y al cuidado ambiental.
- **Nivel de Investigación:** *Clasificadorio-Predictivo*, la investigación propuesta puede considerarse clasificatoria debido a su enfoque fundamental en la categorización y cla-

sificación de bofedales en la región de Arequipa utilizando algoritmos de aprendizaje supervisado.

- **Diseño:** *Experimental*, Se lleva a cabo un experimento o prueba de los algoritmos de clasificación de imágenes satelitales para determinar su eficacia en el monitoreo de los bofedales, lo que implica la manipulación de variables y la medición de resultados.

3.3 Universo y Muestra

Universo: El universo de estudio se extiende a nivel nacional, abarcando todo el territorio de la Cordillera de los Andes con un radio de 100 km a la redonda. Este enfoque permite contextualizar el análisis de bofedales en Arequipa dentro del marco geográfico general del entorno. Brindando una perspectiva integral, considerando la diversidad geográfica y ambiental que podría tener impacto en los bofedales. **Población:** La población de interés se restringe a la región de Arequipa, constituyendo el área específica donde se llevará a cabo el análisis de los bofedales. En este contexto, la población incluiría todos los bofedales presentes en la región de Arequipa. Esto abarcaría bofedales de diferentes tamaños, ubicaciones geográficas y características ambientales dentro de los límites de la región. La selección de Arequipa como población se justifica por la concentración de bofedales en esta área, lo cual permite un análisis más detallado y específico de las características locales de estos ecosistemas. En el caso de la presente investigación, se va a emplear el dataset Sentinel-2 de imágenes multiespectrales, es esencial destacar que la muestra sobre la cual se basará el desarrollo de este proyecto de investigación se compone de imágenes multiespectrales. Estas imágenes, de un tamaño considerable de 100 kilómetros por 100 kilómetros, han sido cuidadosamente seleccionadas y se encuentran dispuestas geográficamente. Esta selección estratégica de la ubicación geográfica de las imágenes multiespectrales es fundamental, ya que permite abordar un área geográfica amplia y diversa, lo que a su vez contribuye a la representatividad y validez de los resultados obtenidos en el estudio. En total, esta muestra abarca un total de 275 unidades de trabajo, cada una de las cuales contiene información

valiosa para el análisis y la posterior interpretación. Cabe destacar que cada una de estas unidades de trabajo se encuentra detalladamente registrada en una matriz que incluye sus coordenadas de latitud y longitud. Este nivel de precisión geográfica asegura una ubicación exacta y confiable para cada una de las imágenes, lo que resulta esencial para la posterior elaboración de análisis espaciales y la georreferenciación precisa de los datos. Estos datos geográficos proporcionan una sólida base para la investigación, garantizando que los resultados obtenidos sean rigurosos y confiables, lo que constituye un componente esencial en la ejecución de esta investigación.

3.4 Técnicas y Herramientas

3.4.1 Técnicas de recolección de datos

- Documental: se realizaron revisiones sistemáticas de literatura científica y se analizaron informes de investigaciones anteriores para obtener datos históricos y contextuales necesarios.

3.4.2 Instrumentos de recolección de datos

- Bibliometría: se analizaron los aspectos clave de los artículos, como título, autor, año, revista, resumen, indicador, tipo de estudio, país, año de publicación, sujetos/muestra y algoritmo, asegurando que los artículos seleccionados fueran de los últimos cinco años, con el objetivo de obtener una visión actualizada del análisis de imágenes usando machine learning
- Google Earth Pro: La herramienta nos permitió capturar las imágenes base de entrenamiento y evaluación del algoritmo además de facilitarnos la validación de resultados

3.4.3 Herramientas para el procesamiento de datos

Lenguaje de programación

Python

El lenguaje de Python es fácil de expandir, y el lenguaje C o C ++ (u otros lenguajes que pueden ser llamados por C) se pueden usar para expandir nuevas funciones y datos.

Python también se puede usar como un lenguaje de programación de extensión en software personalizable. La rica biblioteca estándar de Python proporciona código fuente o código de máquina para cada plataforma de sistema principal. (Challenger Pérez Ivet, 2014)

Características del lenguaje

- *Simplicidad:* Python es un lenguaje que representa la idea de la simplicidad. Permite concentrarse en resolver problemas en lugar de comprender el idioma en sí.
- *Fácil de aprender:* Python es extremadamente fácil de usar, porque Python tiene una documentación extremadamente simple
- *Fácil de leer y mantener:* estilo claro y uniforme, sangría obligatoria
- *Libre y de código abierto:* Python es uno de FLOSS (Software libre/de código abierto). Los usuarios son libres de distribuir copias de este software, leer su código fuente, realizar cambios en él y utilizar partes de él en un nuevo software gratuito. FLOSS se basa en el concepto de una comunidad que comparte conocimientos.
- *Lenguaje de alto nivel:* al escribir programas en el lenguaje Python, no hay preocupaciones por los detalles de bajo nivel, como la forma de administrar la memoria utilizada por su programa.

Plataformas

- *QGIS:* QGIS es un sistema de información geográfica de escritorio fácil de usar que puede ejecutarse en plataformas como Linux , Unix , Mac OSX y Windows. QGIS es un sistema de información geográfica de escritorio de código abierto, multiplataforma y fácil de usar, basado en Qt y desarrollado en C++. QGIS proporciona integración con otros paquetes GIS de código abierto, incluidos PostGIS , GRASS y MapServer , para brindar a los usuarios una amplia gama de funciones. Los complementos escritos en Python amplían la funcionalidad de QGIS. Las características principales del software

QGIS son: Admite múltiples formatos de archivo de datos GIS. Se pueden admitir hasta docenas de formatos de datos a través de las extensiones GDAL/OGR. Admite la base de datos PostGIS. Admite la obtención de datos de WMS, servidor WFS. Integra algunas funciones de Grass. Admitir operaciones básicas en datos GIS, como editar y modificar atributos. Admite la creación de mapas. (QGIS, 2023)

- *Google collab*: Google Collaborative Labs, o Colab, es otro servicio en la nube de Google Research. Es un IDE que permite a cualquier usuario escribir código fuente en su editor y ejecutarlo desde el navegador. Específicamente, admite el lenguaje de programación Python, orientado a tareas de aprendizaje automático, análisis de datos, proyectos educativos y más. El servicio está basado en Jupyter Notebooks, alojado completamente gratis con su cuenta de Gmail , no requiere configuración, descarga o instalación de Jupyter. Le proporcionará recursos informáticos para poder editar y probar su código, como GPGPU de sus servidores, etc. Obviamente, al ser algo gratuito, Google Colaboratory no tiene recursos ilimitados ni garantías, pero varían según el propósito del sistema. (Google, 2023)

3.5 Metodología

La metodología aplicada fue SCRUM, ya que, Scrum(Bolloju, Chawla, y Ranjan, 2018) es un proceso de desarrollo de software incremental iterativo y es uno de los marcos importantes en la metodología ágil, teniendo un conjunto de prácticas y un esqueleto de proceso de roles predefinidos. Esta metodología permite una facilitación del trabajo, porque la organización de las tareas se hace de manera más dinámica y fácil de entender. Gracias a ello, se definió que el enfoque del proyecto es cuantitativo, porque el proyecto implica el uso de algoritmos de clasificación para el análisis de la dinámica de los bofedales en la región Arequipa, lo cual implica el procesamiento de datos y análisis numéricos, lo cual va en relación con este enfoque, que se centra en recopilar datos cuantitativos y utilizar métodos cuantitativos para comprender y predecir los patrones y cambios.

Consideraciones finales

El Capítulo III, proporciona una visión detallada de cómo se llevará a cabo la investigación. Se ha establecido la viabilidad del proyecto, basada en el acceso a fuentes de datos confiables y en el respaldo financiero proporcionado por el Vicerrectorado de Investigación. La elección de Arequipa como el universo de estudio se justifica por su diversidad geográfica y climática, así como por la disponibilidad de datos geográficamente precisos. Además, el Capítulo III establece claramente el tipo y nivel de investigación como "Correlacional" y "Clasificadorio-Predictivo" y describe el diseño del proyecto como "Experimental". Se explican las técnicas, instrumentos y herramientas que se utilizarán, destacando el enfoque en la recolección documental de datos, la bibliometría y el análisis de imágenes multiespectrales con Python y QGIS. Finalmente, se detalla el uso de la metodología SCRUM para la gestión del proyecto. Estas consideraciones finales refuerzan la solidez y la viabilidad del enfoque metodológico elegido para abordar la investigación.



CAPÍTULO IV

4. Desarrollo de la Propuesta

En el siguiente capítulo, se verá el desarrollo de la propuesta. Empezando presentando un mapa de arquitectura que proporciona una vista general de cómo se está estructurando el proyecto.

Dentro de este mapa de arquitectura, se encuentran una serie de etapas que se suceden de manera lógica. Comienza con la adquisición de imágenes satelitales multiespectrales, que representan el punto de partida fundamental del análisis. Estas imágenes constituyen la base sobre la cual se construirá todo el proyecto.

Las imágenes satelitales utilizadas en esta investigación forman parte de una investigación previa en proceso para analizar la totalidad de la Cordillera de los Andes. En esta se utilizó un área de estudio que cubre Venezuela, Colombia, Ecuador, Bolivia, Argentina, Chile y Perú. Inicialmente, se usó el programa Google Earth Pro, para visualizar la cordillera de los Andes y con ayuda de la herramienta ‘‘Polígono’’ se seleccionó cada Unidad de trabajo de 100km x 100km procurando incluir aproximadamente 100m por debajo de la línea de bosque visible. A partir de la información de cada polígono delimitado, se construyó una base de datos en Excel con las coordenadas geográficas de todas las Unidades de trabajo que conformaban los Andes.

Para la obtención de imágenes se seleccionó las coordenadas de cada Unidad de trabajo con la función `ee.Geometry.Rectangle`. Luego se llamó la librería de datos Sentinel 2 –nivel 2A con la función `ee.ImageCollection` a COPERNICUS y se aplicaron prefiltros de:

- Fecha, indicando el rango de interés entre enero 2020 y diciembre 2022
- Porcentaje mínimo de nubes, procurando obtener imágenes con el menor porcentaje de nubes (1%), testeando diferentes valores de porcentaje dependiendo de las características específicas de cada unidad de trabajo, pero estableciendo un valor límite para este filtro de 60%.

Finalmente, para reducir aún más la cobertura de nubes, se aplicó una máscara sobre

las imágenes para eliminar nubes tipo cirrus y nubes opacas con la función “maskS2clouds”. Con la colección de imágenes obtenida para cada unidad de trabajo después de aplicar los filtros y mascara de nubes del paso anterior, se realizó una búsqueda de las mejores imágenes dentro de la colección, para obtener una imagen final que uniera los pixeles con menor porcentaje de nubosidad y priorizando el uso de pixeles de imágenes más recientes en la selección. Para esto, se generaron dos tipos de imagen compuesta de cada unidad de trabajo: la primera estableciendo un criterio de selección de pixeles usando el valor de la mediana de todos los pixeles con la función “dataset.median()”, y la segunda usando un criterio de selección de valor mínimo de pixel en la colección con la función “dataset.min()”. A continuación, los pixeles seleccionados bajo los dos criterios se unieron para general cada imagen final con la función “clip”. Como resultado se obtuvo un total de 273 unidades con 5 para Venezuela, 35 para Colombia, 11 para Ecuador, 60 para Perú, 40 para Bolivia, 73 para Argentina y 49 para Chile. Todo esto permitió tener las imágenes limpias, y normalizadas.

Una vez que se cuenta con las imágenes, se seleccionaron aquellas correspondientes a Arequipa de acuerdo a coordenadas. La precisión en esta etapa se convierte en un aspecto crucial, ya que determinará la calidad de los resultados finales por lo que se continuó haciendo uso de herramienta Google Earth Pro para asegurar resultados correctos. A partir de esto se inició con la creación de ROIs haciendo uso de la herramienta QGIS, seleccionando diferentes secciones de las imágenes de acuerdo a cada clase a clasificar. Gracias a que es una herramienta especializada en análisis de este tipo de imágenes, permite tener un resultado que ya cuenta con todas las características espaciales y espectrales incluidas para la clasificación. Para estar seguro de que estas etiquetas fueran correctas se evaluó haciendo uso de matrices en la herramienta Google Earth y se tuvo una segunda validación por parte de especialistas en el tema (Integrantes del equipo de investigación). Un ejemplo de como se visualiza las etiquetas creadas se presenta en la Figura 2.

Con las categorías y los algoritmos previamente definidos, se avanza hacia la fase de clasificación. En esta etapa, se implementan tres algoritmos de inteligencia artificial di-


Figura 1

Unidades resultantes



ferentes, cada uno con sus enfoques particulares, para llevar a cabo la clasificación de las imágenes.

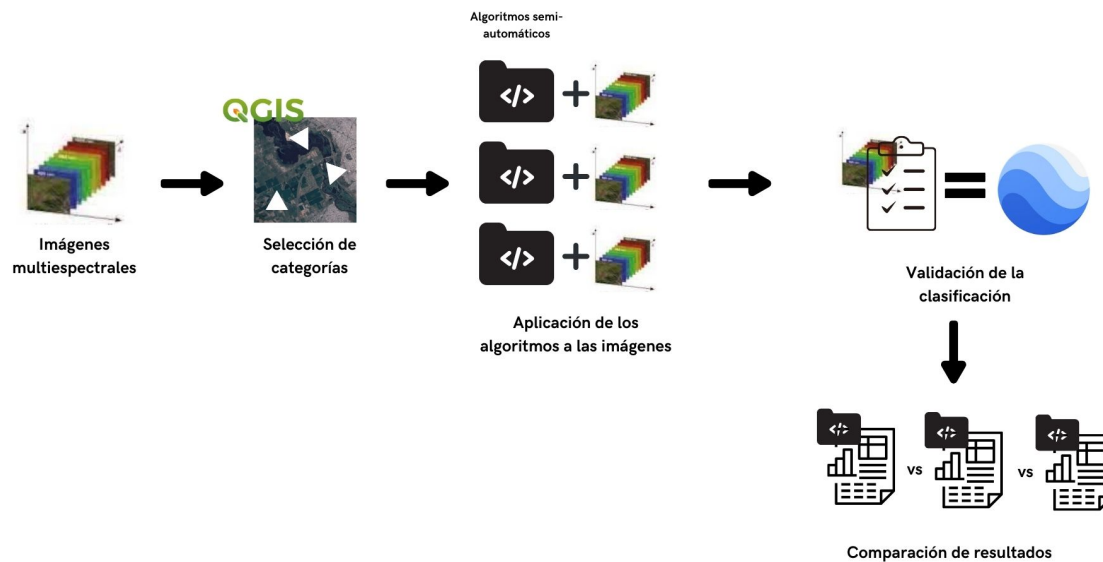
Luego, se lleva a cabo una etapa esencial de pre-validación utilizando Google Earth Engine. Esta plataforma permite verificar la precisión y calidad de las clasificaciones realizadas por los algoritmos, lo que facilita la evaluación de cuán bien se están identificando las

Figura 2*Ejemplo de ROIs*

categorías en las imágenes satelitales.

Finalmente, una vez que se han completado todas las etapas previas, se procede a la comparación de los resultados obtenidos a través de los tres algoritmos de clasificación. Esta comparación revela las fortalezas y debilidades de cada enfoque y contribuye a la selección del método más efectivo para el estudio en particular.

Figura 3

Mapa de Arquitectura

El mapa de arquitectura se presenta como una guía para entender la organización de las actividades y etapas clave en el desarrollo de la propuesta. A lo largo de este capítulo, se profundiza en cada uno de estos componentes y los resultados obtenidos en cada fase.

4.1 Planificación del Proyecto SCRUM

En el contexto de este proyecto de investigación, se ha optado por emplear un enfoque ágil basado en la metodología SCRUM para la planificación y ejecución del trabajo. La elección de SCRUM se basa en su capacidad para gestionar proyectos de manera iterativa e incremental (Bolloju y cols., 2018), lo cual es altamente apropiado para la investigación científica y el procesamiento de datos satelitales.

- **Objetivos del Proyecto:** Clasificar bofedales en imágenes satelitales multiespectrales de la región Arequipa mediante la aplicación de algoritmos de aprendizaje supervisado.
- **Visión del Proyecto:** La visión de este proyecto se enfoca en brindar una solución efectiva y escalable para el monitoreo de los bofedales, lo que facilitará una gestión

más informada y sostenible de este entorno crítico.

- **Constitución de un Equipo SCRUM:** se ha conformado un equipo interdisciplinario compuesto por especialistas en inteligencia artificial y ecología. Cada integrante del equipo asume roles específicos, como el Scrum Master y el Product Owner, en concordancia con los principios de SCRUM, con el fin de asegurar la eficaz implementación de la metodología.
- **Definición del Producto o Entregables:** Los entregables comprenden algoritmos de clasificación de imágenes satelitales, informes de investigación, y modelos de los algoritmos que realizan la clasificación de bofedales.
- **Backlog Inicial:** se ha desarrollado un Backlog del Proyecto que engloba tareas iniciales, tales como la adquisición de imágenes satelitales, la selección de áreas de estudio y la implementación de algoritmos de procesamiento.
- **Planificación de Sprints:** El proyecto se ha estructurado en iteraciones denominadas "Sprints" con una duración aproximada de dos semanas cada una. Durante cada Sprint, se abordarán tareas específicas, como la recopilación de datos, la implementación de algoritmos y el análisis de resultados.
- **Recursos y Tecnologías:** Se identificó y garantizó el acceso a los recursos y tecnologías necesarios, que incluyen software de procesamiento de imágenes y servidores de alto rendimiento para ejecutar los algoritmos.

4.2 Backlog del Proyecto

Dentro del marco de la metodología SCRUM, el Backlog del Proyecto es una herramienta esencial para la planificación y ejecución de las tareas a lo largo del ciclo de vida de la investigación. Este Backlog es, una lista estructurada que engloba todas las actividades necesarias para alcanzar los objetivos del estudio. Su dinamismo permite ajustarse y evolucionar

a medida que se adquiere una comprensión más profunda de los requisitos y se desglosan en elementos más específicos.

El Backlog del Proyecto se inicia con una serie de tareas de alto nivel que representan los objetivos generales de la investigación, como la adquisición de datos, el diseño de algoritmos y la evaluación de resultados. Estas tareas se descomponen en elementos más manejables, denominados "historias de usuario" o "ítems del Backlog", que representan actividades concretas a ser completadas durante los Sprints.

La priorización de las historias de usuario se lleva a cabo en colaboración con el equipo de investigación y se basa en diversos factores, incluyendo la relevancia para los objetivos, la dependencia de otras tareas y la disponibilidad de recursos. Entre las historias de usuario iniciales, se encuentra:

1. La adquisición de imágenes satelitales de alta resolución de áreas de estudio clave.
2. Diseñar y entrenar algoritmos de aprendizaje supervisado, como redes neuronales, para llevar a cabo la clasificación precisa de los bofedales en las imágenes satelitales seleccionadas.
3. Validar los resultados con por lo menos 3 modelos diferentes con su respectiva compilación de resultados.
4. La generación de informes de investigación que presenten los hallazgos y conclusiones.

4.3 Entendimiento del Negocio

4.3.1 Análisis Estadístico Descriptivo de los Datos de Entrada

El análisis estadístico descriptivo es una fase crítica en cualquier proyecto de investigación, ya que proporciona una visión inicial de las características fundamentales de los datos que se utilizarán Gidey y cols. (2023). En este contexto, el presente proyecto, considera esencial realizar un análisis estadístico de los datos del universo de la presente investigación.

Estos datos consisten en imágenes satelitales multiespectrales que abarcan la Cordillera de los Andes.

El análisis estadístico descriptivo tiene como objetivo principal resumir y presentar los datos en bruto de manera que se pueda comprender su naturaleza y distribución antes de su procesamiento y utilización en el proyecto. En esta subsección, se llevará a cabo un análisis de los datos de entrada, centrándose en las coordenadas geográficas (latitud y longitud) y el país de origen de cada imagen satelital.

Se realizarán estadísticas descriptivas básicas para cada una de estas columnas de datos, lo que incluye medidas de tendencia central, como la media y la mediana, así como medidas de dispersión, como la desviación estándar. Además, se presentarán gráficos que ayudarán a visualizar la distribución de los datos. Este análisis proporcionará información crucial sobre la variabilidad geográfica de las imágenes y su distribución en los países de la región andina.

El propósito de este análisis estadístico descriptivo es establecer una comprensión sólida de la composición de los datos de universo, lo que permitirá tomar decisiones informadas sobre cómo abordar y analizar eficazmente estos datos en las fases posteriores del proyecto, incluyendo el modelamiento y las evaluaciones de los algoritmos de inteligencia artificial.

En la tabla 1, se presenta un resumen de las estadísticas descriptivas de las variables clave en el conjunto de datos. Estas variables representan las coordenadas geográficas de las imágenes satelitales, a saber, "Lat1," "Long1," "Lat2," y "Long2." Estas estadísticas son fundamentales para comprender la naturaleza y la distribución de los datos antes de llevar a cabo análisis más detallados y aplicar los algoritmos de clasificación.

La columna *count* muestra el número total de observaciones disponibles para cada variable, que en este caso es 273, lo que indica que se ha recopilado datos de 273 imágenes satelitales.

La fila *mean* presenta el valor promedio de las coordenadas, lo que proporciona una idea de la ubicación geográfica central de las imágenes. Por ejemplo, para "Lat1," la latitud

promedio es de aproximadamente -19.645251.

La fila *std* representa la desviación estándar, una medida de cuánto varían las coordenadas geográficas con respecto a su promedio. Para "Lat1," la desviación estándar es de alrededor de 16.183685.

Las filas *min* y *max* indican los valores mínimos y máximos observados en las coordenadas, lo que permite comprender el rango geográfico de los datos. Por ejemplo, la latitud más baja registrada es -52.900005, y la más alta es 11.17.

Finalmente, los percentiles (25 %, 50 %, y 75 %) dividen los datos en cuartiles, lo que proporciona información sobre la distribución de las coordenadas en diferentes rangos. Por ejemplo, el 25 % de las latitudes son iguales o inferiores a -30.037934.

En resumen, esta tabla de estadísticas descriptivas desempeña un papel fundamental en el proyecto de investigación. Al brindar una comprensión detallada de la distribución geográfica de las coordenadas en las imágenes satelitales, se convierte en una herramienta esencial para guiar las decisiones. Al conocer el número de observaciones en el conjunto de datos, su media, desviación estándar, valores mínimos y máximos, así como los percentiles, se está en una posición sólida para diseñar estrategias efectivas. Esta información no solo permite comprender dónde se concentran las observaciones y cuánto varían con respecto a la media, sino que también proporciona una comprensión más profunda de los límites geográficos de las imágenes. Esto es crucial para garantizar que los algoritmos de inteligencia artificial puedan trabajar de manera precisa y efectiva en una amplia variedad de condiciones geográficas, lo que, en última instancia, impactará en la calidad y la relevancia de los resultados de la investigación.

Los resultados obtenidos al analizar la frecuencia de los valores de Latitud y Longitud mostrados en las figuras 4 5 6 y 7 subrayan la existencia de zonas de estudio desafiantes en términos de clasificación de tierras. Estas áreas muestran una variabilidad significativa en la composición del suelo y en su aptitud para diferentes usos. Los datos indican que estas zonas presentan una topografía y geografía únicas que requieren una investigación más profunda y

Tabla 1

Resultados del análisis de la estadística descriptiva

	Lat1	Long1	Lat2	Long2
count	273	273	273	273
mean	-19.645251	-70.85212	-20.547947	-71.86591
std	16.183685	3.982201	16.182125	3.96281
min	-52.900005	-79.472264	-53.798484	-80.374074
25 %	-30.037934	-73.3979	-30.939935	-74.380999
50 %	-18.601564	-70.463774	-19.504927	-71.549071
75 %	-8.861783	-68.034897	-9.765874	-69.053965
max	11.17	-63.422611	10.26	-64.371604

detallada. Realzando el valor de la presente investigación y justificando el uso de herramientas especializadas.

Figura 4

Distribución de Lat 1





Figura 5

Distribución de Long 1



La comprensión de la distribución geográfica de la cordillera de los Andes por país mostrada en la figura 8 desempeña un papel esencial en la investigación de clasificación de bofedales en esta región. Este conocimiento no solo proporciona una visión más precisa de las particularidades de los distintos territorios, sino que también capacita para anticipar los tipos de ecosistemas y tierras que caracterizan cada área. Al reconocer qué naciones albergan una

Figura 6

Distribución de Lat 2




Figura 7

Distribución de Long 2




Figura 8

Distribución por país





Figura 9

Distribuciones facetadas Lat 1



mayor extensión de esta imponente cadena montañosa, se está mejor preparado para diseñar estrategias de clasificación de bofedales que se ajusten a las condiciones específicas de cada país. Este enfoque diferenciado es crucial, ya que se puede esperar variaciones significativas en cuanto a suelos, vegetación y patrones de uso de la tierra según la ubicación geográfica y la geología propia de cada lugar. Este profundo entendimiento de la distribución territorial proporciona los cimientos necesarios para los modelos de clasificación de tierras, que se vuelven más precisos y efectivos, y tienen un impacto sustancial en la gestión sostenible de los ecosistemas andinos. Además, esta información es de vital importancia para la toma de decisiones informadas sobre la conservación y el desarrollo regional en la región de los Andes,

Figura 10

Distribuciones facetadas Long 1




Figura 11

Distribuciones facetadas Lat 2


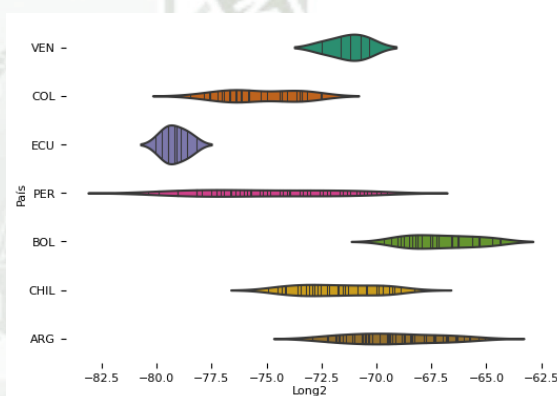


Figura 12

Distribuciones facetadas Long 2



contribuyendo así al avance del conocimiento y al bienestar de las comunidades que habitan esta majestuosa cordillera. En este caso, los países que resaltan son Argentina y Perú con más de 50 imágenes, representando más de 5000 km².

La gráfica de distribuciones facetadas mostradas en las figuras 9 10 11 y 12, que presenta las coordenadas longitudinales y latitudinales en la región de la cordillera de los Andes, resalta por su capacidad para ofrecer un panorama completo y detallado de la topografía en diferentes países que componen esta región geográfica. Esto resulta fundamental

para la investigación, ya que permite identificar patrones geospaciales específicos que inciden en la variabilidad de los ecosistemas andinos. Al analizar minuciosamente las diferencias en latitud y longitud, se puede entender mejor cómo se distribuyen factores críticos como la altitud, la exposición solar y la humedad en la cordillera. Esto, a su vez, arroja luz sobre las diferencias en tipos de suelos, vegetación y microclimas, lo que es esencial para llevar a cabo una clasificación de tierras precisa

4.4 Sprint 2: Entendimiento de Datos

Los Sentinel comprenden una flota de satélites gemelos A y B, separados por 180° para lograr una mejor cobertura y están diseñados para obtener abundantes datos e imágenes que alimentan el programa Copernicus, de la Comisión Europea. Sentinel 2 consta de una cámara multiespectral de alta resolución, con 13 bandas espectrales que proporcionan diferentes perspectivas de la superficie terrestre y la vegetación. En un periodo de 5 días, los satélites gemelos logran recorrer toda la superficie terrestre. El primer satélite Sentinel 2A fue lanzado en junio de 2015 y posteriormente en el primer trimestre de 2017 se ejecutó el lanzamiento de Sentinel 2B (Bolloju y cols., 2018)

4.5 Proceso de división del conjunto de datos

El proceso de división de conjunto de datos es la primera parte que se tomó en cuenta para poder realizar el estudio, en este caso, para asegurar los resultados de la clasificación que se hizo. Por ello, a continuación se detalla como fue el proceso:

4.5.1 Recolección y Preparación de los Datos

El conjunto de datos utilizado fueron las imágenes satelitales multiespectrales, adquiridas del área de estudio seleccionada. Estas imágenes fueron limpiadas y normalizadas para asegurar consistencia en el tamaño y formato.

4.5.2 Método de División del Conjunto de Datos

Para la evaluación del rendimiento de los algoritmos de clasificación, se realizó una división del conjunto de datos en tres subconjuntos: entrenamiento, validación y prueba. La

distribución utilizada fue 70 % para entrenamiento, 15 % para validación y 15 % para prueba.

- **Entrenamiento:** 70 % del conjunto de datos, utilizado para ajustar los parámetros de los modelos.
- **Validación:** 15 % del conjunto de datos, empleado para ajustar hiperparámetros y prevenir el sobreajuste.
- **Prueba:** 15 % del conjunto de datos, reservado para evaluar el rendimiento final de los modelos.

La división 70-15-15 se justifica porque en problemas como la clasificación de imágenes satelitales multiespectrales, es crucial disponer de una cantidad significativa de datos (70 %) para capturar la alta variabilidad espectral y espacial necesaria para entrenar modelos robustos. Al mismo tiempo, asignar un 15 % para validación permite ajustar configuraciones del modelo considerando las complejidades de los datos sin influir en el proceso de aprendizaje, mientras que el 15 % restante garantiza una evaluación objetiva en un conjunto independiente, minimizando sesgos y asegurando que las métricas reflejen el desempeño real en datos no vistos Soori, Arezoo, y Dastres (2023).

4.6 Modelos de Clasificación

4.6.1 Modelos utilizados

Redes Neuronales Convolucionales (CNN).

Las redes neuronales convolucionales (CNN) son un modelo de aprendizaje profundo que simula el mecanismo de procesamiento visual del cerebro humano, extrae características de la imagen mediante operaciones de agrupación y convolución multicapa y logra tareas como clasificación de imágenes, detección de objetivos y segmentación semántica. Al entrenar una gran cantidad de muestras de imágenes, CNN puede aprender una variedad de características diferentes, como bordes, texturas y formas, para lograr una clasificación precisa de las imágenes. Jamali, Mahdianpari, Mohammadimanesh, Brisco, y Salehi (2022)

Se consideró el modelo debido a que:

- Captura de patrones espaciales y espectrales: Las imágenes satelitales no solo contienen información espectral por píxel, sino también relaciones espaciales entre píxeles. Las CNN aprovechan las convoluciones para capturar patrones locales como texturas, bordes y formas, lo que permite una clasificación más precisa en regiones heterogéneas.
- Procesamiento jerárquico: Las CNN aprenden características desde niveles bajos (bordes, texturas) hasta niveles altos (formas y estructuras completas), algo esencial para detectar patrones complejos como zonas urbanas o mosaicos agrícolas.
- Eliminación de la extracción manual de características: A diferencia de los modelos tradicionales, no requiere diseñar manualmente las características de entrada. Las CNN aprenden automáticamente qué aspectos de las bandas espectrales y la estructura espacial son más relevantes para la clasificación.
- Excelente desempeño en alta resolución: Con datos satelitales de alta resolución, las CNN sobresalen al capturar detalles finos en el paisaje, como carreteras, edificios o límites entre vegetación y suelo. Flexibilidad para múltiples tareas:
- Además de la clasificación de píxeles, las CNN pueden realizar segmentación semántica (asignar una clase a cada píxel) o clasificación por objetos (por ejemplo, identificar cuerpos de agua específicos). Capacidad de trabajar con grandes volúmenes de datos:
- Las CNN son ideales para proyectos que requieren procesar grandes áreas geográficas o múltiples escenas satelitales, gracias a su capacidad de escalar y manejar datos en paralelo.

K-Nearest Neighbors (KNN).

KNN es un algoritmo de clasificación que ingresa el aprendizaje basado en instancias y pertenece al aprendizaje diferido. KNN realiza la clasificación midiendo la distancia entre diferentes valores de características. Du y cols. (2023)

Se consideró este modelo debido a que McRoberts (2008):

- Similitud espectral directa: El modelo se basa en la comparación directa entre los valores espectrales de los píxeles y sus vecinos más cercanos, lo que es ideal para datos multiespectrales donde las diferencias de valores en bandas específicas son cruciales para identificar clases como vegetación, agua o suelo.
- Modelo no paramétrico: No asume ninguna distribución subyacente de los datos, lo que permite que sea eficaz en imágenes satelitales donde las clases no siempre tienen fronteras lineales.
- Efectividad en regiones homogéneas: En áreas con características espectrales consistentes, como grandes masas de agua o vegetación uniforme, KNN ofrece alta precisión porque asigna píxeles a clases similares basándose en sus vecinos.

Árboles de Decisión (Random Forest).

Random Forest es un algoritmo de aprendizaje automático supervisado creado a partir del algoritmo del árbol de decisión y lo utilizan los científicos de datos para resolver problemas de regresión y clasificación. Utilizan el aprendizaje conjunto y combinan muchos clasificadores para proporcionar soluciones a problemas complejos. Du y cols. (2023)

Se consideró este modelo debido a que Lowe y Kulkarni (2015):

- Manejo eficiente de alta dimensionalidad: Las imágenes multiespectrales tienen muchas bandas (dimensiones), y RF puede manejar datos de alta dimensionalidad de manera eficiente seleccionando características relevantes durante el entrenamiento.
- Robustez ante ruido: Las bandas espectrales pueden contener ruido (como interferencias atmosféricas o errores del sensor). RF es resistente al ruido, ya que combina múltiples árboles de decisión entrenados con diferentes subconjuntos de datos.
- Importancia de características: Una ventaja clave es que RF calcula automáticamente la importancia de cada banda espectral. Esto permite identificar qué bandas tienen mayor peso en la clasificación, lo que es útil para optimizar el uso de los datos satelitales.

- Generalización sólida: Al promediar los resultados de múltiples árboles, RF reduce el riesgo de sobreajuste, asegurando un buen desempeño tanto en los datos de entrenamiento como en nuevos conjuntos de datos.
- Adaptación a clases complejas: Puede manejar problemas de clasificación donde las clases tienen patrones espectrales similares pero pequeñas diferencias significativas, como diferentes tipos de cultivos o zonas urbanas mixtas.

4.6.2 Implementación

Se utilizó un pipeline que integró las librerías Keras y TensorFlow para implementar las CNN. Para la extracción de características y la clasificación final, se configuró una arquitectura típica con capas convolucionales.

La implementación de scikit-learn se utilizó para implementar KNN. El modelo se configuró para buscar las K muestras más cercanas utilizando una métrica de distancia apropiada.

Finalmente, Random Forest se implementó utilizando la biblioteca scikit-learn. Para crear el modelo inicial, se configuró un conjunto de cien árboles de decisión.

4.6.3 Proceso de Entrenamiento

El proceso de entrenamiento incluyó la serialización de datos para preparar ejemplos de entrenamiento iniciales, después, se utilizó Apache Beam para crear un flujo de trabajo para convertir y guardar los datos en un archivo TensorFlow Record comprimido, esta parte del proceso, es la que sirve como base para el desarrollo de los modelos.

En el caso de las CNN se hizo uso de las capas convolucionales para recopilar datos, luego capas densas para agrupar y clasificar, y al finalizar se utilizó el optimizador Adam por defecto durante el entrenamiento para ajustar los pesos del modelo en diferentes momentos.

Para el modelo KNN se configuró con un número específico de vecinos (en este caso, $k=5$), y se calculó la proximidad entre puntos en el espacio de características definido por imágenes satelitales multiespectrales utilizando la distancia euclidiana como métrica, para

el conjunto de datos preparado que se utilizó para entrenar al modelo, cada instancia fue clasificada en función de sus vecinos más cercanos en este espacio definido.

Finalmente, el modelo Random Forest utiliza un conjunto de 100 árboles de decisión para formarse, en este caso cada árbol recibe entrenamiento de las muestras de datos, y las predicciones de cada árbol se combinan mediante votación mayoritaria para crear la predicción final del modelo.

4.6.4 Proceso de Validación Cruzada

Para evaluar el rendimiento de los modelos utilizados y reducir el fenómeno de sobreajuste, se utilizó la técnica de validación cruzada k-fold con un valor k igual a 5. El proceso consiste en dividir el conjunto de datos en cinco particiones, también conocido como “folding”. Luego, el modelo se entrena cinco veces utilizando cada partición como conjunto de validación en diferentes iteraciones. La validación cruzada K-fold ayuda a evitar el sobreajuste y garantiza que el modelo se generalice correctamente a datos nuevos, lo que permite una estimación más precisa del rendimiento del modelo. Además, esta técnica le ayuda a seleccionar hiperparámetros óptimos al entrenar el modelo con diferentes configuraciones de hiperparámetros en cada iteración y luego seleccionar la configuración que produzca el rendimiento promedio más alto. En los modelos K-Vecinos más cercanos (KNN), la validación cruzada de k-cuadrado le permite ajustar el hiperparámetro “k”, que representa el número de vecinos más cercanos utilizados para la clasificación, eligiendo un valor que optimice el rendimiento general del modelo. Finalmente, utilice un modelo de bosque aleatorio para optimizar hiperparámetros como la cantidad de árboles y la profundidad máxima, evalúe el rendimiento del modelo en varias configuraciones y seleccione la configuración que pueda mejorar el rendimiento general del modelo.

4.7 Afinamiento de los hiperparámetros

4.7.1 Redes Neuronales Convolucionales

Se utilizaron métodos manuales y automatizados para ajustar los hiperparámetros de las redes neuronales convolucionales (CNN). Inicialmente, se creó una arquitectura CNN

genérica utilizando TensorFlow y Keras para agregar capas densas, convolucionales y de agrupación. Se han modificado los siguientes parámetros importantes:

- **Número de filtros y tamaño del Kernel:** se exploraron varios valores de número de filtros y tamaño del Kernel en las capas convolucionales, terminando en que los tamaños de los Kernel variaron de 3x3 a 5x5.
- **Número y tamaño de filtros convolucionales:** el número de filtros en la capa convolucional se ajustó de 16 a 32.
- **Número de epochs:** inicialmente establecido en 5 epochs, ajustado a 100 epochs después del proceso de optimización.

4.7.2 *K-Nearest Neighbors*

Para el modelo K-Nearest Neighbors (KNN), el principal parámetro ajustado fue el número de vecinos (K). Se realizaron pruebas variando K para determinar el número óptimo de vecinos que proporcionara el mejor equilibrio.

- **Número de vecinos (K):** Se ajustó de 3 a 5 vecinos.

4.7.3 *Random Forest*

En el caso de Random Forest, se optimizaron varios hiperparámetros utilizando métodos manuales basados en la observación del rendimiento del modelo.

- **Número de árboles:** Se varió de 80 a 100 árboles.
- **Profundidad máxima:** Se ajustó de 10 a 20 niveles.

4.8 Pruebas comparativas

Se realizaron pruebas finales de cada modelo después de ajustar los hiperparámetros, para poder evaluar la capacidad de clasificación de cada modelo en el conjunto de datos de prueba, se utilizaron métricas como precisión, recall y score F1. Estas pruebas ayudaron a

determinar qué modelos proporcionan la mayor precisión y solidez en comparación con datos nuevos e invisibles durante el entrenamiento. Los resultados de estas mismas, se pueden hallar en la capítulo 5, donde se detalla con mayor detenimiento los resultados de cada una.

4.9 Proceso del despliegue

El modelo entrenado no se implementó externamente y se mantuvo en el entorno de desarrollo. Esto garantiza que el modelo esté disponible para pruebas y ajustes posteriores y permite integrarlo con otras aplicaciones o servicios en el mismo entorno de desarrollo.

4.10 Aprendizajes y Conclusiones SCRUM

Durante el desarrollo del proyecto utilizando la metodología SCRUM, se ha identificado varias conclusiones que han contribuido significativamente al éxito del proyecto, estas son:

- **Flexibilidad y Adaptabilidad:** SCRUM ha demostrado ser altamente flexible y adaptable a medida que se enfrentan cambios en los requisitos del proyecto y desafíos inesperados. La capacidad de realizar ajustes y mejoras continuas en cada Sprint ha sido fundamental para la eficiencia del equipo.
- **Comunicación y Colaboración:** La comunicación efectiva y la colaboración son pilares esenciales en SCRUM. La interacción regular entre los miembros del equipo, las reuniones diarias de seguimiento (Daily Standups) y las sesiones de retrospectiva han mejorado la comprensión mutua y fortalecido la colaboración.
- **Roles Claros y Responsabilidades:** La definición clara de roles, como Scrum Master y Product Owner, ha contribuido a una distribución efectiva de responsabilidades. Esto ha asegurado que cada miembro del equipo tenga un papel específico y sea responsable de contribuir al éxito del proyecto.
- **Retroalimentación Continua:** La incorporación de la retroalimentación continua mediante las sesiones de retrospectiva ha sido valiosa para la mejora continua del pro-

ceso. Identificar áreas de mejora y ajustar las prácticas en consecuencia ha fortalecido la eficacia del equipo.

En resumen, el proyecto de investigación ha tenido un marco sólido y eficiente gracias a la implementación de SCRUM. La combinación de flexibilidad, comunicación efectiva y entregas incrementales ha permitido abordar los desafíos y lograr avances significativos en la clasificación. La metodología SCRUM ha mejorado la gestión de tareas técnicas y la cooperación en equipos interdisciplinarios, demostrando ser particularmente ventajoso para este proyecto científico, ya que ofrece una estructura adaptable a la naturaleza iterativa y evolutiva de la investigación.





CAPÍTULO V

5. Pruebas y Resultados

En este capítulo se presentan los resultados del análisis estadístico inferencial de los datos de salida obtenidos tras la clasificación de las imágenes satelitales utilizando tres algoritmos distintos: Random Forest (RF), Redes neuronales convolucionales (CNN) y K-Nearest Neighbors (KNN). Además se presenta la discusión de estos resultados y los gráficos correspondientes.

5.1 Análisis Estadístico Inferencial de los Datos de Salida

En las tablas 2, 3 y 4, se presenta un resumen de las estadísticas inferenciales de la clasificación de 5 imágenes satelitales utilizando tres algoritmos diferentes: Random Forest (RF), Redes neuronales convolucionales (CNN) y K-Nearest Neighbors (KNN).

La columna *count* muestra el número de observaciones disponibles para cada algoritmo, que en este caso es 5. Esto indica que se clasificaron 5 imágenes satelitales.

La fila *mean* presenta el valor promedio de la precisión de cada algoritmo, lo que proporciona una idea de la precisión general de cada algoritmo. Por ejemplo, la precisión promedio de CNN es de aproximadamente 70.0 %.

La fila *std* representa la desviación estándar de la precisión, una medida de cuánto varían las precisiones de cada algoritmo con respecto a su promedio. Por ejemplo, la desviación estándar de CNN es de alrededor de 2.0 %.

Las filas *min* y *max* indican los valores mínimos y máximos observados en las precisiones, lo que permite comprender el rango de precisión de cada algoritmo. Por ejemplo, la precisión mínima de RF es de 58.0 %, y la máxima es de 61.0 %.

Finalmente, los percentiles (25 %, 50 %, y 75 %) dividen las precisiones en cuartiles, lo que proporciona información sobre la distribución de las precisiones en diferentes rangos. Por ejemplo, el 25 % de las precisiones de CNN son iguales o inferiores a 70.0 %.

En resumen, esta tabla de estadísticas inferenciales proporciona una visión general de la precisión de los tres algoritmos de clasificación utilizados para clasificar las imágenes satelitales. Los resultados muestran que CNN es el algoritmo más preciso, seguido de RF

y KNN. En resumen, sobre los resultados de la tabla:

- Se determina que RF es un algoritmo de aprendizaje automático supervisado que se basa en árboles de decisión. Es un algoritmo robusto que suele ser preciso en una variedad de tareas de clasificación.
- CNN son un tipo de red neuronal profunda especialmente diseñada para el procesamiento de datos estructurados, como las imágenes. A través de capas convolucionales, las CNN pueden identificar patrones y características complejas en los datos visuales.
- KNN es un algoritmo simple que se basa en la distancia entre puntos de datos en un espacio multidimensional. Funciona asignando una etiqueta a un nuevo punto de datos basándose en las etiquetas de sus vecinos más cercanos en el espacio.

Los resultados de la tabla sugieren que CNN es el algoritmo más preciso para la clasificación de imágenes satelitales de bofedales en la región de Arequipa. RF tiene un rendimiento similar a CNN, pero con una menor precisión y especificidad. KNN tiene el menor rendimiento en términos de precisión, sensibilidad y especificidad.

Tabla 2

Resultados del análisis de la estadística inferencial

	CNN Accuracy	RF Accuracy	KNN Accuracy
count	5.0	5.0	5.0
mean	70.0	59.0	59.0
std	1.0	1.0	1.0
min	69.0	58.0	58.0
25 %	70.0	59.0	58.0
50 %	70.0	59.0	59.0
75 %	70.0	59.0	59.0
max	71.0	60.0	59.0

Fuente: original

Tabla 3

Resultados del análisis de la estadística inferencial

	CNN Precision	RF Precision	KNN Precision
count	5.0	5.0	5.0
mean	70.0	59.0	59.0
std	1.0	1.0	1.0
min	69.0	58.0	58.0
25 %	70.0	59.0	58.0
50 %	70.0	59.0	59.0
75 %	71.0	60.0	60.0
max	71.0	61.0	60.0

Fuente: original

5.2 Resultados de la Clasificación y Evaluación de Modelos

Los datos de la tabla 5 muestran que los tres algoritmos de clasificación considerados son relativamente precisos para la tarea de clasificación de imágenes de satélite. Sin embargo,

Tabla 4

Resultados del análisis de la estadística inferencial

	CNN Recall	RF Recall	KNN Recall
count	5.0	5.0	5.0
mean	70.0	59.0	58.0
std	1.0	1.0	1.0
min	69.0	59.0	57.0
25 %	70.0	59.0	58.0
50 %	70.0	59.0	59.0
75 %	70.0	59.0	59.0
max	71.0	61.0	59.0

Fuente: original

CNN es el algoritmo más preciso, seguido de RF y KNN. En la tabla, los datos de todos los algoritmos están expresados en porcentajes. Por ejemplo, CNN clasifica correctamente el 70 % de las imágenes. La precisión de CNN es del 70 %. Los resultados de esta tabla son consistentes con los resultados anteriores. CNN es el algoritmo que mejor clasifica las imágenes, seguido de KF y KNN. CNN tiene la precisión más alta y la tasa de error más baja.

Tabla 5

Compilación de resultados de los algoritmos

Algoritmo	Correctas	Incorrectas	Precisión	Tasa de error
CNN	70 %	30 %	70 %	30 %
RF	59 %	41 %	59 %	41 %
KNN	58 %	42 %	58 %	42 %

Fuente: original

Los datos de la tabla 6 presentan los resultados del modelo CNN en cinco iteraciones distintas. Cada iteración se caracteriza por un número diferente de epoch, una tasa de apren-

dizaje específica (que determina la velocidad de ajuste del modelo), ña precisión que tuvo y la pérdida también. Los resultados muestran cómo evolucionan la precisión del modelo y la pérdida (error del modelo) a medida que aumenta el número de épocas y disminuye la tasa de aprendizaje. Se observa una tendencia general de mejora en la precisión y disminución de la pérdida a medida que se avanza en las iteraciones, lo que sugiere que el modelo está asimilando los patrones de forma efectiva.

Tabla 6

Resultados de las iteraciones del modelo CNN

Iteración	Epochs	Tasa de Aprendizaje	Precisión (%)	Pérdida (Loss)
1	5	0.01	55.0	0.75
2	10	0.01	60.2	0.68
3	20	0.001	65.8	0.58
4	50	0.001	68.5	0.45
5	100	0.0001	70.0	0.30

Fuente: original

5.3 Gráficas de Resultados

La representación gráfica de la evolución de la precisión del modelo a lo largo de las épocas refleja un desarrollo positivo en términos de aprendizaje y generalización. La línea correspondiente al conjunto de entrenamiento muestra un crecimiento consistente, indicativo de la asimilación efectiva de los patrones presentes en los datos de entrenamiento. De manera paralela, la línea que representa la precisión en el conjunto de prueba sigue una trayectoria similar y se estabiliza en un nivel elevado, sugiriendo una capacidad de generalización a datos no observados.

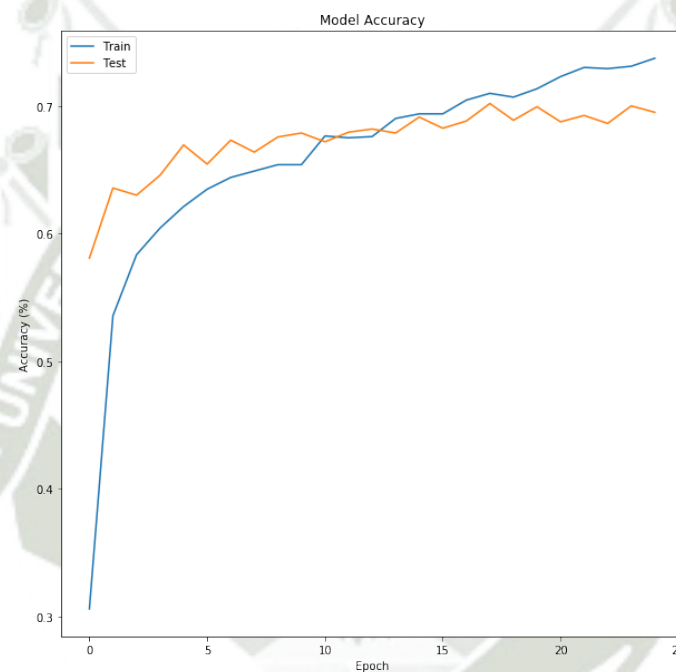
La convergencia observada en ambas curvas y su estabilidad apuntan a que el modelo ha alcanzado un punto óptimo de aprendizaje sin incurrir en sobreajuste. Este equilibrio es esencial para asegurar la precisión en predicciones en situaciones del mundo real. La coherencia entre las curvas de entrenamiento y prueba destaca la robustez y capacidad de

generalización del modelo, fortaleciendo la confianza en su aplicabilidad para escenarios prácticos.

Estos resultados subrayan la importancia de la evaluación en conjuntos de prueba independientes, respaldando la idoneidad del modelo para aplicaciones prácticas y reforzando la validez de los hallazgos obtenidos durante el proceso de entrenamiento.

Figura 13

Nivel de precisión



5.4 Discusión

La clasificación de la cubierta terrestre está estrechamente ligada al estado ecológico de la superficie terrestre y tiene importantes implicaciones para la salud de los ecosistemas mundiales, la calidad del agua y la gestión sostenible de la tierra. En la investigación realizada por Robinson en (Robinson y cols., 2021) se puede ver resultados del Data Fusion Contest del 2020 organizado por la IEEE Geoscience and Remote Sensing Society. Donde se resalta que muchos participantes tuvieron en cuenta diferentes fuentes de datos de satélites diferentes. Sin embargo debido a la calidad del lente que usa Sentinel, es considerado el más efectivo en análisis de imágenes, entre sus virtudes también se considera los diferentes ángulos que brinda y el poco ruido.

Por otro lado, en la investigación de Sahu Sahu y Dash (2022) también se presenta una comparatoria de algoritmos de clasificación de imágenes, pero se consideran los modelos de CNN, KNN y Naive Bayes. Sin embargo se emplearon unidades de imagen sin filtrado y limpieza de ruido por nubes por herramientas especializadas como Google Earth. Por lo que el resultado en muchas secciones presentaba errores.

Los resultados del análisis estadístico inferencial proporcionan información importante sobre cómo funcionan los algoritmos de clasificación utilizados en clasificar imágenes satelitales muy populares en otras investigaciones como las de García Álvarez y Paegelow (2022) y García Álvarez y Hinojosa (2022) donde se resalta su uso por el nivel de performance que tienen con una cantidad de datos muchas veces limitada. Los algoritmos Random Forest (RF), Redes neuronales convolucionales (CNN) y K-Nearest Neighbors (KNN) fueron evaluados en este contexto en términos de su precisión, lo que reveló diferencias notables en sus resultados.

En primer lugar, la tabla de estadísticas inferenciales (ver Tabla 2) proporciona una visión detallada de las precisiones por cada algoritmo. La alta precisión de CNN, con una media cercana al 70%, destaca su eficacia en la tarea de clasificación. Por otro lado, RF y KNN muestran resultados inferiores, indicando posiblemente una menor capacidad para

discriminar entre las clases específicas.

Muchos estudios previos han examinado de manera detallada la evaluación de la clasificación mediante redes neuronales convolucionales (CNN), utilizando un proceso de entrenamiento con conjuntos de datos de diferentes tamaños. Las conclusiones de estas investigaciones muestran cierta heterogeneidad y contradicciones a pesar de la gran cantidad de literatura existente. Los trabajos de Colditz (2015) y Mellor, Boukir, Haywood, y Jones (2015), que identificaron una tendencia hacia una asignación proporcional al área de las muestras de entrenamiento, sirven como ejemplos paradigmáticos de esta diversidad de hallazgos. Estos estudios sugieren que, a medida que aumenta el área de la clase de interés, se requieren proporcionalmente más muestras de entrenamiento para alcanzar la máxima precisión en la clasificación mediante la CNN. Sin embargo, los hallazgos de la investigación actual brindan una perspectiva adicional, señalando que, en condiciones donde el tamaño del conjunto de entrenamiento es suficientemente amplio, las CNN muestran una comparabilidad asombrosa en muestras de entrenamiento balanceadas y desbalanceadas. Este resultado demuestra que las CNN no solo son útiles y fuertes, sino que también sugiere que el impacto del desequilibrio en las muestras de entrenamiento puede ser reducido en ciertos entornos. Es importante destacar que, a pesar de la alta precisión de las CNN, estos resultados deben interpretarse teniendo en cuenta tanto el tamaño del conjunto de datos como las características únicas de la tarea de clasificación. Al emplear CNN para abordar problemas clasificatorios complejos y dinámicos, la capacidad de generalización y la robustez del modelo emergen como factores cruciales que deben tenerse en cuenta en entornos de aplicaciones del mundo real.

La interpretación de los percentiles y la variabilidad (ver Tabla 2) proporciona una comprensión más profunda de la consistencia de los algoritmos en diferentes situaciones. La baja desviación estándar de CNN indica una estabilidad en su rendimiento, mientras que RF y KNN presentan una mayor variabilidad, lo que podría sugerir una sensibilidad a condiciones específicas de los datos. En investigaciones similares como la de Rehman y cols. (2022) al muestran resultados similares, donde si bien estos modelos cuentan con un

buen rendimiento, el desempeño de CNN y otros algoritmos de redes neuronales llega a ser superior.

Los resultados dejan ver que la implementación de las CNN fue efectiva al llegar a un 70% precisión, dejando ver que el uso de estas en una arquitectura estándar permite manejar la clasificación de imágenes satelitales de una manera precisa, así como en el artículo Laban y cols. (2021), en donde se utiliza la arquitectura U-Net, la cual fue diseñada para la segmentación de imágenes, pero el problema fue que tuvo su enfoque en pocos datos y con píxeles bastante dispersos, lo cual no reflejaba una ventaja ante la CNN aplicada al proyecto, dejando ver que si se implementa una CNN estándar de una manera correcta, esta puede llegar a superar en ciertos casos a arquitecturas más complejas que no se aplican de una manera que destaque todo el potencial que pueden llegar a tener.

Además en el artículo Li y cols. (2020) se presenta MBFNet como modelo avanzado junto con SAR con el objetivo de mejorar la clasificación de imágenes LULC, su precisión no alcanza la demostrada en este proyecto, destacando así que a pesar de las innovaciones presentadas, las CNN del proyecto han demostrado un mejor rendimiento junto con una implementación más directa y menos compleja, reafirmando su efectividad para clasificar imágenes satelitales multiespectrales.

En cuanto a las características de los algoritmos aplicados, las redes neuronales convolucionales (CNN) se distinguen de otros algoritmos por su capacidad para aprender patrones jerárquicos y características complejas a través de capas convolucionales, lo que las posiciona como una opción poderosa y versátil para tareas de clasificación. Por otro lado, Random Forest (RF) se basa en árboles de decisión, lo que lo hace robusto y adaptable, siendo particularmente efectivo en una amplia gama de contextos clasificatorios. Mientras tanto, k-Nearest Neighbors (KNN) utilizan una estrategia de clasificación basada en la proximidad de muestras en el espacio de características, destacando por su simplicidad conceptual y su adaptabilidad a diversos tipos de datos. Sin embargo, es importante tener en cuenta que k-Nearest Neighbors (KNN) pueden presentar rendimientos inferiores en ciertos casos debido

a su enfoque directo y dependiente de la proximidad de los datos, a pesar de que CNN y RF exhiben enfoques más avanzados y complejos. Las CNN aprenden representaciones más abstractas y complejas debido a su naturaleza de aprendizaje profundo, mientras que RF aprovecha la diversidad de árboles de decisión para mejorar la generalización del modelo. En consecuencia, la elección entre estos algoritmos dependerá de la complejidad de la tarea de clasificación, la cantidad de datos disponibles y la necesidad de interpretabilidad del modelo. Por ello, viendo los resultados que se obtuvieron de aplicar los algoritmos en las imágenes se determinó que las redes neuronales son el algoritmo más adecuado para la clasificación de imágenes satelitales.

Los resultados detallados en las Tablas 3 y 4 corroboran la superioridad de CNN en términos de precisión, accuracy y precision. RF y KNN muestran consistentemente resultados inferiores en estas métricas, respaldando la conclusión de que CNN es el algoritmo más adecuado para esta tarea específica.

En relación con la representación gráfica de los resultados (ver Figura 13), se observa un desarrollo positivo y consistente en la precisión del modelo a lo largo de las épocas de entrenamiento. La estabilización en un nivel elevado en el conjunto de prueba sugiere una capacidad efectiva de generalización, reforzando la confianza en la aplicabilidad práctica del modelo.

En resumen, los resultados presentados destacan la eficacia del algoritmo de redes neuronales en la clasificación de imágenes satelitales, especialmente en la identificación de áreas forestales. Estos hallazgos ofrecen una base sólida para futuras investigaciones en el ámbito de la clasificación de imágenes satelitales.

Conclusiones y Recomendaciones

Conclusiones

En conclusión, la presente investigación ha abordado la urgente necesidad de clasificar bofedales en imágenes multiespectrales de la región Arequipa, destacando su importancia a nivel mundial, regional y local. A través de un exhaustivo análisis del problema, se identificaron las carencias en el conocimiento actual y la falta de propuestas de investigación a nivel local.

1. Los objetivos de este estudio, que incluían una investigación exhaustiva sobre las propuestas de análisis de los bofedales en imágenes satelitales, se lograron satisfactoriamente permitiendo una guía para la selección de algoritmos a evaluar.
2. La utilización de conjuntos de datos específicamente curados y adaptados a la problemática de clasificación de imágenes fue fundamental para el rendimiento del sistema. La calidad y representatividad de los datos de entrenamiento influyeron directamente en la capacidad del modelo para generalizar y clasificar nuevas imágenes con precisión debido a que son parte de una fuente validada de Google.
3. Los hallazgos de la investigación respaldan el éxito del método utilizado. El uso de algoritmos de inteligencia artificial como Random Forest, CNN y KNN permitió la identificación y clasificación efectivas de los bofedales.
4. Random Forest, CNN Y KNN son algunos de los algoritmos de clasificación de imágenes que se utilizaron durante el estudio. Estos algoritmos fueron elegidos porque eran capaces de manejar grandes cantidades de datos y dar resultados precisos en problemas de clasificación.
5. Después de evaluar los resultados de varios algoritmos, CNN resultó ser el más eficiente en la clasificación de imágenes satelitales multiespectrales para la identificación de bofedales con una media cercana al 70% evidenciando su eficacia.

Se espera que estos resultados contribuyan significativamente al conocimiento científico al mejorar la comprensión de la distribución de los bofedales. Apoyando el análisis y la toma de decisiones a través del uso de redes neuronales. Como adicional se cuenta con la publicación de un artículo científico indexado en Scopus el cual muestra la aplicación de este algoritmo y sus resultados principales



Recomendaciones

En primer lugar, se sugiere la exploración y utilización de conjuntos de datos adicionales, como los catálogos proporcionados por Google Earth, con el objetivo de ampliar la diversidad y representatividad de las clases de cobertura terrestre consideradas. La integración de estos datos complementarios podría contribuir a mejorar la precisión y robustez del modelo propuesto.

Además, se recomienda la evaluación de otros modelos de redes neuronales en comparación con los empleados en este estudio. La experimentación con arquitecturas de redes alternativas y la adaptación de parámetros específicos podrían revelar insights valiosos sobre la eficacia de diferentes enfoques en el contexto de la clasificación de cobertura terrestre. La diversificación de modelos permitirá una evaluación más exhaustiva de las capacidades y limitaciones de distintas metodologías, facilitando así la identificación de la mejor estrategia para abordar la problemática específica de la clasificación de land cover.

Adicionalmente, se aconseja considerar la incorporación de técnicas de preprocesamiento de datos avanzadas, como la normalización de imágenes y la aplicación de filtros específicos, con el propósito de mejorar la calidad y consistencia de los datos de entrada. La implementación de estas prácticas puede contribuir a mitigar posibles fuentes de ruido y mejorar la capacidad del modelo para generalizar patrones.

La expansión de conjuntos de datos, la exploración de diversos modelos de redes neuronales, y la aplicación de técnicas de preprocesamiento avanzadas son aspectos clave que pueden potenciar significativamente la eficacia y aplicabilidad de los modelos de clasificación de cobertura terrestre. Estas recomendaciones, combinadas de manera sinérgica, pueden proporcionar una base sólida para futuras investigaciones y contribuir al avance de la comprensión y monitorización de los patrones de cobertura terrestre a escala global.

Trabajos Futuros

Para los trabajos futuros se buscará incorporar imágenes de otros satélites con el fin de mejorar la categorización y el estudio de los bofedales. Algunas fuentes alternativas podrían ser los satélites Landsat 8/9, que suministran datos multiespectrales parecidos a los de Sentinel-2, aunque con una resolución espacial de 30 m, o los datos de MODIS (Moderate Resolution Imaging Spectroradiometer), que, pese a su resolución espacial (250-500 m), resulta beneficioso para el análisis temporal a largo plazo debido a su elevada frecuencia de obtención, y cuyos datos se encuentran disponibles en el portal LAADS DAAC de la NASA. Otra alternativa es el satélite PlanetScope, que es muy conveniente para áreas específicas y con cobertura diaria, aunque su acceso generalmente es de pago. Asimismo, se podrían tomar en cuenta los datos RADAR/SAR, particularmente beneficiosos para áreas cubiertas por nubes o épocas de precipitaciones. Estos sistemas funcionan en distintos grados y facilitan un estudio más exhaustivo de la topografía y la composición del agua.

Considerando que los bofedales varían considerablemente con la altitud, se propone un estudio más exhaustivo del impacto de la altitud en la estructura del modelo. En zonas con mayores altitudes y menor cantidad de vegetación, se dará la preferencia a las bandas que son sensibles a la reflectividad del agua y las características del terreno. Además, se investigarán las variaciones en los hiperparámetros del modelo, tales como la profundidad de la red neuronal en CNN, la cantidad de árboles en bosques aleatorios o el valor k en KNN, modificándolos para representar las propiedades espectrales y espaciales del modelo para cada región de altitud. Esto requerirá la creación de un enfoque adaptable en el que el modelo modifique sus parámetros de manera automática en base a la geografía y la altitud.

Igualmente, para optimizar el estudio de los bofedales, se aconseja incorporar datos complementarios como datos climáticos como la temperatura o la lluvia para asociar las variaciones en los bofedales con las variables climáticas.

Finalmente, considerando la ausencia de datos etiquetados exactos en ciertas áreas, se aconseja investigar algoritmos de aprendizaje no supervisado, tales como el clustering

o el semisupervisado, que facilitan la detección de patrones en zonas donde existe escasa información accesible. Esto podría ser beneficioso para ampliar el análisis a áreas con datos iniciales escasos.



Referencias

- Alayo Ontón, J. T. (2021). *Análisis de imágenes satelitales para la identificación y determinación de variación espacial de deslizamientos de tierra en la ciudad de huancabamba, piura, para el periodo 2017 – 2019* (Tesis de pregrado).
- Amani, M., Brisco, B., Mahdavi, S., Ghorbanian, A., Moghimi, A., DeLancey, E. R., ... LaRocque, A. (2021). Evaluation of the landsat-based canadian wetland inventory map using multiple sources: Challenges of large-scale wetland classification using remote sensing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 32-52. doi: 10.1109/JSTARS.2020.3036802
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M., ... Brisco, B. (2020). Google earth engine cloud computing platform for remote sensing big data applications: A comprehensive review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5326-5350. doi: 10.1109/JSTARS.2020.3021052
- Amani, M., Mahdavi, S., Kakooei, M., Ghorbanian, A., Brisco, B., DeLancey, E. R., ... Reyes, E. L. (2021). Wetland change analysis in alberta, canada using four decades of landsat imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 10314-10335. doi: 10.1109/JSTARS.2021.3110460
- Arlitt Lozano-Povis, N. M., Carlos E. Alvarez-Montalván. (2021). El cambio climático en los andes y su impacto en la agricultura: una revisión sistemática. *SciELO Analytics*, 12. doi: <http://dx.doi.org/10.17268/sci.agropecu.2021.012>
- Arndt, J., y Lunga, D. (2021). Large-scale classification of urban structural units from remote sensing imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 2634-2648. doi: 10.1109/JSTARS.2021.3052961
- Arthur L. Samuel. (2023). *Some studies in machine learning using the game of checkers* . https://hci.iwr.uni-heidelberg.de/system/files/private/downloads/636026949/report_frank_gabel.pdf.

- Berdugo Muñoz, A. G., y Relaes Lopez, G. J. (2016). *Análisis multiespectral de imágenes satelitales para evaluar variaciones espacio - temporales en la calidad del agua del embalse el guájaro, atlántico* (Tesis de pregrado).
- Bolloju, N., Chawla, R., y Ranjan, R. (2018). Pros and cons of rotating scrum master role: A qualitative study.. Descargado de <https://doi.org/10.1145/3172871.3172883> doi: 10.1145/3172871.3172883
- Bosco, M. J., Wang, G., y Hategekimana, Y. (2021). Learning multi-granularity neural network encoding image classification using dcnn for easter africa community countries. *IEEE Access*, 9, 146703-146718. doi: 10.1109/ACCESS.2021.3122569
- Botero, E. U. (2015). *El cambio climático y sus efectos en la biodiversidad en américa latina*. CEPAL.
- Cai, H., Chen, T., Niu, R., y Plaza, A. (2021). Landslide detection using densely connected convolutional networks and environmental conditions. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 5235 - 5247. doi: 10.1109/JSTARS.2021.3079196
- Challenger Pérez Ivet, B. G. R. A., Díaz Ricardo Yanet. (2014). El lenguaje de programación python. *Sistema de Información Científica Redalyc-Ciencias Holguín*, 55.
- Chen, J., Chen, G., Fang, B., Wang, J., y Wang, L. (2021). Class-aware domain adaptation for coastal land cover mapping using optical remote sensing imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 11800-11813. doi: 10.1109/JSTARS.2021.3128527
- Chilán, N. Y. D. (2020). Fundamentos teóricos para una estrategia de conservación y valorización turístico-recreativa de los humedales de ecuador. *REVISTA INTERNACIONAL DE TURISMO, EMPRESA Y TERRITORIO*, 4. doi: <https://doi.org/10.21071/riturem.v4i1.12724>
- Christmann, T., Palomeque, X., Armenteras, D., Wilson, S. J., Malhi, Y., y Oliveras Menor, I. (2023). Disrupted montane forest recovery hinders biodiversity conservation

- in the tropical andes [Article]. *Global Ecology and Biogeography*. Descargado de <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85150830266&doi=10.1111%2fgeb.13666&partnerID=40&md5=0d8cf40eff2ec28668d2e7a47dc3f7ea> (Cited by: 0) doi: 10.1111/geb.13666
- Colditz, R. R. (2015). An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms. *Remote Sensing*, 7(8), 9655–9681. Descargado de <https://www.mdpi.com/2072-4292/7/8/9655> doi: 10.3390/rs70809655
- Data, S., y (sedac), A. C. (2023). *Land use and land cover (lulc)*. <https://sedac.ciesin.columbia.edu/data/collection/lulc>. (A Data Center in NASA's Earth Observing System Data and Information System (EOSDIS) — Hosted by CIESIN at Columbia University)
- Deep learning - matlab & simulink*. (2023). <https://www.mathworks.com/discovery/deep-learning.html>.
- Du, H., Li, M., Xu, Y., y Zhou, C. (2023). An ensemble learning approach for land use/land cover classification of arid regions for climate simulation: A case study of xinjiang, northwest china. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 2413 - 2426. doi: 10.1109/JSTARS.2023.3247624
- Edwin, G. A. (2016). *Estado de salud de los bofedales de las cabeceras de las microcuencas de san luis y san nicolás* (Tesis Doctoral no publicada).
- Fan, Z., Zhan, T., Gao, Z., Li, R., Liu, Y., Zhang, L., ... Xu, S. (2022). Land cover classification of resources survey remote sensing images based on segmentation model. *IEEE Access*, 10, 56267-56281. doi: 10.1109/ACCESS.2022.3175978
- Fonkén, M. (2015). Introducción a los bofedales de la región altoandina peruana. *International Mire Conservation Group and International Peat Society*, 15, 1-13.
- García Álvarez, D., y Hinojosa, J. (2022, 06). General land use cover datasets for africa. En (p. 347-360). doi: 10.1007/978-3-030-90998-7_17

- García Álvarez, D., y Paegelow, M. (2022, 06). Spatial metrics to validate land use cover maps. En (p. 205-228). doi: 10.1007/978-3-030-90998-7_11
- Gidey, E., Dikinya, O., Sebego, R., Segosebe, E., Zenebe, A., Mussa, S., ... Birhane, E. (2023). Land use and land cover change determinants in raya valley, tigray, northern ethiopian highlands. *Agriculture*, 13(2). Descargado de <https://www.mdpi.com/2077-0472/13/2/507> doi: 10.3390/agriculture13020507
- Gonda, C. M. (2020). *Cambio climático y biodiversidad en los andes tropicales*. Estudio REC.
- Gonzales, R. L. (2015). *Mapa nacional de cobertura vegetal memoria descriptiva*. Ministerio del Ambiente.
- Google. (2023). *Te damos la bienvenida a colab*. <https://colab.research.google.com/?hl=es>. (Colab, también conocido como Colaboratory", te permite programar y ejecutar Python en tu navegador con las siguientes ventajas)
- Huanca, S. M. E. (2019). *Monitoreo de sequías para sistemas de alerta temprana*. Senamhi.
- Huang, H., Pu, C., Li, Y., y Duan, Y. (2020). Adaptive residual convolutional neural network for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 2520-2531. doi: 10.1109/JSTARS.2020.2995445
- IBM. (2023). *Artificial intelligence - overview*. <https://www.ibm.com/topics/artificial-intelligence>.
- IBM. (2023). *Machine Learning*. <https://www.ibm.com/topics/machine-learning>.
- Ienco, D., Gbodjo, Y. J. E., Gaetano, R., y Interdonato, R. (2020). Weakly supervised learning for land cover mapping of satellite image time series via attention-based cnn. *IEEE Access*, 8, 179547 - 179560. doi: 10.1109/ACCESS.2020.3024133
- Isuhuaylas, L. A. V., Hirata, Y., Santos, L. C. V., y Torobeo, N. S. (2018). Natural forest mapping in the andes (peru): A comparison of the performance of machine-learning algorithms. *MDPI*, 10, 782. doi: 10.3390/rs10050782
- Jacob, A. W., Notarnicola, C., Suresh, G., Antropov, O., Ge, S., Praks, J., ... Lavalle, M.

- (2020). Sentinel-1 insar coherence for land cover mapping: A comparison of multiple feature-based classifiers. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *13*, 535-552. doi: 10.1109/JSTARS.2019.2958847
- Jamali, A., Mahdianpari, M., Mohammadimanesh, F., Brisco, B., y Salehi, B. (2022). 3-d hybrid cnn combined with 3-d generative adversarial network for wetland classification with limited training data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *15*, 8095-8108. doi: 10.1109/JSTARS.2022.3206143
- Jennifer Calderón-Caro, A. M. B. (2021). Deforestación y fragmentación en las áreas más biodiversas de la cordillera occidental de antioquia (colombia). *SciELO Analytics*, *23*. doi: <https://doi.org/10.21068/2539200x.942>
- Laban, N., Abdellatif, B., Ebeid, H. M., Shedeed, H. A., y Tolba, M. F. (2021). Sparse pixel training of convolutional neural networks for land cover classification. *IEEE Access*, *9*, 52067 - 52078. doi: 10.1109/ACCESS.2021.3069882
- Le, Q. T., Dang, K. B., Giang, T. L., Tong, T. H. A., Nguyen, V. G., Nguyen, T. D. L., y Yasir, M. (2022). Deep learning model development for detecting coffee tree changes based on sentinel-2 imagery in vietnam. *IEEE Access*, *10*, 109097-109107. doi: 10.1109/ACCESS.2022.3203405
- Li, X., Lei, L., Sun, Y., Li, M., y Kuang, G. (2020). Multimodal bilinear fusion network with second-order attention-based channel selection for land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *13*, 1011 - 1026. doi: 10.1109/JSTARS.2020.2975252
- Liu, Y., Qian, J., y Yue, H. (2020). Combined sentinel-1a with sentinel-2a to estimate soil moisture in farmland. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *16*, 1292 - 1310. doi: 10.1109/JSTARS.2020.3043628
- Lowe, B., y Kulkarni, A. (2015, 02). Multispectral image analysis using random forest. *International Journal on Soft Computing*, *6*, 1-14. doi: 10.5121/ijsc.2015.6101
- McCarthy, J. (2007). What is ai? *Stanford Computer Science Department*. Descargado de

<https://www-formal.stanford.edu/jmc/whatisai.pdf>

- McRoberts, R. E. (2008). Using satellite imagery and the k-nearest neighbors technique as a bridge between strategic and management forest inventories. *Remote Sensing of Environment*, 112(5), 2212-2221. Descargado de <https://www.sciencedirect.com/science/article/pii/S0034425708000163> (Earth Observations for Terrestrial Biodiversity and Ecosystems Special Issue) doi: <https://doi.org/10.1016/j.rse.2007.07.025>
- Mellor, A., Boukir, S., Haywood, A., y Jones, S. (2015). Exploring issues of training data imbalance and mislabelling on random forest performance for large area land cover classification using the ensemble margin. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, 155-168. Descargado de <https://www.sciencedirect.com/science/article/pii/S0924271615000945> doi: <https://doi.org/10.1016/j.isprsjprs.2015.03.014>
- MINAM. (2019). *Informe nacional sobre el estado del ambiente 2014-2019*. Viceministerio de Gestión Ambiental.
- Minam. (2023). *Minam publica el primer inventario nacional de bofedales*. <https://www.gob.pe/institucion/minam/noticias/775811-minam-publica-el-primer-inventario-nacional-de-bofedales>.
- Morata, M., Siegmann, B., Pérez-Suay, A., García-Soria, J. L., Rivera-Caicedo, J. P., y Verrelst, J. (2023). Neural network emulation of synthetic hyperspectral sentinel-2-like imagery with uncertainty. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 762-772. doi: 10.1109/JSTARS.2022.3231380
- Orozco, O. L. P., Cardenas, M. P., Meneses, J. B., Sanchez, T. L., y Núñez, Y. H. J. (2023). Detection of long-term changes by multispectral analysis in the high-altitude andean wetlands vegetation's: Michincha case study, 1985-2019; [detección de cambios a largo plazo con análisis multispectral en la vegetación azonal hídrica altoandina: caso de estudio salar michincha, 1985-2019] [Article]. *Revista de Geografía Norte Grande*, 2023(84), 177 –

200. Descargado de <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85164579491&doi=10.4067%2fS0718-34022023000100177&partnerID=40&md5=b12c5438a44e8877610a40be5223d169> (Cited by: 0; All Open Access, Gold Open Access) doi: 10.4067/S0718-34022023000100177
- Peyre, G., Osorio, D., François, R., y Anthelme, F. (2021). Mapping the páramo land-cover in the northern andes. *International Journal of Remote Sensing*, 42(20), 7777-7797. Descargado de <https://doi.org/10.1080/01431161.2021.1964709> doi: 10.1080/01431161.2021.1964709
- Pizarro, S. E., Pricope, N. G., Vargas-Machuca, D., Huanca, O., y Ñaupari, J. (2022). Mapping land cover types for highland andean ecosystems in peru using google earth engine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 5177-5189. doi: <https://doi.org/10.3390/rs14071562>
- QGIS. (2023). *Qgis - el sig líder de código abierto para escritorio*. <https://qgis.org/es/site/about/index.html>. (<https://qgis.org/es/site/about/index.html>)
- Rehman, A., Qin, J., Pervez, A., Khan, M. S., Ullah, S., Ahmad, K., y Rehman, N. U. (2022). Land-use/land cover changes contribute to land surface temperature: A case study of the upper indus basin of pakistan [Article]. *Sustainability (Switzerland)*, 14(2). Descargado de <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85122963729&doi=10.3390%2fsu14020934&partnerID=40&md5=6a37d3b41e2fac2a47fb1c301c29ecbb> (Cited by: 16; All Open Access, Gold Open Access) doi: 10.3390/su14020934
- Robinson, C., Malkin, K., Jojic, N., Chen, H., Qin, R., Xiao, C., ... Yokoya, N. (2021). Global land-cover mapping with weak supervision: Outcome of the 2020 ieee grss data fusion contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 3185-3199. doi: 10.1109/JSTARS.2021.3063849
- Russell, S., y Norvig, P. (2010). *Artificial intelligence: A modern approach*. Pearson Education. Descargado de <https://aima.cs.berkeley.edu> (2023)

- Sahu, M., y Dash, R. (2022). A fusion based land cover classification model using remote sensed images. , *16*(1), 37 – 49. Descargado de <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85129310389&doi=10.3233%2fIDT-210037&partnerID=40&md5=29082bdcbb65c101be3c56578f109> doi: 10.3233/IDT-210037
- Sebastianelli, A., Zaidenberg, D. A., Spiller, D., Saux, B. L., y Ullo, S. L. (2022). On circuit-based hybrid quantum neural networks for remote sensing imagery classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *15*, 565-580. doi: 10.1109/JSTARS.2021.3134785
- Shao, H., Li, Y., Ding, Y., Zhuang, Q., y Chen, Y. (2020). Land use classification using high-resolution remote sensing images based on structural topic model. *IEEE Access*, *8*, 215943-215955. doi: 10.1109/ACCESS.2020.3041645
- Soori, M., Arezoo, B., y Dastres, R. (2023). Artificial intelligence, machine learning and deep learning in advanced robotics, a review. *Cognitive Robotics*, *3*, 54-70. Descargado de <https://www.sciencedirect.com/science/article/pii/S2667241323000113> doi: <https://doi.org/10.1016/j.cogr.2023.04.001>
- Soylu, M. E., y Bras, R. L. (2022). Global shallow groundwater patterns from soil moisture satellite retrievals. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *15*, 89-101. doi: 10.1109/JSTARS.2021.3124892
- Stahl, A. T., Andrus, R., Hicke, J. A., Hudak, A. T., Bright, B. C., y Meddens, A. J. (2023). Automated attribution of forest disturbance types from remote sensing data: A synthesis [Review]. *Remote Sensing of Environment*, *285*. Descargado de <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85144408272&doi=10.1016%2fj.rse.2022.113416&partnerID=40&md5=60b8db4b4116f595071032f1a00d6291> (Cited by: 1) doi: 10.1016/j.rse.2022.113416
- Sun, X., Zhang, B., Zhuang, L., Gao, H., Sun, X., y Ni, L. (2023). Anomaly detection based on tree topology for hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *16*, 1985-2008. doi: 10.1109/

JSTARS.2022.3197642

- Tombe, R., y Viriri, S. (2021). Adaptive deep co-occurrence feature learning based on classifier-fusion for remote sensing scene classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 155-164. doi: 10.1109/JSTARS.2020.3044264
- Tu, B., Ren, Q., Zhou, C., Chen, S., y He, W. (2021). Feature extraction using multidimensional spectral regression whitening for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 8326-8340. doi: 10.1109/JSTARS.2021.3104153
- Tu, Y., Lang, W., Yu, L., Li, Y., Jiang, J., Qin, Y., ... Xu, B. (2020). Improved mapping results of 10 m resolution land cover classification in guangdong, china using multisource remote sensing data with google earth engine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5384-5397. doi: 10.1109/JSTARS.2020.3022210
- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, LIX(236), 433-460. Descargado de <https://redirect.cs.umbc.edu/courses/471/papers/turing.pdf>
- Unal, Z. (2020). Smart farming becomes even smarter with deep learning - a bibliographical analysis. *IEEE Access*, 8, 105587-105609. doi: 10.1109/ACCESS.2020.3000175
- Villasante Benavides, J. F. (2021). *Influencia del cambio climático sobre los humedales altoandinos: estudio comparativo entre un humedal manejado (perca, castilla, arequipa) y uno no manejado (ccallaccapcha, la unión, arequipa)* (Tesis Doctoral no publicada).
- Wu, P., Zhan, W., Cheng, N., Yang, H., y Wu, Y. (2021). A framework to calculate annual landscape ecological risk index based on land use/land cover changes: A case study on shengjin lake wetland. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 11926-11935. doi: 10.1109/JSTARS.2021.3129183
- Xu, Y., Du, B., Zhang, L., Cerra, D., Pato, M., Carmona, E., ... Saux, B. L. (2019, 6). Advanced multi-sensor optical remote sensing for urban land use and land cover

- classification: Outcome of the 2018 ieeegrss data fusion contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12, 1709-1724. doi: 10.1109/JSTARS.2019.2911113
- Zaabar, N., Niculescu, S., y Kamel, M. M. (2022). Application of convolutional neural networks with object-based image analysis for land cover and land use mapping in coastal areas: A case study in ain témouchent, algeria. *IEEE Access*, 15, 5177 - 5189. doi: 10.1109/JSTARS.2022.3185185.
- Zafari, A., Zurita-Milla, R., y Izquierdo-Verdiguier, E. (2020). A multiscale random forest kernel for land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 2842-2852. doi: 10.1109/JSTARS.2020.2976631
- Zerrouki, Y., Harrou, F., Zerrouki, N., Dairi, A., y Sun, Y. (2021). Desertification detection using an improved variational autoencoder-based approach through etm-landsat satellite data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 202-213. doi: 10.1109/JSTARS.2020.3042760
- Zhipeng, G., Jiang, W., Peng, K., Deng, Y., y Wang, X. (2023). Wetland mapping and landscape analysis for supporting international wetland cities: Case studies in nanchang city and wuhan city. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 8858-8870. doi: 10.1109/JSTARS.2023.3302031
- ¿qué es el aprendizaje profundo? (fecha de acceso: 2023). <https://aws.amazon.com/es/what-is/deep-learning/>. (Accedido el 14 de mayo de 2023)

Anexos

Anexo A.

Glosario:

- RF: Random Forest (Bosques Aleatorios)
- CNN: Convolutional Neural Networks (Redes Neuronales Convolucionales)
- KNN: K-Nearest Neighbors (Algoritmo de k vecinos más cercanos)
- LULC: Land Use Land Cover (Uso de la tierra y cobertura de la tierra)

