



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Facultad de Ingeniería Geológica, Minera, Metalúrgica y Geográfica

Escuela Profesional de Ingeniería Geográfica

Estimación del área glaciar mediante inteligencia artificial y cubos de datos. Caso de estudio: Parque Nacional Huascarán, Ancash – Perú del 2018-2022

TESIS

Para optar el Título Profesional de Ingeniero Geógrafo

AUTORES

Lesly Aracelly BAUTISTA BUENDIA

Junior Antonio CALVO MONTAÑEZ

ASESOR

Dr. Francisco Alejandro ALCÁNTARA BOZA

Lima, Perú

2024



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Bautista, L. & Calvo, J. (2024). *Estimación del área glaciar mediante inteligencia artificial y cubos de datos. Caso de estudio: Parque Nacional Huascarán, Ancash – Perú del 2018-2022*. [Tesis de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería Geológica, Minera, Metalúrgica y Geográfica, Escuela Profesional de Ingeniería Geográfica]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor 1	
Nombres y apellidos	Lesly Aracelly Bautista Buendia
Tipo de documento de identidad	DNI
Número de documento de identidad	76189897
URL de ORCID	https://orcid.org/0000-0003-3523-8687
Datos de autor 2	
Nombres y apellidos	Junior Antonio Calvo Montañez
Tipo de documento de identidad	DNI
Número de documento de identidad	76864605
URL de ORCID	https://orcid.org/0009-0009-2611-2450
Datos de asesor	
Nombres y apellidos	Francisco Alejandro Alcántara Boza
Tipo de documento de identidad	DNI
Número de documento de identidad	27074721
URL de ORCID	https://orcid.org/0000-0001-9127-4450
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	José Jorge Espinoza Eche
Tipo de documento	DNI
Número de documento de identidad	06184372
Miembro del jurado 1	
Nombres y apellidos	José Luis Quispe Vilchez

Tipo de documento	DNI
Número de documento de identidad	08119070
Datos de investigación	
Línea de investigación	C.16.0.20 Geoinformática
Grupo de investigación	GLACIARES Y ECOSISTEMAS DE ALTA MONTAÑA
Agencia de financiamiento	Perú. Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica y ProCiencia. Contrato N° PE501083135-2023-PROCIENCIA
Ubicación geográfica de la investigación	Parque Nacional Huascarán País: Perú Departamento: Ancash Latitud: -9.132444 Longitud: -77.530133
Año o rango de años en que se realizó la investigación	2023 - 2024
URL de disciplinas OCDE	Geociencias, Multidisciplinar https://purl.org/pe-repo/ocde/ford#1.05.01 Sensores remotos https://purl.org/pe-repo/ocde/ford#2.07.04 Ciencias del medio ambiente https://purl.org/pe-repo/ocde/ford#1.05.08



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS

Universidad del Perú, DECANA DE AMÉRICA

FACULTAD DE INGENIERÍA GEOLÓGICA, MINERA, METALÚRGICA Y GEOGRÁFICA
ESCUELA PROFESIONAL DE INGENIERÍA GEOGRÁFICA

ACTA DE SUSTENTACIÓN DE TESIS PARA OPTAR TÍTULO PROFESIONAL DE INGENIERO GEÓGRAFO

En el Salón de Grados y Títulos de la Escuela Profesional de Ingeniería Geográfica de la Facultad de Ingeniería Geológica, Minera, Metalúrgica y Geográfica de la Universidad Nacional Mayor de San Marcos, el día jueves 23 de mayo del 2024, siendo las 06:00 horas, en presencia de los Señores Docentes designados como Miembros del Jurado Calificador:

Dr. JOSÉ JORGE ESPINOZA ECHE
Ing. JOSÉ LUIS QUISPE VILCHEZ

Presidente
Miembro

Reunidos en Acto Académico Público de Sustentación de la Tesis titulada: «**ESTIMACIÓN DEL ÁREA GLACIAR MEDIANTE INTELIGENCIA ARTIFICIAL Y CUBOS DE DATOS. CASO DE ESTUDIO: PARQUE NACIONAL HUASCARÁN, ANCASH – PERÚ DEL 2018-2022**», para optar el Título Profesional de Ingeniero Geógrafo.

Expuesta la Tesis; los miembros del Jurado plantearon a los Bachilleres las preguntas pertinentes, que fueron absueltas por los tesista: *SATISFACCION*


Concluida la sustentación de Tesis, el Jurado procedió a evaluar y calificar la calidad y sustentación en secreto, cuyo calificativo fue: *Diecisiete (17) APROBADO CON MENCIÓN HONROSA*

Habiendo sido aprobada la Sustentación de la Tesis por el Jurado Calificador, el Presidente del Jurado recomienda que la Facultad de Ingeniería Geológica, Minera, Metalúrgica y Geográfica, otorgue el TÍTULO PROFESIONAL DE INGENIERO GEÓGRAFO, a Don **JUNIOR ANTONIO CALVO MONTAÑEZ y LESLY ARACELLY BAUTISTA BUENDIA.**

Siendo las *19* horas, se dio por concluido el acto académico, expidiéndose cinco (05) Actas Originales de la Sustentación de Tesis, firmadas por el Jurado Calificador.

Ciudad Universitaria, 23 de mayo del 2024


Dr. JOSÉ JORGE ESPINOZA ECHE
PRESIDENTE


Ing. JOSÉ LUIS QUISPE VILCHEZ
MIEMBRO


Dr. FRANCISCO ALEJANDRO ALCÁNTARA BOZA
ASESOR DE TESIS



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Vicerrectorado de Investigación y Posgrado



CERTIFICADO DE SIMILITUD

Yo Alcántara Boza Francisco Alejandro, en mi condición de asesor acreditado con la Resolución Decanal N°000358-2024-D-FIGMMG/UNMSM de la tesis de investigación, cuyo título es "ESTIMACIÓN DEL ÁREA GLACIAR MEDIANTE INTELIGENCIA ARTIFICIAL Y CUBOS DE DATOS. CASO DE ESTUDIO: PARQUE NACIONAL HUASCARÁN, ÁNCASH – PERÚ DEL 2018 AL 2022", presentado por los bachilleres Junior Antonio Calvo Montañez y Lesly Aracelly Bautista Buendia para optar el título de Ingeniero Geógrafo. CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante el software de similitud textual, el documento evaluado cuenta con el porcentaje de 11% de similitud, nivel **PERMITIDO** para continuar con los trámites correspondientes y para su **publicación en el repositorio institucional.**

Se emite el presente certificado en cumplimiento de lo establecido en las normas vigentes, como uno de los requisitos para la obtención del título correspondiente.

Firma del Asesor

DNI: 27074721

Francisco Alejandro Alcántara Boza



Agradecimientos

Deseo comenzar esta tesis expresando mi más sincera y profunda gratitud hacia todas las personas e instituciones que me brindaron su apoyo y contribuyeron a la realización de esta investigación.

Mi agradecimiento se extiende al CONCYTEC, ya que este trabajo fue subvencionado por esta institución a través del programa PROCIENCIA en el marco del concurso “PROYECTOS DE INVESTIGACIÓN BÁSICA - 2023-01”, según contrato N° PE501083135-2023-PROCIENCIA del Proyecto: “AndesDataCube: Desarrollo de algoritmos de inteligencia artificial para la cuantificación de activos naturales en los Andes del Perú a partir del procesamiento de imágenes de satélite”, el cual es ejecutado por el equipo de investigación del Laboratorio de Ecotoxicología de la Universidad Peruana Cayetano Heredia (UPCH) e investigadores del Centro de Competencias del Agua (CCA), Universidad Nacional Mayor de San Marcos (UNMSM), Universidad Nacional Agraria La Molina (UNALM), Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM) y la Universidad de Salzburgo.

Al Dr. Alejandro Alcántara Boza, asesor de Tesis, por sus sugerencias y constante apoyo en el presente trabajo de investigación. Asimismo, debo agradecer también a Cesar Aybar quien estuvo conmigo desde el inicio de esta tesis, por siempre estar dispuesto a ayudar y compartir sus conocimientos conmigo de manera incondicional.

Quisiera expresar mi gratitud a mis colegas Antony Barja y Diana Aranibar por su apoyo emocional y motivación que me acompañaron a lo largo de esta jornada académica. Su presencia en los momentos más retadores de este proceso ha sido de un valor incalculable para mí.

Y por último, quiero dar las gracias a mi familia: a mis padres, mi hermana y Yue. Sin su amor, paciencia y comprensión, enfrentar los desafíos de este proyecto de tesis no habría sido posible. Su apoyo incondicional ha sido el pilar de mi fortaleza y fuente constante de ánimo.

-Lesly Bautista Buendia

Quiero expresar mi más profundo agradecimiento a mi madre, Marina Montañez Cashpa, cuyo amor, sacrificio y constante apoyo han sido el motor que impulsó cada paso de mi trayecto académico. Su dedicación inquebrantable y sus palabras de aliento fueron mi luz en los momentos más desafiantes, y sin su presencia constante, este logro no habría sido posible.

Asimismo, deseo agradecer sinceramente a Don Maximo Niño por su invaluable orientación y apoyo incondicional a lo largo de mi vida. No puedo dejar de reconocer el apoyo fundamental de mis queridos hermanos, Beronica, Carmen, Jorge y Florinda, cuyo aliento y comprensión fueron un pilar fundamental en este camino, su presencia y ánimo hicieron posible este logro.

-Junior Calvo Montañez

Tabla de contenido

Agradecimientos.....	ii
Tabla de contenido.....	iv
Lista de tablas.....	vii
Lista de Figuras.....	viii
Capítulo I. Introducción.....	1
1.1. Introducción	1
1.2. Planteamiento del problema	2
1.3. Formulación del problema	4
1.3.1. Pregunta general.....	4
1.3.2. Preguntas específicas	4
1.4. Objetivos de la investigación	5
1.4.1. Objetivo general.....	5
1.4.2. Objetivos específicos	5
1.5. Justificación de la investigación.....	5
1.6. Limitaciones en la investigación	6
Capítulo II. Marco teórico y conceptual.....	7
2.1. Antecedentes de la investigación	7
2.1.1. Antecedentes internacionales.....	7
2.1.2. Antecedentes nacionales	8
2.2. Bases teóricas	10
2.2.1. Teledetección y sus características	10
2.2.2. Energía Electromagnética	12
2.2.3. Espectro electromagnético	13
2.2.4. Resolución De Imágenes.....	14
2.2.5. Inteligencia artificial	15
2.2.6. Machine Learning	16
2.2.7. Tipos de aprendizaje automático	16
2.2.8. Deep Learning.....	17
2.2.9. Deep Learning en Teledetección	18
2.2.10. Redes Neuronales Recurrentes	18
2.2.11. Redes Neuronales Convolucionales.....	18
2.2.11.1. Redes Neuronales Artificiales	18

2.2.11.2. Función de Activación.....	20
2.2.12. Arquitectura U-Net	20
2.2.13. Criosfera.....	28
2.2.14. Precipitación	29
2.2.15. Glaciar.....	30
2.2.16. Formación de un glaciar.....	31
2.2.17. Zonificación de un glaciar	32
2.2.18. Glaciares tropicales.....	35
2.2.19. Estacionalidad de los glaciares	37
2.2.20. Glaciares de Perú	38
2.3. Definición de términos	39
Capítulo III. Hipótesis y variables.....	41
3.1. Hipótesis.....	41
3.1.1. Hipótesis general.....	41
3.1.2. Hipótesis específicas.....	41
3.2. Variables.....	41
3.2.1. Variable 1	41
3.2.2. Variable 2.....	42
3.2.3. Consideraciones Adicionales	42
3.3. Variables.....	42
Capítulo IV. Materiales y metodología	43
4.1. Descripción del área de estudio.....	43
4.1.1. Ubicación	43
4.2. Metodología	45
4.2.1. Recolección de datos de entrada:.....	45
4.2.2. Recolección de datos de referencia:.....	46
4.2.2.1. CloudSEN12.....	46
4.2.2.2. DynamicWorld	51
4.2.3. Diseño del Modelo de entrenamiento	55
4.2.3.1. Detector de nubes	55
4.2.3.2. Detector de cobertura de suelo	56
4.2.4. Evaluación del Modelo:	58
4.2.4.1. Detector de nubes	58
4.2.4.2. Detector de cobertura de suelo	59

4.2.5. Inferencia y despliegue:	59
4.2.6. Estimación del área glaciar	61
Capítulo V. Resultados	63
5.1. Precisión de los modelos	63
5.1.1. Precisión del detector de nubes.....	63
5.1.2. Precisión del detector de nieve	65
5.2. Detección del área glaciar	67
5.3. Estacionalidad	70
5.4. Comparación con el inventario del INAIGEM	73
Capítulo VI. Discusión de Resultados	75
Capítulo VII. Conclusiones	77
Capítulo VIII. Recomendaciones.....	79
Referencias.....	81

Lista de tablas

Tabla 1 Áreas de Glaciares Tropicales por Región	36
Tabla 2 Variables	42
Tabla 3 Límites del tile T18LTQ	44
Tabla 4 Lista de las bandas disponible en Sentinel-2 L1C y Sentinel-2a.....	46
Tabla 5 Categorías semánticas en las nubes consideradas en CloudSEN12	50
Tabla 6 Taxonomía de la Clasificación Dinámica del Uso de la Tierra y la Cubierta Terrestre (LULC, por sus siglas en inglés)	53
Tabla 7 Métricas del algoritmo de detección de nubes utilizado en esta tesis.....	63

Lista de Figuras

Figura 1 Elementos del Proceso Pasivo de Teledetección: Diagrama de flujo desde la captación de datos hasta el usuario final	12
Figura 2 Espectro Electromagnético: Rango de longitudes de onda desde rayos gamma hasta ondas de radio.....	13
Figura 3 Jerarquía de la Inteligencia Artificial. Representación de IA, aprendizaje automático y aprendizaje profundo como subconjuntos.....	15
Figura 4 Principales algoritmos y Aplicaciones de ML: Categorías y ejemplos de uso.....	16
Figura 5 Rendimiento de Deep Learning vs Machine Learning: Curvas que muestran mejora en rendimiento con más datos	18
Figura 6 Arquitectura de Red Neuronal Profunda: Muestra red con capas de entrada, ocultas y de salida.....	19
Figura 7 Arquitectura U-Net para Segmentación de Imágenes: Diagrama de flujo de las fases de contracción y expansión	21
Figura 8 a) ejemplos de mallas regulares e irregulares consistentes con el CIS, b) recorte de cubo de datos (izquierda) y segmentación (derecha)	22
Figura 9 El concepto de cubo de datos AGDC	23
Figura 10 Descripción general del concepto de cubo de datos.....	25
Figura 11 Componentes de la criosfera: regiones con agua sólida en superficies terrestres y oceánicas	29
Figura 12 Proceso de precipitación: nubes saturadas descargan lluvia, nieve o granizo por gravedad	30
Figura 13 Dinámica Glaciar: El campo de nieve y línea de nieves con zonas de acumulación y pérdida.....	32
Figura 14 Zonificación Glaciar y ELA: se muestra las áreas de acumulación y ablación con la Línea de Equilibrio Altitudinal.....	33
Figura 15 Estratificación de la Zona Glaciar: Se muestra acumulación y ablación, subdivididas por procesos y características.....	35
Figura 16 Distribución de Glaciares Tropicales: Mapa mundial de glaciares en la Zona de Convergencia Intertropical	36
Figura 17 Distribución de Glaciares en los Andes Tropicales: Clasificación por zonas climáticas y elevación	38
Figura 18 Área de estudio	44

Figura 19 Área de Estudio	45
Figura 20 Distribución global de la base de datos - CloudSEN12	47
Figura 21 Metodología para la obtención de CloudSEN12	48
Figura 22 Interfaz gráfica de usuario de IRIS (Segmentación de Imágenes Reforzada Inteligentemente).....	49
Figura 23 Nombre	50
Figura 24 Distribución espacial de los datos de entrenamientos pertenecientes a DynamicWorld	51
Figura 25 Nombre	52
Figura 26 Arquitectura utilizada para la detección de nubes	55
Figura 27 Arquitectura utilizada para la clasificación de cobertura de suelo	57
Figura 28 Ubicación de las regiones de entrenamiento (gris) y testeo (negro)	58
Figura 29 Ubicación de las imágenes de testeo (puntos en blanco)	59
Figura 30 Modelo de inferencia para la predicción de áreas con nieve/glaciar	61
Figura 31 Modelo propuesto para la estimación del área glaciar	62
Figura 32 Datos de entrenamiento del modelo de detección de nubes	64
Figura 33 Curva de densidad entre la cobertura de nubes estimada a partir del modelo de la ESA y el modelo actual propuesto	65
Figura 34 Gráfico de barras de los valores de PA	65
Figura 35 Gráfico de barras de los valores de UA	66
Figura 36 Comparación del modelo de la ESA con el modelo propuesto en esta investigación (CloudSEN12 + DynamicWorld).....	67
Figura 37 Comparación de la máxima área glaciar considerando los modelos de la ESA y CloudSEN12 + DynamicWorld.....	68
Figura 38 Comparación de la máxima área glaciar considerando los modelos de la ESA y CloudSEN12 + DynamicWorld.....	68
Figura 39 Comparación del área glaciar considerando los modelos de la ESA y CloudSEN12 + DynamicWorld.....	69
Figura 40 Comparación de la ocurrencia entre la Época Húmeda y seca.....	70
Figura 41 Comparación entre el área glaciar y periglaciar	71
Figura 42 Comparación entre la temporada húmeda y seca según el producto de la ESA.....	72
Figura 43 Comparación entre la temporada húmeda y seca según el modelo actual propuesto	73

Figura 44 Comparación entre la area glaciár para el nevado Pucajirca (primera fila) y Mateo (segunda fila).....	74
--	----

Capítulo I.

Introducción

1.1. Introducción

El cambio climático es uno de los desafíos más urgentes que enfrenta la humanidad en el siglo XXI, y sus efectos son especialmente evidentes en los ecosistemas de alta montaña, donde los glaciares juegan un papel crucial en el equilibrio hidrológico y climático. En este contexto, la estimación precisa del área glaciar se convierte en un componente fundamental para comprender y monitorear los cambios en estos sistemas.

En los últimos años, el avance de la inteligencia artificial (IA) ha revolucionado la forma de abordar problemas complejos, permitiendo analizar grandes volúmenes de datos de manera eficiente y precisa. En este sentido, el presente trabajo se centra en la aplicación de técnicas de IA, junto con el uso de cubos de datos, para la estimación del área glaciar en el Parque Nacional Huascarán, ubicado en la región de Ancash, Perú.

El Parque Nacional Huascarán alberga una gran diversidad de ecosistemas, incluyendo extensas áreas glaciares vitales para el suministro de agua dulce en la región. Sin embargo, el retroceso glaciar observado en las últimas décadas genera preocupación sobre la disponibilidad futura de este recurso hídrico y sus impactos en las comunidades locales y los ecosistemas circundantes.

El mapeo y la segmentación precisa de la cubierta terrestre, especialmente en la estimación del área glaciar, son claves para el monitoreo continuo de los glaciares que experimentan un retroceso acelerado frente al cambio climático. La teledetección, mediante distintos métodos y algoritmos, permite cuantificar eficientemente las coberturas glaciares. No obstante, persisten problemas de precisión y capacidad computacional, por lo que se vuelve necesario aplicar algoritmos de inteligencia artificial utilizando una arquitectura que optimice la precisión y automatice los procesos de análisis de cubos de datos de imágenes satelitales.

El objetivo general de la investigación es estimar el área glaciar en el Parque Nacional Huascarán, Ancash, Perú, durante el período 2018-2022 mediante el uso de cubos de datos e inteligencia artificial. Específicamente, se busca confirmar si la arquitectura U-Net ofrece mejoras en la estimación del tamaño de los glaciares en comparación con otros métodos de clasificación convencionales. El presente estudio se desarrolla con herramientas *open source*

para evitar la dependencia de licencias, impulsar la innovación tecnológica, facilitar la accesibilidad y reducir gastos. El uso de estas herramientas permite su aplicación legal y sin costo. (Rius & Gonzalez, 2011)

El resultado esperado es la creación de un modelo adaptado a los Andes para la estimación precisa y automatizada del área glaciar utilizando la arquitectura U-Net de inteligencia artificial. El capítulo 1 se centra en la identificación del problema, el planteamiento de objetivos, la importancia y el alcance. El capítulo 2 aborda los antecedentes internacionales y nacionales sobre investigaciones relacionadas con la inteligencia artificial en glaciares, así como las bases teóricas de las variables dependientes e independientes. En el capítulo 3, se define la hipótesis de que la inteligencia artificial permitirá estimar con precisión el área glaciar, además de definirse las variables de estudio. El capítulo 4 detalla la metodología aplicada al estudio del Parque Nacional Huascarán en Perú, reconocido por su biodiversidad. Se utiliza un enfoque observacional longitudinal con datos satelitales para estimar la cobertura glaciar. Se emplean imágenes de Sentinel-2 y bases de datos como CloudSEN12 y DynamicWorld. Se describe el diseño y entrenamiento de modelos de detección de nubes y cobertura del suelo, utilizando redes neuronales convolucionales como U-Net y FCNN. La metodología combina herramientas estadísticas y técnicas de aprendizaje automático para abordar los desafíos de la detección de cobertura glaciar en un entorno montañoso. El presupuesto, presentado en el capítulo 5, incluye varios rubros: equipos (laptop y disco duro), servicio de internet, papelería y útiles, software y el componente humano (sueldo de investigadores). Se detallan los costos unitarios, la cantidad y el total para cada rubro, determinando un presupuesto total aproximado en soles peruanos. Finalmente, el capítulo 6 presenta un cronograma que detalla las actividades planificadas. Este cronograma indica el inicio de cada actividad, su duración y la cantidad de semanas estimadas para completarlas. Sirve como una herramienta crucial para la organización y gestión del proyecto, permitiendo un seguimiento claro del progreso.

1.2. Planteamiento del problema

En los últimos años, se han propuesto diferentes técnicas para la extracción y mapeo de la cobertura de nieve, así como diversos algoritmos de clasificación y metodologías. Por ejemplo, el índice espectral NDSI permite la estimación de la cobertura de nieve y el mapeo de lagunas de origen glaciar, aunque la diferenciación de estas áreas para distinguirlas de las áreas glaciares puede tomar tiempo (Colque, 2019). Existen metodologías que utilizan índices mejorados para extraer áreas de lagunas, como el Índice Diferencial Normalizado de Nieve sin

información de agua (NDSInw) y el Índice Diferencial Normalizado de Agua sin información de nieve (NDWIns) (Yan et al., 2020). Asimismo, métodos tradicionales de *machine learning* (ML), como Support Vector Machine o Random Forest, se han aplicado con éxito en la clasificación de distintas coberturas de uso del suelo en todo el planeta (Pelletier et al., 2019). Sin embargo, estas propuestas requieren complicadas rutinas de preprocesamiento (*feature engineering*) para tomar en cuenta la información temporal.

Recientemente, algoritmos de *deep learning* (DL), como *temporal convolutional neural network* (Pelletier et al., 2019) y U-Net (Ronneberger et al., 2015), permiten desarrollar clasificadores robustos que extraen características espectrales, temporales y espaciales automáticamente. Los glaciares, de alta reflectividad y variables en el espacio y el tiempo, son ecosistemas ideales para analizar mediante *DL*. Sin embargo, su uso en aplicaciones para el mapeo de áreas glaciares es relativamente nuevo y continúa en desarrollo con nuevas investigaciones.

La gran mayoría de expertos en glaciología a nivel global utiliza el índice espectral NDSI como metodología para la estimación y segmentación de glaciares. Dependiendo de la comunidad, se desarrollan modificaciones del índice para adaptarlo a sus aplicaciones. En Perú, la responsabilidad del monitoreo, estudios e investigación recae en el Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM), que cuenta con un manual metodológico para el inventario nacional de glaciares donde se emplea el índice espectral NDSI. Este índice es ampliamente utilizado para la segmentación de áreas cubiertas de nieve, aunque su aplicación puede presentar confusiones con las lagunas cercanas a los glaciares.

La presente investigación se centra en los glaciares tropicales de la Cordillera Blanca, ubicados en Perú, que han experimentado un rápido deterioro en las últimas décadas debido al cambio climático. Este fenómeno representa una amenaza significativa para los recursos hídricos, la biodiversidad y las comunidades que dependen de los servicios ecosistémicos que proveen los glaciares. Se vuelve necesario utilizar nuevas tecnologías para obtener estimaciones precisas; en este caso, se aplicarán algoritmos de *DL* utilizando la arquitectura U-Net (Francou et al., 2004).

La investigación surge de la necesidad de desarrollar un método preciso y automatizado para estimar el área glaciario en la región de los Andes, motivada por las dificultades inherentes a las estimaciones manuales y la importancia de monitorear los cambios en los glaciares debido

al cambio climático. El avance en técnicas de inteligencia artificial y la creciente disponibilidad de datos satelitales ofrecen una oportunidad para abordar este desafío de manera más efectiva. El objetivo principal es la creación de un modelo basado en inteligencia artificial que pueda estimar con precisión y frecuencia el área glaciar en los Andes. Este modelo tendría diversos impactos positivos, incluyendo una mejor comprensión de la dinámica glaciar en la región, la capacidad de monitorear los efectos del cambio climático de manera más precisa y oportuna, y la provisión de información valiosa para la toma de decisiones en la gestión de recursos naturales y la planificación del desarrollo.

El método propuesto para la estimación del área glaciar se fundamenta en la utilización de la arquitectura U-Net de inteligencia artificial. Esta arquitectura, diseñada específicamente para tareas de segmentación de imágenes, permite identificar y delinear con precisión las áreas de interés en las imágenes satelitales, en este caso, el área cubierta por los glaciares. Al combinar esta técnica con datos satelitales de alta resolución y un enfoque observacional longitudinal, se espera obtener estimaciones más precisas y frecuentes del área glaciar en los Andes. Este enfoque no solo ofrece una solución automatizada y eficiente, sino que también aprovecha el potencial de la inteligencia artificial para mejorar la calidad de los resultados y la capacidad de monitoreo de los glaciares en la región.

1.3. Formulación del problema

1.3.1. Pregunta general

- ¿Es posible estimar el área glaciar en el Parque Nacional Huascarán utilizando inteligencia artificial y cubos de datos?

1.3.2. Preguntas específicas

- ¿Resulta viable alcanzar una mayor precisión en la estimación de áreas glaciares mediante el empleo de la arquitectura U-net, en contraposición a los métodos de clasificación tradicionales?
- ¿Es posible desarrollar un método preciso de estimación de la cobertura glaciar que nos permita obtener resultados automáticos de forma frecuente?
- ¿Es posible entrenar una red neuronal para que sea capaz de distinguir con precisión entre glaciar, nubes y sombras de nubes en el contexto específico de los Andes?

1.4. Objetivos de la investigación

1.4.1. Objetivo general

- Estimar el área glaciar en el Parque Nacional Huascarán, Ancash – Perú, durante el período 2018-2022 mediante el uso de cubos de datos e inteligencia artificial.

1.4.2. Objetivos específicos

- Determinar si es viable mejorar la precisión en la estimación de áreas glaciares empleando la arquitectura U-net en contraposición a los métodos de clasificación tradicionales.
- Desarrollar un método preciso de estimación de la cobertura glaciar que permita obtener resultados automáticos de forma frecuente.
- Determinar si es posible entrenar una red neuronal que sea capaz de distinguir con precisión entre glaciar, nubes y sombras de nubes en el contexto específico de los Andes.

1.5. Justificación de la investigación

La relevancia de la investigación radica en la aplicación de un algoritmo de IA como alternativa para el mapeo y segmentación de la cobertura glaciar. Los métodos tradicionales de estimación, como el NDSI, presentan limitaciones en la precisión de detección de cobertura glaciar, ya que emplean un umbral predefinido para clasificar los píxeles como "nieve" o "no nieve", lo que puede resultar en errores de cuantificación al digitalizar manualmente lagunas de origen glaciar y sombras.

El estudio tiene como objetivo principal determinar la extensión de la cobertura glaciar durante el período 2018-2022 en tiempo real, permitiendo así un monitoreo continuo de los glaciares tropicales en la zona sur del Parque Nacional Huascarán. Los resultados obtenidos facilitarán la gestión sostenible de los recursos hídricos en toda la cuenca hidrográfica del Río Santa.

Además, se proporcionará información crucial a diversas instituciones de investigación sobre el estado de los glaciares de la Cordillera Blanca, lo que permitirá llevar a cabo un inventario glaciar más preciso y detallado. Esto se logra mediante el empleo de una arquitectura

innovadora de aprendizaje automático, que destaca por su alta precisión y menor costo en comparación con otras técnicas o métodos disponibles.

1.6. Limitaciones en la investigación

Una limitación significativa se relaciona con la dependencia de la calidad y disponibilidad de los datos satelitales de Sentinel-2. La selección de las imágenes está restringida por la resolución espacial y la calidad de los datos, lo cual puede afectar la precisión de las estimaciones de cobertura glaciar debido a la variabilidad de las condiciones atmosféricas.

Además, los métodos tradicionales de clasificación, como el índice espectral NDSI, han mostrado limitaciones en la precisión de detección de cobertura glaciar debido a la necesidad de emplear umbrales predefinidos y la digitalización manual de ciertos errores. Aunque se pretende mitigar estas limitaciones mediante el uso de algoritmos de inteligencia artificial como U-Net y redes neuronales convolucionales, es importante reconocer que estos enfoques también pueden presentar restricciones propias. Por ejemplo, la efectividad de estos algoritmos puede estar condicionada por la calidad y diversidad del conjunto de entrenamiento, así como por la complejidad de las características espectrales, temporales y espaciales capturadas.

En la investigación que emplea cubos de datos e inteligencia artificial para la teledetección, se enfrentan limitaciones significativas. Primero, la calidad de los análisis depende fuertemente de la calidad y exactitud de los datos de entrada; errores menores en los datos pueden inducir errores en los resultados. Además, los modelos de inteligencia artificial pueden no manejar bien datos que divergen de los entrenamientos previos, lo que es especialmente problemático en el contexto de un cambio climático que modifica constantemente las condiciones ambientales. La complejidad computacional y los requerimientos de almacenamiento para operar estos modelos también suponen desafíos en términos de costos y accesibilidad, limitando su uso en instituciones con recursos limitados. Finalmente, las técnicas utilizadas pueden no capturar completamente los efectos dinámicos y rápidamente cambiantes del cambio climático, lo que podría afectar la precisión y aplicabilidad de los resultados de la investigación.

Capítulo II.

Marco teórico y conceptual

2.1. Antecedentes de la investigación

2.1.1. Antecedentes internacionales

La investigación de Prashant (2022) tuvo como objetivo mapear la extensión de los glaciares de Jostedalsbreen y Svalbard, Noruega, utilizando datos satelitales de código abierto Sentinel-1 y Sentinel-2 mediante un método de fusión de datos basado en *deep learning* (DL). Se investigó la secuencia de combinaciones de bandas de datos ópticos y SAR en redes totalmente convolucionales prediseñadas (FCN-DK-6, SegNet, UNet y ResUNet) para delinear con precisión la extensión de los glaciares. La precisión de UNet fue la más consistente y arrojó una puntuación F1 más alta. El rendimiento del modelo basado en Sentinel-2 fue superior al del modelo basado en Sentinel-1. En el experimento de 12 bandas, se observó que el mismo modelo U-Net (utilizado para el experimento de 4 bandas) aumentó la precisión en un 2%, logrando un valor F1 de 0,90. En el experimento, Prashant fusionó los conjuntos de datos Sentinel-1 y Sentinel-2. El modelo con un método independiente arrojó mejores resultados con la fusión de datos. Por ejemplo, FCN-DK con el experimento de 3 bandas Sentinel-1 obtuvo una puntuación F1 de 0,73, y el experimento de 4 bandas Sentinel-2 obtuvo 0,83. Al fusionar los mismos tres canales derivados de la polarización VV y VH de Sentinel-1 y las cuatro bandas de Sentinel-2, realizando un experimento de fusión de 7 bandas, se logró una puntuación F1 de 0,88. Esta investigación concluyó que UNet es un modelo robusto para mapear con precisión la extensión de los glaciares y puede contribuir a la creación y actualización de bases de datos sobre glaciares.

La investigación de Aryal (2022) se enfocó en abordar los desafíos relacionados con la segmentación de glaciares utilizando ML, mejorar el rendimiento de los métodos existentes mediante técnicas de DL y comprender el funcionamiento de estos modelos. En este estudio, se emplearon diversas técnicas de ML y DL para segmentar glaciares a partir de imágenes Landsat-7, destacando la eficacia del modelo U-Net. Aunque aplicables a glaciares alpinos en general, se evaluó su desempeño en el Hindu Kush Himalayas (HKH), una región vulnerable al cambio climático. La segmentación del hielo glaciar limpio (CIG) resultó más sencilla que la del hielo glaciar con escombros (DGI). Se introdujo una pérdida de autoaprendizaje consciente de bordes (LSLBA) para mejorar la precisión en la segmentación de DGI. Además, se propusieron puntajes de saliencia por características para una mejor comprensión del modelo.

Se abordó la limitación del etiquetado intensivo con datos esparcidos. Estos métodos tienen aplicaciones más amplias en la segmentación de características geomorfológicas y resultan relevantes para abordar desafíos globales como el cambio climático y la influencia humana en los ecosistemas.

2.1.2. Antecedentes nacionales

En 2014, se llevó a cabo una investigación con el propósito de analizar el cambio en el área de los glaciares en la Cordillera Blanca, Perú, durante el período comprendido entre 1987 y 2010, utilizando imágenes Landsat corregidas atmosféricamente. El estudio incluyó la evaluación de los efectos atmosféricos y las correcciones topográficas mediante la comparación de estimaciones de áreas glaciares libres de escombros generadas a partir de escenas sin procesar y escenas corregidas. Se empleó el Índice de Nieve de Diferencia Normalizada (NDSI) con un umbral comúnmente utilizado en la literatura (0,35 a 0,55). Para determinar el área total del glaciar, se realizó el mapeo manual de los glaciares cubiertos de escombros, dado que los métodos automatizados no resultaron efectivos en esta región. Para agosto de 2010, se estimó que la Cordillera Blanca contaba con un área total de glaciares de 482 km², lo que representó una disminución del 25 % desde 1987. Además, se observó que entre 2004 y 2010, los glaciares de esta cordillera perdieron área a una velocidad aproximadamente 3,5 veces mayor que la tasa promedio de pérdida de área registrada entre 1970 y 2003 (Burns & Nolin, 2014).

En el artículo de Mohajerani et al. (2019), se llevó a cabo una investigación acerca de la detección de los márgenes de desprendimiento de glaciares utilizando redes neuronales convolucionales. En este estudio, se desarrolló un conjunto de herramientas de aprendizaje automático con el fin de identificar automáticamente los márgenes de desprendimiento de los glaciares a partir de imágenes satelitales. Se emplearon redes neuronales convolucionales (CNN) con una arquitectura U-Net modificada para la segmentación semántica, entrenadas con un conjunto de datos de imágenes satelitales para extraer los frentes de desprendimiento de los glaciares. La capacidad de la red neuronal para detectar los desprendimientos en nuevas imágenes se evaluó mediante una desviación media de 96.3 metros con respecto a los desprendimientos reales, equivalente a una media de 1.97 píxeles. En comparación, el error asociado a los desprendimientos identificados manualmente en imágenes de la misma resolución fue de 92.5 metros en desviación media, lo que equivale a 1.89 píxeles en promedio. En conclusión, se encontró que la red neuronal supera de manera significativa a las técnicas

convencionales de detección y puede ser empleada para cartografiar los frentes de desprendimiento de hielo en bloques glaciares.

Colque (2019), realizó una investigación centrada en la estimación del área glaciar en el nevado Ausangate, ubicado en las provincias de Canchis y Quispicanchis, en el departamento de Cuzco, Perú. Se señala que la estimación convencional del área glaciar se realiza típicamente utilizando el Índice de Nieve de Diferencia Normalizada (NDSI) con un umbral estándar establecido de 0.4. Sin embargo, se reconoce que este método tiende a sobreestimar el área glaciar y requiere un proceso manual para eliminar áreas no glaciares, como las lagunas periféricas, lo cual puede ser lento y propenso a errores. La investigación propone una solución basada en la arquitectura U-Net de redes neuronales convolucionales (CNN) como metodología para estimar áreas glaciares. Para entrenar y validar los algoritmos de inteligencia artificial, se optó por utilizar la infraestructura de Google Earth Engine (GEE) para recopilar datos de imágenes de los satélites Sentinel 2A y 2B. En total, se recolectaron 1883 muestras para el entrenamiento y 1470 para la validación, centrándose en glaciares tropicales del Perú. Se seleccionaron 12 escenas de prueba, fuera del periodo de entrenamiento y que abarcaban desde 2016 hasta 2019, específicamente en el glaciar Ausangate, para evaluar el desempeño del modelo. Los resultados indicaron que el modelo U-Net logró una precisión del 97.89% en el conjunto de entrenamiento y del 97.88% en el conjunto de validación. Estos hallazgos demuestran que el uso de la arquitectura U-Net resulta en una estimación más precisa del área glaciar y reduce la probabilidad de sobreestimar o confundir lagunas glaciares, en comparación con el método tradicional basado en el NDSI con un umbral de 0.4. Además, se destacó la aplicabilidad de este enfoque para mapear áreas glaciares en general, lo que lo hace útil en el contexto de otros glaciares.

La investigación realizada por Leon (2022) tuvo como objetivo analizar el impacto de la precipitación y la temperatura en el cambio de masa glaciar en la Cordillera Blanca durante el período 1962-2020. El estudio se enfocó en las unidades hidrográficas de Llullán, Quillcay y Yanayacu, utilizando el Índice de Nieve de Diferencia Normalizada (NDSI) en imágenes de satélite Landsat (5TM y 8 OLI) para delimitar el área glaciar. Se aplicó una metodología geodésica con Modelos Digitales del Terreno (DEM) de SRTM y ASTER para estimar el balance de masa entre 2000 y 2020, abarcando toda la Cordillera Blanca. Para el glaciar Gueshgue (unidad Yanayacu), se reconstruyó el DEM con imágenes aéreas de 1962 e imágenes RPAS de 2020, utilizando fotogrametría. Los resultados evidencian un claro retroceso glaciar

desde 1962 hasta 2020 en las unidades hidrográficas de Llullán, Quillcay y Yanayacu, con reducciones en el área de 12.164 km² (64%), 17.238 km² (63%) y 11.391 km² (32%), respectivamente. De manera similar, la Cordillera Blanca experimentó una pérdida total de 327.056 km² (56%) en el mismo intervalo temporal. Entre 2000 y 2020, los valores de balance de masa glaciar en las unidades hidrográficas fueron de -1.086 ± 0.035 m w.e.a⁻¹, 0.52 ± 0.029 m w.e.a⁻¹ y -0.532 ± 0.007 m w.e.a⁻¹, respectivamente. La Cordillera Blanca presentó un balance de masa promedio de -0.60 ± 0.058 m w.e.a⁻¹. En un análisis específico, el glaciar Gueshgue, perteneciente a la unidad hidrográfica Yanayacu, exhibió un balance de masa de -1.949 m w.e.a⁻¹ durante el período 1962-2020.

2.2. Bases teóricas

2.2.1. Teledetección y sus características

Se trata de un método o enfoque para obtener información sin la necesidad de establecer contacto directo con el objeto de estudio. Asimismo, se puede definir como una técnica cuyo propósito principal es la obtención, procesamiento y evaluación de imágenes capturadas por satélites artificiales en órbita (Pérez & Muñoz, 2006).

La Teledetección o Percepción Remota implica obtener información sobre un objeto o sistema desde lejos, es decir, sin tener contacto físico directo con el objeto observado. Los sensores de los satélites recopilan información sobre un objeto mediante la energía electromagnética. Esta información puede estar codificada en la frecuencia, intensidad o polarización de las ondas y se transmite directamente desde el objeto o de manera indirecta a través de reflexiones, dispersión o reemisiones hasta llegar al sensor. Todos los elementos presentes en la Tierra tienen interacciones con la energía electromagnética de alguna manera. Los sensores evalúan la intensidad de esta radiación emitida por un objeto y analizan sus características físicas según cómo varíe con la frecuencia. Para poder realizar la observación remota de un sistema, es esencial que el sensor detecte el flujo magnético proveniente de dicho sistema. De ahí la introducción de conceptos como flujo radiante, densidad de flujo radiante y la intensidad radiante, que son términos comúnmente utilizados en física para describir el campo radiativo (Sobrino, 2001).

La Teledetección o Percepción Remota se refiere a la metodología utilizada para adquirir datos geoespaciales de la superficie terrestre. Esto se logra a través de la interacción energética entre la Tierra y un sensor espacial satelital que mide los niveles de reflectancia


terrestre (Chuvieco, 2010). En el ámbito de la teledetección, los sensores se dividen en dos categorías principales: pasivos y activos.

- Los sensores pasivos: Operan recogiendo la energía distribuida naturalmente en el entorno, principalmente emitida por el sol. Estos dispositivos son capaces de identificar diferentes tipos de reflectancia, incluyendo luz visible, emisión infrarroja y térmica, así como ciertas bandas de microondas. Generan imágenes en una variedad de formatos como pancromáticas, RGB, infrarrojas, hiperespectrales y multiespectrales (Chang & Bai, 2018). Algunos de los ejemplos más destacados de misiones que utilizan sensores pasivos incluyen imágenes de satélites como Landsat y Sentinel, así como CBRS-4, entre otros.
- Los sensores activos: Se distinguen por emitir su propia energía hacia la superficie terrestre y luego capturar y medir la radiación reflejada por los elementos del terreno. Estos pueden incluir tecnologías como radar, láser o LiDAR (Detección y Medición de Luz o Detección de Imágenes y Medición de Luz por sus siglas en inglés) (Chang & Bai, 2018).

Los componentes esenciales en el proceso de teledetección incluyen la fuente de energía, que origina las radiaciones electromagnéticas; la cubierta terrestre, que se refiere al territorio bajo análisis; el sistema sensor, un equipo especial encargado de recopilar datos espaciales; el sistema de recepción, que es el elemento receptor situado en la Tierra; y, finalmente, el intérprete, que engloba los elementos o procesos encargados de convertir los datos en información con aplicaciones específicas y utilidad práctica.

Figura 1

Elementos del Proceso Pasivo de Teledetección: Diagrama de flujo desde la captación de datos hasta el usuario final



Fuente: Chuvieco (1990)

La teledetección es un área de investigación centrada en obtener datos sobre la superficie de la Tierra mediante la medición de las respuestas que surgen de las interacciones entre la radiación electromagnética y los materiales presentes en la Tierra (Meneses & Almeida, 2012). Según una definición más convencional, se entiende como un método que posibilita la captura de imágenes de la superficie terrestre a través de sensores colocados en plataformas espaciales, lo cual involucra una interacción energética entre la Tierra y el sensor (Martín & Chuvieco, 1995).

2.2.2. Energía Electromagnética

La energía electromagnética (EM) se propaga a través de ondas que componen un extenso espectro, que va desde las ondas de radio de gran longitud hasta los rayos gamma de longitud extremadamente corta. De todo este espectro, solo una fracción, conocida como luz visible, es perceptible al ojo humano (National Aeronautics and Space Administration, 2010). En cuanto a su naturaleza, puede manifestarse tanto como onda como en forma de energía radiante, compuesta por partículas denominadas fotones (Tempfli et al., 2009).

La energía electromagnética se mueve por el espacio mediante oscilaciones regulares de los campos eléctricos y magnéticos. Estas oscilaciones ocurren de manera simultánea en planos mutuamente perpendiculares y en la dirección de propagación a través del espacio, a una

velocidad constante igual a la velocidad de la luz ($c \approx 2.99792458 \times 10^8$ m/s) (Camps-Valls et al., 2012).

2.2.3. Espectro electromagnético

El espectro electromagnético consiste en la totalidad de ondas electromagnéticas organizadas de acuerdo a su frecuencia o longitud de onda (Camps-Valls et al., 2012).

$$c = \lambda * \nu$$


Donde:

- c = Velocidad de la luz. (m/s)
- λ = Longitud de onda (m)
- ν = Frecuencia (Hz)

Las distintas secciones del espectro electromagnético se clasifican en función de la longitud de onda. En un extremo se encuentran los rayos gamma, con longitudes de onda muy cortas, aproximadamente de 10^{-6} micrómetros. En el otro extremo, están las ondas de radio, cuyas longitudes de onda son considerablemente más largas, extendiéndose hasta varios kilómetros (Camps-Valls et al., 2012).

Figura 2

Espectro Electromagnético: Rango de longitudes de onda desde rayos gamma hasta ondas de radio



Fuente: Camps-Valls et al. (2012)

La luz visible, conocida como VIS, comprende longitudes de onda que se extienden desde 400 hasta 700 nanómetros, abarcando desde el azul hasta el rojo. Esta franja específica del espectro constituye la totalidad de la energía electromagnética detectable por el ojo humano. Más allá del extremo rojo del rango visible (VIS), se encuentra la zona de energía infrarroja (IR), que engloba el infrarrojo cercano (NIR), el infrarrojo de onda corta (SWIR), el infrarrojo medio (MIR) y la energía térmica, también conocida como infrarrojo térmico (TIR) (Camps-Valls et al., 2012). Las áreas que van desde la luz visible (VIS) hasta el infrarrojo de onda corta (SWIR) son frecuentemente utilizadas en la observación remota óptica, ya que se basan en la luz solar para la iluminación, con longitudes de onda comúnmente utilizadas que van desde 400 nanómetros hasta 3000 nanómetros (Camps-Valls et al., 2012).

2.2.4. Resolución De Imágenes

- **Resolución espacial** se refiere al tamaño mínimo de un objeto que puede ser identificado en una imagen (Meneses & Almeida, 2012). Por lo general, se define como el ángulo máximo en el que un sensor puede detectar de manera efectiva la energía electromagnética, y se expresa como el campo de visión instantáneo (Camps-Valls et al., 2012).
- **La resolución espectral** se relaciona con la cantidad de bandas de un sensor, las longitudes de onda de esas bandas y sus ubicaciones en la firma electromagnética (Meneses & Almeida, 2012). Una alta resolución espectral proporciona una firma espectral más precisa (Camps-Valls et al., 2012).
- **La resolución radiométrica** se refiere a las variaciones en la radiación espectral recibida (Martín & Chuvieco, 1995) y está determinada por la cantidad de niveles en los que la señal de radiación puede ser dividida (Camps-Valls et al., 2012). Una mayor capacidad de resolución radiométrica conduce a una interpretación más detallada de la imagen (Martín & Chuvieco, 1995).
- **La resolución temporal** se refiere a la frecuencia con la que un sensor revisita una región y toma imágenes periódicamente a lo largo de su vida útil (Meneses & Almeida, 2012).

2.2.5. Inteligencia artificial


La inteligencia artificial (IA) se define como la capacidad demostrada por una entidad artificial para resolver problemas complicados; esta entidad suele ser una computadora o una máquina (Luger, 2009). La IA intenta abordar problemas complicados de una manera similar a la humana y en un tiempo considerablemente menor que el requerido por una persona (Kumar & Thakur, 2012).

En otros términos, la IA se refiere al campo de la computación diseñado para crear sistemas capaces de resolver problemas y tareas que demanden inteligencia humana (Jakhar & Kaur, 2020). Estos sistemas tienen la capacidad de analizar y entender información proveniente del exterior de manera precisa, aprender de dicha información y aplicar esos conocimientos para alcanzar objetivos y llevar a cabo tareas específicas mediante una adaptación flexible (Kaplan & Haenlein, 2019).

En el ámbito de la IA, las máquinas ejecutan tareas según reglas y algoritmos específicos. La IA es un término general que abarca cualquier programa de computadora con capacidad de inteligencia humana, lo que incluye tanto el aprendizaje automático (*Machine Learning*) como el aprendizaje profundo (*Deep Learning*). (Jakhar & Kaur, 2020)

Figura 3

Jerarquía de la Inteligencia Artificial. Representación de IA, aprendizaje automático y aprendizaje profundo como subconjuntos



Fuente: Jakhar & Kaur (2020)

2.2.6. Machine Learning (ML)

Machine Learning (ML) o aprendizaje automático se refiere a las técnicas que otorgan a las computadoras la capacidad de aprender automáticamente a partir de la experiencia sin necesidad de ser programadas explícitamente por los seres humanos (Samuel, 1967). Este proceso implica el estudio de algoritmos que aprenden y mejoran mediante la experiencia, siendo un concepto fundamental dentro del ámbito de la IA (Visvikis et al., 2019).


El ML es considerado un subconjunto de la IA que incorpora el aprendizaje experimental asociado con la capacidad e inteligencia humanas, mientras que también puede aprender y mejorar sus análisis mediante el uso de algoritmos computacionales. Estos algoritmos utilizan una gran cantidad de datos de entrada y salida para identificar patrones y aprender de manera precisa, permitiendo que la máquina, una vez entrenada, realice recomendaciones o tome decisiones autónomas. Después de suficientes iteraciones y ajustes al algoritmo, se puede introducir una entrada y prever una salida (Bini, 2018).

2.2.7. Tipos de aprendizaje automático

ML se clasifica ampliamente en cuatro clases principales de algoritmos como muestra en la Figura 4: a) aprendizaje supervisado (*supervised learning*), b) aprendizaje no supervisado (*unsupervised learning*), c) aprendizaje semi-supervisado (*semi-supervised learning*) y d) aprendizaje reforzado (*reinforcement learning*). (Alpaydin, 2016)

Figura 4

Principales algoritmos y Aplicaciones de ML: Categorías y ejemplos de uso



Fuente: Mellit & Kalogirou (2021)

El aprendizaje supervisado se refiere a algoritmos de aprendizaje que adquieren la capacidad de establecer asociaciones entre ciertas entradas y salidas, utilizando un conjunto de ejemplos que consta de entradas (x) y salidas (y). En muchos casos, la obtención de estos resultados puede ser una tarea compleja de automatizar y, por lo tanto, debe ser suministrada por un "supervisor" humano (Goodfellow et al., 2016).

Por otro lado, el aprendizaje no supervisado se aplica a algoritmos que se centran en la exploración de las características de los datos, pero no requieren una señal de supervisión o indicación específica. Este tipo de aprendizaje se emplea principalmente en situaciones en las que se busca extraer información de una distribución de datos sin necesidad de intervención humana directa (Goodfellow et al., 2016).


2.2.8. Deep Learning

El Deep Learning (DL) o aprendizaje profundo, constituye un subconjunto de Machine Learning (ML) donde un modelo, implementando un algoritmo y utilizando una arquitectura, aprende a realizar tareas de clasificación a partir de sonido, texto o imágenes. Por lo general, se aplica mediante la utilización de una arquitectura de red neuronal. El término "profundo" se refiere a la cantidad de capas en la red; esta es más profunda cuanto más capas tiene. Mientras que las redes neuronales convencionales suelen tener 2 o 3 capas, las redes neuronales profundas están compuestas por cientos de capas. (Mathworks, 2018)

Los principales métodos de aprendizaje profundo incluyen las redes neuronales convolucionales, la memoria a corto plazo, las redes de creencias profundas, las redes antagónicas generativas, las combinaciones híbridas convolucionales profundas y otras (LeCun et al., 2015). Como se observa en la Figura 5, una ventaja clave de las redes de aprendizaje profundo es que a menudo continúan mejorando a medida que aumenta el tamaño de los datos (Najafabadi et al., 2015).

Figura 5

Rendimiento de Deep Learning vs Machine Learning: Curvas que muestran mejora en rendimiento con más datos



Fuente: Alpaydin (2016)

2.2.9. Deep Learning en Teledetección

DL ha demostrado ser extremadamente efectivo cuando existe una relación entre las dimensiones de los datos, como texto, audio o imágenes. Las aplicaciones a la teledetección se realizan por dos principales arquitecturas, las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN). (Pelletier et al., 2019)

2.2.10. Redes Neuronales Recurrentes

Redes Neuronales Recurrentes o Recurrent Neural Networks (RNNs) constituyen un tipo de arquitectura de DL que está intrínsecamente diseñada para datos secuenciales como voz y texto. En estas redes, la información se transmite mediante un bucle (Sun et al., 2019). Se ha demostrado que las RNNs poseen un potencial considerable, superando a algoritmos tradicionales como Random Forest (RF) o Support Vector Machines (SVM), especialmente en estudios de casos que involucran áreas pequeñas y en series de tiempo cortas (con menos de 100,000 instancias de entrenamiento) (Pelletier et al., 2019).

2.2.11. Redes Neuronales Convolucionales

2.2.11.1. Redes Neuronales Artificiales


Las redes neuronales convolucionales (CNN) han sido ampliamente aplicadas en diversas tareas de visión artificial y lideran el estado del arte para algunas tareas de detección remota, como la clasificación de imágenes hiperespectrales. A pesar de su éxito, recientemente

se han investigado en la clasificación de series temporales (Rawat & Wang, 2017). La particularidad de estas redes radica en su capacidad para aplicar convoluciones en el dominio temporal en lugar del dominio espacial (Pelletier et al., 2019).

El término "red neuronal" hace referencia a la neurobiología, y algunos principios fundamentales en el campo del aprendizaje profundo se han desarrollado a partir de la inspiración en nuestra comprensión del funcionamiento del cerebro. Sin embargo, es importante destacar que los modelos de aprendizaje profundo no son representaciones exactas del cerebro humano. No existen pruebas que indiquen que el cerebro utilice mecanismos de aprendizaje similares a los empleados en los modelos actuales de aprendizaje profundo (Chollet, 2021).

Figura 6

Arquitectura de Red Neuronal Profunda: Muestra red con capas de entrada, ocultas y de salida



Fuente: Nielsen (2015)

- **Capa de entrada o Input Layer:** Se define comúnmente como los datos de entrada sin procesar, que, en el caso de imágenes, pueden consistir en los valores de píxeles correspondientes a varios canales de color. Además, tiene la capacidad de manejar datos de entrada con diferentes dimensiones y estructuras, como un arreglo unidimensional o una estructura similar a un tensor (Bhardwaj et al., 2018).
- **Capa de salida o Output Layer:** Esta capa representa el valor de salida generado por la red, y su configuración se adapta a la naturaleza específica del problema en cuestión (Bhardwaj et al., 2018).

- **Capas ocultas o Hidden Layers:** Estas capas se sitúan entre las capas de entrada y salida. Las neuronas en las capas ocultas pueden tener diferentes configuraciones, como capas de *pooling*, capas convolucionales, y más, cada una con funcionalidades matemáticas específicas (Bhardwaj et al., 2018).

2.2.11.2. Función de Activación

La función de activación de cada neurona artificial cumple la función de determinar si las señales de entrada han alcanzado el nivel umbral requerido para enviar señales hacia la siguiente etapa del proceso.

- **La Función Sigmoide:** También conocida como función logística, se caracteriza por su forma en "S" y su rango se encuentra en el intervalo de valores entre 0 y 1. Su representación matemática es la siguiente: (Bhardwaj et al., 2018).

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

La expresión matemática de su primera derivada, que desempeña un papel en el proceso de retropropagación durante la fase de entrenamiento, es la siguiente:

$$\frac{d\sigma(x)}{d(x)} = \sigma(x) \cdot (1 - \sigma(x))$$

- **Función Tangente Hiperbólico (Tanh):** Produce una salida en un rango centrado de -1 a 1. La expresión matemática es la siguiente:

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$$

- **La Unidad Lineal Rectificada (ReLU):** Es ampliamente utilizada y ha ganado popularidad en años recientes. Su expresión matemática es la siguiente:

$$\sigma(x) = \begin{cases} \max(0, x) & , x \geq 0 \\ 0 & , x < 0 \end{cases}$$


2.2.12. Arquitectura U-Net

El proceso de entrenamiento de una red U-Net requiere el uso de imágenes junto con sus respectivos mapas de segmentación, que se emplean en la capacitación de la red mediante la aplicación del descenso del gradiente estocástico. La arquitectura de U-Net se divide en tres

partes: la fase de contracción, el cuello de botella y la fase de expansión. La Figura 7 muestra la estructura original de U-Net empleada para la segmentación de imágenes médicas. (Ronneberger et al., 2015).

Figura 7

Arquitectura U-Net para Segmentación de Imágenes: Diagrama de flujo de las fases de contracción y expansión



Fuente: Ronneberger et al. (2015)


2.2.13. Cubo de Datos

Un cubo es una estructura de datos multidimensional diseñada para capturar y analizar información, extendiendo la capacidad de las hojas de cálculo tabulares al permitir múltiples dimensiones en lugar de limitarse a dos. Estas dimensiones pueden incluir jerarquías y fórmulas integradas que no requieren duplicación de definiciones (Jensen et al., 2010). Aunque el término "cubo" implica la existencia de tres dimensiones, en realidad puede variar desde unidimensional hasta dimensiones superiores, adoptando el término "hipercubo" para describir estructuras de mayor dimensionalidad. En el contexto de la cobertura geoespacial, un cubo de datos utiliza un sistema de cuadrícula específico, caracterizado por tener dimensiones definidas espacial o temporalmente, lo que es fundamental para el manejo y análisis de datos en ámbitos geoespaciales o temporales. (OGC, 2020)

En el campo de la teledetección y el análisis de datos geospaciales, el término "cubo de datos" o Data Cube (DC) se utiliza para referirse a una estructura multidimensional que organiza y almacena datos espaciales y/o temporales de manera regular e irregular. Es importante destacar que, al igual que el concepto de "Big Data", la definición de un cubo de datos puede variar dependiendo del contexto en el que se emplee (Strobl et al., 2017). Además, para abordar los desafíos de Big Data, como el volumen, la variedad y la velocidad, el concepto Data Cube ha surgido como una solución para reducir barreras y ofrecer nuevas posibilidades para aprovechar Big Data con bajo costo y esfuerzo (Giuliani et al., 2017).

Figura 8

a) Ejemplos de mallas regulares e irregulares, b) Recorte de cubo de datos (izquierda) y segmentación (derecha)




Fuente: OGC (2020)

El término "cubo de datos" se originó en el contexto de procesamiento analítico en línea o Online Analytical Processing (OLAP), donde representaba una matriz multidimensional junto con metadatos que describen la semántica de ejes, coordenadas y celdas. Sin embargo, en el ámbito geoespacial, los cubos de datos adquieren una dimensión adicional al integrar datos espaciales y/o temporales. Esta evolución del concepto se refleja en el Manifiesto Datacube, que aboga por una visión holística del sistema de cubos de datos geospaciales o Geospatial Data Cube (GDC), enfatizando la importancia de la conciencia sobre todos los aspectos necesarios de dicha infraestructura (Strobl et al., 2017). Los cubos de datos representan un nuevo paradigma con el objetivo de aprovechar todo el potencial de los datos de la cubierta terrestre, reduciendo las barreras causadas por los desafíos del Big Data y brindando acceso a grandes datos espacio-temporales en una forma lista para el análisis (Giuliani et al., 2017).

Figura 9

El concepto de cubo de datos AGDC



Nota. Las escenas Landsat se reformatean como mosaicos de datos espacialmente consistentes. La huella espacial de las escenas Landsat cambia con el tiempo, mientras que los conjuntos de datos en mosaico mantienen una huella constante. El área que se muestra es la isla Brooks en el lago Eyre, Australia central, en 2009.

Fuente: Lewis et al. (2016)

2.2.13.1. Implementación de Cubos de Datos en Teledetección

La teledetección es una técnica fundamental para la observación de la Tierra que genera grandes volúmenes de datos espaciales y temporales. La implementación de cubos de datos en teledetección ha surgido como una solución robusta para gestionar, procesar y analizar eficientemente los grandes volúmenes de datos espaciales y temporales generados en la observación de la Tierra. Estos cubos de datos son representaciones multidimensionales que integran variables como el tiempo y diferentes bandas espectrales en un sistema organizado único. Su uso facilita la manipulación y el análisis de datos complejos, permitiendo a los investigadores acceder a información procesada y lista para el análisis de manera más eficaz y eficiente. Este enfoque no solo mejora la capacidad de manejar grandes volúmenes de datos, sino que también optimiza la extracción de valor de las vastas cantidades de información recopilada por los sensores remotos (Xu et al., 2020).

2.2.13.1.1. Componentes de un cubo de datos

La implementación efectiva de un cubo de datos en teledetección requiere varios componentes clave que permiten su funcionalidad óptima:


- **Recopilación de datos:** Se debe comenzar recolectando y almacenando datos de múltiples sensores satelitales, necesitando estandarización y preprocesamiento significativos para asegurar la calidad y usabilidad de los datos. Esta fase incluye asegurar el acceso a imágenes de múltiples fuentes satelitales, en diferentes bandas espectrales y resoluciones temporales (Haut et al., 2021).
- **Preprocesamiento de Datos:** Antes de integrar los datos en un cubo, es crucial realizar un preprocesamiento que puede incluir la corrección geométrica y la corrección atmosférica. Estos pasos son esenciales para garantizar que las imágenes de diferentes fechas y sensores sean comparables y estén alineadas espacialmente (Haut et al., 2021). Además, muchos datos geoespaciales de agencias tecnológicas ofrecen sus productos corregidos, como el conjunto de datos de Google Earth Engine.
- **Diseño del Cubo de Datos:** Definir la estructura del cubo de datos especificando los ejes que incluirán dimensiones como el tiempo, el espacio (coordenadas x, y), y características espectrales o de otro tipo como bandas de infrarrojo o índices de vegetación (Sabri et al., 2021).
- **Normalización de coordenadas:** Homologar el sistema de coordenadas dentro del cubo para asegurar que todos los datos puedan ser accedidos y comparados uniformemente. Esto puede incluir la interpolación espacial y temporal para llenar los vacíos de datos y asegurar continuidad (Popovich & Galiano, 2018).
- **Integración de Datos:** Integrar las imágenes y datos procesados en la estructura del cubo de datos. Este paso implica mapear cada conjunto de datos a su respectiva ubicación en el cubo según sus coordenadas espaciales y temporales (Rathore et al., 2015).
- **Almacenamiento y acceso:** Los sistemas de almacenamiento deben ser capaces de manejar grandes volúmenes de datos y permitir un acceso rápido y eficiente. Las bases de datos no convencionales, como las orientadas a objetos o las columnares, son frecuentemente utilizadas en este contexto. Implementar herramientas analíticas que

puedan interactuar con el cubo de datos para extraer información útil, incluyendo análisis de series temporales y clasificación de cobertura terrestre (Rathore et al., 2015).

- **Análisis y Aplicación de Datos:** Implementar herramientas analíticas que puedan interactuar con el cubo de datos para extraer información útil. Esto puede incluir análisis de series temporales, detección de cambios, clasificación de cobertura terrestre y otros algoritmos de procesamiento de imágenes y datos de teledetección (Rathore et al., 2015).
- **Visualización y Diseminación:** Desarrolle interfaces de usuario y visualizaciones que permitan a los investigadores y partes interesadas explorar y analizar los datos del cubo de manera intuitiva. Esto facilitará la interpretación de los resultados y la toma de decisiones basada en los análisis realizados (Rathore et al., 2015).

Figura 10

Descripción general del concepto de cubo de datos



Fuente: Frantz (2020)

2.2.13.1.2. Tecnologías y herramientas

- **Herramientas de Procesamiento Distribuido:** Tales como Hadoop y Spark, que son esenciales para manejar y procesar grandes volúmenes de datos de forma eficiente. Estas plataformas permiten el procesamiento paralelo de datos a través de *clusters* de

computadoras, lo que acelera significativamente las operaciones de análisis de datos (Li et al., 2014).

- **Aprendizaje Profundo Distribuido:** Herramientas como TensorFlow y PyTorch permiten implementar modelos de aprendizaje profundo para la interpretación de datos de teledetección, aprovechando arquitecturas de computación distribuida para mejorar el manejo de la alta dimensionalidad y volumen de los datos (Haut et al., 2021).
- **Modelos de Cubos OLAP Espaciales (SOLAP):** Herramientas que integran capacidades OLAP (Online Analytical Processing) con soporte espacial, como los basados en el paradigma Map-Reduce, para mejorar el rendimiento en operaciones de agregación y análisis espacial de datos *raster* y de teledetección (Li et al., 2014).
- **Plataformas de Sensoriamento Remoto:** Como Google Earth Engine (GEE), que integra múltiples funciones para el manejo de datos de teledetección, incluyendo la creación y análisis de cubos de datos. GEE es una plataforma destacada para la gestión, preprocesamiento, análisis y visualización de datos de teledetección. Proporciona acceso a *petabytes* de imágenes de teledetección y otros productos listos para usar, facilitando el manejo de datos de múltiples sensores y en diferentes bandas espectrales. La plataforma utiliza el potente motor de procesamiento en la nube de Google para realizar análisis a gran escala de manera eficiente, lo que permite a los usuarios no solo tradicionales científicos de teledetección, sino también a un público más amplio que carece de la capacidad técnica necesaria para utilizar supercomputadoras o recursos de computación en la nube a gran escala (Gorelick et al., 2017). Además, de acuerdo a Tamiminia et al. (2020), se ha confirmado la efectividad y versatilidad de GEE para diferentes aplicaciones ambientales a nivel regional y global, aprovechando sus capacidades de procesamiento paralelo y algoritmos de aprendizaje automático. Estas plataformas proporcionan herramientas de preprocesamiento, análisis y visualización de datos, facilitando la gestión de datos de múltiples sensores y en diferentes bandas espectrales.

2.2.13.2. Ventajas y desventajas

2.2.13.2.1. Ventajas

- **Optimización del Manejo de Volumen de Datos:** Los cubos de datos ofrecen una estructura optimizada para el manejo de datos a gran escala, empleando técnicas como

la indexación multidimensional y particionamiento, lo cual facilita operaciones complejas de búsqueda y análisis espacial-temporal. Estas técnicas permiten un acceso rápido y eficiente a los datos, crucial para el procesamiento de series temporales y datos multispectrales en aplicaciones de teledetección (Wang et al., 2012).

- **Integración de Diversas Fuentes de Datos:** Los cubos de datos en teledetección facilitan la integración de información proveniente de distintos sensores y plataformas, como datos LIDAR, imágenes satelitales y datos de radar. Esta integración se realiza mediante la normalización y alineación de los datos en un formato único, lo que permite realizar análisis más complejos y precisos al combinar diferentes tipos de datos y extraer un mayor valor de la información (Ferreira et al., 2020).
- **Accesibilidad y Analítica Mejoradas:** Los cubos de datos transforman datos crudos en formatos “análisis listos” mediante la implementación de procedimientos de preprocesamiento automatizados que incluyen correcciones atmosféricas, geométricas y radiométricas. Esto reduce significativamente el tiempo y los recursos necesarios para preparar los datos para el análisis, permitiendo a los investigadores centrarse más en el análisis de datos y menos en su preparación (Xu et al., 2020).

2.2.13.2.2. Desventajas

- **Desafíos de Gestión y Almacenamiento:** La implementación de cubos de datos requiere infraestructuras de almacenamiento de alta capacidad y sistemas de gestión de bases de datos especializados, capaces de manejar estructuras de datos multidimensionales y operaciones de agregación complejas. Esto puede implicar costos elevados y la necesidad de hardware especializado, además de personal técnico cualificado para su mantenimiento (Sabri et al., 2021).
- **Rendimiento del Procesamiento de Datos a Gran Escala:** Aunque los cubos de datos mejoran la eficiencia del procesamiento, la manipulación de grandes volúmenes de datos, especialmente en sistemas distribuidos, puede presentar desafíos relacionados con la latencia, el balance de carga y la optimización de consultas. Esto puede requerir algoritmos avanzados de paralelización y técnicas de reducción de datos para garantizar un procesamiento eficiente y escalable (Li et al., 2014).

- **Pérdida de Información Durante la Compresión de Datos:** Para manejar eficientemente el almacenamiento de grandes cubos de datos, a menudo se requiere la compresión de datos, lo que puede llevar a la pérdida de información crítica, especialmente en aplicaciones donde la precisión de los datos es crucial, como en el monitoreo ambiental o en estudios climáticos. Las técnicas de compresión deben ser cuidadosamente seleccionadas para equilibrar la necesidad de reducir el tamaño de los datos con el riesgo de perder información importante. Por ejemplo, la compresión con pérdida puede ser adecuada para algunas aplicaciones donde no se requiere una precisión absoluta, pero para otras, como la clasificación precisa de la cobertura terrestre, podría ser inadecuada debido a la posible pérdida de detalles importantes en los datos (Vozel et al., 2021).

2.2.13.3. Caso de uso y aplicaciones

Los cubos de datos en teledetección se aplican en una variedad de contextos, mostrando su versatilidad y utilidad en distintas áreas de estudio y aplicación. Un ejemplo destacado es el uso de técnicas de aprendizaje profundo distribuido para la interpretación de datos de teledetección. Este enfoque se beneficia especialmente del procesamiento en la nube para manejar grandes volúmenes de datos espaciales con alta dimensionalidad, facilitando aplicaciones como el monitoreo ambiental y la planificación urbana (Haut et al., 2021). Otro caso de uso importante es el monitoreo de desastres naturales, donde los cubos de datos permiten integrar y analizar rápidamente grandes conjuntos de datos multitemporales para detectar cambios y evaluar daños. Este punto es crucial para la gestión de emergencias y la mitigación de desastres, donde el tiempo es un factor crítico (Chi et al., 2016). Además, en Brasil, los cubos de datos de observación de la Tierra están siendo utilizados para mejorar la monitorización del uso del suelo y la cobertura terrestre a través del análisis de series temporales de imágenes de satélite, combinado con técnicas de aprendizaje automático. El enfoque no solo mejora la precisión de los mapas generados sino que también aumenta la eficiencia del procesamiento de datos (Ferreira et al., 2020).


2.2.14. Criosfera

La criosfera es un subsistema del planeta integrado por regiones donde se encuentra el agua en estado sólido, tanto en la Tierra como en los océanos. Comprende la nieve, el hielo de los ríos y lagos, el hielo marino, los glaciares, las plataformas de hielo y las capas de hielo, así como el suelo congelado, conocido como permafrost (IPCC, 2014). Esta división se compone

de dos elementos principales: el hielo terrestre, que incluye capas de hielo, casquetes y glaciares, y el hielo marino. Ambos componentes han sido identificados como indicadores significativos del cambio climático en escalas de tiempo que abarcan desde años hasta milenios. (Bamber & Payne, 2004)

Figura 11

Componentes de la criosfera: regiones con agua sólida en superficies terrestres y oceánicas



Fuente: Rivera et al. (2017)

2.2.15. Precipitación

La precipitación, un componente fundamental del ciclo hidrológico, es un fenómeno atmosférico en el que las partículas de agua o sustancias sólidas presentes en la atmósfera se transforman en lluvia, nieve o granizo. Este proceso se desencadena cuando una masa de aire asciende, se condensa en nubes y, al alcanzar su máxima capacidad de saturación, libera el exceso en forma de precipitaciones. Este fenómeno es esencial para aportar agua dulce al planeta. Cuando las nubes alcanzan un punto crítico de saturación, forman gotas de agua o fragmentos de hielo que, impulsados por la fuerza de gravedad, caen hacia la superficie terrestre (Sarochar, 2009; Gámez, 2010).

Figura 12

Proceso de precipitación: nubes saturadas descargan lluvia, nieve o granizo por gravedad



Fuente: Madrid (2023)

De acuerdo con Sarochar (2009), la precipitación requiere la presencia de tres factores fundamentales:

- **Temperatura:** Su incremento provoca un mayor movimiento entre las partículas, lo que hace más fácil que se eleven hacia capas superiores de la atmósfera.
- **Núcleos de condensación:** Por lo general, estas partículas o aerosoles posibilitan la formación de la gota alrededor de ellos.
- **Humedad atmosférica:** A medida que aumenta la cantidad de agua en la nube condensada, la probabilidad de precipitación aumenta debido a la saturación que se produce. El nivel de agua necesario para alcanzar la saturación dependerá de la temperatura y estará directamente influenciado por esta última.

2.2.16. Glaciar

Un glaciar se define como una extensa masa de hielo formada en la superficie terrestre, resultado de la transformación de nieve en hielo, lo que refleja tanto la historia antigua como la contemporánea (IPCC, 2018). Esta masa, compuesta principalmente de hielo y nieve, es especialmente visible durante las estaciones de deshielo, observándose en glaciares de regiones tropicales tras la fusión de la nieve estacional (Kargel et al., 2014). Los glaciares se desplazan lentamente debido al peso de su masa y la influencia de la gravedad. Su formación se debe a la acumulación prolongada de nieve, seguida por un proceso de compactación. Los glaciares se

desarrollan en zonas donde las bajas temperaturas favorecen la caída y permanencia de nieve durante todo el año, típicamente en áreas polares y en altas montañas (Rivera, 2005).

En términos de movimiento, la masa helada de un glaciar avanza cuesta abajo, tanto por deformación interna como por deslizamiento en su base, y está confinada por la topografía circundante, como las laderas de los valles o los picos próximos. La forma del lecho rocoso subyacente juega un papel crucial en la dinámica y la pendiente superficial del glaciar. La existencia de un glaciar se mantiene gracias al equilibrio entre la acumulación de precipitación sólida en forma de nieve en las alturas y la fusión del hielo en altitudes más bajas o su descarga en los océanos (IPCC, 2001).

2.2.17. Formación de un glaciar

El hielo glaciar se forma a partir de la nieve en áreas donde las condiciones climáticas permiten grandes precipitaciones que persisten durante todo el año. La nieve, siendo la materia prima, se acumula principalmente en regiones polares y en las altas cordilleras. (Rivera, 2011)

La nieve perenne que cubre una extensión se conoce como "campos de nieve o zonas de acumulación", las cuales tienen una "línea de nieve", que marca el límite inferior del campo de nieve. Esta línea no es precisa y varía según las condiciones climáticas regionales. Durante su formación, hay una acumulación de nieve en la zona alta y una pérdida en la zona baja (zona de pérdida de nieve). (Rivera, 2011)


El papel de los climas regionales es crucial en la modulación de las respuestas de los glaciares ante la variabilidad climática y sus fluctuaciones (Sagredo et al., 2014). Comprender cómo la temperatura y las precipitaciones afectan el equilibrio de masa de un glaciar es esencial para comprender las variaciones y las influencias pasadas, presentes y futuras en dicho cuerpo glaciar.

Los glaciares son estructuras geológicas compuestas por masas de hielo que se forman a través de procesos de acumulación, compactación y recrystalización de precipitaciones sólidas, como la nieve, la escarcha y el granizo. Estas masas de hielo pueden variar significativamente en términos de forma y dimensiones, y contienen una variedad de materiales detríticos en su superficie e interior. La composición de los glaciares puede incluir sedimentos y rocas que se han incorporado durante su formación y evolución. Los glaciares exhiben propiedades dinámicas notables, como la velocidad de flujo, que varía con el tiempo. Su

comportamiento puede describirse como el de un cuerpo plástico o semiplástico. La permanencia de un glaciar puede extenderse desde varias décadas hasta varios miles de años, dependiendo de su ubicación y las tasas de acumulación y pérdida de hielo. La movilidad de los glaciares depende en gran medida de la pendiente del terreno en el que se encuentran. Pueden permanecer estáticos en terrenos planos o con una pendiente suave, o fluir hacia abajo siguiendo la pendiente del terreno. Incluso en ciertos casos, los glaciares pueden moverse localmente contra la pendiente debido a procesos de compresión y empuje (Ferrando, 2014).

Figura 13

Dinámica Glaciar: El campo de nieve y línea de nieves con zonas de acumulación y pérdida



Fuente: Rivera (2011)

2.2.18. Zonificación de un glaciar

Los glaciares se dividen en una zona de acumulación, donde hay una ganancia neta de masa debido a la agregación de nieve y hielo, y una zona de ablación, donde se produce una pérdida de masa glaciar. La acumulación representa una contribución positiva, mientras que la ablación representa una contribución negativa (Cuffey & Paterson, 2010). Estas zonas están marcadas por una línea de equilibrio altitudinal (ELA), que indica los puntos en los que la masa neta del glaciar es "cero", es decir, donde se igualan la acumulación y la ablación (Kaser et al., 2003).

La acumulación de nieve y hielo en la zona de acumulación se debe a la precipitación en forma de nieve que cae en esta área y se acumula con el tiempo. La cantidad de nieve y hielo agregada en esta zona es un indicador clave de las condiciones climáticas y de la entrada de agua en forma de precipitación sólida al glaciar. Esta cantidad puede variar significativamente de un año a otro, lo que proporciona información valiosa sobre la cantidad de agua incorporada al glaciar mediante el proceso de acumulación (Francou & Pouyaud, 2008). Estos procesos comprenden todas las actividades que generan un aumento en la masa glaciar, reflejado en términos numéricos positivos.

Los procesos que contribuyen a la acumulación de hielo y nieve en una región incluyen eventos como la nevada, la formación de cristales de hielo mediante la transferencia de vapor seguida de sublimación y deposición, el aumento de la nieve por el viento, la nieve transportada por la deriva, las avalanchas, la congelación basal típicamente debajo del hielo flotante y la acumulación interna. Estos mecanismos desempeñan un papel crucial en el equilibrio de masa de los glaciares, ya que cada uno de ellos agrega capas sucesivas de hielo y nieve que se acumulan con el tiempo, contribuyendo al crecimiento y la evolución de estas masas de hielo a lo largo del tiempo (Singh, Singh & Haritashya, 2011). Es relevante señalar que la precipitación en forma de agua no se clasifica como parte de la acumulación en glaciología, a menos que experimente un proceso de congelación. Este principio es análogo al hecho de que no se considera acumulación la incorporación de material, como desechos por avalanchas, la caída de cenizas u otros procesos similares.

Figura 14

Zonificación Glaciar y ELA: se muestra las áreas de acumulación y ablación con la Línea de Equilibrio Altitudinal



Fuente: Rivera et al. (2017)

La zona de ablación comprende una serie de procesos que resultan en la reducción de la masa de hielo. Estos procesos incluyen la fusión, que implica la transformación del hielo en agua líquida debido al aumento de la temperatura, la evaporación, que es el cambio directo del hielo en vapor de agua, la sublimación, donde el hielo se convierte directamente en vapor sin pasar por el estado líquido, y el desprendimiento de masas de hielo, que es la liberación de fragmentos de hielo. Estos fenómenos son cruciales para comprender la evolución de los glaciares y los sistemas de hielo, ya que indican la pérdida neta de hielo en una región específica (Francou et al., 2004). Estos procesos, en su conjunto, conducen a la disminución de la masa glaciar y se expresan como valores numéricos negativos.

Las zonas de acumulación de un glaciar se subdividen en subregiones específicas de acuerdo con los cambios de transformación y las características de las propiedades de la nieve (Cuffey & Paterson, 2010).


- **Zona de nieve seca:** En esta región, la fusión es prácticamente inexistente, y el deshielo no ocurre en ningún momento del año. La nieve permanece congelada y no experimenta cambios significativos en su estado físico.
- **Zona de percolación:** En esta zona, se registra una fusión superficial mínima. El agua resultante de esta fusión puede filtrarse a cierta profundidad en la nieve, incluso a temperaturas por debajo de 0 °C, antes de volver a congelarse. Este proceso de percolación es característico de esta área.
- **Zona de nieve húmeda:** Al finalizar el verano, la nieve acumulada desde la temporada de verano anterior se ha calentado hasta alcanzar los 0 °C en esta región. Además, parte del agua del deshielo se filtra hacia las capas más profundas de la nieve. Esta zona experimenta cambios en la temperatura y humedad de la nieve a lo largo del año.
- **Zona de nieve sobreimpuesto:** Esta zona se encuentra en las áreas de percolación y nieve húmeda. Está compuesta por capas de hielo, lentes, y glándulas que se alternan con capas y parches de nieve. Esta compleja estructura es el resultado de procesos de acumulación y fusión a lo largo del tiempo, lo que contribuye a la formación de una estructura estratificada en esta región del glaciar.

En la zona de ablación, diversos procesos ejercen influencia, incluyendo la fusión, la deflación (transporte de nieve por el viento), las caídas de hielo desde el frente del glaciar o las

avalanchas, el derretimiento y la sublimación. Los cambios en el balance de masa glaciar, representando ganancias y pérdidas superficiales, se denominan de esta manera para cuantificar dichas variaciones (Rivera et al., 2017).

Figura 15

Estratificación de la Zona Glaciar: Se muestra acumulación y ablación, subdivididas por procesos y características




Fuente: Rivera et al. (2017)

2.2.19. Glaciares tropicales

Los glaciares tropicales se sitúan en regiones comprendidas entre el Trópico de Cáncer y el Trópico de Capricornio, específicamente en latitudes aproximadas de 23°26'013,3" al norte y 23°26'013,3" al sur. Estos glaciares se encuentran dentro de la Zona de Convergencia Intertropical (ZCIT). Se pueden hallar glaciares tropicales en diversas partes del mundo, incluyendo los Andes sudamericanos, África Oriental y Australasia, como se muestra en la Figura 16. El reciente Inventario de Glaciares Randolph (RGI; versión 5.0) estima el área total de glaciares tropicales en 2344.15 km² (Veettil & Kamp, 2019). Dentro de la cadena de la cordillera de los Andes, es innegable la inclusión de la cadena andina ubicada en el norte de Venezuela y Colombia, así como de los Andes centrales que comprenden regiones de Ecuador, Perú y Bolivia. Es relevante mencionar que la delimitación geográfica de estas cordilleras ha sido objeto de consideración por varios autores, quienes han debatido acerca de la inclusión o exclusión de las porciones tropicales más septentrionales de los Andes en el sur de Chile y Argentina (Veettil & Kamp, 2017)

Figura 16

Distribución de Glaciares Tropicales: Mapa mundial de glaciares en la Zona de Convergencia Intertropical



Fuente: Veettil & Kamp (2019)

La mayoría de los glaciares tropicales de la cordillera de los Andes en América del Sur, representa el 99% de la distribución global. Los glaciares en Venezuela, Colombia y Ecuador pertenecen al trópico inferior, con precipitaciones que carecen de estacionalidad durante todo el año. Los glaciares en el Perú, Bolivia, el norte de Chile y en el norte de Argentina pertenecen al trópico exterior, con precipitaciones estacionales (Veettil & Kamp, 2019).

Tabla 1

Áreas de Glaciares Tropicales por Región

Región	País	Área (km ²)
Sudamérica	Venezuela	0.79
	Colombia	66.19
	Ecuador	123.9
	Perú	1602.96
	Bolivia	531.58
	Norte de Chile	11.81
	Norte de Argentina	0.32
	Total	2337.55
África	Kenya	0.40
	Tanzania	2.87
	La República Democrática del Congo	1.14
	Total	4.41
Irian Jaya	Indonesia	2.14
Trópicos enteros		2344.10

Nota. Datos del Inventario de Glaciares Randolph clasificados por país.

Fuente: Veettil & Kamp (2019)

En la región andina, la diversidad de condiciones climatológicas da origen a una abundante y variada presencia de cubiertas de hielo (Sagredo & Lowell, 2012). Esto se encuentra estrechamente vinculado con la magnitud y la distribución temporal y espacial de las condiciones de temperatura y precipitación propias de cada región. La incidencia de la temperatura y la precipitación en los glaciares generalmente se conceptualiza en términos de su capacidad para mantener el equilibrio de masas en respuesta a cambios en la temperatura o en la cantidad de precipitación. En líneas generales, se observa que la sensibilidad a las variaciones en la temperatura y la precipitación aumenta significativamente a medida que aumenta la cantidad anual de precipitación (Cogley et al., 2012).

En los Andes Tropicales, la actividad convectiva en la región amazónica genera grandes cantidades de lluvia en la vertiente oriental de la cordillera y, en menor medida, en el lado occidental, un efecto que se ve amplificado por fenómenos de teleconexión a nivel hemisférico. Además de las precipitaciones en forma de nieve, existen otros mecanismos que contribuyen de manera secundaria, como la transformación de agua de lluvia en hielo superficial debido a bajas temperaturas, la aparición de una niebla blanca al interactuar con los glaciares, o la congelación del agua derretida que se acumula en capas de hielo superpuestas (Cogley et al., 2012).

2.2.20. Estacionalidad de los glaciares

Los glaciares tropicales de los Andes funcionan de manera distinta a los glaciares de montaña de latitudes medias. En estos últimos, una estacionalidad definida dicta períodos de crecimiento en invierno y de disminución de masa en verano. En cambio, la ausencia de una estacionalidad marcada en los glaciares tropicales conduce a un ciclo más condensado, con acumulación de nieve posible durante todo el año y pérdida de masa influenciada por las fluctuaciones diarias de temperatura. Esta característica única añade complejidad y cierto grado de imprevisibilidad al estudio de estos glaciares.


En cuanto a la estacionalidad, los glaciares tropicales se ven fuertemente influenciados por el patrón de las precipitaciones. Presentan una estacionalidad notable, con acumulaciones de nieve en la temporada de lluvias y un proceso de fusión más intenso en la temporada seca. Además, los efectos del cambio climático y el aumento de las temperaturas pueden intensificar la fusión de estos glaciares tropicales.

2.2.21. Glaciares de Perú

En Perú se encuentra alrededor de 71% de los glaciares tropicales del planeta, donde cubre un área 1602.96 km². La cordillera Blanca es la región más extensa y tiene la mayor concentración de glaciares tropicales en todo el mundo. Existen glaciares en las cordilleras de Huaguruncho, Huaytapallana, Vilcabamba, Urubamba, Vilcanota y Carabaya, estando ubicada la Cordillera de Apolobamba en la frontera entre Perú y Bolivia. En la Cordillera Occidental, los glaciares se ubican en las montañas Blanca, Huallanca, Huayhuash y Raura por el oeste, La Viruda por el norte y Huanzo, Chile, Ampato, Volcánica y Barroso por el sur (Veettil & Kamp, 2017). Como resultado del cambio climático, en los últimos 54 años, los glaciares tropicales peruanos tuvieron una reducción de 53.56% (INAIGEM, 2017).

Figura 17

Distribución de Glaciares en los Andes Tropicales: Clasificación por zonas climáticas y elevación



Fuente: Veettil & Kamp (2017)

La Cordillera Blanca no escapa a la influencia de estos factores, lo que subraya la importancia de evaluar la sensibilidad de los glaciares, especialmente en lo que respecta a la temperatura del aire y la cantidad total de precipitación recibida, así como su variabilidad estacional. Esto se debe, en parte, a las pequeñas variaciones estacionales y a las notables

fluctuaciones diarias en las temperaturas, así como a la transición marcada entre una temporada de lluvias y una temporada seca. (Kaser et al., 1990)

La temporada de lluvias en esta región está influenciada por la Zona de Convergencia Intertropical (ZCIT), que se manifiesta durante el verano austral, desde octubre hasta abril. Durante estos meses, cerca del 90% de la precipitación anual se concentra. En la Cordillera Blanca, las lluvias provienen mayormente del flujo de masas de aire húmedo provenientes del este, desde la cuenca amazónica, y también de células convectivas generadas localmente (Kaser, G., 1999). En consecuencia, la mayor parte de la acumulación de masa en los glaciares tiene lugar durante la estación de lluvias (Kaser et al., 1990).

2.3. Definición de términos

- Epoch: En el entrenamiento de redes neuronales, una *epoch* se refiere a una pasada completa por todo el conjunto de datos de entrenamiento. Durante una *epoch*, el algoritmo de aprendizaje ajusta los pesos de la red en un intento de minimizar el error entre las predicciones y las etiquetas reales.
- Falsos positivos y falsos negativos: En el contexto de la clasificación, un falso positivo ocurre cuando un sistema identifica incorrectamente una muestra negativa como positiva. Por otro lado, un falso negativo ocurre cuando el sistema no logra reconocer una muestra positiva, clasificándola erróneamente como negativa. Ambos son indicadores críticos del rendimiento de los sistemas de clasificación y detección.
- Intelligence for Image Segmentation (IRIS): Este término parece referirse a sistemas o plataformas de inteligencia artificial diseñadas para la segmentación de imágenes. No obstante, no es un término ampliamente reconocido o estándar en el ámbito de la inteligencia artificial o el procesamiento de imágenes, y podría referirse específicamente a una implementación o solución particular que utilice inteligencia artificial para segmentar imágenes.
- LightGBM: Es una implementación de *gradient boosting framework* que utiliza algoritmos basados en árboles de decisión. Diseñado para ser distribuido y eficiente, se destaca por su velocidad y eficiencia, con soporte para el manejo de grandes volúmenes de datos. Es ampliamente utilizado en competiciones de ciencia de datos y en la industria para tareas de clasificación, regresión y ranking.

- PyTorch: Es un *framework* de aprendizaje profundo y computación tensorial con aceleración de GPU. Es popular por su flexibilidad y su diseño orientado a la investigación, facilitando la experimentación rápida y el desarrollo de modelos de inteligencia artificial, especialmente en áreas como visión por computadora y procesamiento de lenguaje natural.
- S2cloudless: Es una herramienta o algoritmo que utiliza aprendizaje automático para la detección de nubes en imágenes satelitales, específicamente en datos provenientes del satélite Sentinel-2. Su objetivo es identificar y eliminar la cobertura nubosa de las imágenes para mejorar la calidad y la precisión del análisis de datos satelitales.
- Sen2Cor: Es un software de procesamiento que convierte datos multiespectrales de nivel 1C del satélite Sentinel-2 de la Agencia Espacial Europea (ESA) a datos de nivel 2A. Esto implica la corrección atmosférica de las imágenes y la clasificación de tipos de cobertura de suelo, incluyendo la detección de nubes, vapor de agua y correcciones de sombras de nubes.
- U-net: Es una arquitectura de red neuronal convolucional diseñada específicamente para tareas de segmentación de imágenes biomédicas, aunque se ha generalizado con éxito para otras tareas de segmentación de imágenes. Se caracteriza por su estructura en forma de "U", que facilita la localización precisa de objetos en imágenes al combinar información de contexto y localización.

Capítulo III.

Hipótesis y variables

3.1. Hipótesis

3.1.1. Hipótesis general

“El uso de cubos de datos e inteligencia artificial permitirá estimar de manera precisa el área glaciar en el Parque Nacional Huascarán, Ancash – Perú, durante el período 2018-2022”.

La hipótesis sugiere que la integración de cubos de datos y tecnologías de inteligencia artificial proporcionará una metodología eficaz para estimar con precisión el área glaciar en el Parque Nacional Huascarán durante el período de estudio. Al aprovechar el poder de análisis multidimensional de los cubos de datos y la capacidad predictiva de la inteligencia artificial, se espera que esta investigación contribuya significativamente a la comprensión y el monitoreo de los cambios en el área glaciar de esta importante región de Ancash, Perú.

3.1.2. Hipótesis específicas

- El empleo de la arquitectura U-net mejora significativamente la precisión en la estimación de áreas glaciares en comparación con las técnicas de clasificación tradicionales.
- Desarrollar un método preciso para estimar la cobertura glaciar permitirá obtener resultados automáticos de manera frecuente.
- Mediante el método adecuado, es posible entrenar una red neuronal capaz de distinguir con precisión entre glaciar, nubes y sombras de nubes en el contexto específico de los Andes.

3.2. Variables

3.2.1. Variable 1

“El uso del cubo de datos e inteligencia artificial”.

Esta variable engloba el proceso completo de aplicar tecnologías de inteligencia artificial para estimar el área glaciar en el Parque Nacional Huascarán. Incluye la selección y preparación de conjuntos de datos, el diseño de la red neuronal y el entrenamiento del modelo.

3.2.2. Variable 2

“El área glaciaria estimada en el Parque Nacional Huascarán, Ancash – Perú, durante el período 2018-2022”.

Esta variable representa la medida cuantitativa del área cubierta por los glaciares en el Parque Nacional Huascarán entre 2018 y 2022, utilizando técnicas de inteligencia artificial para analizar datos satelitales.

3.2.3. Consideraciones Adicionales

- Validación de Modelos: Es crucial validar los modelos de IA con datos de campo o compararlos con estudios previos para asegurar su precisión.
- Sensibilidad a Cambios Temporales: Dado que los glaciares pueden cambiar rápidamente, es importante considerar la capacidad de la IA para detectar cambios a corto plazo.
- Impacto Ambiental y Climático: Los resultados podrían utilizarse para entender mejor el impacto del cambio climático en los glaciares del Parque Nacional Huascarán.

3.3. Variables

Tabla 2

Variables

Variable	Definición	Operacionalización	Método de Medición	Herramienta
Variable 1	Uso del cubo de datos e inteligencia artificial	Implementación de modelos de IA y análisis a través de cubos de datos para el entrenamiento de redes neuronales utilizando los datos preprocesados.	Eficiencia del modelo en la identificación correcta de cobertura glaciaria, precisión y exactitud del mapeo.	Python
Variable 2	La cobertura glaciaria en el Parque Nacional Huascarán	Medida en kilómetros cuadrados (km ²), determinada a través de imágenes satelitales y análisis geoespacial.	Uso de imágenes satelitales y comparación con datos históricos para determinar cambios en la cobertura glaciaria.	Python

Capítulo IV.

Materiales y metodología

La investigación se fundamenta íntegramente en el análisis de imágenes Sentinel-2, aunque su aplicabilidad puede expandirse de manera sencilla hacia otros sensores ópticos que incluyen bandas en el infrarrojo de onda corta (SWIR), tal como el sensor Landsat. La banda SWIR juega un papel esencial en el análisis glaciar, ya que es la única que posibilita una distinción precisa entre la cobertura nival y las formaciones nubosas.

La metodología propuesta para la detección del área nival abarca dos niveles de análisis mediante técnicas de IA. En el primer nivel, se enfoca en la identificación de píxeles afectados por contaminación atmosférica, incluyendo nubes densas, nubes dispersas y sombras originadas por nubes (píxeles contaminados). Una vez que se han definido los píxeles contaminados, se emplea un segundo modelo para clasificar aquellos píxeles que no exhiben interferencias atmosféricas.


4.1. Descripción del área de estudio

4.1.1. Ubicación

La investigación se llevará a cabo en el Parque Nacional Huascarán, situado en la región norte-central de Perú. El parque es reconocido como uno de los santuarios naturales más destacados del país debido a su contribución a la preservación de una amplia diversidad biológica y cultural. Resguarda la ecorregión de la Puna Húmeda de los Andes Centrales y abarca terrenos accidentados que incluyen el flanco oriental de la Cordillera Blanca, cercano al Callejón de Conchucos, y el flanco occidental en el área del Callejón de Huaylas. Destaca por sus imponentes picos nevados, que oscilan en altitud desde los 5,000 hasta los 6,768 metros sobre el nivel del mar, siendo el Huascarán su punto culminante. Además, presenta profundos valles esculpidos por procesos de erosión glaciar y alrededor de 300 lagunas de origen glaciar. Ubicado en su mayoría en una zona tropical, el Parque Nacional Huascarán se distingue por albergar los picos nevados más elevados de esta área geográfica, con aproximadamente 660 glaciares.

Figura 18

Área de estudio



Para la realización del estudio, se utilizará una muestra representativa de la población. Se ha seleccionado el tile T18LTQ de Sentinel-2, el cual abarca una amplia área del Parque Nacional Huascarán y posee una importante cobertura glaciaria. Esta decisión se justifica por la necesidad de asegurar una adecuada representación de la región de interés. El enfoque en este tile específico permitirá obtener una visión integral y detallada de la distribución y variabilidad de la cobertura glaciaria en el área de estudio. Los datos extraídos de este tile serán fundamentales para el entrenamiento y la validación de los modelos de IA, lo que garantiza la obtención de resultados confiables y precisos en el análisis científico.


Tabla 3

Límites del tile T18LTQ

Límites	Sistema de coordenadas	Este	Norte
P1	UTM WGS84 18S	199970	9000050
P2	UTM WGS84 18S	309770	9000050
P3	UTM WGS84 18S	309770	8890250
P4	UTM WGS84 18S	199970	8890250

Figura 19

Área de Estudio



4.2. Metodología

4.2.1. Recolección de datos de entrada

Tanto el primer nivel, orientado a la detección de nubes, como el segundo nivel, enfocado en la clasificación de la cobertura del suelo, han sido desarrollados y entrenados utilizando imágenes provenientes del sensor Sentinel-2. Las imágenes multiespectrales de Sentinel-2 empleadas en este estudio abarcan el periodo comprendido entre 2018 y 2022. En esta recopilación, se incorporaron todas las bandas espectrales detalladas en la Tabla 4, abarcando tanto la reflectancia en la parte superior de la atmósfera (TOA o L1C en su nomenclatura en inglés), como los valores de reflectancia de superficie (SR) derivados del proceso de corrección atmosférica llevado a cabo por el procesador Sen2Cor.

Tabla 4*Lista de las bandas disponible en Sentinel-2 L1C y Sentinel-2a*

File/ Folder	Nombre	Escala	Longitud de onda	Descripción
S2L1C & S2L2A	B1	00,001	443.9 nm (S2A)/442.3 nm (S2B)	Aerosoles.
	B2	00,001	496.6 nm (S2A)/492.1 nm (S2B)	Azul.
	B3	00,001	560 nm (S2A)/559 nm (S2B)	Verde.
	B4	00,001	664.5 nm (S2A)/665 nm (S2B)	Rojo.
	B5	00,001	703.9 nm (S2A)/703.8 nm (S2B)	Red Edge 1.
	B6	00,001	740.2 nm (S2A)/739.1 nm (S2B)	Red Edge 2.
	B7	00,001	782.5 nm (S2A)/779.7 nm (S2B)	Red Edge 3.
	B8	00,001	835.1 nm (S2A)/833 nm (S2B)	NIR.
	B8A	00,001	864.8 nm (S2A)/864 nm (S2B)	Red Edge 4.
	B9	00,001	945 nm (S2A)/943.2 nm (S2B)	Vapor de agua.
	B11	00,001	1613.7 nm (S2A)/ 1610.4 nm (S2B)	SWIR 1.
	B12	00,001	2202.4 nm (S2A)/2185.7 nm (S2B)	SWIR 2.
S2L1C	B10	00,001	1373.5 nm (S2A)/ 1376.9 nm (S2B)	Cirrus.
	AOT	0,001	-	Espesor óptico de aerosol.
	WVP	0,001	-	Presión de vapor de agua.
S2L2A	TCI_R	1	-	Imagen en Color Verdadero, Rojo.
	TCI_G	1	-	Imagen en Color Verdadero, Verde.
	TCI_B	1	-	Imagen en Color Verdadero, Azul.

4.2.2. Recolección de datos de referencia

Los datos de referencia (o *target* en su definición en inglés) para realizar la segmentación de nubes y área nival fueron obtenidos de las bases de datos CloudSEN12 (Aybar et al. 2022) y DynamicWorld (Brown et al., 2022).

4.2.2.1. CloudSEN12

CloudSEN12 consta de 9 880 regiones de interés (o ROI en su nomenclatura en inglés) distribuidas a nivel global, como se muestra en la Figura 20. Cada una de estas ROI abarca una extensión de $5,090 \times 5,090$ metros. Dentro de cada ROI, se han seleccionado meticulosamente 5 imágenes que satisfacen tres criterios esenciales: En primer lugar, se asegura que las imágenes Sentinel-2 L1C no contengan valores de píxeles saturados o áreas sin información. En segundo lugar, la diferencia temporal entre las adquisiciones de imágenes Sentinel-1 y Sentinel-2 no supera los 2.5 días. Por último, se garantiza la disponibilidad de al menos 15 escenas de Sentinel-2 L1C para la ROI en cuestión, tras la aplicación del filtro anterior. Cabe destacar que, junto a estos filtros, la elección de imágenes se fundamentó en una interpretación visual. Esto se debió a que los enfoques automáticos de enmascaramiento basados en nubes o metadatos de cobertura nubosa tienden a generar resultados inexactos, especialmente en zonas de elevada

altitud (Tiede et al., 2021), terrenos con coberturas complejas (Rittger et al., 2020) y escenarios con diversos tipos de nubosidad.

Figura 20


Distribución global de la base de datos - CloudSEN12



Con el objetivo de asegurar una distribución equitativa de píxeles que abarcara diferentes niveles de claridad, presencia de nubes y zonas sombreadas por las mismas, se contó con la participación de 14 expertos especializados en detección de nubes. Estos expertos realizaron una selección manual de las imágenes, tal como se ilustra en la Figura 21 Para cada ROI, se seleccionaron 5 imágenes que representaban una variedad de niveles de cobertura nubosa: sin presencia de nubes (0%), escasa nubosidad (0-25%), nubosidad ligera (25-65%), nubosidad moderada (45-65%) y nubosidad alta (>65%). Es importante destacar que las nubes inusuales, como estelas de condensación, nubes de hielo y fenómenos de neblina/bruma, fueron priorizadas por encima de las nubes convencionales durante este proceso de selección.

Figura 21

Metodología para la obtención de CloudSEN12




Fuente: Aybar et al. (2022)

Definidas las imágenes Sentinel-2, se generó la información de referencia utilizando el software de aprendizaje activo 'Intelligence for Image Segmentation (IRIS)' (Figura 22). Este sistema permitió al equipo de etiquetadores entrenar un modelo inicial (aprendiz) mediante un conjunto de muestras etiquetadas de tamaño reducido. Luego, el modelo se enriqueció de manera iterativa al incorporar nuevas muestras proporcionadas por un etiquetador adicional (oráculo). Esta metodología posibilitó una reducción significativa del tiempo invertido en la creación manual de etiquetas, sin comprometer la capacidad del etiquetador para realizar revisiones manuales detalladas cuando fuese necesario.

Figura 22

Interfaz gráfica de usuario de IRIS (Segmentación de Imágenes Reforzada Inteligentemente)



Nota. Hay siete barras de características. A) Barra de edición y navegación. B) Seleccionar clases semánticas de dibujo. C) Barra de dibujo; el último botón de este grupo ejecuta el algoritmo GBDT que completa la máscara utilizando anotaciones manuales previas. D) Barra de pruebas, ayuda a comparar anotaciones humanas y de IA. E) Barra de contraste de imagen que cambia el brillo y la saturación de la imagen. F) Metadatos de la imagen que muestra la miniatura de la imagen y la ubicación del IP usando Google Maps. G) Resumen de soporte de aprendizaje automático que muestra las métricas de rendimiento de GBDT. La interfaz de IRIS muestra la banda Cirrus, Rojo-Verde-Azul y Azul-SWIR1-SWIR2.


Para la generación de las etiquetas utilizadas en el contexto de la presente investigación (Figura 22), se consideraron cuatro clases semánticas (Tabla 5). El proceso inició con IRIS, entrenando un árbol de decisión impulsado por gradiente (GBDT, según su nomenclatura en inglés) (Friedman, 2001). Este algoritmo GBDT utilizó valores de probabilidad inicial obtenidos del 's2cloudless' (Zupanc, 2017), considerando valores superiores a 0.7 como indicativos de nubes densas y aquellos por debajo de 0.3 como áreas sin nubes. El algoritmo GBDT comenzó su proceso creando árboles de decisión débiles que segmentaron los datos de entrenamiento. Gradualmente, estos árboles se combinaron para formar un aprendiz fuerte, lo que culminó en una predicción final. Se empleó el paquete de Python llamado LightGBM para la implementación de GBDT en IRIS, y se sugiere la obra de Ke et al. (2017) para una comprensión más detallada del algoritmo.

Tabla 5*Categorías semánticas en las nubes consideradas en CloudSEN12*

Code	Class	Superclase 1	Superclase 2	Descripción	Prioridad
0	Limpio	no nube	valido	Píxeles sin nubes o sombra de nubes	4
1	Nube gruesa	nube	invalido	Nubes opacas que bloquean toda la reflectancia de la superficie terrestre	1
2	Nube delgada	nube	invalido	Nubes semitransparentes que alteran la señal espectral de la superficie pero aún permiten reconocer el fondo	3
3	Sombra de nube	no nube	invalido	Píxeles oscuros generados por una nube espesa o delgada	2

Nota. Niveles de prioridad más bajos indican una mayor relevancia.

Una vez obtenidas las predicciones del GBDT, los etiquetadores llevaron a cabo ajustes en los resultados iniciales y, cuando fue necesario, incorporaron otras clases semánticas relacionadas con las nubes, como sombras de nubes y nubes delgadas. Utilizando este conjunto de muestras modificado, el modelo GBDT fue sometido a un proceso de reentrenamiento. Los pasos anteriores se repitieron en varias iteraciones hasta que las anotaciones cumplieran con los requisitos del filtro de inspección visual aplicado por el etiquetador. Finalmente, se llevó a cabo un refinamiento manual adicional para asegurar la obtención de anotaciones de alta calidad. Dado que no existen métricas cuantitativas para discernir con precisión entre los límites de las clases semánticas, los etiquetadores se esforzaron por maximizar la sensibilidad en zonas de fronteras ambiguas durante todo el proceso.

Figura 23*Base de datos CloudSEN-12*


Nota. Las dos primeras columnas muestran imágenes Sentinel-2 pertenecientes al conjunto de datos de entrenamiento. Las figuras de la tercera columna son las clases de referencia, es decir la segmentación semántica que buscamos que el algoritmo logre aprender.

4.2.2.2. DynamicWorld

DynamicWorld está compuesto por un conjunto de 4,000 imágenes interpretadas por un panel de 25 expertos y un conjunto adicional de 20,000 imágenes analizadas por un grupo compuesto por 45 individuos no expertos en la materia. La Figura 24 ilustra la distribución de las imágenes de referencia, siendo el color morado indicativo de aquellas imágenes en las que se identifica la presencia de la categoría de cobertura correspondiente a nieve. Es importante destacar que, con el fin de asegurar la homogeneidad de las imágenes de referencia, solo se incluyeron aquellas que carecían de la presencia de nubes (Brown et al., 2022).

Figura 24

Distribución espacial de los datos de entrenamientos pertenecientes a DynamicWorld




La selección de las imágenes libres de nubes se llevó a cabo mediante la aplicación del método de enmascaramiento automático denominado “*sen2cloudless*”. Este algoritmo, desarrollado por Sentinel-2 Hub, se encargó de discernir y descartar las imágenes con presencia de nubosidad (Zupanc, 2017).

Los anotadores en el proyecto DynamicWorld emplearon la plataforma Labelbox (2023) como pilar fundamental para llevar a cabo la labor de anotación. A través de esta plataforma, se proporcionó una herramienta de trazado vectorial que permitió demarcar con precisión los límites de las diferentes clases de elementos presentes en las imágenes capturadas por Sentinel-2 (Figura 25).

Figura 25

Base de datos DynamicWorld



Nota. Las dos primeras columnas muestran imágenes Sentinel-2 pertenecientes al conjunto de datos de entrenamiento del DynamicWorld. Las figuras de la tercera columna son las clases de referencia, es decir la segmentación semántica que buscamos que el algoritmo logre aprender.

La tarea de identificar categorías como cuerpos de agua, áreas arboladas, cultivos, zonas edificadas, terrenos descubiertos, áreas cubiertas de nieve, superficies de hielo y formaciones nubosas se llevó a cabo de manera fluida, aprovechando la resolución de 10 metros de las

imágenes de Sentinel-2. Dado que estas categorías suelen presentarse en configuraciones visualmente homogéneas, este procedimiento resultó especialmente viable (Brown et al., 2022).

Además del mosaico de imágenes de Sentinel-2, los anotadores tuvieron acceso a imágenes satelitales de alta resolución proporcionadas por Google Maps, las cuales estaban georreferenciadas con precisión respecto a la ubicación de interés en cada caso. También se les facilitaron imágenes capturadas en terreno a través de Google Street View desde el punto central de cada imagen. Para enriquecer el contexto, se incluyó la fecha de captura y las coordenadas geográficas correspondientes al punto central de cada imagen (Brown et al., 2022).

Con el fin de asegurar la eficiencia del proceso, se estableció que los anotadores debían abordar al menos el 70% de un mosaico en un lapso de 20 a 60 minutos. Esta metodología no solo promovió la agilidad en el etiquetado, sino que también les permitió omitir algunos mosaicos para lograr un equilibrio coherente entre la precisión de las anotaciones y la eficacia del proceso (Brown et al., 2022).

Las clases semánticas de Dynamic World están ampliamente descritas en la siguiente tabla.

Tabla 6

Taxonomía de la Clasificación Dinámica del Uso de la Tierra y la Cubierta Terrestre (LULC, por sus siglas en inglés)

ID	LULC Type	Descripción	Ejemplos
0	Agua	• El agua está presente en la imagen.	• Ríos
		• Contiene poca o ninguna vegetación dispersa, sin afloramientos rocosos ni características construidas como muelles.	• Estanques y Lagos
		• No incluye tierra que pueda o haya sido cubierta previamente por agua.	• Océano
1	Bosque	• Cualquier agrupación significativa de vegetación densa, típicamente con un dosel cerrado o denso.	• Salinas Inundadas
		• Más alta y más oscura que la vegetación circundante (si está rodeada de otra vegetación).	• Vegetación arbórea
			• Arbustos densos y verdes
			• Agrupación de vegetación densa y alta dentro de sábanas
			• Plantaciones como manzanos, plátanos, cítricos y caucho
			• Pantano (vegetación densa/alta sin agua evidente)
			• Cualquier combinación de lo anterior
			• Cualquier área quemada de lo anterior

2	Gras	• Áreas abiertas cubiertas de pastos homogéneos con poca o ninguna vegetación más alta.	• Praderas y campos naturales con poca o ninguna cobertura arbórea
		• Otras áreas homogéneas de vegetación tipo pasto (hojas tipo cuchilla) que parecen diferentes de los árboles y matorrales.	• Sabana abierta con poca o ninguna cobertura arbórea
		• Cereales y pastos silvestres sin trazas evidentes de intervención humana (es decir, no son campos estructurados).	• Parques, campos de golf, céspedes cuidados por humanos, incluidos campos grandes en entornos urbanos como fútbol y béisbol. • Áreas de paso de árboles para líneas eléctricas, gas, etc. • Pastizales • Carrizales y marismas sin inundación evidente
3	Vegetación inundada	• Áreas de cualquier tipo de vegetación con una mezcla evidente de agua.	• Manglares inundados
		• No asumir que un área está inundada si se observa inundación en otra imagen.	• Vegetación emergente
		• Áreas inundadas estacionalmente que son una mezcla de pasto, arbustos, árboles y suelo desnudo.	
4	Cultivos	• Cereales, pastos y cultivos plantados/trazados por humanos.	• Maíz, trigo, soya, etc. • Heno y parcelas en barbecho de tierras estructuradas
5	Arbustos y matorrales	• Mezcla de pequeñas agrupaciones de plantas o plantas individuales dispersas en un paisaje que muestra suelo y rocas expuestas.	• Cobertura moderada a dispersa de arbustos, matorrales y mechones de pasto
		• Claros llenos de matorrales dentro de bosques densos que claramente no son más altos que los árboles. Aparecen más grises/marrones debido a una cobertura de hojas menos densa.	• Sabanas con pastos muy dispersos, árboles u otras plantas
6	Área construida	• Agrupaciones de estructuras hechas por humanos o estructuras individuales muy grandes.	• Agrupación de casas, que puede incluir pequeños céspedes o pequeñas áreas de árboles
		• Edificaciones industriales, comerciales y privadas, y sus respectivos estacionamientos.	• Pueblos densos, áreas urbanas y paisajes urbanos (edificios y carreteras juntos)
		• Una mezcla de edificios residenciales, calles, céspedes, árboles, estructuras residenciales aisladas o edificios rodeados por cubiertas vegetales.	• Agrupaciones de carreteras pavimentadas y autopistas grandes
		• Redes principales de carreteras y ferrocarriles fuera de las áreas residenciales predominantes.	• Asfalto y otras superficies hechas por humanos
		• Superficies homogéneas grandes e impermeables, incluyendo estructuras de estacionamiento, grandes edificios de oficinas y desarrollos residenciales que contienen agrupaciones de calles sin salida.	
7	Suelo desnudo	• Áreas de roca o suelo con muy poca vegetación o ninguna.	• Roca expuesta
		• Grandes extensiones de arena y desiertos con poca o ninguna vegetación.	• Suelo expuesto
		• Grandes áreas individuales o densas redes de caminos de tierra.	• Desiertos y dunas de arena • Salinas secas y salinas • Fondos de lagos secos • Minas

			• Parcelas grandes vacías en áreas urbanas
8	Nieve	• Grandes áreas homogéneas de espeso hielo o nieve, típicamente sólo en áreas montañosas o latitudes más altas. • Grandes áreas homogéneas de nevadas.	• Glaciares • Capa permanente de nieve • Nevadas

Nota: Las definiciones y ejemplos se proporcionan como parte de los materiales de referencia del anotador, junto con descripciones de los colores y patrones típicamente asociados con cada tipo de LULC.

Fuente: Brown et al. (2022).


4.2.3. Diseño del Modelo de entrenamiento

4.2.3.1. Detector de nubes

Para entrenar la red U-Net (Ronneberger et al., 2015), se emplearon los datos de entrenamiento provenientes de CloudSEN12, utilizando como estructura base el codificador MobileNetV2 (Sandler et al., 2018). Cabe destacar que las redes U-Net suelen requerir considerables recursos de memoria debido a las extensas conexiones de salto de tensores entre los componentes del codificador y decodificador (*skip connections*). Sin embargo, el uso del codificador MobileNetV2 mitiga de forma significativa esta necesidad gracias a la implementación de convoluciones separables en profundidad y residuos invertidos (Figura 26).

Figura 26

Arquitectura utilizada para la detección de nubes



Fuente: Jiao Libin et al. (2020)

El modelo resultante logra mantener una demanda total de memoria por debajo de 1 GB, considerando un único lote con una imagen de dimensiones $1 \times 13 \times 512 \times 512$, contemplando tanto el proceso hacia adelante como hacia atrás (*forward/backward* en su traducción al inglés)

y los parámetros inherentes al modelo. Este logro se materializó utilizando la potente biblioteca de aprendizaje profundo PyTorch.

Para segmentar adecuadamente CloudSEN12, se procedió a dividirlo en conjuntos de entrenamiento, validación y prueba. Inicialmente, se efectuó la división del conjunto de entrenamiento y no entrenamiento basándose en bloques geográficos predefinidos. Posteriormente, el conjunto no destinado al entrenamiento se fragmentó aleatoriamente, observando la relación 90/10%, para establecer los conjuntos de entrenamiento y validación.

El entrenamiento de la red U-Net se llevó a cabo considerando todas las bandas Sentinel-2 L1C, empleando un tamaño de lote de 32 (*batch size*). Se utilizó el optimizador Adam con una tasa de aprendizaje de 10^{-3} , y la función de pérdida implementada fue la entropía cruzada. Durante la fase de entrenamiento, la tasa de aprendizaje se redujo en un factor de 0.10 si la entropía cruzada, medida en el conjunto de validación, no mostraba mejoras en un período de cuatro pasadas por el conjunto de datos (*epochs*).


Finalmente, en el escenario en que el modelo no demostrara mejoras después de diez *epochs*, se optó por seleccionar el modelo que presentaba el valor más bajo de entropía cruzada en el conjunto de validación como la iteración final del modelo.

4.2.3.2. Detector de cobertura de suelo

Se empleó una Red Neuronal Completamente Convolutiva (FCNN) similar a la propuesta presentada en Long et al. (2015), aunque fue sometida a un proceso de reentrenamiento en el entorno de PyTorch. Este reentrenamiento resultó esencial para establecer una coherencia armónica con el modelo preexistente de detección de nubes. Desde un punto conceptual, este enfoque implica la transformación de las bandas ópticas previamente preprocesadas de Sentinel-2 en una distribución discreta de probabilidad correspondiente a las clases dentro de nuestra taxonomía, en función del contexto espacial.

Figura 27

Arquitectura utilizada para la clasificación de cobertura de suelo



Fuente: Brown et al. (2022)

La propuesta presentada en Brown et al. (2022) introduce estrategias de normalización que posibilitan la obtención de una red neuronal de dimensiones aproximadamente 100 veces inferiores en comparación con las arquitecturas convencionales destinadas a la segmentación semántica, específicamente cuando se establece una comparativa con las arquitecturas U-Net (Ronneberger et al., 2015) y DeepLab V3+ (Chen et al., 2018). Siguiendo esta línea, el enfoque presentado también capitaliza la noción de supervisión débil (*weakly supervision*). Esta última contempla una réplica de la arquitectura inherente al modelo de etiquetado, el cual aprende a establecer un mapeo desde las probabilidades calculadas hacia las reflectancias de entrada. De manera esencial, se puede considerar una suerte de clasificador inverso LULC que opera en un modo multitarea y aporta una restricción crucial para abordar las limitaciones presentes en el proceso de etiquetado humano.


4.2.4. Evaluación del Modelo

4.2.4.1. Detector de nubes

La evaluación del algoritmo de detección de nubes se realizó utilizando la base de datos de validación de CloudSEN12 (Figura 28). Esta base de datos se configura mediante un enfoque de muestreo estratificado en bloques (*block stratified sampling*), que asegura una representación adecuada en términos espaciales. La evaluación de la concordancia entre las categorías semánticas (detalladas en la Tabla 5) generadas por el modelo de IA y las anotaciones manuales fue llevada a cabo mediante la agregación de las clases “contaminado” y “no contaminado”.

Figura 28

Ubicación de las regiones de entrenamiento (gris) y testeo (negro)



En el primero de ellos, se agregaron las clases nube gruesa, delgada y sombra de nubes (ver Tabla 5), mientras que la otra superclase “no contaminado” solo agrupa los píxeles como “clear”.

Las métricas utilizadas para evaluar las discrepancias entre los píxeles predichos y los valores esperados son la precisión del productor (PA), la precisión del usuario (UA) y la precisión general equilibrada (BOA). Estas métricas proporcionan una medida integral de la calidad del desempeño del algoritmo, considerando las relaciones entre verdaderos positivos, falsos positivos y falsos negativos:

$$PA = \frac{TP}{TP + FN} \quad UA = \frac{TP}{TP + FP} \quad BOA = 0.5 \left(PA + \frac{TN}{TN + FP} \right)$$

Donde TP , TN , FP y FN hacen referencia a los conceptos de verdadero positivo, verdadero negativo, falso positivo y falso negativo, respectivamente. La presencia de valores


elevados en la métrica PA evidencia la eficaz ocultación de píxeles correspondientes a nubes (enfoques conservadores para la detección de cielos despejados). Contrariamente, la manifestación de valores considerables en UA apunta a que el algoritmo es precavido al descartar píxeles que no pertenecen a nubes (estrategias cautelosas para la detección de nubes). Por su parte, los valores elevados en BOA están ligados a un equilibrio adecuado entre falsos positivos y falsos negativos. Cabe señalar que hemos generado una serie única de valores PA, UA y BOA para cada imagen contenida en el conjunto de validación.

4.2.4.2. Detector de cobertura de suelo

La validación del modelo de clasificación de cobertura del suelo se efectuó empleando el conjunto de datos de validación proveniente de DynamicWorld. Este conjunto de datos engloba 409 mosaicos provenientes de Sentinel-2. A diferencia del conjunto de datos de entrenamiento, cada mosaico de validación fue sometido a la revisión por parte de tres etiquetadores, sin que existiera la opción de discusión entre ellos. En este proceso de evaluación se recurrió a métricas análogas a las utilizadas en la detección de nubes.

Figura 29

Ubicación de las imágenes de testeo (puntos en blanco)



Fuente: Brown et al. (2022)

4.2.5. Inferencia y despliegue:

Ambos modelos han sido integrados dentro de una única clase torch.Module, lo cual posibilita la conjunción sinérgica de ambos modelos. Este enfoque se diseñó para manejar volúmenes masivos de datos satelitales, permitiendo la aplicación de métodos personalizados de procesamiento y clasificación de imágenes.


Una vez que los datos de entrada (Sentinel-2 L1C) ingresan al modelo de detección de nubes, el resultado obtenido es un tensor de 4 canales (Figura 30), con una estructura (N, 4, H, W); donde "N" representa los lotes de datos, "H" denota la dimensión de altura, y "W" refiere al ancho de la escena. Cada canal de este tensor indica la probabilidad correspondiente a una de las cuatro clases semánticas de nubes (como se detalla en la Tabla 5).

Una vez obtenida las probabilidades de las clases de nubes estas se usan para generar una máscara binaria que permite filtrar los píxeles contaminados y sin contaminación atmosférica (Figura 30). Los datos de entrada (Sentinel-2 L1C) entran al modelo de clasificación de cobertura del suelo junto con la máscara binaria. En este caso, el resultado del modelo de cobertura es un tensor de 9 canales, donde cada canal hace referencia a la probabilidad de que el píxel pertenezca a una de las clases. La segmentación de píxeles de nieve o hielo se logra mediante la aplicación del operador "argmax", que permite la identificación de los píxeles donde se registra el valor máximo de probabilidad. En el contexto del DynamicWorld, la clase correspondiente a nieve/hielo ocupa la posición 8. Por consiguiente, los píxeles clasificados como nieve serán aquellos que posean el valor más elevado en dicha posición.

Este procedimiento se repite para cada imagen dentro del entorno del presente estudio. En este sentido, en su totalidad, se procesaron más de 400 billones de píxeles, lo que subraya la magnitud del análisis y la capacidad del sistema desarrollado para manejar datos de gran envergadura.

Figura 30

Modelo de inferencia para la predicción de áreas con nieve/glaciar




4.2.6. Estimación del área glaciar

Como se vio en la Sección 2.2.16 el área glaciar es una región de hielo perpetuo que persiste durante todo el año, acumulándose a lo largo del tiempo y formando masas compactas y densas que pueden moverse y fluir bajo su propio peso, moldeando el paisaje subyacente y sirviendo como indicador clave de los cambios climáticos en la región (IPCC, 2018). En este sentido, esta definición muestra claramente que la detección del área glaciar depende de un

componente temporal. Mediante la presente hipótesis se estimó el área glaciár de la siguiente forma (Figura 4.12).

Figura 31

Modelo propuesto para la estimación del área glaciár



Capítulo V.

Resultados

5.1. Precisión de los modelos

5.1.1. Precisión del detector de nubes

Las métricas presentadas en el presente acápite revelan la alta eficacia del modelo de algoritmo propuesto en la detección de áreas contaminadas. Los resultados indican que el 70.66% de las imágenes de testeo (test dataset, en inglés) exhibieron un PA (precisión del productor) superior a 0.9, como se detalla en la Tabla 7. Una inspección visual adicional reveló que las discrepancias generadas por el detector de nubes pueden atribuirse principalmente a la imprecisión en la definición de los límites entre nube delgada y sombra de nube.

Es esencial señalar que, a pesar de estos desafíos, los valores obtenidos sustancialmente superan los obtenidos mediante Sen2Cor, algoritmo de la Agencia Espacial Europea (ESA), en las mismas condiciones. En una evaluación comparativa, la ESA logró únicamente un **16.6%** de píxeles que alcanzaron un PA en el mismo rango deseado (**PA > 0.9**).

Tabla 7

Métricas del algoritmo de detección de nubes utilizado en esta tesis

Experimento	CD algorithm	BOA	PA _{low} %	PA _{middle} %	PA _{high} %	UA _{low} %	UA _{middle} %	UA _{high} %
c. valido/ invalido	Human-level	0.99	1.03	14.8	84.17	0.13	2.33	97.55
	UNetMobV2	0.91	0.77	28.57	70.66	0	17.14	82.86
	Sen2Cor	0.67	13.77	69.63	16.6	1.05	18.58	80.37

En cuanto a los valores de UA (precisión del usuario), se observa una notable similitud entre los valores exhibidos por el modelo que proponemos y el Sen2Cor. Esto sugiere que ambos modelos tienden a sobrestimar de manera similar la extensión de la cobertura de nubes, aunque el modelo propuesto muestra una ligera tendencia menor a esta sobrestimación, como se refleja en las métricas UA_{middle} y UA_{high}.


Cabe destacar que los valores de BOA (precisión general equilibrada) consideran tanto los falsos positivos como los falsos negativos en sus evaluaciones, proporcionando así una evaluación holística del rendimiento. El BOA de 0.99 para el modelo de nivel humano (Aybar et al., 2022) y 0.91 para UNetM5.1obV2 demuestra una robustez significativa en la detección

de nubes en comparación con el 0.67 de Sen2Cor. Este alto rendimiento en la métrica BOA indica una mayor capacidad del modelo UNetMobV2 para equilibrar la precisión en la detección de nubes verdaderas y la exclusión de no nubes, lo cual es fundamental para aplicaciones prácticas en teledetección donde la confianza en la clasificación de nubes es crucial para el posterior análisis en la detección del area glaciar.

En la Figura 32 se presentan los datos de entrenamiento y validación utilizados para calibrar nuestro modelo. A través del análisis de esta figura, se puede observar que el modelo alcanza una convergencia satisfactoria tras aproximadamente 2000 iteraciones. Este punto de convergencia indica que el modelo ha aprendido de manera efectiva los patrones y características relevantes en los datos, lo que respalda la calidad y la confiabilidad de las predicciones realizadas.

Figura 32


Datos de entrenamiento del modelo de detección de nubes



En la Figura 33, se presentan las distribuciones de la cobertura de nubes (CC) correspondientes tanto al modelo de la ESA como al modelo que proponemos en esta investigación. Al realizar un análisis detallado de las curvas de densidad, resulta evidente que nuestro modelo propuesto identifica un mayor número de imágenes como "muy nubosas" ($CC > 0.75$) en comparación con el de la ESA. Asimismo, las diferencias notables en los picos de densidad indican que nuestro modelo estima que la gran mayoría de las imágenes en nuestro conjunto de datos presentan condiciones nubosas. En contraste, la distribución más dispersa de valores reportada por la ESA sugiere que esta característica no se encuentra tan acentuada en su análisis.

Figura 33

Curva de densidad entre la cobertura de nubes estimada a partir del modelo de la ESA y el modelo actual propuesto




5.1.2. Precisión del detector de nieve

Las métricas presentadas evidencian la eficacia destacada de nuestro algoritmo en la identificación de áreas con presencia de nieve/hielo, como se puede observar en la Figura 32 y Figura 33. A diferencia de la base de datos CloudSEN12, en DynamicWorld no se proporcionan datos sobre otros algoritmos, lo que imposibilitó llevar a cabo una comparación directa entre nuestro modelo y los valores registrados por la ESA en el conjunto de validación, como se hizo en la subsección 5.1.1.

Figura 34

Gráfico de barras de los valores de PA




Nota. Obtenido mediante la comparación con los datos de referencia del conjunto de validación del DynamicWorld

La **Figura 34** y **Figura 35** muestra gráficos de barras de las métricas PA para todas las clases que considera el DynamicWorld. Como puede observarse la clase snow presenta una eficiencia de 93.20 % para UA y de 86.6 % para PA. Los valores de UA y PA que presenta la clase nieve son los segundos más altos, sólo por debajo de la clase agua. A fin de tener referencia de la eficiencia del algoritmo de detección de nieve entre la ESA y el modelo propuesto realizamos una inspección visual detallada para todas las imágenes de nuestra área de estudio.

Figura 35

Gráfico de barras de los valores de UA




Nota. Obtenido mediante la comparación con los datos de referencia del conjunto de validación del DynamicWorld.

La **Figura 36** resume nuestros descubrimientos. Los valores magenta fuera de la cordillera de los andes pueden interpretarse como potenciales errores en el enmascaramiento de nubes. En la primera fila, se aprecia que claramente la ESA sobreestima el área glaciaria al malinterpretar los píxeles de nube como superficie nival, esto ocurre en gran parte de las imágenes y es esperable debido al bajo PA que reportamos en su detección de nubes (Sección 5.1.1). En algunos casos nuestro modelo entrenado en CloudSEN12 + DynamicWorld, muestra errores en los bordes (segunda fila). Esto es debido a que tanto el modelo de detección de nubes como el de nieve utilizan convoluciones como operador principal y en los bordes donde no existe información tienden a cometer errores. La tercera fila, muestra que la ESA no solo tiene problemas con los falsos negativos (PA) sino también con falsos positivos (UA), confundiendo glaciares con nubes.

Figura 36

*Comparación del modelo de la ESA con el modelo propuesto en esta investigación
(CloudSEN12 + DynamicWorld)*




Nota. Los pixeles en color crema muestran las areas sin nubes, mientras que los pixeles rosados muestran los pixeles con nieve. Pixeles sin mascara representan los pixeles etiquetados como nubes.

5.2. Detección del área glaciar

Una vez obtenido el cubo de datos (Figura 30) se procedió a estimar la ocurrencia para los 3 años de referencia. Los resultados muestran que la elección del año de referencia es muy importante ya que el área glaciar puede experimentar cambios significativos dependiendo de si se trata de un año húmedo o seco (Figura 37). Durante un año húmedo, las precipitaciones aumentan, lo que puede llevar a una mayor acumulación de nieve en las regiones glaciares. Esta acumulación de nieve puede compactarse y convertirse en hielo, contribuyendo al crecimiento y expansión del glaciar. Por otro lado, en un año seco (2020), las precipitaciones son escasas y las temperaturas pueden ser más altas, lo que provoca un aumento en el derretimiento del area nival. Nuestros resultados muestran que entre el 2019 y 2020 hubo retroceso de 6% y 4% según los modelos. Mientras que entre el 2020 y 2021 hubo un aumento de 3% y 1% estos cambios están relacionados a la variación interanual de las precipitaciones.

Figura 37


Comparación de la máxima área glaciar considerando los modelos de la ESA y CloudSEN12 + DynamicWorld



El área nival tiende fácilmente a ser confundido con la presencia de nubes. Por lo que la ocurrencia también puede ser utilizada como un indicador de la eficiencia de los modelos. La Figura 38 muestra los píxeles en donde la ocurrencia es mayor a 0.1. Estos mapas muestran que la ESA tiende a confundir significativamente los píxeles de nubes con nieve. Incluso reporta nieve en Huaycabamba - ceja de selva de Huánuco (esquina superior derecha). En comparación el modelo propuesto en esta investigación reduce significativamente los falsos positivos. Pero a diferencia del modelo propuesto por la ESA, este considera toda la zona de Antamina como área glaciar (ver área en blanco al centro derecha de la Figura 38, tercera columna).

Figura 38


Comparación de la máxima área glaciar considerando los modelos de la ESA y CloudSEN12 + DynamicWorld



Finalmente considerando nuestra metodología descrita en la Figura 39. Estimamos el área glaciar tanto con el modelo de la ESA como con CloudSEN12 + DynamicWorld.

Figura 39

Comparación del área glaciar considerando los modelos de la ESA y CloudSEN12 + DynamicWorld



La tabla proporciona una comparación directa entre las estimaciones de la cobertura glaciar utilizando dos modelos distintos: el modelo propuesto por CloudSEN12 + Dynamic World y el modelo desarrollado por la Agencia Espacial Europea (ESA). Presenta los datos de los años 2019 a 2022, mostrando las estimaciones del área glaciar en kilómetros cuadrados para cada año según cada modelo. Se observan variaciones en las estimaciones entre ambos modelos a lo largo de los años, lo que sugiere diferencias en la metodología o en la precisión de la información utilizada para la estimación. Esta comparación es esencial para evaluar la confiabilidad y la precisión de cada modelo en la estimación de la cobertura glaciar, lo que contribuye significativamente al entendimiento de los cambios en el hielo glaciar y sus implicaciones ambientales.


Tabla 8
Estimación del área glaciár

Año	Modelo propuesto	Modelo de la ESA
	Estimación del área glaciár (km2)	Estimación del área glaciár (km2)
2019	451.93	444.16
2020	430.61	439.35
2021	432.13	434.72
2022	419.48	430.611

5.3. Estacionalidad

La estacionalidad nos permite ver el impacto del cambio climático en los glaciares. El retroceso glaciár, es decir, el proceso cuando la ablación estacional puede superar la acumulación puede ser estimado de manera precisa analizando la tendencia temporal del cubo de datos. A diferencia de los *composites* anuales, los cubos de datos pueden estimar el área periglaciár, es decir el área circundante al glaciár afectada por flujos de agua de deshielo y procesos geomorfológicos relacionados con el movimiento del glaciár.

Figura 40




La Figura 40 muestra la ocurrencia de nieve para los nevados que están por encima de la ciudad de Huaraz (Churup, Palcaraju, Ranrapalca, Carhuascancha, etc.) considerando la

época seca y la época húmeda. Como se puede observar para la época seca tanto el modelo de la ESA como el modelo propuesto en esta tesis muestran un área glaciaria muy consistente, con una diferencia menor al 4%, la diferencia principal se da en el nevado Huascarán del Sur. Por otro lado, en la época húmeda se ve una diferencia mucho más notoria. Si consideramos una ocurrencia mayor al 0.25 la diferencia entre el modelo propuesto y el de la ESA es de casi el 30 %. La Figura 41 muestra el área glaciaria y periglaciaria estimada por ambos modelos.

Figura 41

Comparación entre el área glaciaria y periglaciaria



La tabla presenta una comparación entre las estimaciones del área glaciaria durante la temporada húmeda, utilizando dos modelos distintos: el modelo propuesto por CloudSEN12 + DynamicWorld y el modelo desarrollado por la Agencia Espacial Europea (ESA). Los datos abarcan un período de cuatro años, desde 2018 hasta 2022, y muestran las estimaciones del área glaciaria durante la temporada húmeda en kilómetros cuadrados para cada año según cada modelo. Se observa una notable variación en las cantidades detectadas, con diferencias en algunos casos de hasta casi un 30%. Esta discrepancia subraya la importancia de evaluar y comparar detalladamente los resultados de diferentes modelos en la estimación de la cobertura glaciaria durante períodos específicos, como la temporada húmeda, lo que contribuye a una comprensión más completa de los cambios en el hielo glaciario y sus implicaciones para el medio ambiente.

Tabla 9

Comparación de la temporada húmeda entre el modelo propuesto CloudSEN12 y el modelo de la ESA

Año	Modelo propuesto		Modelo de la ESA	
	Estimación del área glaciar (km2)	Temporada húmeda (km2)	Estimación del área glaciar (km2)	Temporada húmeda (km2)
2019	451.93	483.095	444.16	582.72
2020	430.61	465.932	439.35	580.61
2021	432.13	469.18	434.72	594.13
2022	419.48	451.37	430.611	582.82

La Figura 42 y Figura 43 muestra los resultados para todas las cuencas de nuestra área de estudio. Las cuencas que presentan diferencias más altas (rojo oscuro) muestran mayor sensibilidad a la erosión glaciar.

Figura 42

Comparación entre la temporada húmeda y seca según el producto de la ESA





Figura 43

Comparación entre la temporada húmeda y seca según el modelo actual propuesto



5.4. Comparación con el inventario del INAIGEM


La Figura 44 muestra una comparativa visual entre tres diferentes modelos de clasificación de áreas glaciares en dos nevados distintos, Huascaran y Mateo. Los modelos son el inventario del INAIGEM (Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña), la clasificación de la ESA (Sen2Cor), y el modelo propuesto.

- **1. INAIGEM - Inventariado:** Este modelo parece proporcionar una delimitación más precisa y detallada de las áreas glaciares, con validación en campo. En ambas filas, el modelo de INAIGEM muestra una diferenciación más clara entre las áreas glaciares y el terreno circundante. Las fronteras entre los glaciares y la tierra son más definidas, lo que sugiere un nivel alto de detalle en la detección de bordes. Sin embargo, también hay áreas no glaciares pequeñas que parecen estar marcadas como glaciares, lo que podría indicar un grado de sobrestimación en la clasificación.
- **2. Sen2Cor:** La clasificación proporcionada por la ESA muestra una cobertura glacial mucho más extensa y menos detallada en comparación con el INAIGEM. Las áreas glaciares se muestran como bloques más grandes, con menos variación y menos bordes irregulares. Esto podría ser un indicio de una menor precisión en la identificación de los límites del glaciar, lo que resulta en una sobrestimación general de la extensión glacial. Es evidente especialmente en la imagen del nevado Mateo, donde la cobertura glacial de la ESA es significativamente más extensa que en el modelo de INAI.

- **3. CloudSEN12 + DynamicWorld:** La combinación de estos dos modelos parece ofrecer un término medio entre el INAIGEM y el Sen2Cor. Hay más detalle en la clasificación de las áreas glaciares que en la de la ESA, pero con menos precisión que el INAIGEM. Los bordes del glaciar se ven más naturales y menos abruptos que en la ESA, sugiriendo una mejor capacidad para capturar la variabilidad natural de los bordes glaciares. No obstante, se observan algunos espacios sin clasificar dentro de las áreas glaciares, lo que podría indicar una cierta tendencia a la subestimación en comparación con el INAIGEM.

Figura 44

Comparación entre la area glaciar para el nevado Pucajirca (primera fila) y Mateo (segunda fila)



Capítulo VI.

Discusión de Resultados

La estimación del área glaciaria en los ecosistemas de alta montaña (EAM) del Perú ha cobrado especial relevancia debido al déficit en el monitoreo de estos entornos. Esta carencia ha limitado la comprensión de los servicios ecosistémicos que brindan y de los efectos del cambio climático sobre ellos.

Según Aldoseri et al. (2023), los algoritmos de IA impulsados por datos (*data-driven*), se basan en conjuntos grandes de datos para identificar patrones y tendencias que son difíciles de detectar mediante métodos tradicionales (*knowledge-driven*). En este contexto, la capacidad de la IA se presenta como un recurso valioso en la comprensión y el abordaje de los impactos del cambio climático en los ecosistemas de montaña, incluyendo la evaluación de la extensión de los glaciares y su evolución temporal.

El estudio ha demostrado que es posible calcular efectivamente el área glaciaria para el período de 2018 a 2022 utilizando tecnologías de cubos de datos e inteligencia artificial. Los resultados revelan que, en 2020, el área glaciaria alcanzó los 432.13 km². Esta cifra, al compararse con los datos proporcionados por el INAIGEM en 2023, muestra una variación de tan solo el 1.7%, lo que confirma la precisión y fiabilidad del método empleado. Este enfoque automatizado ofrece ventajas sustanciales sobre los métodos convencionales, especialmente en términos de eficiencia y precisión en la monitorización de los cambios glaciares. Sin embargo, es crucial considerar algunas limitaciones, como la necesidad de datos precisos de entrada y la continua validación para mantener la precisión en el tiempo. Además, aunque este método proporciona una herramienta valiosa, no puede reemplazar por completo la importancia de las observaciones de campo y otros análisis complementarios.

La comparación entre el algoritmo de IA utilizado (CloudSEN12 + DynamicWorld) y el modelo Sen2Cor para la identificación de áreas glaciares reveló notables diferencias en la precisión de la detección de nubes y áreas contaminadas, evaluadas a través de las métricas de precisión del productor (PA) y precisión del usuario (UA).

En cuanto al DynamicWorld, el algoritmo mostró una efectividad sobresaliente en la identificación de áreas con presencia de nieve o hielo. Sin embargo, se observaron ciertos errores en los bordes, debido a la naturaleza de los operadores convolucionales de la CNN utilizados en áreas donde la información es limitada, lo que ocasionó imprecisiones en estos

límites. Las etiquetas no logran capturar completamente la complejidad de los ecosistemas de alta montaña en el Perú, resultando en algunos casos en una delimitación demasiado general de la clase hielo/nieve, que no representa con precisión la realidad de estas áreas y tiende a la sobrestimación.

Respecto a la identificación de nubes, CloudSEN12 superó significativamente a Sen2Cor en términos de eficacia. Existe evidencia sólida, como lo respalda Aybar et al. (2022), de la superioridad del enmascaramiento de CloudSEN12 en comparación con el proporcionado por Sen2Cor. Esto resulta en un cubo de datos con una menor cantidad de falsos negativos en la delimitación de áreas cubiertas por nubes. Sin embargo, enfrentó desafíos al discernir entre nubes delgadas y sombras de nubes, una distinción crítica para la precisión global del modelo. Estas dificultades se manifestaron en una tendencia a sobrestimar áreas nubosas y en errores visuales específicos donde los bordes de nubes se confundían con sus sombras.

La convergencia lograda durante el entrenamiento del modelo sugiere que, si bien el aprendizaje es efectivo para detectar patrones nubosos más evidentes, se necesita una estrategia mejorada para casos más sutiles. La inclusión de un espectro más amplio de ejemplos de nubes delgadas y sombras en el conjunto de entrenamiento, junto con la aplicación de técnicas avanzadas de segmentación de imágenes, podría mejorar sustancialmente la habilidad del modelo para distinguir entre estos elementos con similitudes visuales. Aquello resulta fundamental para aplicaciones de teledetección, donde la precisión en la clasificación de nubes determina la confiabilidad de los análisis posteriores en estudios ambientales y climáticos.

Capítulo VII.

Conclusiones

En resumen, este estudio ha demostrado la eficacia de la combinación de tecnologías de cubos de datos e inteligencia artificial para estimar la cobertura glaciar durante el período de 2018 a 2022. Los resultados revelan que, en 2020, el área glaciar se calculó en 430.13 km², con una variación mínima del 1.7% en comparación con los datos publicados por el INAIGEM en 2023. Estos resultados validan la precisión y la confiabilidad del enfoque propuesto. Además, se ha destacado que este método automatizado ofrece ventajas sustanciales sobre las técnicas convencionales, particularmente en términos de monitoreo continuo y eficiente de los cambios glaciares. En consecuencia, este estudio sugiere que la aplicación de inteligencia artificial y cubos de datos representa una herramienta valiosa para la gestión y la conservación de los recursos glaciares en el futuro.

La implementación de la arquitectura U-net ha mejorado la precisión en la estimación de áreas glaciares comparada con métodos tradicionales, aunque requirió un mayor poder computacional. Los resultados, al ser comparados con el Inventario Nacional de Glaciares del INAIGEM, demostraron una alta fiabilidad y precisión. Esta mejora justifica la inversión en recursos computacionales, resaltando el valor de U-net para la monitorización avanzada de glaciares.

El análisis del DynamicWorld reveló una efectividad destacada en la identificación de áreas con nieve o hielo. No obstante, se notaron errores en los bordes debido a las limitaciones en la representación de la complejidad de los ecosistemas de alta montaña. En comparación con los modelos del INAIGEM y la ESA, el primero mostró una precisión detallada en la clasificación de áreas glaciares, mientras que la ESA proporcionó una visión más conservadora y menos detallada de la cobertura glaciar. La combinación de CloudSEN12 con DynamicWorld presentó un equilibrio entre precisión y cobertura, siendo una opción intermedia adecuada para estudios de variabilidad glaciar y evaluaciones del cambio climático a nivel local.

El método desarrollado utilizando cubos de datos ha permitido actualizar la estimación de la cobertura glaciar cada vez que se capta una imagen del Sentinel-2, aproximadamente cada 10 días. El tiempo de procesamiento necesario para entrenar la red neuronal es de 5 días continuos, lo que posibilita ofrecer una estimación actualizada de la cobertura glaciar cada 15 días. Esta frecuencia y automatización del método aseguran una monitorización constante y

eficiente de los cambios glaciares. Aunque el proceso es intensivo en recursos, especialmente en cuanto a la capacidad computacional necesaria, futuras investigaciones podrían explorar optimizaciones para reducir el tiempo de entrenamiento y los recursos requeridos, mejorando así la eficiencia del sistema.

El modelo propuesto demostró efectividad en diferenciar entre nubes y glaciar, aunque presentó dificultades para distinguir nubes delgadas de sus sombras. Comparativamente, los resultados superaron a los del modelo de la ESA, que tiende a subestimar la cobertura glaciar por confundirla con nubes, dado que su modelo no está adaptado a las características específicas de los Andes.

Estos hallazgos subrayan la importancia de la IA en la evaluación de la cobertura glaciar y sus cambios. La comprensión detallada proporcionada por este estudio es fundamental para apreciar el impacto del retroceso glaciar en los ecosistemas de montaña y la disponibilidad de recursos hídricos. Este trabajo no solo contribuye al conocimiento científico, sino que también informa las decisiones políticas y de conservación relacionadas con los ecosistemas de montaña en Perú.

Capítulo VIII.

Recomendaciones

A partir de los resultados obtenidos y las observaciones realizadas durante este estudio sobre la estimación del área glaciar en los ecosistemas de alta montaña del Perú, se sugieren las siguientes recomendaciones:

- Se recomienda continuar explorando técnicas avanzadas de inteligencia artificial para refinar la identificación de nubes delgadas y sombras. Este enfoque busca reducir los errores y mejorar la precisión general en la delimitación de áreas cubiertas por nubes.
- Es esencial mejorar la calidad de las etiquetas en DynamicWorld para representar con mayor precisión la diversidad y complejidad de los ecosistemas de montaña en Perú. Esto permitirá una clasificación más detallada y exacta de las áreas de hielo y nieve.
- Se sugiere continuar en la investigación y mejorar de los algoritmos que capturen con mayor precisión la variabilidad estacional y los cambios interanuales en la cobertura glaciar. Esto mejorará la capacidad de distinguir entre la nieve estacional y las formaciones glaciares permanentes, un aspecto crucial para comprender el impacto del cambio climático en estos ecosistemas.
- Se alienta a la creación de modelos que combinen diferentes fuentes de datos, como observaciones satelitales, información de campo y datos climáticos, para obtener estimaciones más precisas y completas del área glaciar. La combinación de diversas fuentes de información podría mejorar significativamente la comprensión de los procesos glaciares y su evolución a lo largo del tiempo.
- Es crucial validar los resultados obtenidos a través de técnicas de teledetección con mediciones y observaciones directas en terreno. Esto asegurará la precisión de los modelos y su validez para la estimación del área glaciar en los ecosistemas de alta montaña del Perú.

- Finalmente, fomentar la colaboración entre instituciones, investigadores y entidades gubernamentales para compartir datos, metodologías y experiencias en el monitoreo y estimación del área glaciaria. El intercambio de información puede enriquecer los modelos existentes y mejorar las estrategias de gestión y conservación de estos valiosos ecosistemas.

Referencias

- Aldoseri, A., Al-Khalifa, K. N., & Hamouda, A. M. (2023). Re-Thinking Data Strategy and Integration for Artificial Intelligence: Concepts, Opportunities, and Challenges. *Applied Sciences*, 13(12), 7082. <https://doi.org/10.3390/app13127082>
- Alpaydin, E. (2016). *Machine Learning: The New AI*. MIT Press.
- Aryal, B. (2022). *Glacier Segmentation from Remote Sensing Imagery Using Deep Learning—ProQuest*.
<https://www.proquest.com/openview/bd19be7f83315b9cf23992ee6a3bec68/1?pq-origsite=gscholar&cbl=18750&diss=y>
- Aybar, C., Ysuhuaylas, L., Loja, J., Gonzales, K., Herrera, F., Bautista, L., ... & Gómez-Chova, L. (2022). CloudSEN12, a global dataset for semantic understanding of cloud and cloud shadow in Sentinel-2. *Scientific data*, 9(1), 782.
- Bamber, J. L., & Payne, A. J. (2004). *Mass balance of the cryosphere: Observations and modelling of contemporary and future changes*.
<https://www.cabdirect.org/cabdirect/abstract/20073109092>
- Bhardwaj, A., Di, W., & Wei, J. (2018). *Deep Learning Essentials: Your hands-on guide to the fundamentals of deep learning and neural network modeling*. Packt Publishing Ltd.
- Bini, S. A. (2018). Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care? *The Journal of Arthroplasty*, 33(8), 2358-2361.
<https://doi.org/10.1016/j.arth.2018.02.067>
- Brown, C. F., Brumby, S. P., Guzder-Williams, B., Birch, T., Brooks Hyde, S., Mazzariello, J., Czerwinski, W., Pasquarella, V. J., Haertel, R., Ilyushchenko, S., Schwehr, K., Weisse, M., Stolle, F., Hanson, C., Guinan, O., Moore, R., & Tait, A. M. (2022). Dynamic World, Near real-time global 10 m land use land cover mapping. *Sci Data*, 9, 251 <https://doi.org/10.1038/s41597-022-01307-4>
- Burns, P., & Nolin, A. (2014). Using atmospherically-corrected Landsat imagery to measure glacier area change in the Cordillera Blanca, Peru from 1987 to 2010. *Remote Sensing of Environment*, 140, 165-178. <https://doi.org/10.1016/j.rse.2013.08.026>
- Camps-Valls, G., Tuia, D., Gómez-Chova, L., Jiménez, S., & Malo, J. (2012). *Remote Sensing Image Processing*. Springer International Publishing.
<https://doi.org/10.1007/978-3-031-02247-0>

- Chang, N.-B., & Bai, K. (2018). *Multisensor Data Fusion and Machine Learning for Environmental Remote Sensing*. CRC Press.
- Chen, L., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). *Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation*. ArXiv. /abs/1802.02611
- Chi, M., Plaza, A., Benediktsson, J. A., Sun, Z., Shen, J., & Zhu, Y. (2016). Big Data for Remote Sensing: Challenges and Opportunities. *Proceedings of the IEEE*, 104(11), 2207-2219. <https://doi.org/10.1109/JPROC.2016.2598228>
- Chollet, F. (2021). *Deep Learning with Python*. Simon and Schuster.
- Chuvieco, E. (1990). Fundamentos de teledetección espacial. <https://bibliotecadigital.ciren.cl/handle/20.500.13082/23090>
- Chuvieco, E. (2010). *Teledetección Ambiental: La observación de la Tierra desde el espacio*. Editorial Planeta.
- Cogley, J. G., Hock, R., Rasmussen, L. A., & Arendt, A. A. (2012). Review of Glossary of Glacier Mass Balance and Related Terms. *Arctic, Antarctic, and Alpine Research*, 44(2), 256-258.
- Colque, P. E. (2019). *Estimación de área glaciar utilizando Redes Neuronales convolucionales U-Net en imágenes multiespectrales sentinel 2 en el glaciar ausangate, 2019*. Universidad Nacional del Altiplano. <https://repositorio.unap.edu.pe/handle/20.500.14082/12231>
- Cuffey, K. M., & Paterson, W. S. B. (2010). *The Physics of Glaciers*. Academic Press.
- EcuRed. (2020). *Precipitación*. <https://www.ecured.cu/Precipitaci%C3%B3n>
- Ferrando, F. (2014). *Análisis y propuesta de definición de “Glaciar”*. <https://www.camara.cl/verDoc.aspx?prmID=18201&prmTIPO=DOCUMENTOCOMISION>
- Ferreira, K. R., Queiroz, G. R., Vinhas, L., Marujo, R. F. B., Simoes, R. E. O., Picoli, M. C. A., Camara, G., Cartaxo, R., Gomes, V. C. F., Santos, L. A., Sanchez, A. H., Arcanjo, J. S., Fronza, J. G., Noronha, C. A., Costa, R. W., Zaglia, M. C., Zioti, F., Korting, T. S., Soares, A. R., ... Fonseca, L. M. G. (2020). Earth Observation Data Cubes for Brazil: Requirements, Methodology and Products. *Remote Sensing*, 12(24). <https://doi.org/10.3390/rs12244033>
- Francou, B., & Pouyaud, B. (2004). *Métodos de observación de glaciares en los Andes tropicales—Mediciones de terreno y procesamientos de datos*. IRD. <https://doi.org/10.13140/RG.2.1.4220.8164>

- Francou, B., & Pouyaud, B. (2008). *Glaciares: ¿cómo y dónde estudiarlos?*
https://horizon.documentation.ird.fr/exl-doc/pleins_textes/divers13-12/010042831.pdf
- Frantz, D. (2020). *The Datacube—FORCE 3.0 documentation*. <https://force-eo.readthedocs.io/en/latest/howto/datacube.html>
- Friedman, J. H. (2001). Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 25(9), 1189-1232. <https://www.jstor.org/stable/2699986>
- Gámez, W. (2010). *Texto básico de hidrología*. Universidad Nacional Agraria.
<https://repositorio.una.edu.ni/2464/>
- Giuliani, G., Chatenoux, B., De Bono, A., Rodila, D., Richard, J.-P., Allenbach, K., Dao, H., & Peduzzi, P. (2017). Building an Earth Observations Data Cube: Lessons learned from the Swiss Data Cube (SDC) on generating Analysis Ready Data (ARD). *Big Earth Data*, 1(1-2), 100-117. <https://doi.org/10.1080/20964471.2017.1398903>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Haut, J. M., Paoletti, M. E., Moreno-Álvarez, S., Plaza, J., Rico-Gallego, J.-A., & Plaza, A. (2021). Distributed Deep Learning for Remote Sensing Data Interpretation. *Proceedings of the IEEE*, 109(8), 1320-1349.
<https://doi.org/10.1109/JPROC.2021.3063258>
- INAIGEM. (2017). *Manual metodológico de inventario nacional de glaciares*.
<https://sigrid.cenepred.gob.pe/sigridv3/documento/10535>
- IPCC. (2001). *The intergovernmental panel on climate change*.
<https://www.ipcc.ch/site/assets/uploads/2001/04/doc3d.pdf>
- IPCC. (2014). *Climate Change 2013 – The Physical Science Basis*. Cambridge University Press. <https://doi.org/10.1017/CBO9781107415324>
- IPCC. (2018). *Global Warming of 1.5°C*. Cambridge University Press.
<https://doi.org/10.1017/9781009157940>
- Jakhar, D., & Kaur, I. (2020). Artificial intelligence, machine learning and deep learning: Definitions and differences. *Clinical and Experimental Dermatology*, 45(1), 131-132.
<https://doi.org/10.1111/ced.14029>
- Jensen, C. S., Pedersen, T. B., & Thomsen, C. (2010). *Multidimensional Databases and Data Warehousing*. Springer International Publishing. https://doi.org/10.1007/978-3-031-01841-1_2

- Jiao, L., Huo, L., Hu, C., & Tang, P. (2020). Refined UNet V2: End-to-End Patch-Wise Network for Noise-Free Cloud and Shadow Segmentation. *Remote Sensing*, 12(21), 3530. <https://doi.org/10.3390/rs12213530>
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15-25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Kargel, J. S., Leonard, G. J., Bishop, M. P., Käab, A., & Raup, B. H. (2014). *Global Land Ice Measurements from Space*. Springer.
- Kaser, G., & Osmaston, H. (2002). *Tropical Glaciers*. Cambridge University Press.
- Kaser, G., Ames, A., & Zamora, M. (1990). Glacier Fluctuations and Climate in the Cordillera Blancaq, Peru. *Annals of Glaciology*, 14, 136-140. <https://doi.org/10.3189/S0260305500008430>
- Kaser, G., Fountain, A. G., & Jansson, P. (2003). *A manual for monitoring the mass balance of mountain glaciers: With particular attention to low latitude characteristics*. <https://snia.mop.gob.cl/repositorioidga/handle/20.500.13000/1467>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). *LightGBM: A Highly Efficient Gradient Boosting Decision Tree*. <https://dl.acm.org/doi/10.5555/3294996.3295074>
- Kumar, K., & Thakur, G. S. M. (2012). Advanced Applications of Neural Networks and Artificial Intelligence: A Review. *International Journal of Information Technology and Computer Science*, 4(6), 57-68. <https://doi.org/10.5815/ijitcs.2012.06.08>
- Labelbox. (2024). *Portal web de Label Box*. <https://labelbox.com/education/>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553). <https://doi.org/10.1038/nature14539>
- Leon, E. P. (2022). *Influencia de la temperatura y la precipitación en el balance de masa glaciar en la cordillera blanca, 1962 – 2020* (Tesis de licenciatura, Universidad Nacional Santiago Antúnez de Mayolo). <http://repositorio.unasam.edu.pe/handle/UNASAM/5496>
- Lewis, A., Lymburner, L., Purss, M. B. J., Brooke, B., Evans, B., Ip, A., Dekker, A. G., Irons, J. R., Minchin, S., Mueller, N., Oliver, S., Roberts, D., Ryan, B., Thankappan, M., Woodcock, R., & Wyborn, L. (2016). Rapid, high-resolution detection of environmental change over continental scales from satellite data – the Earth Observation Data Cube. *International Journal of Digital Earth*, 9(1), 106-111. <https://doi.org/10.1080/17538947.2015.1111952>

- Li, J., Meng, L., Wang, F. Z., Zhang, W., & Cai, Y. (2014). A Map-Reduce-enabled SOLAP cube for large-scale remotely sensed data aggregation. *Computers & Geosciences*, 70, 110-119. <https://doi.org/10.1016/j.cageo.2014.05.008>
- Long, J., Shelhamer, E., Darrell; T. (2015). *Fully Convolutional Networks for Semantic Segmentation*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
https://openaccess.thecvf.com/content_cvpr_2015/html/Long_Fully_Convolutional_Networks_2015_CVPR_paper.html
- Luger, G. F. (2009). *Artificial intelligence: Structures and strategies for complex problem solving*. Pearson Addison-Wesley.
- Madrid, M. (2023). *Ciclo del Agua: Importancia, Procesos y Conservación*. Geoplaneta.net.
<https://geoplaneta.net/ciclo-del-agua-importancia-procesos-y-conservacion/>
- Martín, I., & Chuvieco, E. (1995). Cartografía y evaluación superficial de grandes incendios a partir de imágenes de satélite. *Ecología*, 9, 9-22.
- Mathworks. (2018). *Introducing Deep Learning with MATLAB*.
<https://www.mathworks.com/campaigns/offers/deep-learning-with-matlab.html>
- Mellit, A., & Kalogirou, S. (2021). Artificial intelligence and internet of things to improve efficacy of diagnosis and remote sensing of solar photovoltaic systems: Challenges, recommendations and future directions. *Renewable and Sustainable Energy Reviews*, 143, 110889. <https://doi.org/10.1016/j.rser.2021.110889>
- Meneses, P., & Almeida, T. (2012). *Introdução ao processamento de imagens de sensoriamento remoto*.
https://www.researchgate.net/publication/332292728_INTRODUCAO_AO_PROCESSAMENTO_DE_IMAGENS_DE_SENSORIAMENTO_REMOTO
- Mohajerani, Y., Wood, M., Velicogna, I., & Rignot, E. (2019). Detection of Glacier Calving Margins with Convolutional Neural Networks: A Case Study. *Remote Sensing*, 11(1), Article 1. <https://doi.org/10.3390/rs11010074>
- Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of Big Data*, 2(1), 1. <https://doi.org/10.1186/s40537-014-0007-7>
- National Aeronautics and Space Administration. (2010). *Introduction to the Electromagnetic Spectrum—NASA Science*. https://science.nasa.gov/ems/01_intro/
- Nielsen, M. A. (2015). *Neural Networks and Deep Learning*.
<http://neuralnetworksanddeeplearning.com>

- OGC. (2020). *Community practices*. Open Geospatial Consortium.
<https://www.ogc.org/standards/cp/>
- Pelletier, C., Webb, G. I., & Petitjean, F. (2019). Temporal Convolutional Neural Network for the Classification of Satellite Image Time Series. *Remote Sensing*, 11(5).
<https://doi.org/10.3390/rs11050523>
- Pérez, C., & Muñoz, A. (2006). Teledetección: Nociones y Aplicaciones.
- Popovich, V., & Galiano, F. (2018). *Algorithmic Component of an Earth Remote-Sensing Data-Analysis System*. Springer International Publishing. https://doi.org/10.1007/978-3-319-59539-9_10
- Prashant, P. (2022, junio). Mapping of glacier extend using deep learning method [Info:eu-repo/semantics/masterThesis]. University of Twente. <https://essay.utwente.nl/90934/>
- Rathore, M. M. U., Paul, A., Ahmad, A., Chen, B.-W., Huang, B., & Ji, W. (2015). Real-Time Big Data Analytical Architecture for Remote Sensing Application. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(10), 4610-4621. <https://doi.org/10.1109/JSTARS.2015.2424683>
- Rawat, W., & Wang, Z. (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, 29(9), 2352-2449.
https://doi.org/10.1162/neco_a_00990
- Rittger, K., Raleigh, M. S., Dozier, J., Hill, A. F., Lutz, J. A., & Painter, T. H. (2020). Canopy Adjustment and Improved Cloud Detection for Remotely Sensed Snow Cover Mapping. *Water Resources Research*, 56(6), e2019WR024914.
<https://doi.org/10.1029/2019WR024914>
- Rius, R., & Gonzalez, J. A. (2011). Software libre: Una oportunidad para los investigadores. *Medicina Clínica*, 136(5), 205-206. <https://doi.org/10.1016/j.medcli.2010.05.011>
- Rivera, A., Bown, F., Napoleoni, F., Muñoz, C., & Vuille, M. (2017). Manual Balance de masa glaciar. <http://repositorioslatinoamericanos.uchile.cl/handle/2250/3347904>
- Rivera, H. (2005). Geología general. Universidad Nacional Mayor de San Marcos, 2.
- Rivera, H. (2011). *Geología general*. Megabyte. <http://biblioteca.unfv.edu.pe/cgi-bin/koha/opac-detail.pl?biblionumber=60638>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-Net: Convolutional Networks for Biomedical Image Segmentation*. arXiv.Org. <https://arxiv.org/abs/1505.04597v1>
- Sabri, Y., Bahja, F., Siham, A., & Maizate, A. (2021). Cloud Computing in Remote Sensing: Big Data Remote Sensing Knowledge Discovery and Information Analysis.

- International Journal of Advanced Computer Science and Applications (IJACSA)*, 12(5). <https://doi.org/10.14569/IJACSA.2021.01205104>
- Sagredo, E. A., & Lowell, T. V. (2012). Climatology of Andean glaciers: A framework to understand glacier response to climate change. *Global and Planetary Change*, 86, 101-109. <https://doi.org/10.1016/j.gloplacha.2012.02.010>
- Sagredo, E. A., Rupper, S., & Lowell, T. V. (2014). Sensitivities of the equilibrium line altitude to temperature and precipitation changes along the Andes. *Quaternary Research*, 81(2), 355-366. <https://doi.org/10.1016/j.yqres.2014.01.008>
- Samuel, A. L. (1967). Some Studies in Machine Learning Using the Game of Checkers. II—Recent Progress. *IBM Journal of Research and Development*, 11(6), 601-617. <https://doi.org/10.1147/rd.116.0601>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. (2018) Mobilenetv2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 4510-4520. <https://doi.org/10.1109/CVPR.2018.00474>
- Sarochar, H. (2009). *Introducción a la meteorología general*. Universidad Nacional de la Plata. http://extension.fcaglp.unlp.edu.ar/content/obs/descargas/Introduccion_a_la_Meteorologia_I.pdf
- Singh, V. P., Singh, P., & Haritashya U. K. (2011). *Encyclopedia of Snow, Ice and Glaciers*. Springer. https://doi.org/10.1007/978-90-481-2642-2_341
- Sobrino, J. A. (2001). *Teledetección*. Universitat de València.
- Strobl, P., Baumann, P., Lewis, A., Szantoi, Z., Killough, B., Purss, M., Craglia, M., Nativi, S., Held, A., & Dhu, T. (2017). *The Six Faces of the Data Cube*. https://www.researchgate.net/profile/Zoltan-Szantoi/publication/321385814_The_Six_Faces_of_the_Data_Cube/links/5a200deaaca272088b23f822/The-Six-Faces-of-the-Data-Cube.pdf
- Sun, Z., Di, L., & Fang, H. (2019). Using long short-term memory recurrent neural network in land cover classification on Landsat and Cropland data layer time series. *International Journal of Remote Sensing*, 40(2), 593–614. <https://doi.org/10.1080/01431161.2018.1516313>
- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., & Brisco, B. (2020). Google Earth Engine for geo-big data applications: A meta-analysis and systematic

- review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 152-170.
<https://doi.org/10.1016/j.isprsjprs.2020.04.001>
- Tempfli, K., Huurneman, G. C., Bakker, W. H., Janssen, L. L. F., Feringa, W. F., Gieske, A. S. M., Grabmaier, K. A., Hecker, C. A., Horn, J. A., Kerle, N., Meer, F. D. van der, Parodi, G. N., Pohl, C., Reeves, C. V., Ruitenbeek, F. J. A. van, Schetselaar, E. M., Weir, M. J. C., Westinga, E., & Woldai, T. (2009). *Principles of remote sensing: An introductory textbook*. International Institute for Geo-Information Science and Earth Observation. <https://research.utwente.nl/en/publications/principles-of-remote-sensing-an-introductory-textbook-4>
- Tiede, D., Schwendemann, G., Alobaidi, A., Wendt, L., & Lang, S. (2021). Mask R-CNN-based building extraction from VHR satellite data in operational humanitarian action: An example related to Covid-19 response in Khartoum, Sudan. *Transactions in GIS*, 25, 1213-1227. DOI: 10.1111/tgis.12766.
- Veettil, B. K., & Kamp, U. (2017). Remote sensing of glaciers in the tropical Andes: A review. *International Journal of Remote Sensing*, 38(23), 7101-7137.
<https://doi.org/10.1080/01431161.2017.1371868>
- Veettil, B. K., & Kamp, U. (2019). Global Disappearance of Tropical Mountain Glaciers: Observations, Causes, and Challenges. *Geosciences*, 9(5).
<https://doi.org/10.3390/geosciences9050196>
- Visvikis, D., Cheze Le Rest, C., Jaouen, V., & Hatt, M. (2019). Artificial intelligence, machine (deep) learning and radio(geno)mics: Definitions and nuclear medicine imaging applications. *European Journal of Nuclear Medicine and Molecular Imaging*, 46(13), 2630-2637. <https://doi.org/10.1007/s00259-019-04373-w>
- Vozel, B., Lukin, V., & Serra-Sagristà, J. (2021). Editorial to Special Issue “Remote Sensing Data Compression”. *Remote Sensing*, 13(18). <https://doi.org/10.3390/rs13183727>
- Wang, Y., Huang, S., Liu, D., & Wang, B. (2012). Research Advance on Band Selection-Based Dimension Reduction of Hyperspectral Remote Sensing Images. *2012 2nd International Conference on Remote Sensing, Environment and Transportation Engineering*, 1-4. <https://doi.org/10.1109/RSETE.2012.6260684>
- Xu, D., Ma, Y., Yan, J., Liu, P., & Chen, L. (2020). Spatial-feature data cube for spatiotemporal remote sensing data processing and analysis. *Computing*, 102(6), 1447-1461. <https://doi.org/10.1007/s00607-018-0681-y>

- Yan, D., Huang, C., Ma, N., & Zhang, Y. (2020). Improved Landsat-Based Water and Snow Indices for Extracting Lake and Snow Cover/Glacier in the Tibetan Plateau. *Water*, 12(5), Article 5. <https://doi.org/10.3390/w12051339>
- Zupanc, A. (2017). *Improving Cloud Detection with Machine Learning*. Sentinel Hub Blog. <https://www.sentinel-hub.com/blog/improving-cloud-detection-machine-learning>