



UNIVERSIDAD PERUANA
CAYETANO HEREDIA

Facultad de

Ciencias e Ingeniería

OPTIMIZACIÓN DEL MAPEO DE SUPERFICIES GLACIARES MEDIANTE
UN ALGORITMO DE CLASIFICACIÓN DE PÍXELES PERMANENTES Y
TEMPORALES EN LA SUBCUENCA QUILLCAY, ANCASH - PERÚ

TESIS PARA OPTAR POR EL TÍTULO PROFESIONAL DE INGENIERO
AMBIENTAL

AUTOR(ES)

SAMANTHA BRISEYDA ACHIC ARREDONDO

RODRIGO JULIO CUEVA ESPINOZA

ASESOR(ES)

BRAM LEO WILLEMS

LIMA - PERÚ

2026

Jurado calificador

Presidente: Mg. Danny Emerson Robles Sanchez

Vocal: Ing. Oscar Dante Vilca Gomez

Secretario: Mg. Albert Johan Mamani Larico

DECLARACIÓN DE ORIGINALIDAD

Los egresados:

Nº	APELLIDOS Y NOMBRES
1.	ACHIC ARREDONDO SAMANTHA BRISEYDA
2.	CUEVA ESPINOZA RODRIGO JULIO

(Agregar más ediciones al key más autores)

Pertenecientes al programa de la **CARRERA PROFESIONAL DE INGENIERÍA AMBIENTAL**, autores del trabajo titulado: **OPTIMIZACIÓN DEL MAPEO DE SUPERFICIES GLACIARES MEDIANTE UN ALGORITMO DE CLASIFICACIÓN DE PÍXELES PERMANENTES Y TEMPORALES EN LA SUBCUENCA QUILLCAY, ANCASH - PERÚ**, el cual ha sido elaborado, sustentado y aprobado, según corresponda, para optar por el **TÍTULO PROFESIONAL DE INGENIERO AMBIENTAL** bajo la modalidad de **TESIS**. En calidad de docentes asesores de la Universidad Peruana Cayetano Heredia:

Nº	APELLIDOS Y NOMBRES DEL DOCENTE	FACULTAD	NIVEL DE ASESORÍA
1.	BRAM LEO WILLEMS	FACI	ASESOR

Declaramos que el contenido del presente documento es original y que las citas y referencias a otros autores cumplen con las normas académicas establecidas. En ese sentido, hacemos constar que:

- El documento presenta un porcentaje de similitud de **11%**, según el reporte emitido por el software **Turnitin®** (identificador de entrega: **3632786877**; fecha de entrega: **24/08/2026**).
- Tras una revisión detallada del reporte y del contenido del trabajo en cuestión, no se han identificado indicios de plagio.
- Se certifica que el documento respeta los principios de integridad académica y cumple con los requisitos institucionales de originalidad.

Lugar y fecha: **Lima, 24 de agosto de 2026**



Firma del asesor
Nº DNI: 48373712
ORCID: 0000-0002-0666-4655

ÍNDICE

RESUMEN	1
ABSTRACT.....	2
I. INTRODUCCIÓN.....	3
1.1. La importancia de los glaciares tropicales	3
1.2. Retroceso glaciar en los Andes peruanos	6
1.3. Rol de los glaciares tropicales en la subcuenca Quillcay	9
1.4. Riesgos asociados al retroceso glaciar en la subcuenca Quillcay.....	11
1.5. Teledetección en el monitoreo glaciar	15
1.6. Índices espectrales para la detección de glaciares	19
1.7. Uso del aprendizaje automático para la clasificación de glaciares	21
1.8. Justificación de la investigación	25
II. PREGUNTA DE INVESTIGACIÓN Y OBJETIVOS	28
2.1. Pregunta de investigación	28
2.2. Objetivos.....	28
2.2.1. Objetivo general.....	28
2.2.2. Objetivos específicos	28
III. MATERIALES Y MÉTODOS	29
3.1. Tipo de estudio.....	29
3.2. Área de estudio	29
3.3. Materiales.....	32
3.4. Diseño de investigación	33
3.5. Objetivo específico 1	34
3.5.1. Recolección de datos satelitales.....	35
3.5.2. Generación de puntos de entrenamiento	36
3.5.3. Implementación del modelo <i>Random Forest</i>	37
3.5.4. Análisis de información	39
3.6. Objetivo específico 2	41
3.6.1. Desarrollo del algoritmo de permanencia	43
3.6.2. Análisis de información	44
3.7. Objetivo específico 3	46

3.7.1. Obtención de datos de referencia.....	47
3.7.2. Cálculo del NDSI.....	47
3.7.3. Análisis de información	48
IV. RESULTADOS	52
4.1. Estimación de superficies glaciares con <i>Random Forest</i>	52
4.1.1. Rendimiento del modelo de clasificación.....	52
4.1.2. Series temporales de cobertura	54
4.2. Clasificación de píxeles según permanencia	57
4.2.1. Mapa final del algoritmo de permanencia	57
4.3. Validación de resultados a partir del inventario de INAIGEM	60
4.3.1. Obtención de <i>data</i> de referencia	60
4.3.2. Estimación empleando el NDSI.....	61
4.3.3. Vectores de cada modelo para comparación.....	64
4.3.4. Comparación entre INAIGEM y los diferentes métodos.....	65
4.3.5. Comparación entre <i>random forest</i> y NDSI.....	70
V. DISCUSIÓN	75
5.1. Desempeño espacial del algoritmo de permanencia	75
5.2. Análisis de discrepancias visuales y zonales	77
5.3. Comparación entre <i>Random Forest</i> y NDSI.....	78
5.4. Desempeño del modelo <i>Random Forest</i>	79
5.5. Dinámica glaciar de la subcuenca Quillcay	80
5.6. Limitaciones.....	81
VI. CONCLUSIONES	83
VII. RECOMENDACIONES	85
VIII. REFERENCIAS BIBLIOGRÁFICAS.....	86
ANEXOS	110

RESUMEN

En la subcuenca del río Quillcay de la Cordillera Blanca (Perú), el deshielo acelerado de los glaciares tropicales se ha convertido en un desafío ambiental de primer orden. No es de extrañar que esto plantee un desafío crítico para más de 140,000 personas, con consecuencias directas en la calidad y provisión de agua y en la generación de riesgos. La tarea de vigilar estos glaciares no es sencilla; su superficie va en retroceso constante y la variabilidad estacional, sumada a una nubosidad intensa, complica el seguimiento.

Para hacer frente a ello, este trabajo de investigación ofrece una perspectiva novedosa: un método que integra imágenes preprocesadas de Sentinel-2 con un algoritmo de permanencia en *Python* y un modelo de *Random Forest*. Con tres mil puntos de referencia para su entrenamiento, el *Random Forest* ha mostrado una gran capacidad discriminativa, obteniendo un *F1-score* de 0.956 y una *kappa* de 0.933. Al aplicar el algoritmo de permanencia a las series mensuales de 2016 a 2024, hemos obtenido mapas anuales que no solo muestran el avance del retroceso, sino que también categorizan la dinámica glaciar según la persistencia de los píxeles.

La validación se realizó con el inventario del INAIGEM, que otorgó buenos resultados: en 2020 la diferencia en el área estimada fue mínima, de un 0.08%, con un índice de intersección sobre unión (IoU) de 0.833 y 24.79 km² de intersección. Es una concordancia que superó el método del NDSI y se ajusta mejor a lo observable. En definitiva, la metodología que proponemos es una herramienta precisa y replicable para el monitoreo dinámico en tiempos del cambio climático, indispensable para una buena planificación hídrica y gestión de riesgos.

Palabras clave: *Random Forest*, algoritmo de permanencia, glaciares tropicales, monitoreo glaciar.

ABSTRACT

In the Quillcay river sub-basin of the Cordillera Blanca (Peru), the accelerated melting of tropical glaciers has become a top-tier environmental challenge. It is not surprising that this poses a critical challenge for more than 140,00 people, with direct consequences on water quality and supply and the generation of risks. The task of monitoring these glaciers is not easy; their surface is constantly retreating and seasonal variability, combined with intense cloud cover, complicates tracking.

To address this, this research work offers a novel perspective: a method that integrates preprocessed Sentinel-2 images with a permanence algorithm in Python and a Random Forest model. With three thousand reference points for training, the Random Forest has shown a great discriminative capacity, achieving an F1-score of 0.956 and a kappa of 0.933. By applying the permanence algorithm to the monthly series from 2016 to 2024, we have obtained annual maps that not only show the progression of the retreat but also categorize the glacier dynamics according to the persistence of the pixels.

The validation was carried out with the INAIGEM inventory, which yielded good results: in 2020, the difference in the estimated area was minimal, at 0.08%, with an intersection over union (IoU) index of 0.833 and an intersection of 24.79 km². It is a concordance that surpassed the NDSI method and better aligns with what is observable. Ultimately, the methodology we propose is a precise and replicable tool for dynamic monitoring in times of climate change, essential for good water planning and risk management.

Keywords: *Random Forest*, permanence algorithm, tropical glaciers, glacier monitoring.

I. INTRODUCCIÓN

1.1. La importancia de los glaciares tropicales

Los glaciares son grandes masas de agua en fase sólida sobre la superficie terrestre que se forman mediante el proceso de almacenamiento y compresión de nieve por el transcurso de un largo periodo de tiempo (Willige, 2023). Entre sus tipos, destacan los glaciares libres, aquellos que no están cubiertos por sedimentos ni detritos, lo que los hace más susceptibles a la radiación solar directa y, por ende, más vulnerables al retroceso glaciar (Rabatel et al., 2013). Los glaciares situados en el trópico de los Andes son también conocidos como glaciares tropicales, ecosistemas de montaña o glaciares de montaña (Vuille et al., 2008). Estos se encuentran extendidos por Sudamérica, abarcando desde Venezuela hasta Chile y Argentina, atravesando países como Colombia, Ecuador, Perú y Bolivia (Gonda, 2019). Además, estos glaciares proporcionan diversos servicios ecosistémicos que, a su vez, impulsan la economía de los países, así como, contribuyen a la calidad de vida de la población y los ecosistemas (Cook et al., 2021).

Entre los múltiples beneficios que ofrecen los ecosistemas de montaña, destaca la contribución a la regulación del clima a nivel global (Gonda, 2019) mediante propiedades físicas como el albedo glaciar, o simplemente como albedo. Esta propiedad caracteriza a un glaciar como un cuerpo que busca la medida de la reflectancia y la radiación solar incidente sea ~99% (Laboratorio de Glaciología, 2025). De este modo, la radiación recibida en la Tierra no se queda atrapada en la superficie terrestre y la temperatura media no aumenta drásticamente en el planeta. Por ende, ser un indicador hipersensible ante las variables climáticas como la precipitación, humedad y temperatura es otra particularidad de los glaciares de montaña (Francou et al., 2013; Marr et al., 2022; Thompson et al., 2017; Veettil et al., 2016).

Además de su influencia climática, los glaciares también desempeñan un papel esencial en la dinámica del ciclo hidrológico al alimentar con sus aguas a otros ecosistemas de montaña (ANA, 2019). De este modo, participan dentro del ciclo del agua y la recarga de estos (UNEP, 2018; Pozada et al., 2023); mientras que, regulan

el flujo hídrico constante durante todo el año. Al mismo tiempo, permiten la formación de ecosistemas como humedales, que constituyen una notable fuente de biodiversidad en alta montaña (Inoue, 2018). Dicho vínculo con el medio ambiente evidencia cómo los glaciares son considerados como base fundamental para los ecosistemas completamente. Como consecuencia, crean un medio capaz de producir vida en lagunas y manantiales (ANA, 2019).

En este mismo contexto, los glaciares tropicales actúan como potenciales reguladores del recurso hídrico, almacenan agua durante la época húmeda mediante las lluvias y nevadas presentes de la estación; mientras que, en la época seca reducen de tamaño (Gonda, 2019; Buytaert et al., 2017; Boyano, 2017). De esta manera, el balance hídrico atenúa la temporada de sequía y los cambios estacionales distribuyendo las aguas de sus cuencas hidrográficas más altas. Esta repartición realizada permite que recibamos agua todos los meses del año y el suministro de este líquido vital en los cuerpos de agua sea permanente y constante (Garreaud et al., 2017; Gonda, 2019). Sobre todo, en los Andes, esta función es necesaria para la población y la economía de países como Perú, Bolivia y Chile (Aedo & Montecinos, 2011).

A la par de su función reguladora, los glaciares constituyen vastos depósitos de agua dulce, lo que los posiciona como fuentes estratégicas para el consumo humano y diversas actividades económicas (ANA, 2019; Klusak, 2019; Shrestha & Nepal, 2019). Esta disposición indica que el 68.7% de 2.5% agua dulce se encuentra en fase sólida perenne, como casquetes polares y glaciares (Aedo & Montecinos, 2011; Musie & Gonfa, 2023; Villalobos, 2008). Son 68 millones de personas que están asentadas en la región de los Andes, utilizando directamente las aguas frías de los glaciares para su supervivencia diaria (Iniciativa Andina de Montañas et al., 2022). Es así como los glaciares pueden otorgar la provisión de agua, siendo este uno de los beneficios más significativos para la población como para los otros ecosistemas.

Esta dependencia del agua glaciar es particularmente notoria en países andinos como Bolivia, Perú y Chile, donde las poblaciones utilizan directamente el agua de deshielo glaciar para el uso doméstico y otras necesidades vitales (IPCC, 2019a; Johansen et al., 2018; Vuille et al., 2018). Un ejemplo claro es Perú y Bolivia donde

presentan épocas de estiaje con precipitaciones escasas durante un periodo prolongado desde abril a septiembre (Vuille et al., 2018). A su vez, el 70% de la población chilena se abastece de aguas provenientes del deshielo glaciar (Aedo & Montecinos, 2011). Estos países presentan una marcada vulnerabilidad y una notoria dependencia hídrica para la supervivencia de la población y sus actividades económicas cotidianas. Aproximadamente, 2000 millones de seres humanos necesitan de los glaciares, la fusión y el escurrimiento de aguas de montaña para su consumo personal a nivel mundial (Shekinskaya, 2025; Úbeda & Palacios, 2008).

Adicionalmente, los ecosistemas de montaña son indispensables, ya que suministran el agua para la generación de energía hidroeléctrica y el abastecimiento de sectores productivos en países como Perú, Bolivia, Ecuador y Colombia (Chevallier et al., 2010). Por ejemplo, Ecuador y Perú dependen de las aguas provenientes de los glaciares para la producción de energía hidroeléctrica en 50% y 80% aproximadamente (Chamorro & Mera, 2025; Vergara et al., 2007). Este recurso es fundamental para diversas actividades económicas y sociales en cada región. Además, los glaciares de montaña abastecen sus aguas para los cultivos en la agricultura, la manufactura y minería principalmente (ANA, 2019; Burger et al., 2018) garantizando la seguridad alimentaria y energética en cada uno de estos países.

En particular, el sector de agricultura peruano, consumió 15997 millones de metros cúbicos por año (MMC/año) entre los años 2000 - 2001, siendo esta la actividad productiva base en el país (De Piérola C., 2017). De ello se deduce que los glaciares son fundamentales para la captación y almacenamiento de agua, esenciales para el riego de cultivos y el sustento del ganado. Igualmente, el sector de minería utilizó 399 MMC/año para los diferentes procesos que requiere la extracción de los metales preciosos, asimismo el sector industrial contribuyó en el consumo de 1151 MMC/año (De Piérola C., 2017). La diferencia entre los valores de consumo presentados enfatiza que nuestro país depende económicamente de las actividades mencionadas.

Finalmente, los ecosistemas de montaña atraen el turismo y montañismo (ANA, 2019) promoviendo la conciencia ambiental; así como, ingresos económicos mediante las inversiones en negocios locales (Shaw, 2019). Además, esta actividad


económica en estas zonas fomenta el desarrollo de construcciones y ofrecimiento de servicios beneficiando así a las comunidades locales. Los destinos turísticos hacia los glaciares a nivel global son diversos; por ejemplo, en el 2019, se cuantificó la venida de alrededor de 195–375 millones de visitantes a las áreas montañosas (ONU, 2023). De manera concisa, se plasmó que el 10–20% de visitas extranjeras a Ecuador fueron hacia lugares de montaña; el 20–40%, a Chile y Venezuela; el 40–60%, a Nicaragua y el 78%, a Perú (UNWTO, 2023).

1.2. Retroceso glaciar en los Andes peruanos

Durante las últimas décadas, los glaciares ubicados en los Andes peruanos han experimentado una drástica disminución, mostrando una tendencia de retroceso cada vez más acelerada como consecuencia del cambio climático. Según los resultados del último inventario de glaciares, desde el año 1962 hasta el año 2020 se ha registrado una pérdida 1348.75 km² de superficie glaciar, lo que equivale a un 56% en un periodo de 58 años (INAIGEM, 2023). Esta pérdida alarmante, en poco más de medio siglo, refleja los efectos del cambio climático en los glaciares tropicales. En este contexto, la Cordillera Blanca, el sistema glaciar más extenso del Perú (ANA, 2014), también ha sufrido una disminución significativa. Desde el año 1962, ha perdido 301.4 km² de área glaciar, y para el año 2020 se registró una superficie glaciar remanente de 424.86 km² presentado en la Figura 1 (INAIGEM, 2023).

Figura 1

Evolución de la cobertura glaciar a nivel nacional desde 1962 al 2020



Nota: De INAIGEM (2023). Inventario Nacional de Glaciares y Lagunas de Origen Glaciar 2023, p. 71

Este fenómeno, en el Perú, no se limita únicamente a la Cordillera Blanca, sino que también se ha documentado en otros sistemas glaciares, como la Cordillera Huayhuash y la Cordillera Vilcanota, donde el retroceso glaciar ha sido igualmente significativo. En los últimos 58 años, la Cordillera Huayhuash ha perdido el 42.88% de su superficie glaciar; mientras que, la Cordillera Vilcanota ha registrado una reducción del 50.86% expuesto en la Figura 1. En comparación, la Cordillera Blanca ha experimentado una pérdida del 41.5% en el mismo periodo (ANA, 2017; INAIGEM, 2023; Quispe, 2015). Aunque estas dos cordilleras han experimentado una mayor reducción porcentual de su superficie glaciar en comparación con la Cordillera Blanca, siguen siendo, después de esta última, las que han registrado una menor pérdida en relación con otros sistemas glaciares del país.

Además de la reducción de superficie, los estudios de balance de masa glaciar en los Andes Peruanos han evidenciado un adelgazamiento progresivo de los cuerpos de hielo, lo que resulta una disminución en su volumen total de estos macizos (Fyffe et al., 2021; Izaguirre et al., 2024; Taylor et al., 2022). Este proceso no solo refleja la pérdida de hielo en términos de área, sino también una reducción en la capacidad de almacenamiento de agua de los glaciares. En los últimos años, este fenómeno se ha acelerado debido a la intensificación de eventos climáticos extremos, como olas de calor, sequías prolongadas y alteraciones en los patrones de precipitación (IPCC, 2019b). Estos cambios evidencian la vulnerabilidad de los glaciares tropicales y resaltan la necesidad de comprender los factores que están acelerando su proceso.

Uno de los principales factores que explican la pérdida acelerada de los glaciares en los Andes peruanos está vinculado al aumento sostenido de la temperatura del aire, lo cual afecta directamente los procesos de acumulación y fusión del hielo (Vuille, 2018). En los últimos años, estudios han evidenciado que existe una correlación entre la temperatura y la tasa de fusión glaciar, ya que el incremento de la temperatura altera los flujos de energía entre la atmósfera y la superficie del glaciar, aumentando la transferencia de calor hacia estos cuerpos (ANA, 2017; Bulege-Gutiérrez & Custodio, 2020; Loarte et al., 2015; Mojica et al., 2021; Sicart et al., 2008). Por otro lado, registros meteorológicos demuestran que en las próximas dos décadas la temperatura aumentará en promedio 0.2 °C en la región andina (SGCAN, 2008), lo que en la actualidad se refleja en la elevación de la cota altitudinal de

congelación y reducción de las zonas de acumulación de nieve. Como consecuencia, la regeneración glaciar se encuentra severamente comprometida.

A la par del aumento térmico, la variabilidad en los patrones de precipitación también influye notablemente en el retroceso glaciar, especialmente con los cambios de temperatura cuando las lluvias reemplazan a las nevadas en zonas de alta montaña (SENAMHI, 2011). Un estudio realizado en la Cordillera Blanca, muestra que el ascenso de la isoterma de 0°C permite que las precipitaciones ocurran a una mayor altitud en forma de lluvia (ANA, 2017). El incremento de estas precipitaciones, en altitudes donde antes predominaba la nieve, acelera el derretimiento glaciar, ya que el agua líquida reduce el albedo de la superficie glaciar, aumentando la absorción de radiación solar en un 20–30% (Sicart et al., 2008), y por ende intensificando la fusión del hielo. Estos cambios en los patrones de precipitación, sumados al aumento de temperatura, contribuyen a la aceleración del retroceso de los glaciares tropicales.

Por último, además de los factores climáticos, existen los procesos geofísicos como la deposición de carbono negro y polvo mineral en la superficie glaciar también desempeñan un papel de relevancia en la fusión de los glaciares (Gilardoni et al., 2022; UNEP, 2019). Estas partículas, generadas por la quema de biomasa amazónica (Magalhães et al., 2019), actividades mineras (Gilardoni et al., 2022) y combustibles fósiles (Bonilla et al., 2023), reducen la capacidad de reflejar la radiación solar de las superficies glaciares, donde es ilustrado en la Figura 2. Esta capacidad de reflejo fue evaluada en un estudio realizado en cinco montañas de la Cordillera de los Andes, el cual reveló que la reducción del albedo varía entre 0.4–1.1% (Bonilla et al., 2023). Poniendo en contexto estos valores, aunque parezcan bajos, representan un efecto crítico en glaciares tropicales, donde la radiación solar es intensa en todo el año.

Figura 2

Proceso de deposición de carbono negro en los glaciares



Nota: De Gilardoni et al. (2022). Black carbon, organic carbon, and mineral dust in South American tropical glaciers: A review.

1.3. Rol de los glaciares tropicales en la subcuenca Quillcay

La subcuenca del río Quillcay constituye un caso representativo de la estrecha dependencia de las comunidades y ecosistemas locales respecto al agua de deshielo glaciar. Esta subcuenca recibe una parte significativa de su caudal de los glaciares de la Cordillera Blanca, contribuyendo como un río secundario a la cuenca del río Santa (ANA et al., 2015; INAIGEM, 2018a). De esta manera, la subcuenca asegura el abastecimiento de agua dulce a los distritos de Independencia y Huaraz (La Matta, 2020; Loayza, 2014), caracterizándose por poseer un mayor potencial hídrico. Los beneficiarios de estas aguas provenientes del deshielo de glaciares suman alrededor de 1 969 222 personas (equivale el 36.7% de la población total de la cuenca) para el año 2014 (ANA, 2015). Actualmente, la población beneficiada llega a alcanzar los dos tercios (2/3) de los habitantes peruanos, que se encuentran viviendo en la costa peruana (INAIGEM, 2023).

En este territorio, dicha dependencia se refleja también en la significativa demanda de agua para múltiples actividades socioeconómicas esenciales para la vida en la subcuenca. Esta zona presentaba una demanda de agua para el consumo poblacional

de 7.28 hm³/año (equivalente al 30.38% del total de la cuenca del río Santa) (ANA, 2015). Además, en esta subcuenca se desarrollan actividades socioeconómicas base para su crecimiento y supervivencia como la agricultura, ganadería, turismo, comercio entre otras. Principalmente, el desarrollo agrícola desde tiempos atrás hasta ahora sigue siendo una de las principales actividades productivas que otorgan un buen sustento económico a la población. Se evidenció, en el reporte llamado “Evaluación de Recursos Hídricos en la cuenca Santa”, que el subsistema Quillcay demandaba 32.13 hm³/año de agua destinada netamente para la agricultura en la primera década del año 2000 (ANA et al., 2015).

A ello se suma que otras actividades estratégicas como la generación de electricidad, la ganadería y el turismo también se ven condicionadas por el aporte hídrico de los glaciares. Por ejemplo, la producción de energía hidroeléctrica en la subcuenca depende en gran medida del flujo glaciar haciéndose vulnerable ante las fluctuaciones de este (Vergara et al., 2007). Las aguas procedentes del deshielo glaciar producen energía en la central hidroeléctrica de 265.6 MW llamada Cañón del Pato, el cual capta las aguas del río Santa (OSINERGMIN, 2022). Otro sector que depende del agua de origen glaciar es la ganadería. Esta necesita del recurso hídrico inminente para el crecimiento de pastos (Zimmer, 2016), que sirve de alimento básico para la subsistencia de los animales. Por otro lado, la subcuenca posee una gran cantidad de lagunas engendradas por el derretimiento de glaciares que potencian el turismo y el comercio en la zona (INAIGEM, 2023).

Además de su valor hídrico y productivo, los glaciares tropicales de la subcuenca Quillcay tienen un impacto importante en la climatología local y regional debido a su funcionamiento como un regulador de temperatura natural (Thompson et al., 2006). El equilibrio de la masa de estos glaciares permite moderar las condiciones térmicas en las zonas altas de la cuenca. Al actuar como escudos que reducen la cantidad de radiación solar reflejada, estos ecosistemas cercanos mantienen el equilibrio térmico y evitan que el ciclo de vida de estas especies se vea interrumpido (Gonda, 2019). También aseguran que, mediante el deshielo gradual durante los meses cálidos, el suministro de agua para los ecosistemas de montaña es constante, lo cual resulta ser vital para la flora y fauna de la región (Santiago et al., 2021). La

salud de los ecosistemas de la subcuenca Quillcay no sería posible sin los glaciares, que les proporcionan un clima estable que les permite ser biodiversos.

Este papel regulador se complementa con la interrelación entre los glaciares y los cuerpos de agua que estos alimentan, que contribuye a la estabilidad ecológica de los ecosistemas acuáticos y terrestres. Durante todo el año, los glaciares son recursos de agua que liberan, lo que, gracias al drenaje, garantiza el abastecimiento constante a los ríos y quebradas, para que la vida en los ecosistemas no corra tantos riesgos (CENEPRED, 2018). Una oferta de agua constante y sin variaciones abruptas es indispensable en un ecosistema acuático, donde el caudal debe regularse adecuadamente (ANA et al., 2015). Además, el deshielo gradual ayuda a mejorar la calidad del agua al prevenir el riesgo de desbordes, mientras aumenta la disponibilidad de agua para las especies terrestres que habitan en la zona (Municipalidad Distrital de Independencia & Municipalidad Provincial de Huaraz, 2017). Los glaciares ayudan a la regulación de los recursos hídricos, lo que a su vez garantiza la estabilidad ecológica y asiste a la resiliencia de los ecosistemas a ciertos cambios.

Sin embargo, la progresiva reducción de la masa de los glaciares en la subcuenca está afectando directamente en gran medida la regulación climática de la zona (Jara, 2024; Loayza, 2014). Sin el agua proveniente de deshielos, los ecosistemas montañosos se ven obligados a enfrentar sequías más severas y prolongadas, lo que afectaría en gran medida a muchas especies (Loayza, 2014). La alteración de los glaciares también contribuye a alterar el ciclo hidrológico, lo que incrementa el riesgo de inundaciones repentinas por el agua que podría acumularse en los glaciares restantes (CENEPRED, 2018; INAIGEM, 2018b). Con respecto al clima, la reducción de los glaciares resulta en una menor cantidad de agua disponible para regular la temperatura en la región (INAIGEM, 2018a; Jara, 2024), lo cual a su vez contribuiría a un mayor calentamiento global.

1.4. Riesgos asociados al retroceso glaciar en la subcuenca Quillcay

La fusión de los glaciares en la subcuenca Quillcay ha generado una reducción progresiva en la disponibilidad de agua, afectando a las comunidades y actividades económicas que dependen de este recurso. Durante la época seca, el aporte glaciar

es crucial, ya que puede representar hasta el 40% del caudal del río Santa (SINIA et al., 2012). Sin embargo, estudios recientes indican que la escorrentía de las cuencas ha disminuido en un 10% o más, lo que intensifica la escasez hídrica y aumenta la vulnerabilidad de la población (Mark et al., 2017). Por ejemplo, Huaraz obtiene un fuerte aporte de agua dulce del río Quillcay, pero presenta peligros y desafíos en la continuidad del recurso sobre todo en los periodos secos (USAID, 2014). Es decir, que en los meses de mayo a septiembre no hay presencia de precipitaciones y en ocasiones atraviesan épocas de sequía.

Esta reducción del caudal se traduce en una mayor irregularidad en el flujo de los ríos, comprometiendo el acceso al agua potable, el riego agrícola y la generación de energía hidroeléctrica, pilares fundamentales para el desarrollo de la región (Jara, 2024). En la subcuenca Quillcay, la disminución de los glaciares ha causado escasez de agua a los ríos que nacen de estos. De acuerdo con investigaciones en la región, los caudales de los ríos que nacen de glaciares han disminuido hasta el rústico treinta por ciento en veinte años (Jara, 2024). Esto ha causado un consumo sobreexplotado de las fuentes de agua, lo que a la larga perjudica la irrigación de cultivos y el saneamiento de la gente que habita en esta región.

Como consecuencia de esta disminución de agua, también causan impactos negativos en los ecosistemas desequilibrándolos, al reducir su capacidad de sostener la biodiversidad. Al mismo tiempo que los ríos reciben un menor caudal disminuyen su capacidad de nutrir y oxigenar el agua por lo que disminuye la biodiversidad de los organismos acuáticos (Bury et al., 2011). En unos años, las aguas se volverán aún más escasas con el retroceso de los glaciares. En varias partes de los Andes se estima que en unas cuantas décadas se conseguirán caudales provenientes de los glaciares un 40% inferior a los actuales (Bradley et al., 2006). Las proyecciones indican que el agua seguirá desapareciendo, por lo que hay que prepararse para la escasez.

Además de la escasez, el retroceso glaciario en la subcuenca Quillcay no solo disminuye la disponibilidad de agua, sino que conlleva a un deterioro en la calidad de esta. A medida que los glaciares se derriten, dejan expuestas grandes cantidades de roca que, al entrar en contacto con el aire y el agua, generan procesos de

oxidación que dan lugar al drenaje ácido de roca (DAR). Este fenómeno libera metales pesados como el arsénico, plomo y cadmio, que pueden contaminar ríos y lagunas (La Matta, 2020; Rojas & Rengifo, 2022). La presencia de estos contaminantes en el agua representa una grave amenaza para la salud de la población y para los ecosistemas acuáticos, afectando tanto la biodiversidad como la seguridad alimentaria de las comunidades locales (Martel et al., 2018).

Los efectos del drenaje ácido de roca se han identificado en varias lagunas y cuerpos de agua de la subcuenca, donde se han detectado alteraciones en el pH y una mayor concentración de metales tóxicos (Martel et al., 2018). En áreas donde los glaciares se están retrayendo rápidamente, como la subcuenca del Quillcay, el drenaje ácido se ha convertido en un problema emergente. En algunos casos, algunos glaciares han erosionado grandes depósitos de minerales sulfurosos, lo que ha resultado en la acidificación de lagunas glaciares (Loayza, 2014). Un claro ejemplo es la laguna Palcacocha, que fue estudiada, y los resultados informaron que la laguna posee un pH menor a 4 con metales pesados tóxicos en elevadas concentraciones y el enlutado del sedimento nocivo (Crisanto & Iannacone, 2023).

Esta situación incide negativamente tanto en la producción agrícola como en la biodiversidad acuática, poniendo en riesgo la seguridad alimentaria y la salud de las comunidades locales (La Matta, 2020). Además, la contaminación hídrica pone en riesgo la fauna acuática, reduciendo la biodiversidad y afectando a las especies que dependen del agua como hábitat natural (Quispe et al., 2020). El transcurso de los cambios que los glaciares están pasando a causa del cambio climático está dejando repercusiones de manera que impacta directamente a la disponibilidad hídrica futura (Baraer et al., 2017). La protección de la subcuenca Quillcay no solo es una necesidad ambiental, sino también una prioridad para la salud y el bienestar de sus habitantes.

Otro de los riesgos más significativos del deshielo glaciar, en la subcuenca, es la formación de nuevas lagunas inestables y también ha incrementado el riesgo de desbordes violentos de lagos glaciares, conocidos como GLOF (Glacial Lake Outburst Floods) (IPCC, 2013). A medida que los glaciares se derriten, se forman nuevas lagunas que crecen en tamaño y volumen, aunque inicialmente son estables,

estos lagos van representando la posibilidad de que sus diques naturales colapsen. Este fenómeno ha sido registrado en varias partes de la Cordillera Blanca, donde eventos de aluvión han causado daños significativos a la infraestructura y la población (Rivas et al., 2015; Somos et al., 2014). En la subcuenca Quillcay, lagunas como Palcacocha han sido identificadas como de alto riesgo debido a su rápido crecimiento y la inestabilidad de los glaciares cercanos (Huggel et al., 2020; INAIGEM, 2023).

Estos eventos del colapso de una laguna glaciar pueden generar consecuencias devastadoras como la ocurrencia de un aluvión de grandes proporciones, que arrastra rocas, lodo y escombros a gran velocidad. En el pasado, Huaraz ha sido testigo de tragedias causadas por estos eventos, como el desborde de Palcacocha en 1941, que cobró miles de vidas y destruyó gran parte de la ciudad (CENEPRED, 2018; Municipalidad Distrital de Independencia & Municipalidad Provincial de Huaraz, 2017). Este desastre ocasionó más de 5000 pérdidas humanas, otros miles quedaron damnificados, destruyó puentes e infraestructuras (Carey, 2005; Carey, 2010). También, perjudicó a las comunidades acentuadas en las partes bajas en la zona y todas las tierras de cultivo (Emmer & Vilímek, 2013). Por eso, en el 2010, la laguna Palcacocha fue categorizada como una laguna en emergencia, ya que sigue siendo un potencial peligro para alrededor de 49000 habitantes (INDECI, 2017; Municipalidad Distrital de Independencia & Municipalidad Provincial de Huaraz, 2017; USAID, 2014).

En la actualidad, con el incremento del volumen de agua de estas lagunas, junto con la inestabilidad de los glaciares, mantiene la amenaza persistente agravando la situación con los efectos del cambio climático (Somos et al., 2014). A su vez, los desprendimientos de roca en zonas de alta montaña pueden actuar como detonantes de estos desbordes, aumentando aún más el nivel de peligro. Además de las amenazas inminentes, los GLOF también representan un riesgo a largo plazo para los ecosistemas acuáticos y la infraestructura (Carey, 2005; Carey, 2010). La gravedad de tales eventos ha aumentado en los últimos años debido al rápido retroceso de los glaciares y a la acumulación de agua en los lagos, lo que destaca la necesidad de estudios detallados sobre el riesgo de GLOFs (Johansen et al., 2018).

1.5. Teledetección en el monitoreo glaciar

Históricamente, el monitoreo de los glaciares ha representado un desafío considerable debido a la peligrosidad e inaccesibilidad de los terrenos de alta montaña. En el pasado, el mapeo de superficies glaciares se realizaba a través de observaciones de campo, un método que era bastante preciso, pero estaba limitado por las grandes extensiones del glaciar y la exposición al riesgo de los investigadores (Aniya et al., 1996). Es por ello que actualmente, el mapeo de las superficies glaciares se realiza mediante técnicas de teledetección, debido a que estas proporcionan información del lugar de estudio sin tener contacto directo con esta área (Bevington & Menounos, 2022). Este cambio metodológico ha permitido una mejora sustancial en el seguimiento y la interpretación de la variabilidad de la superficie glaciar, optimizando la eficiencia como la seguridad en los procesos de observación.


En este contexto, la teledetección es una técnica avanzada que permite la captura, tratamiento y análisis de información sobre el territorio mediante imágenes digitales obtenidas desde satélites o plataformas artificiales equipadas con sensores (Pérez & Muñoz, 2006). Estos sensores ópticos registran la radiación electromagnética reflejada o emitida por los distintos elementos de la cobertura terrestre, lo cual permite observar el estado y la evolución de los ecosistemas o fenómenos naturales (Pérez & Muñoz, 2006). Este proceso no requiere de contacto físico con el área en estudio, lo que resulta especialmente valioso en zonas de difícil acceso o de gran extensión. Gracias a esta estructura integrada, es posible transformar la energía captada desde la superficie terrestre en información útil para diversos fines científicos y de gestión ambiental.

Aunado a esto, un sistema de teledetección espacial está compuesto por varios elementos interconectados que permiten la adquisición, procesamiento e interpretación tal como se grafica en la Figura 3. En primer lugar, está la fuente de energía que generalmente es el Sol o energía emitida por los mismos objetos observados. Luego, la cubierta terrestre, formada por distintos espacios geográficos y tipos de superficies. También, un sistema sensor, encargado de captar la energía emitida por la cubierta terrestre. A su vez, un sistema de recepción, que se encarga

de grabar la información en un formato adecuado y tras las correcciones distribuye esta a los interesados. Posteriormente, un intérprete, que se encarga de transformar los datos en una información temática relevante como mapas de cobertura o series temporales. Por último, un usuario final, que puede ser un científico o tomador de decisiones, que analiza la información obtenida para emplearla en casos según sus intereses (Chuvieco, 2002, 17-19).

Figura 3

Componentes de un sistema de teledetección



Nota: Adaptado de Chuvieco (2002). Teledetección Ambiental, p. 19


El uso de esta técnica ha mejorado significativamente la capacidad de análisis de la criosfera a escala global, favoreciendo el seguimiento y comprensión de la variabilidad glaciar. Estas tecnologías han sido de gran relevancia para evaluar la magnitud y la velocidad del retroceso glaciar, un fenómeno documentado a nivel mundial y atribuido al cambio climático de origen antropogénico (Arias et al., 2024; Hewitt, 2011; Rabatel et al., 2023; Ritse et al., 2025). En este marco, la teledetección

se ha podido consolidar como una de las herramientas más eficientes e indispensables para monitorear la dinámica glaciar, generando datos consistentes para diferentes espacios geográficos en el planeta.

El estudio en el mapeo de glaciares mediante teledetección se basa en la capacidad de los sensores ópticos para captar la radiación electromagnética reflejada por estos macizos de hielo y nieve. En este proceso, la reflectancia espectral del hielo y la nieve permite diferenciar estos elementos de otras coberturas superficiales en la imagen satelital (Dozier, 1989). Las propiedades ópticas de la nieve varían según su estado físico, la nieve compactada refleja entre 25–30% menos que la nieve reciente, y el hielo glaciar muestra una reflectancia alta en el espectro visible azul (400–500 nm) y verde (500–600 nm), mientras que en la roja una reflectancia muy baja (600–700 nm) (Pellikka & Rees, 2009). Estos intervalos de trabajo se muestran en la Figura 4. Sin embargo, los escombros presentes en la superficie glaciar reducen considerablemente la reflectancia, haciendo más difícil la detección por los sensores ópticos (Escalante-Ramirez, 2012).

Figura 4

Espectro electromagnético



Nota: De Chuvieco (2002). Teledetección Ambiental, p. 47

Los sensores remotos son herramientas claves en el monitoreo de los glaciares, ya que proporcionan imágenes satelitales con diferentes niveles de detalle y frecuencia de adquisición. Estas imágenes se caracterizan por las resoluciones del sensor como la resolución espacial, espectral, radiométrica y temporal (Pérez & Muñoz, 2006). La primera resolución determina el tamaño mínimo de un objeto que puede ser

distinguido en una imagen y la segunda define el número y anchura de bandas que discrimina el sensor respectivamente (Pérez & Muñoz, 2006). La tercera resolución indica la capacidad del sensor en diferenciar intensidades de radiación y la última mide el tiempo en el que el satélite pasa por el mismo punto correspondientemente (Pérez & Muñoz, 2006). Por ello, la integración de estas resoluciones es fundamental en la detección de superficies glaciares, permitiendo diferenciarla de otras superficies mediante la reflectancia en el espectro electromagnético.

Diversos estudios sobre la detección y monitoreo de diferentes coberturas glaciares han comparado los productos de los satélites Landsat y Sentinel, evaluando su eficiencia. Los satélites Landsat son operados por la *National Aeronautics and Space Administration* (NASA) y el *United States Geological Survey* (USGS) desde 1972 (NASA, 2022). Por su parte, los satélites Sentinel son gestionados por la Agencia Espacial Europea (ESA) (Copernicus, s.f.). Los resultados han evidenciado que las imágenes obtenidas mediante el sensor *MultiSpectral Instrument* (MSI) de Sentinel-2 presentan mejores resultados con las metodologías aplicadas. Esto se debe a su mayor resolución espacial, que varía entre 10 a 20 metros, en contraste con la resolución de 30 metros en el espectro visible e infrarrojo cercano del sensor OLI-2 de Landsat-9 (Carvalho et al., 2025; Jia et al., 2024; Palanisamy et al., 2023; Parente et al., 2024; Zeller et al., 2024).

Además de su ventaja espacial, Sentinel-2 destaca por una mayor mayor resolución temporal, ya que cuenta con un intervalo de 5 días; mientras que, Landsat ofrece el periodo de 16 días (Carvalho et al., 2025). Esta diferencia permite interpretar como un mejor monitoreo más continuo y preciso en los cambios en las coberturas superficiales, lo que resulta especialmente útil en zonas de alta dinámica ambiental como las áreas glaciares. En esta misma línea, un estudio realizado en la Cordillera Blanca, resalta que el sensor MSI presenta un mejor desempeño en la detección de cobertura de nieve bajo sombras proyectadas y terrenos escarpados que el sensor de Landsat-8 (Veettil, 2018). Este tipo de evidencia reafirma la importancia de seleccionar adecuadamente el sensor satelital según las características geográficas y objetivos específicos del análisis.

1.6. Índices espectrales para la detección de glaciares

El Índice de Nieve de Diferencia Normalizada (NDSI) se define como la diferencia normalizada entre dos bandas del espectro electromagnético. Una de las bandas se caracteriza por tener una alta reflectancia en el espectro visible (VIS) y la otra por tener una gran absorción en el infrarrojo de onda corta (SWIR). Este cálculo fue documentado a mediados de la década de 1970 por Valovcin, donde seis años después este mismo dio introducción a utilizar los valores de radiancia desde VIS (0.68– 0.76 μm) y en SWIR (1.55–1.75 μm) (Hall & Riggs, 2011, pp. 779-780). Este avance permitió dar inicio a su aplicación en el mapeo global de la cobertura nival, marcando un hito en el monitoreo remoto de zonas nevadas y glaciares (Hall & Riggs, 2011).

La ecuación del cálculo del NDSI se expresa en (1) como (Hall et al., 1995):

$$NDSI = \frac{BANDA_{(VIS)} - BANDA_{(SWIR)}}{BANDA_{(VIS)} + BANDA_{(SWIR)}} \quad (1)$$

En relación con su funcionamiento, el resultado obtenido de esta operación está comprendido entre -1 y 1, siendo determinante para la clasificación de superficies nevadas (Singh et al., 2011). Esta metodología, propuesta por Jeff Dozier, es una de las más utilizadas para la detección de cobertura de nieve, en la que se establece que cualquier píxel con un valor superior a 0.4 en una imagen será considerada como superficie cubierta de nieve (Dozier, 1989). En el Perú, la entidad responsable de realizar monitoreos, estudios e investigaciones sobre los glaciares es el Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM). Es por ello que esta institución publicó, en el año 2017, un manual metodológico para el inventario nacional de glaciares donde emplean el umbral de 0.4 del NDSI para mapear superficies glaciares (INAIGEM, 2017).

A partir de esta metodología, diversas investigaciones han demostrado la efectividad del NDSI en múltiples contextos geográficos para el análisis de retrocesos glaciares (Banerjee et al., 2024; Dematteis et al., 2024; Gascoin et al., 2022; Pandey et al., 2011; Veettil & Kamp, 2019). En particular, investigaciones en las principales cordilleras del mundo evidencian su utilidad. En la Cordillera Blanca, un análisis del retroceso glaciar en las subcuencas Llullan, Quillcay y Yanayacu reportó una

disminución del 64 %, 63 % y 32 % respectivamente, entre 1962 y 2020 (León, 2022). En los Himalayas, un estudio donde evaluaron el periodo 2000–2022, determinó que los glaciares cubiertos de la cuenca Bhilangana experimentaron una tasa de retroceso de 31 metros por año (Banerjee A. et al., 2024). De manera similar, en los Alpes europeos, la combinación del NDSI con modelos de elevación topográfica ha demostrado mejorar la precisión en la identificación de glaciares (Paul et al., 2020).

Sin embargo, pese a su amplia adopción, el NDSI aún presenta limitaciones en áreas con sombras topográficas, presencia de escombros y variabilidad climática, lo que impide realizar una correcta discriminación de nieve (Toledo et al., 2024). Ante estas limitaciones, se han desarrollado índices mejorados que combinan diferentes bandas espectrales y criterios topográficos. Entre ellos, se encuentra, el Índice Glaciar de Diferencia Normalizada (NDGI) que permite diferenciar las cubiertas de nieve, hielo y restos mixtos de hielo mediante el uso de las bandas Verde y Rojo del espectro visible. A su vez, el Índice de Diferencia Normalizada de nieve y hielo (NDSII) permite discriminar entre el hielo y la nieve, empleando las bandas Verde e Infrarrojo Cercano (NIR) (Keshri et al., 2009). Por otra parte, el Índice de Nieve de Diferencia Normalizada sin información de agua (NDSInw) facilita la reducción en la detección de información hídrica, empleando las bandas NIR y SWIR, para obtener la cobertura de nieve y suprimir el ruido de las superficies de agua (Yan et al., 2020).

Finalmente, al considerar los glaciares tropicales del Perú, se observa que la aplicación de estos índices enfrenta retos particulares vinculados a la ubicación geográfica y a las condiciones climáticas. La alta nubosidad, la variabilidad estacional y la nieve húmeda dificultan la aplicación de umbrales predefinidos como el 0.4 del NDSI. La alta concentración de nubosidad limita la adquisición de imágenes satelitales de mayor calidad para el monitoreo de estos ecosistemas. Además, mientras exista un aumento en la humedad de la nieve, la dispersión en volumen y su capacidad de reflectancia se reducirán (Salcedo, 2011), lo que puede llevar a sobreestimaciones o subestimaciones de la extensión glaciar. En consecuencia, estas condiciones específicas demandan enfoques más flexibles y


adaptativos en la interpretación de los índices espectrales para una representación precisa de la cobertura glaciar en los Andes tropicales.

1.7. Uso del aprendizaje automático para la clasificación de glaciares

La inteligencia artificial (IA) es definida como la capacidad de una máquina o artefacto para poder ejecutar tareas asociadas al razonamiento y la toma de decisiones, replicando funciones cognitivas propias del ser humano (Mellit & Kalogirou, 2008). En otros términos, la IA lleva a cabo tareas según reglas y algoritmos específicos. Esta se compone de subconjuntos que se observan en la Figura 5. Estos son el aprendizaje automático o Machine Learning (ML) y el aprendizaje profundo o Deep Learning (DL), donde este último a su vez es un subconjunto del ML (Mellit & Kalogirou, 2021). Así, la comprensión de la estructura jerárquica entre estas diversas ramas resulta fundamental en el procesamiento y análisis de datos complejos como los glaciares.

Figura 5

Jerarquía de la Inteligencia Artificial




Nota: De Mellit & Kalogirou, (2021). Artificial intelligence and internet of things to improve efficacy of diagnosis and remote sensing of solar photovoltaic systems: Challenges, recommendations and future directions, p. 3

A continuación, el ML permite a las máquinas aprender a partir de datos sin la necesidad de programación explícita. En lugar de seguir un conjunto determinado de instrucciones, los algoritmos de ML identifican patrones y ajustan su desempeño

a través de un entrenamiento con datos. Dentro de este enfoque, el DL se destaca por el uso de redes neuronales artificiales con múltiples capas, lo que permite procesar información y realizar análisis complejos (Sussmann, 2024). Además, cabe resaltar que, la Figura 6 destaca que el DL requiere muchos más datos que un algoritmo de ML para que funcione correctamente. El ML trabaja con miles de puntos de datos, mientras que el aprendizaje profundo trabaja con millones de datos para poder presentar un correcto funcionamiento, debido a su estructura compleja de múltiples capas (Wolfewicz, 2024). Por lo tanto, la elección entre ML y DL dependerá en gran medida de la disponibilidad de datos y de la complejidad de la tarea a resolver.

Figura 6

Comparación gráfica del Machine Learning y el Deep Learning



Nota: Adaptado de Sruthy (2025). Difference in Data Mining Vs Machine Learning Vs Artificial Intelligence.

Seguidamente, en cuanto a la clasificación, el aprendizaje automático se divide en cuatro tipos principales de algoritmos. Estos son el aprendizaje supervisado o *supervised learning*, el aprendizaje no supervisado o *unsupervised learning*, el

aprendizaje semi-supervisado o *semi-supervised learning* y por último el aprendizaje por refuerzo o *reinforcement learning* (Alpaydin, 2016). Esta caracterización permite seleccionar el tipo de aprendizaje más adecuado, ya que ofrece soluciones específicas que pueden ser aplicadas según la naturaleza del problema de los datos disponibles y el objetivo de análisis.

A continuación, El aprendizaje supervisado emplea datos etiquetados para establecer relaciones entre las características de entrada y salida, logrando resolver problemas de regresión y clasificación. Por otro lado, el aprendizaje no supervisado utiliza datos no etiquetados e identifica patrones ocultos sin conocer los resultados esperados, siendo útil para tareas de agrupamiento y asociación. El aprendizaje semi-supervisado combina los enfoques ya descritos, trabajando con una pequeña cantidad de datos etiquetados junto con un gran tamaño de datos sin etiquetar, resultando útil en clasificaciones manuales y complejas. Por último, el aprendizaje por refuerzo no se centra en trabajar con datos preexistentes, sino en la relación continua de un agente con su entorno, optimizando sus decisiones mediante un sistema de recompensas y penalizaciones, empleándose en tareas de control y clasificación (Mellit & Kalogirou, 2021, pp. 4).


Con base en lo anterior, en las últimas décadas, el uso de algoritmos ha revolucionado la detección y delimitación de zonas glaciares mediante imágenes satelitales, proporcionando herramientas precisas y automatizadas para monitoreo y análisis de cambios en la criosfera de montañas. Entre los enfoques más utilizados en esta temática se encuentran los algoritmos supervisados y las redes neuronales profundas, estos modelos han demostrado ser bastante útiles para mejorar la precisión en el mapeo glaciar en regiones donde la variabilidad estaciones y condiciones climáticas dificultan los métodos tradicionales de clasificación basados en umbrales fijos (Bouchayer et al., 2022; Hassan et al., 2025; He et al., 2020; Rajat et al., 2022; Sharda & Srivastava, 2024). De este modo, el ML ha emergido como una solución robusta frente a las limitaciones de las técnicas convencionales.

Dentro de los modelos de DL, destacan la máquina de vectores de soporte (SVM), la red neuronal artificial (ANN) y el bosque aleatorio (RF), donde (Khan et al., 2020), que ofrecen una alta precisión y capacidad para manejar grandes volúmenes de datos. Por otro lado, los algoritmos de DL han mostrado excelentes resultados en

la cuantificación de cambios glaciares y en la exclusión de cuerpos de agua y sombras en imágenes satelitales (He et al., 2020; Khan et al., 2023; Rajat et al., 2022). Sin embargo, el rendimiento del DL depende de la cantidad de datos para el entrenamiento. Mientras que para las redes neuronales convolucionales requieren millones de muestras etiquetadas, los modelos de aprendizaje automático trabajan con miles. Es por ello que en estudios más localizados, donde se cuenta con miles de datos en lugar de millones, el uso de DL puede no ser la opción más eficiente, ya que requiere volúmenes de datos altos para alcanzar un buen rendimiento, como se revela en la Figura 7 (Mellit & Kalogirou, 2021).

Figura 7

Comparación de rendimiento entre DL y ML con respecto a la cantidad de datos



Nota: De Mellit & Kalogirou, (2021). Artificial intelligence and internet of things to improve efficacy of diagnosis and remote sensing of solar photovoltaic systems: Challenges, recommendations and future directions, p. 6

Finalmente, estudios que evalúan el rendimiento de los modelos de DL, determinan que el modelo que presenta mejores resultados es el *Random Forest* (Abbas et al., 2024; Bueno et al., 2023; Khan et al., 2020). En un estudio realizado en la cuenca Passu en Pakistán, se evaluó el uso de tres algoritmos supervisados (SVM, ANN y RF) para mapear glaciares utilizando imágenes Sentinel-2, donde el modelo *Random Forest* presentó una exactitud del 95.06%, destacando sobre el resto (Khan et al., 2020). De manera similar, en una investigación sobre el mapeo de glaciares

en nueve regiones de montaña importantes del Perú, se compararon cuatro modelos de ML, máquinas de impulso de gradiente (GBM), k vecinos más cercanos (KNN), bosques aleatorios (RF) y regresión logística (LR). Por medio de métodos de validación cruzada espacial y no espacial, se evaluaron los errores de clasificación en términos del coeficiente de correlación de Matthews, en la Cordillera Blanca, el modelo de RF obtuvo un coeficiente superior a 0.97 (Bueno et al., 2023). Este modelo equilibra precisión y eficiencia, reduciendo el costo computacional frente a los modelos de DL.

1.8. Justificación de la investigación

El estudio de los glaciares tropicales en los Andes peruanos es fundamental en el contexto del cambio climático, ya que estos ecosistemas actúan como reservas estratégicas de agua para las poblaciones andinas. En particular los glaciares de la subcuenca del río Quillcay situada en la Cordillera Blanca han sido gravemente afectados por el aumento de temperatura. De la cordillera se ha perdido un 41.50% de su superficie glaciar entre 1962 y 2020 (INAIGEM, 2023) provocando consecuencias importantes en la disponibilidad hídrica y la seguridad de la ciudad de Huaraz, con una población de 145,615 habitantes (MINAM, 2014; Stitelmann, 2024; INEI, 2017a). El agua de deshielo glaciar es primordial para el abastecimiento de la población, casi el 67% del suministro anual y hasta el 91% en el caso de los años de sequía (Kari et al., 2018). Por tanto, el mapeo preciso de la superficie glaciar permite comprender la evolución de los ecosistemas en relación con la seguridad hídrica. En el presente trabajo de investigación se desarrolló un algoritmo que permite detectar glaciares en la subcuenca Quillcay y los cambios en su cobertura glaciar durante la última década.

La mayoría de los métodos para la detección de glaciares se desarrollaron en regiones extratropicales, y se centraron en la detección de cobertura glaciar en una sola fecha o en dos períodos y en la detección de cambios al comparar cobertura glaciar en fechas distintas, sin incluir los cambios interanuales, y no se estableció un criterio con una complejidad temporal. Se aplicaron diferentes algoritmos de detección de nieve en una sola imagen y de detección de glaciares usando un umbral de NDSI. Las técnicas se basan en el uso de bandas espectrales y, dado que la

mayoría de los métodos se desarrollaron en regiones extratropicales, no se pudo detectar correctamente los glaciares tropicales pues plantean limitaciones como la variabilidad estacional y anual, la alta cobertura nubosa y la presencia de escombros en la capa sobre el hielo. El algoritmo proporcionó una clasificación de cobertura de nieve temporal, hielo permanente o superficies mixtas y no se diferenciaron correctamente los tipos de cobertura. Para la definición de coberturas glaciares se han propuesto diversos métodos de clasificación de imágenes satelitales, sin embargo, una de las limitaciones que presentan es la imposibilidad de incluir un componente temporal.

En este estudio se ha propuesto un algoritmo de clasificación basado en la permanencia de los píxeles, generando una ventaja al ser un algoritmo de clasificación de imágenes tradicional. La motivación de nuestra propuesta, es la posibilidad de diferenciar técnicamente entre coberturas glaciares permanentes y temporales, partiendo de series temporales de imágenes con resolución espacial de 30 m de las de Landsat temáticamente clasificadas mensualmente. Con este algoritmo, diferenciar entre coberturas permanentes y temporales ante eventos de nieve recientes o fusión, reducirá la incertidumbre inherente al uso de métodos de clasificación de imágenes convencionales.

En este sentido, esta investigación tiene el objetivo de optimizar el mapeo de superficies glaciares mediante el desarrollo de un algoritmo de clasificación que distinga píxeles permanentes y temporales en la subcuenca Quillcay. Para ello, se empleará el modelo *Random Forest*, el cual ha demostrado un alto nivel de precisión en estudios previos, alcanzando una exactitud del 95.06% en la identificación de glaciares cubiertos de escombros en Pakistán (Khan et al., 2020) y un coeficiente de correlación de Matthews superior a 0.97 en el mapeo de glaciares de la Cordillera Blanca (Bueno et al., 2023). La combinación de imágenes Sentinel-2 con este modelo permitirá mejorar la detección y clasificación de la superficie glaciar, diferenciando entre píxeles de cobertura permanente y temporal.

Finalmente, esta investigación no solo busca mejorar la precisión en el monitoreo de la dinámica glaciar, sino que también contribuir a la generación de un inventario de glaciares más detallado, al incorporar información temporal que permite analizar variaciones mensuales de la cobertura glaciar. Esto facilitará una mejor

comprensión de la evolución de estos ecosistemas y fortalecerá la toma de decisiones para la gestión sostenible de los recursos hídricos y la planificación de estrategias de adaptación frente a los efectos del retroceso glaciar.

II. PREGUNTA DE INVESTIGACIÓN Y OBJETIVOS

2.1. Pregunta de investigación

¿Cómo se puede optimizar el mapeo de superficies glaciares mediante el desarrollo y aplicación de un algoritmo de clasificación que distinga píxeles permanentes y temporales en la subcuenca Quillcay, Ancash - Perú?

2.2. Objetivos

2.2.1. Objetivo general

Optimizar el mapeo de superficies glaciares mediante el desarrollo de un algoritmo de clasificación que distinga píxeles permanentes y temporales en la subcuenca Quillcay, Ancash - Perú.

2.2.2. Objetivos específicos

1. Estimar las superficies glaciares en la subcuenca Quillcay utilizando imágenes Sentinel-2 mediante un modelo de *machine learning* que permita la detección precisa de áreas glaciares.
2. Clasificar los píxeles que representan superficies glaciares según su permanencia y temporalidad mediante el desarrollo de un algoritmo de clasificación en lenguaje *Python*.
3. Analizar los resultados comparándolos con el inventario de glaciares del INAIGEM y empleando su metodología a imágenes Sentinel-2 para evaluar la precisión en el mapeo de superficies glaciares.

III. MATERIALES Y MÉTODOS

3.1. Tipo de estudio

El presente trabajo de investigación presenta las características de un tipo de estudio analítico y exploratorio. Se consideró analítico porque se enfocó en analizar datos existentes de imágenes satelitales Sentinel-2 de un periodo establecido. A través del uso de algoritmos de aprendizaje automático como el modelo *Random Forest*, se buscó identificar, a través de los valores de reflectancia, patrones de clasificación de superficies glaciares y no glaciares, evaluando su precisión y aplicando un análisis de los resultados. Por otro lado, tiene exploratorio porque se adentró en el estudio de permanencia glaciar en la subcuenca Quillcay, un área que ha sido poco investigada con herramientas de clasificación automática de glaciares. Se exploró una metodología alternativa al uso de métodos convencionales, planteando un enfoque innovador para monitorear glaciares, en un periodo más corto, en regiones como la Cordillera de los Andes.


3.2. Área de estudio

Este trabajo de investigación tuvo como área de estudio a la subcuenca del río Quillcay, ubicada en los distritos de Huaraz e Independencia, provincia de Huaraz, departamento de Ancash, Perú, mostrada en la Figura 8. La subcuenca, perteneciente al flanco occidental de la Cordillera Blanca, mediante el sistema de coordenadas UTM (Zona 18S), se ubica entre los puntos 221496 m E; 8946764 m N y 247495 m E; 8955757 m N. Desde el aspecto hidrográfico, la subcuenca Quillcay pertenece a la Vertiente del Pacífico y a la cuenca del río Santa; formada por la convergencia de las microcuencas Paria y Auqui. Esta zona, presenta un amplio gradiente altitudinal de 3051 a 6274 m.s.n.m., y está compuesta, en su parte alta, por importantes quebradas como: Cojup, Quillcayhuanca, y Shallap. La red hidrológica de esta cuenta con 10 glaciares, siendo los nevados Palcaraju, Pucaranra, Tullparaju, Carhuascancha, Churup y Ranrapalca vitales para la población de Huaraz. Además, parte de los glaciares de la subcuenca se encuentran dentro del Parque Nacional Huascarán. Asimismo, cuenta con muchas lagunas producto del

deshielo, habiendo 5 principales son las lagunas de Churup, Shallap, Palcacocha, Cuchillacocha y Tullpacocha (SIGRID, 2018).

Figura 8

Mapa de ubicación del área de estudio



3.3. Materiales

Para el desarrollo de esta investigación fue necesario contar con una serie de materiales y herramientas técnicas que resultaron esenciales en cada etapa del proceso metodológico, las cuales son presentadas en la Tabla 1. La elección adecuada de estos recursos, así como su aplicación en el manejo de datos geoespaciales, permitió asegurar un trabajo riguroso en la obtención, procesamiento y análisis de la información relacionada con la cobertura glaciar en la subcuenca del río Quillcay.

Tabla 1

Componentes necesarios para el desarrollo del estudio


Componentes	Item	Cantidad	Uso
Materiales	Computadora	1	Procesamiento de imágenes satelitales
	Laptop	1	Trabajo de análisis
	Imágenes Sentinel-2	105	Clasificación de cobertura glaciar
	Data de INAIGEM	1	Información para comparar
Software	QGIS 3.2.2.	1	Generación de puntos
	ArcGIS Pro	1	Procesamiento geoespacial avanzado
	Python	1	Programación del algoritmo
	Jupyter Notebook	1	Codificación y producción de data geoespacial
	Microsoft Office	1	Redacción y presentación
	RStudio	1	Análisis estadístico y creación de gráficas
Servicios	Internet fibra óptica	1	Acceso a datos en línea
	Google Earth Engine	1	Procesamiento remoto de imágenes
	Google Drive	2	Almacenamiento y respaldo de datos
	Google Colab	1	Publicación de los códigos en la nube

3.4. Diseño de investigación

La Figura 9 explica de manera concisa la serie de pasos que se realizó en la metodología.

Figura 9

Diagrama de flujo de la metodología empleada




3.5. Objetivo específico 1

La Figura 10 presenta el flujo de etapas realizadas para cumplir el primer objetivo planteado para el desarrollo del trabajo de investigación.

Figura 10

Flujo de actividades para el Objetivo específico 1



3.5.1. Recolección de datos satelitales

La recopilación de datos satelitales se realizó mediante el uso de la librería [SatCube](#), un paquete de Python desarrollado en el marco del proyecto AndesDataCube, financiado por PROCENCIA bajo el título “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” (código de proyecto: PE501083135-2023). *SatCube* constituye una herramienta en desarrollo orientada a la automatización de la descarga y preprocesamiento de imágenes Sentinel-2 desde Google Earth Engine (GEE), incorporando técnicas avanzadas de procesamiento como enmascaramiento de nubes mediante modelos de deep learning, interpolación espacio-temporal y generación de composiciones mensuales libres de ruido. En ese sentido, su uso en esta investigación se enmarca dentro de aplicaciones metodológicas en fase de validación científica (Aybar et al., 2024; Contreras & Aybar, s.f.).

El primer paso consistió en delimitar el polígono del área de estudio, mediante las herramientas que te ofrece el software QGIS 3.2.2. A partir de este polígono, se generaron coordenadas centrales de las celdas de 384 x 384 píxeles para cubrir la zona delimitada. Cada una de las coordenadas se usó para consultar y descargar las imágenes satelitales de esa celda a través de GEE. Una vez descargadas las imágenes, la librería aplicó un modelo de *Deep Learning* que identificó y enmascaró automáticamente las nubes (Aybar et al., 2024). Luego, se rellenaron los huecos espaciales y temporales de las imágenes que podrían afectar la continuidad de los datos. Con las imágenes limpias, se generaron composiciones mensuales utilizando la mediana de reflectancia, cubriendo el periodo de enero de 2016 a septiembre de 2024. Finalmente, se unieron todas las celdas procesadas en un mosaico mensual que abarca completamente el área de la subcuenca Quillcay. Esta actividad permitió construir una serie de imágenes mensuales homogéneas y continuas, adecuadas para el análisis de la variación de las superficies glaciares (Contreras & Aybar, s.f.).

3.5.2. Generación de puntos de entrenamiento

La generación de puntos de entrenamiento se basó en imágenes satelitales correspondientes durante los meses de agosto, septiembre y octubre del año 2020. Estas fechas fueron seleccionadas por coincidir con la temporada seca en la región de estudio, lo que garantiza una menor presencia de nubosidad y, por tanto, una mejor calidad de observación (Jara et al., 2023). Además, el periodo de referencia es el año de inventario de glaciares publicado por el Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM), lo que le da validez técnica a dicha clasificación. Se generaron de manera manual 2,000 puntos por imagen, con las clases de glaciar (valor 1) y no glaciar (valor 0) en el *software* QGIS 3.2.2, alcanzando los 6,000 puntos en total. De acuerdo con estudios previos, los modelos de aprendizaje automático pueden ser desarrollados con más de 1,000 puntos, aunque los resultados pueden variar según el dominio de estudio (Khan et al., 2020). Por este motivo, se desarrollaron 5 modelos de clasificación con *Random Forest*, con conjuntos de clases de 750, 1,500, 3,000, 4,500 y 6,000 puntos, documentando que los resultados de 3,000 eran los mejores visualmente (Colque, 2019).

Una vez definidos los puntos en formato *shapefile* y con el mismo sistema de coordenadas que las imágenes satelitales, se procedió a extraer los valores de reflectancia de cada punto utilizando la herramienta “Muestra de valores ráster” en QGIS. Esta función permite asociar a cada punto los valores correspondientes en las distintas bandas espectrales de las imágenes satelitales Sentinel-2. La información resultante se exportó a una hoja de cálculo y se guardó en formato CSV, como se muestra de ejemplo para dos puntos en la Tabla 2. Este archivo sirvió como insumo para entrenar el modelo de aprendizaje automático, permitiéndole aprender a distinguir entre superficies glaciares y no glaciares en función de los valores espectrales de cada banda.

Tabla 2

Datos para el entrenamiento


Source	Cod.	S2_1	S2_2	S2_3	S2_4	S2_5	S2_6	S2_7	S2_8	S2_9	S2_10
glaciar	1	5872	5608	5692	5713	5125	4825	5052	4583	1148	737
no glaciar	0	779	756	682	905	1375	1537	1597	1697	1603	996

3.5.3. Implementación del modelo *Random Forest*

El modelo *Random Forest* es un algoritmo de aprendizaje automático supervisado ampliamente empleado en tareas de clasificación. Su principio de funcionamiento consiste en generar varios árboles de decisión, cada uno entrenado a partir de una muestra aleatoria del conjunto de datos disponible (Belgiu & Drăguț, 2016). La clasificación final se obtiene a través de una votación mayoritaria entre todos los árboles, lo cual permite aumentar la robustez y reducir el riesgo de sobreajuste que presentan otros modelos más simples (Hernández, 2024). De manera esquemática, la Figura 11 representa cómo funciona este modelo, desde la entrada de datos hasta la predicción final de clases.

Figura 11

Random Forest para la clasificación



Nota: De Hernandez (2024). Modelos predictivos, capítulo 4 *Random Forests*.

Antes de aplicar este modelo sobre las imágenes satelitales completas, se llevó a cabo un proceso de entrenamiento y validación para evaluar su desempeño. Para ello se recurrió a una base de datos integrada por 3000 puntos, generados manualmente sobre imágenes Sentinel-2 del año 2020. Cada punto incluía los valores de reflectancia correspondientes a las bandas espectrales y una etiqueta que indicaba si el punto representaba una superficie glaciar (valor 1) o no glaciar (valor 0). Esta base fue dividida en dos subconjuntos, el 70% de los datos se usaron para entrenar el modelo, y el 30% restante para validar (Belgiu & Drăguț, 2016). En la Tabla 3, se demuestra la división de datos para esta evaluación de desempeño del modelo.

Tabla 3

División de datos

Clase	Total	Entrenamiento (70%)	Validación (30%)
Glaciar (1)	1000	700	300
No glaciar (0)	2000	1400	600
Total	3000	2100	900

Esta estrategia permitió medir el rendimiento del modelo sobre datos no vistos durante el entrenamiento, brindando así una estimación objetiva de su capacidad predictiva. Las métricas utilizadas para esta evaluación incluyeron la precisión, la sensibilidad y la puntuación F1, las cuales reflejan qué tan bien el modelo logra diferenciar entre superficies glaciares y no glaciares (Kundu R., 2022). La primera métrica (precisión) evalúa qué tan confiables son las etiquetas de “glaciar” y evitar sobreestimaciones del glaciar (Aberle et al., 2024; Barzycka et al., 2023). El segundo parámetro (sensibilidad) mide la capacidad del modelo para detectar todas las áreas reales del glaciar (Barzycka et al., 2023). La tercera métrica (puntuación F1) evalúa la clasificación punto a punto, el cual identifica si hay sesgos en la distribución de clases (glaciar/no glaciar) (Aberle et al., 2024). El último punto de referencia (coeficiente *Kappa*) mide el grado de exactitud entre la clasificación real y del modelo (Aberle et al., 2024; Olofsson et al., 2014).

La interpretación de cada métrica mencionada representó un buen valor mientras más cercano esté al 1, indicando un buen desempeño.

Por ende, cabe resaltar que las mismas métricas se aplicaron a los 750, 1500, 3000, 4500 y 6000 puntos, revelando que el uso de 3000 puntos de entrenamiento favorecía a cumplir los objetivos de la investigación. Una vez demostrado que el desempeño del modelo de *Random Forest* es óptimo para la clasificación de superficies glaciares. Este es aplicado sobre las composiciones mensuales generadas a partir de las imágenes Sentinel-2 preprocesadas entre 2016 y 2024. Utilizando como insumo los valores de reflectancia de cada píxel en las distintas bandas, el modelo *Random Forest* clasificó cada píxel como glaciar o no glaciar, generando *raster* binarios mensuales con una resolución espacial de 10 metros. A continuación, se presenta el enlace donde se puede consultar el código del modelo entrenado:

<https://colab.research.google.com/drive/16PQofnapNAEl9dTkJwe7K7o9FlgoYkhY?usp=sharing>

3.5.4. Análisis de información

Para el cumplimiento del primer objetivo específico, se estableció una operacionalización de variables que permite vincular los valores espectrales extraídos de las imágenes satelitales con la estimación de superficie glaciar en la subcuenca Quillcay. Las variables definidas se exponen en la Tabla 4 para el análisis de este objetivo.

Tabla 4
Operacionalización de variables para el Objetivo Específico 1

Variable	Definición conceptual	Definición operacional	Tipo de variable	Forma de medición	Unidad	Instrumento
Área Glaciar de la Subcuenca Quillcay	Masa de hielo terrestre que fluye por gravedad, se deforma internamente y desliza entre elementos topográficos adyacentes ^a	Área cubierta por hielo o nieve en una imagen satelital	Dependiente	Conteo de píxeles clasificados como glaciar multiplicado por el área de cada píxel (10 m × 10 m)	km²	Modelo de machine learning (Random Forest)

Variable	Definición conceptual	Definición operacional	Tipo de variable	Forma de medición	Unidad	Instrumento
Reflectancia de bandas espectrales	Físicamente, se obtiene al dividir la potencia de la radiación reflejada y la total recibida ^b	Información espectral obtenida en distintas longitudes de onda (de las bandas B1 hasta la B10)	Independiente	Valores de reflectancia en las 10 bandas de cada imagen satelital	Valor numérico	Imágenes Sentinel-2

Nota: ^aIPCC (2001). ^bAlonso et al., (1999).

El análisis se basó en los resultados obtenidos a partir de la clasificación mensual generada por el modelo *Random Forest*, correspondiente al periodo 2016–2024. Sin embargo, las clasificaciones demostraron unos picos atípicos en ciertos meses del área glaciar (ver en el Anexo 1). Por eso, se realizó un análisis complementario, empleando las series temporales del periodo estudiado depurando los valores atípicos, descartando aquellas fechas cuya cobertura nubosa distorsionaba la detección real de glaciares. Esta depuración permitió conservar únicamente los resultados más confiables, es decir, aquellos que coinciden visualmente con la cobertura glaciar real observada en las imágenes Sentinel-2.

Además, se enfatizó en el año más seco (2020), se eligió ese año debido a que durante esta época se suele registrar la menor presencia de nieve estacional. Asimismo, se implementó un análisis cuantitativo para conocer la dispersión de los resultados realizados por el *Random Forest* conociendo los patrones climáticos de la subcuenca del río Quillcay. Esta prueba identificó la tendencia de los valores y la significancia de los resultados mediante el p-valor < 0.05 junto a un intervalo de confianza del 95%. Este valor refleja la vinculación con la confiabilidad de la investigación y la relevancia de los hallazgos (Molina A., 2017).

Por otro lado, los valores medios mensuales calculados están expuestos en el Anexo 2, complementando la interpretación al mostrar el comportamiento estacional de la subcuenca. Esta oscilación estacional, reflejada en los promedios, ayuda a establecer un marco de referencia para interpretar los valores extremos y las variaciones anuales presentes en las figuras principales. Además, dichos valores medios fueron útiles como insumo para evaluar la

representatividad de los datos seleccionados en el proceso de depuración, reforzando el criterio de confiabilidad aplicado.


Ambos criterios, la depuración visual y la evaluación estadística, se utilizaron de forma conjunta para lograr una identificación más confiable de las áreas glaciares dentro del área de estudio. Esta información permitió calcular la permanencia glaciar correspondiente al objetivo específico 2. Este es un indicador que refleja la frecuencia con la que un área ha sido identificada como glaciar a lo largo del tiempo. Gracias a este enfoque, es posible reconocer con mayor certeza las zonas que han mantenido cobertura glaciar de forma constante, lo cual facilita una delimitación más precisa dentro de la subcuenca Quillcay.

3.6. Objetivo específico 2

La Figura 12 manifiesta el flujo de etapas realizadas para cumplir el segundo objetivo planteado para el desarrollo del trabajo de investigación, las actividades para la clasificación de permanencia glaciar empleando el algoritmo desarrollado.

Figura 12

Flujo de actividades para el Objetivo específico 2



3.6.1. Desarrollo del algoritmo de permanencia

Se desarrolló un algoritmo de clasificación de píxeles en el lenguaje de *Python*, con el propósito de analizar la permanencia y temporalidad de las superficies glaciares dentro de la subcuenca Quillcay. Este algoritmo utilizó como insumo la serie temporal de las clasificaciones mensuales, en formato de *raster* binario, generados por el Objetivo Específico 1. En estas, cada píxel contenía un historial mensual de clasificación binario (glaciar = 1, no glaciar = 0) para el periodo que comprende los años 2016–2024. A partir de este historial, se calculó el porcentaje de permanencia de cada píxel en cada uno de los escenarios de los *rasters*. El cual está definido como la frecuencia con la que fue clasificado como glaciar a lo largo del total de meses analizados. Este cálculo se realizó empleando la ecuación (2).

$$Permanencia = \frac{\text{Número de meses en el que el píxel fue glaciar}}{\text{Número total de imágenes mensuales}} \times 100 \quad (2)$$

Una vez obtenidos los valores de permanencia para cada píxel, estos fueron clasificados en cuatro categorías cualitativas (Pekel et al., 2016). Estas categorías se basan principalmente en la dinámica que tienen los glaciares del ecosistema de montañas, donde su extensión de cobertura de nieve depende de la época seca o húmeda del año. Es por ello que a partir de la medición la permanencia de estos píxeles en un periodo de tiempo ayuda a definir de forma más clara la dinámica de los glaciares dentro de la subcuenca. En la Tabla 5, se muestra la clasificación según el porcentaje de permanencia.

Tabla 5

Clasificación según porcentaje de permanencia

Categoría	Cod.	Permanencia (P)	Explicación
Glaciar	1	$P \geq 90\%$	Aquellos píxeles que se clasificaron como glaciar en más o igual al 90% de las escenas.
Glaciar en retroceso	2	$90\% > P \geq 35\%$	Aquellos píxeles que se clasificaron como glaciar en más del 35% y menor al 90% de las escenas.

Categoría	Cod.	Permanencia (P)	Explicación
Nieve acumulada	3	$35\% > P \geq 10\%$	Píxeles que tienen una corta duración en todo el periodo analizado, debido a la variabilidad estacional de cobertura de nieve.
Nieve efímera	4	$10\% > P$	Píxeles clasificados que representan nieve y desaparecen en cuestión de horas.

El algoritmo implementó un bucle iterativo que recorrió todos los píxeles de la serie temporal de cada *raster*, para calcular el porcentaje de permanencia y asignar la categoría correspondiente. Como resultado de este proceso, se generó un nuevo archivo *raster* categórico, en el que cada pixel de los diferentes escenarios representa el tipo de cobertura en función a su permanencia a lo largo de la serie de tiempo. Por último, a través de la aplicación de recursos de herramientas de Sistema de Información Geográfica (SIG), creando un mapa final que permite la optimización del mapeo de superficies glaciares. Así mismo, el algoritmo de permanencia que se desarrolló en lenguaje python, se puede encontrar en el siguiente enlace para su visualización: <https://colab.research.google.com/drive/1xBvR76IsNPoDJ65nV6fJi9r2LxCBM89g?usp=sharing>

3.6.2. Análisis de información

Para el análisis correspondiente al Objetivo Específico 2, se consideraron dos variables que permitieron caracterizar la variación del comportamiento en el tiempo de la cubierta nival en la subcuenca del río Quillcay durante el periodo de los años 2016–2024. La Tabla 6 muestra la operacionalización de estas variables.

Tabla 6

Operacionalización de variables para el Objetivo Específico 2

Variable	Definición conceptual	Definición operacional	Tipo de variable	Forma de medición	Unidad	Instrumento
Permanencia Glaciar	Duración media de estadía de un objeto sobre un espacio específico ^c	Porcentaje de tiempo en que un píxel se mantiene como glaciar en una serie temporal de imágenes satelitales	Dependiente	Ecuación (2)	Porcentaje (%)	Algoritmo de clasificación desarrollado en lenguaje <i>Python</i>
Frecuencia Glaciar	Repetibilidad con la que un dato está dentro de un mismo grupo ^d	Cantidad de veces que un píxel fue clasificado como glaciar en la serie temporal	Independiente	Número de veces que el píxel tiene valor 1 (Glaciar) en la serie de imágenes mensuales	Valor numérico	Algoritmo de clasificación desarrollado en lenguaje <i>Python</i>

Nota: ^cINEI (2017b, pp. 31). ^dArsuza (2006, pp. 32)


El resultado del algoritmo de clasificación generó un archivo *raster* con cuatro categorías, Glaciar, Glaciar en retroceso, Nieve acumulada y Nieve efímera. Sin embargo, para el análisis se priorizó el estudio de los píxeles clasificados como Glaciar, ya que representan las áreas con mayor estabilidad en el tiempo y son importantes para la comparación con datos oficiales. Para ello, se elaboró un mapa temático con la categorización de las coberturas según su permanencia. Esta representación espacial sobre nuestra área de estudio permitió identificar de forma precisa las zonas con masas de hielo permanente. La categoría Glaciar fue utilizada para comparar con los datos publicados por el INAIGEM correspondientes al año 2020. Así mismo, se realizó un análisis temporal, utilizando las clasificaciones mensuales generadas en el Objetivo Específico 1. Este análisis permitió identificar las áreas glaciares mínimas detectadas en los distintos años incluidos en el periodo analizado, así como los meses específicos en los que estas disminuciones ocurrieron. Esta comparación temporal, lo que permite es diferenciar entre áreas de masa de hielo permanente y aquellas afectadas por el retroceso o la presencia de nieve estacional.

3.7. Objetivo específico 3

En la Figura 13, se visualiza el diagrama de procesos que se realizaron para cumplir con el objetivo específico 3 propuesto en el presente trabajo de investigación.

Figura 13

Flujo de actividades para el Objetivo específico 3



3.7.1. Obtención de datos de referencia

Con el fin de analizar posteriormente los resultados obtenidos en los objetivos anteriores, se utilizaron como datos de referencia los vectores del Inventario Nacional de Glaciares publicado por el INAIGEM en el año 2023. En dicho documento se encuentra la información de áreas glaciares a nivel de las cordilleras del territorio peruano hasta el año 2020. Este inventario funcionó como delimitación oficial de los glaciares. Por otro lado, el archivo vectorial fue descargado desde la página de [ArcGIS Online](#), donde INAIGEM subió los datos vectoriales del inventario. Posteriormente se procedió a subir esta *data* al entorno del software QGIS para delimitar únicamente el polígono correspondiente al área de la subcuenca Quillcay. Esto se logró mediante la herramienta de geometría “corte”, además se verificó que el sistema de coordenadas de trabajo fuera transformado al sistema UTM zona 18S. Todo con el fin de poder superponer correctamente a las imágenes satelitales, para el análisis correspondiente.

3.7.2. Cálculo del NDSI

El cálculo del NDSI se aplicó a las imágenes satelitales que se utilizaron para la estimación de áreas glaciares en el Objetivo Específico 1. Para este cálculo se toman en cuenta las bandas espectrales de las imágenes satelitales Sentinel-2 que a través del preprocesamiento se componen de 10 bandas con una resolución espacial de 10 metros, como se ve en la Tabla 7.

Tabla 7

Bandas espectrales de las imágenes Sentinel-2

Nº	Banda Sentinel-2	Longitud de onda central (nm)	Nombre espectral
1	Banda 2	490	Azul
2	Banda 3	560	Verde
3	Banda 4	665	Rojo
4	Banda 5	705	Vegetation Red Edge (reescalada a 10 m)
5	Banda 6	740	Vegetation Red Edge (reescalada a 10 m)
6	Banda 7	783	Vegetation Red Edge (reescalada a 10 m)

Nº	Banda Sentinel-2	Longitud de onda central (nm)	Nombre espectral
7	Banda 8	842	NIR
8	Banda 8A	865	Narrow NIR (reescalada a 10 m)
9	Banda 11	1610	SWIR 1 (20 m nativa, reescalada a 10 m)
10	Banda 12	2190	SWIR 2 (20 m nativa, reescalada a 10 m)

Nota: Adaptado de Copernicus (2018). El componente espacio Copernicus. p. 9

Tomando en cuenta estas bandas espectrales, para el cálculo del NDSI se utilizaron las bandas Verde = Banda 3 y SWIR 1 = Banda 11. A través de ello, la ecuación (1) se modifica de la siguiente forma en (3).

$$NDSI = \frac{BANDA\ 3_{(Verde)} - BANDA\ 11_{(SWIR\ 1)}}{BANDA\ 3_{(Verde)} + BANDA\ 11_{(SWIR\ 1)}} \quad (3)$$

Las bandas espectrales necesarias para el cálculo fueron extraídas y procesadas en el entorno de *Jupyter Notebook*, donde se aplicó el umbral de 0.4 tal y como lo establece el INAIGEM en el “Manual metodológico de inventario nacional de glaciares” publicado en el año 2017. Cada imagen procesada dio como resultado un archivo *raster* binario, donde los valores de píxeles mayores o iguales a 0.4 se clasificaron como glaciares.

3.7.3. Análisis de información

Las variables incluidas para abordar este objetivo analítico están en la Tabla 8.

Tabla 8

Operacionalización de variables para el Objetivo Específico 3

Variable	Definición operacional	Tipo de variable	Forma de medición	Unidad	Instrumento
Área glaciar según INAIGEM	Área delimitada oficialmente en el inventario de glaciares	Referencia	Cálculo del área total del polígono vectorial recortado a la subcuenca Quillcay	km ²	QGIS 3.2.2.

Variable	Definición operacional	Tipo de variable	Forma de medición	Unidad	Instrumento
Área glaciar por <i>Random Forest</i>	Área estimada mediante el modelo de clasificación supervisada <i>Random Forest</i>	Dependiente	Conteo de píxeles clasificados como glaciar multiplicado por el área de cada píxel (10 m × 10 m)	km ²	Jupyter Notebook
Área glaciar por NDSI	Área calculada con el umbral ≥ 0.4 del NDSI aplicado sobre imágenes Sentinel-2	Dependiente	Conteo de píxeles clasificados como glaciar multiplicado por el área de cada píxel (10 m × 10 m)	km ²	Jupyter Notebook
Área glaciar por permanencia	Área categorizada como glaciar ($\geq 90\%$) según el análisis de permanencia	Dependiente	Cálculo del área total del polígono clasificado como glaciar	km ²	QGIS 3.2.2.

Una vez obtenidos los datos de referencia, consistentes en el vector del inventario oficial de glaciares publicado por INAIGEM, así como los productos generados a partir del modelo *Random Forest*, el índice NDSI y el algoritmo de permanencia, se procedió a realizar un análisis comparativo en distintos niveles, con el objetivo de evaluar la precisión, coherencia temporal y espacial de los métodos empleados. En primer lugar, se realizó una comparación específica utilizando el mes más seco del año 2020, determinado como el periodo de menor cobertura glaciar en la serie analizada. Para este mes, se contrastó el área glaciar identificada mediante el modelo *Random Forest* con la delimitación oficial de INAIGEM, lo cual permitió evaluar la capacidad del modelo para detectar glaciares bajo condiciones mínimas, representativas del estado más reducido del hielo superficial en un año.

Posteriormente, se realizó una comparación entre los resultados obtenidos por el algoritmo de permanencia y el dato vectorizado de referencia. En este caso, se utilizó solamente la clase “Glaciar” (píxeles con permanencia $> 90\%$) con el objetivo de determinar en qué medida las zonas de hielo persistente identificadas por el algoritmo coinciden espacialmente con las zonas del inventario oficial, así como las zonas discrepantes. Después, se utilizó el mismo criterio de comparación con los resultados obtenidos por el índice NDSI, con umbral ≥ 0.4 ,

también con el objetivo de analizar las diferencias entre las zonas identificadas como glaciares por el modelo *Random Forest* y el algoritmo de permanencia, con los mismos parámetros de humedad mínima, usando el índice NDSI calculado en el mismo mes de referencia (mes más seco del 2020).

Para todas las comparaciones, el modelado de *Random Forest*, el algoritmo de permanencia y el NDSI se usaron productos en forma vectorial (*shapefile*) y se llevó a cabo una evaluación visual por medio de software SIG. Dicha evaluación se debe ver por donde el resultado de la comparación se superpone al dato cartográfico de referencia de INAIGEM sobre una imagen satelital, de manera que se puedan identificar las zonas de coincidencia y discrepancia desde el punto de vista espacial. Para eso se eligió la zona de la subcuenca Quillcay, donde existía la mayor diferencia en los resultados de los modelos, por lo que luego se realizaron recortes espaciales para definir los límites de acuerdo con cada enfoque.

El presente análisis cuantitativo utilizó las siguientes métricas, la primera fue la Intersección sobre Unión (IoU), la cual mide el grado de intersección entre el área glaciario predicha por cada modelo y la delimitación oficial del INAIGEM. Esta métrica es fundamental en análisis espaciales porque penaliza tanto los errores por omisión como los de comisión, ofreciendo una medida robusta de la coincidencia geométrica entre ambas capas (Panuntum et al., 2024). Un IoU cercano a 1 implica una excelente correspondencia entre las capas; también se utilizó para el cálculo de la precisión y la sensibilidad. La precisión es el porcentaje de verdaderos positivos sobre el total de positivos y es una medida para la segmentación semántica. Por lo tanto, la sensibilidad es la capacidad de detectar todas las regiones glaciares reales en la imagen evaluada (Sharma et al., 2024). También se calculó el score F1, la medida de desempeño que evalúa la capacidad del modelo para detectar glaciares reales y evitar detectarlos como falsos negativos. Por lo tanto, muy similar a la combinación de precisión y la sensibilidad (Sharma et al., 2024). El valor F1 toma en cuenta la sensibilidad y la precisión. A partir de este análisis se pudieron detectar posibles estimaciones, subestimaciones o confusiones con nieve transitoria sobre la capa actual de la

nieve. Por lo tanto, se llegó a conclusiones cualitativas acerca de los resultados obtenidos por las metodologías propuestas.

En una segunda línea de análisis, se desarrolló una comparación temporal de los resultados. Para ello, se generaron series mensuales por año (2016–2024) para los métodos *Random Forest* y NDSI, graficando la evolución del área glaciar identificada en cada mes. Esta comparación permitió identificar patrones de estacionalidad, momentos de máxima y mínima cobertura glaciar, y tendencias de retroceso. Finalmente, se utilizaron diagramas de caja (*boxplots*), con el fin de evaluar la distribución y variabilidad de las áreas glaciares estimadas por ambos métodos a lo largo del periodo de estudio se realizó la prueba de normalidad de *Shapiro–Wilk*. Esta primera prueba permitió reconocer que los conjuntos de datos eran independientes e idénticamente distribuidos, es decir, seguían una distribución normal (Dudley, 2012; González & Cosmes, 2019; Kwak & Park, 2019). Por ende, se procedió a la siguiente prueba, T–Student, ya que cumple con el supuesto de normalidad y es un tamaño de muestra pequeño (Garzón & Villota, 2020; Kwak & Park, 2019). Esta prueba comparó las medias del *Random Forest* y el NDSI utilizando las estimaciones de la media y desviación estándar, obteniendo la diferencia en el rendimiento entre ambos métodos. Esta herramienta permitió determinar qué tan consistentes fueron las estimaciones realizadas por *Random Forest* y NDSI, y cómo se comportan en relación con el valor de referencia del área oficial de INAIGEM. De esta manera, se facilitó una evaluación de la precisión relativa y la diferencia significativa de cada metodología.

IV. RESULTADOS

4.1. Estimación de superficies glaciares con *Random Forest*


El Objetivo Específico 1 consistió en estimar las superficies glaciares en la subcuenca Quillcay utilizando imágenes Sentinel-2 mediante un modelo de *machine learning* que permita la detección precisa de áreas glaciares. En cumplimiento de este objetivo, se obtuvieron los siguientes resultados.

4.1.1. Rendimiento del modelo de clasificación

El modelo *Random Forest* fue aplicado utilizando cinco conjuntos de entrenamiento de diferentes tamaños (750, 1,500, 3,000, 4,500 y 6,000 puntos), generando un *raster* clasificado para el mes de septiembre del año 2020, ilustrado en la Figura 14. Al observar los resultados de manera visual, se nota que a medida que se aumenta la cantidad de puntos de entrenamiento, la forma del glaciar se define mejor y se ve menos dividida. En particular, cuando se usan 3,000 puntos, la clasificación es más consistente en cuanto a la ubicación y tiene menos errores, lo que muestra que el modelo se vuelve más estable en su calidad después de un cierto punto óptimo de entrenamiento. Esto sugiere que este número de puntos es un buen equilibrio entre la precisión y la velocidad del cálculo.

Figura 14

Rasters de clasificación con distintas cantidades de puntos de entrenamiento



El desempeño del modelo también fue validado con una matriz de confusión, de modo que su capacidad de clasificación esté correctamente identificando los píxeles glaciares y no glaciares, como se muestra en la Tabla 9, el clasificador indicó correctamente 581 píxeles no glaciares y 292 píxeles glaciares, con 19 falsos positivos y 8 falsos negativos.

Tabla 9

Matriz de confusión del modelo Random Forest

		Clase Predicha	
		No glaciar	Glaciar
Clase Real	No glaciar	581	19
	Glaciar	8	292

Asimismo, se evaluó el desempeño de los modelos *Random Forest* desarrollados con cada conjunto de entrenamiento, con herramientas estándar de evaluación en clasificación como la precisión, sensibilidad, puntuación F1 y el coeficiente kappa. Como se muestra en la Tabla 10, se encuentra que el desempeño general en todos los casos es alto, destacándose también el caso de 3,000 puntos, con una mayor precisión de 0.986 para no glaciar y 0.933 para glaciar, con una puntuación F1 equilibrada y el coeficiente kappa de 0.9333. El conjunto de 750 puntos mostró un bajo desempeño en la clasificación del glaciar, mientras que los conjuntos de mayor número de puntos no mostraron mejoras significativas, salvo el conjunto de 3,000 puntos.

Tabla 10

Métricas de rendimiento del modelo Random Forest

N° Puntos	Clasificación	Precisión	Sensibilidad	Puntuación F1	Coeficiente Kappa
750	No glaciar (0)	0.966	0.960	0.963	0.890
	Glaciar (1)	0.921	0.933	0.927	
1500	No glaciar (0)	0.964	0.970	0.967	0.900

N° Puntos	Clasificación	Precisión	Sensibilidad	Puntuación F1	Coeficiente Kappa
3000	Glaciar (1)	0.939	0.927	0.933	0.933
	No glaciar (0)	0.986	0.968	0.977	
	Glaciar (1)	0.939	0.973	0.956	
4500	No glaciar (0)	0.970	0.969	0.969	0.907
	Glaciar (1)	0.936	0.938	0.938	
6000	No glaciar (0)	0.971	0.984	0.977	0.920
	Glaciar (1)	0.959	0.927	0.942	

4.1.2. Series temporales de cobertura


Tras realizar una depuración manual de las imágenes asociadas con presencia de nubosidad (véase el Anexo 2), se construyeron series temporales de esa cobertura por año en el período 2016-2024, que se muestran gráficamente en la Figura 15. A partir de estas gráficas se logra apreciar la variación y estacionalidad de la cobertura glaciar sin interferencia de errores en la detección de la misma debidos a la nubosidad. Además, se pudo observar una tendencia de disminución de la variabilidad intermensual de la cubierta en los últimos años y los valores de la variación anual de la extensión glaciar prevista entre 28 km² y 40 km². Durante años específicos alcanzó valores de la cobertura de 38 km² y un pico de más de 40 km².

El pico de nieve terrestre existente durante el mes de abril de 2017, de 40.9 km², se dio a conocer siempre que exista una amplia cobertura de nieve en la imagen. Se registró un patrón de comportamiento más o menos parecido en el mes de mayo de 2018 con un máximo de 40.2 km² y una alta variabilidad mensual. Luego de 2019, la serie se estabiliza en cuanto a sus fluctuaciones, así como se observaron con valores altos en febrero (38.8 km²) y abril (38.3 km²). En los años 2020, 2021 y 2022, se observa patrones ligeramente homogéneos y estables, con una ligera tendencia a la baja en los últimos meses del año. En 2023, aparecen dos valores superiores a 36 km² (mayo y junio), y en el mes de octubre la cifra es sumamente más baja a 25.6 km². En 2024, las estimaciones son bastante estables entre 27.9 km² y 33.3 km².

En particular, se destaca la gráfica correspondiente al año 2020 (Figura 15e), que fue el año de referencia del estudio, y en él se observó un comportamiento más homogéneo en comparación con los años anteriores. En este año, la variación del área glaciaria mensual se mantuvo dentro de un rango estrecho que oscila entre los 25.5. km² en septiembre y los 33.3 km² en junio. Esta variación homogénea sugiere una menor variación estacional y lo convierte en el punto de referencia para realizar las comparaciones.

Figura 15


Estimaciones mensuales de la cobertura glaciar de cada año desde el periodo 2016–2024



Finalmente, se utilizó una regresión lineal para analizar las coberturas mensuales que habían sido clasificadas por el modelo *Random Forest* durante todo el periodo de estudio. La Figura 16 muestra una gráfica de dispersión con los valores de extensión glaciar y una línea de tendencia que va hacia abajo ($y = -0.041x + 34.161$). Esto indica que la superficie glaciar se reduce de manera progresiva. El análisis arrojó un valor p de 0.006, lo que demuestra que la tendencia es estadísticamente significativa. En consecuencia, los resultados confirman un retroceso sostenido de la cobertura glaciar mensual en la subcuenca Quillcay durante el periodo 2016–2024.

Figura 16

Área glaciar mensual estimada por el modelo Random Forest (2016–2024)



4.2. Clasificación de píxeles según permanencia

El Objetivo Específico 2 consistió en clasificar los píxeles que representan superficies glaciares según su permanencia y temporalidad, mediante el desarrollo de un algoritmo de clasificación en lenguaje *Python*. En relación con este objetivo, se obtuvieron los siguientes resultados.

4.2.1. Mapa final del algoritmo de permanencia


El primer resultado corresponde al producto final del algoritmo de permanencia, elaborado a partir de la clasificación binaria mensual (glaciar/no-glaciar) generada por el modelo *Random Forest* para el periodo 2016 y 2024. Este mapa,

presentado en la Figura 17, muestra la distribución espacial de las coberturas clasificadas en tres categorías: glaciar, glaciar en retroceso y nieve acumulada. Este resultado nos muestra cómo los glaciares en la subcuenca Quillcay durante todo el tiempo. Esto nos permite ver dónde hay zonas que no cambian, dónde hay cambios o dónde hay nieve solo en ciertas épocas del año.

Los resultados muestran que una gran parte de la superficie de los glaciares está retrocediendo de manera constante, especialmente en los bordes de las zonas que se consideran permanentes. También se encontró un patrón que depende de la altura y la dirección: las áreas más altas que miran hacia el oeste cambian más y a veces solo tienen nieve en ciertas épocas del año.

Figura 17

Mapa de coberturas según permanencia para el periodo (2016–2024)



A partir de los mapas anuales generados por el algoritmo de permanencia, se calcularon las áreas correspondientes para cada categoría. El algoritmo fue desarrollado para automatizar la delimitación glaciar y obtener resultados más objetivos.

La Tabla 11 resume la cuantificación anual de cada clase. La categoría mostró un comportamiento consistente, con valores que oscilaron entre 27.25 km² en 2017 y 26.23 km² en 2024. La clase glaciar en retroceso presentó una tendencia creciente desde 2016 hasta 2019, cuando alcanzó un máximo de 8.47 km². Luego, entre 2020 y 2024, se observó un descenso moderado, estabilizándose entre 7.1 y 7.5 km². La categoría nieve acumulada fue la más volátil. Alcanzó sus valores más altos en 2017 y 2018, con 7.66 km² y 7.41 km² respectivamente. Luego se redujo significativamente a partir de 2020, con valores constantes en torno a 5.7 km².

Tabla 11

Área estimada (km²) por categoría de permanencia y año (2017–2024)


Año	Glaciar (km²)	Glaciar en retroceso (km²)	Nieve acumulada (km²)
2017	27.25	6.99	7.66
2018	26.68	8.22	7.41
2019	26.34	8.47	6.99
2020	26.42	7.54	5.74
2021	26.50	7.17	5.80
2022	26.56	7.10	5.64
2023	26.47	7.08	5.71
2024	26.23	7.11	5.72

Finalmente, se elaboró una gráfica que representa la evolución anual de la clase glaciar, derivada del algoritmo de permanencia (Figura 18). Para este análisis se excluyó el año 2016 debido a la baja disponibilidad de imágenes mensuales, lo que imposibilita una estimación confiable para dicho periodo. Esta representación permite visualizar los cambios en la superficie glaciar permanente

entre 2017 y 2024, facilitando la interpretación del comportamiento espacial y temporal del glaciar en la subcuenca. Con valores anuales que se mantienen alrededor de 30 km², se observa una estabilidad relativa en la expansión del glaciar permanente a lo largo del período evaluado. Aunque las variaciones de un año a otro son pequeñas, todavía son perceptibles; de manera general, desde el 2017 al 2024 se muestra una tendencia negativa, lo cual es coherente con el proceso de desglaciación registrado en la región.

Figura 18

Serie temporal del área glaciar (2017–2024)



4.3. Validación de resultados a partir del inventario de INAIGEM

El Objetivo Específico 3 consistió en analizar los resultados comparándolos con el inventario de glaciares del INAIGEM y empleando su metodología a imágenes Sentinel-2 para evaluar la precisión en el mapeo de superficies glaciares. A continuación, se detallan los principales hallazgos obtenidos.


4.3.1. Obtención de *data* de referencia

Se descargó el archivo *shapefile* del inventario nacional de glaciares publicado por INAIGEM. Utilizando herramientas de QGIS, se recortaron únicamente los

glaciares presentes dentro del área de estudio, obteniendo un área de 26.44 km² de glaciar libre. La Figura 19 muestra este vector de referencia.

Figura 19

Delimitación del área glaciar según INAIGEM 2020



4.3.2. Estimación empleando el NDSI


La Figura 20 presenta las estimaciones mensuales de la superficie glaciar (en km²) entre 2016–2024, calculadas a partir del índice NDSI aplicado a la misma cantidad de las imágenes satelitales Sentinel-2. Se utilizó un umbral de 0.4, ya que este valor es el que emplea el INAIGEM para generar el Inventario Nacional de Glaciares del Perú, correspondiente al año 2020. Esto permite establecer una base común para comparar los resultados de esta tesis con la metodología oficial

utilizada en el país. Las gráficas evidencian un comportamiento estacional recurrente, con máximos generalmente entre abril y julio, y mínimos entre septiembre y diciembre. En 2017 y 2018, se registraron valores máximos superiores a 39 km², mientras que en años recientes como 2020, 2021 y 2024, los máximos no superaron los 35 km². A su vez, años como 2019 y 2023 mostraron mayor variabilidad mensual y enfatizaron una tendencia decreciente en los valores máximos anuales en años recientes.

Durante el año 2020, Figura 20e, la evolución estacional fue clara: se observó un incremento desde enero (25 km²) hasta alcanzar un máximo de 34.5 km² en julio, coincidiendo con los meses de menor nubosidad y mayor exposición superficial del hielo (mes más seco). A partir de agosto, la superficie disminuyó hasta los 22.7 km² en septiembre, con ligeras fluctuaciones posteriores. La cobertura glaciaria se recupera parcialmente en octubre (25.2 km²), seguida de una leve disminución en noviembre (22.8 km²), y finalmente un ligero crecimiento en diciembre (24.0 km²). Una revisión visual de las imágenes satelitales en QGIS, reveló que las caídas en los últimos meses no obedecen exclusivamente a la pérdida de hielo, sino también a la presencia de sombras proyectadas por la topografía. Estas sombras reducen el valor del NDSI y genera subestimaciones, así se concluye que la metodología del NDSI es sensible tanto a la estacionalidad como a los efectos de las sombras.

Figura 20

Series temporales mensuales de la superficie glaciar estimada con NDSI > 0.4 de cada año desde el periodo 2016–2024




4.3.3. Vectores de cada modelo para comparación

Para comparar los resultados, se extrajeron vectores correspondientes a los métodos *Random Forest*, NDSI y el algoritmo de permanencia mediante QGIS (Figura 21). En el caso de *Random Forest*, se siguió la lógica utilizada en el inventario de glaciares, considerando como glaciar el área correspondiente al mes en el que la imagen satelital estuviera libre de nubes y ofreciera la mejor visibilidad de las masas glaciares. Según la serie temporal mostrada en la Figura 15, esta condición se cumple en el mes de septiembre de 2020, con un área de 25.54 km². De manera similar, se seleccionó también la imagen de septiembre de 2020 para calcular el área glaciar mediante el índice NDSI, obteniéndose el valor de 22.74 km² (Figura 20). En cuanto al algoritmo de permanencia, se utilizó el resultado del análisis de permanencia de píxeles correspondiente al año 2020, el cual identifica únicamente aquellas zonas clasificadas de forma constante como glaciar a lo largo de todas las escenas disponibles para ese periodo. Esta estimación se encuentra detallada en el Anexo 3 y en la Tabla 11, y alcanza una extensión de 26.42 km².

Figura 21

Superficie glaciar estimada según Random Forest, NDSI y el algoritmo de permanencia 2020




4.3.4. Comparación entre INAIGEM y los diferentes métodos

La Figura 22 muestra la superposición del inventario de INAIGEM (en amarillo) y con los resultados de *Random Forest* (en azul), el NDSI (en fucsia) y el Algoritmo de permanencia (en celeste). Así como, también se visualiza la imagen Sentinel-2 que se utilizó para la delimitación que corresponde a la fecha de septiembre del 2020 caracterizada por estar libre de nubes. Se observa una alta coincidencia entre las estimaciones de *Random Forest* y el algoritmo de permanencia con respecto al inventario oficial. Sin embargo, a pesar de la similitud general, se observa que el método del NDSI tiende a subestimar ligeramente la superficie glaciar.

Figura 22

Superposición espacial entre el inventario de INAIGEM y los otros métodos (Random Forest, NDSI y Algoritmo de Permanencia)




En la Figura 23, se identificaron tres zonas de discrepancia (A, B y C). En la zona A, se aprecia que el modelo *Random Forest* incluye una pequeña área que el inventario no considera glaciar. A su vez, en la zona B, el área azul parece ser que se ajusta casi por completo al contorno amarillo del INAIGEM, aunque se muestran errores dentro lo que es considerado por el vector de referencia. Para finalizar, en la zona C, se visualizan subestimaciones notorias en comparación al borde amarillo y en la parte superior.

Por otro lado, en el solapamiento entre la superficie glaciar mediante el NDSI y el inventario, se observan diferencias notables entre las delimitaciones. Es decir, el NDSI subestima la extensión glaciar, identificando una menor área glaciar que la registrada por el INAIGEM. En la zona A, se puede ver que la delimitación por el NDSI logra un buen trabajo en el glaciar inferior, mientras que en el superior se da el caso contrario. Empero, en la zona B, el área glaciar definida por el NDSI es visiblemente más estrecha que la delimitada por el INAIGEM. Las áreas con alto grado de sombras del glaciar no fueron delimitadas por el NDSI, lo que desestima parcialmente los bordes del glaciar. En el sitio C, se presenta una diferencia aún más notoria. La zona fucsia no cubre completamente la masa glaciar reconocida por el INAIGEM, quedando amplias secciones sin detectar.

Por último, en la superposición espacial entre el resultado realizado por el algoritmo de permanencia y la cobertura glaciar reportada por INAIGEM, se aprecia que la estimación de INAIGEM incluye una pequeña lengua glaciar adicional, que el algoritmo de permanencia no registra en la zona A. Por la zona B se presenta la mejor coincidencia entre ambas capas. Los contornos celestes del algoritmo de permanencia se ajustan mucho al polígono amarillo en contraste con las zonas A y C, pero aún se distinguen ciertos sitios en los que difieren. En fin, en la zona C, se observa una ligera sobreestimación por parte del algoritmo de permanencia en los márgenes superiores del glaciar. Específicamente, la capa celeste se extiende más allá del límite definido por INAIGEM.

Figura 23

Comparación entre el inventario de INAIGEM frente a las otras metodologías



La Tabla 12 presenta el grado de intersección espacial entre las delimitaciones generadas por cada modelo (*Random Forest*, NDSI y algoritmo de permanencia) y la capa oficial del inventario de glaciares de INAIGEM, dentro de las zonas de discrepancia analizadas en la Figura 23. Los resultados evidencian que, en cada una de las zonas evaluadas (A, B y C), el algoritmo de permanencia obtuvo los mayores niveles de coincidencia, superando tanto al modelo *Random Forest* como al método NDSI.

Tabla 12

Porcentajes de intersección por modelo frente a INAIGEM

Zona	<i>Random Forest</i> (%)	NDSI (%)	Algoritmo de Permanencia (%)
A	84.24	81.54	87.62
B	88.35	76.49	95.48
C	87.89	74.56	96.24

De manera general, la Tabla 13 presenta los valores de la intersección y unión espacial entre las delimitaciones generadas por cada método y el inventario de INAIGEM. Además, destacamos que el algoritmo de permanencia obtuvo la mayor área de intersección, con 24.79 km², respecto al inventario de INAIGEM (26.44 km²), así como una unión total de 28.07 km². En comparación, el modelo *Random Forest* alcanzó una intersección de 23.95 km² y el método NDSI solo 21.49 km².

Tabla 13

Comparación de áreas estimadas por distintos métodos con el inventario de INAIGEM

Métodos	Área (km²)	INAIGEM	Intersección	Unión
<i>Random Forest</i>	25.54		23.95	28.02
NDSI	22.74	26.44	21.49	27.69
Algoritmo de Permanencia	26.42		24.79	28.07

Asimismo, se realizó un análisis de evaluación cuantitativa utilizando métricas cuantitativas para comparar los resultados de cada uno de los métodos con la delimitación del inventario glaciar de INAIGEM, tal como se muestra en la Tabla 14. Entre los tres enfoques evaluados, el Algoritmo de Permanencia presentó los valores más altos en todas las métricas aplicadas: un Índice de Intersección sobre Unión (IoU) de 0.883, precisión de 0.939, un valor de sensibilidad de 0.938 y un espacio de puntuación F1 de 0.938. Estas métricas reflejan el grado de coincidencia entre la capa generada por el algoritmo y la referencia oficial.

Tabla 14

Métricas de validación entre INAIGEM y cada uno de los métodos


Método	Intersección sobre Unión	Precisión	Sensibilidad	Puntuación F1
<i>Random Forest</i>	0.855	0.938	0.906	0.922
NDSI	0.777	0.945	0.813	0.874
Algoritmo de Permanencia	0.883	0.939	0.938	0.938

4.3.5. Comparación entre *random forest* y NDSI

La Figura 24 muestra la distribución comparativa de las estimaciones realizadas por *Random Forest* y NDSI, ambos modelos aplicados sobre todas las imágenes satelitales. Esta figura permite visualizar las diferencias entre ambos métodos en cuanto a las áreas estimadas de superficie glaciar (en km²). En general, se observa que las estimaciones de *Random Forest* tienden a ser sistemáticamente mayores que las del NDSI, con una diferencia promedio de 2.48 km².

Figura 24


Distribución comparativa de las estimaciones de superficie glaciar obtenidas con Random Forest y NDSI



Sin embargo, existen ciertos meses, principalmente entre junio y agosto, en los que el NDSI presenta valores superiores. Esta sobreestimación puntual se debe a que el índice tiende a clasificar cuerpos de agua como glaciares, en especial las lagunas de origen glaciar que presentan alta reflectancia superficial (Figura 25), lo cual puede generar confusión en la delimitación.

Figura 25


Sobreestimación del mapeo por parte del NDSI



Por otro lado, las diferencias más marcadas se presentan en los meses de enero, febrero y marzo, donde las estimaciones del NDSI caen abruptamente respecto a *Random Forest*. En estos casos, el índice subestima la cobertura glaciar debido a su sensibilidad frente a condiciones atmosféricas adversas, como nubosidad densa o sombras topográficas, que afectan su respuesta espectral (Figura 26). Esto impide una adecuada detección de glaciares reales, especialmente en áreas con topografía compleja.

Figura 26


Desestimación del mapeo por parte del NDSI



En la Figura 27, el *boxplot* evidencia un análisis más integral de ambos métodos. Se observa que la mediana de las áreas estimadas por el NDSI es notablemente menor a la de *Random Forest*, lo que refuerza su tendencia general a subestimar. Además, presenta una mayor dispersión de los datos y un rango intercuartil más amplio, lo cual indica menor estabilidad en sus estimaciones. En cambio, *Random Forest* muestra una distribución más compacta, con valores más consistentes a lo largo de las escenas analizadas, salvo algunos valores atípicos por encima de los 37 km².

Figura 27

Boxplot de las diferencias de superficie glaciar estimada entre Random Forest y NDSI



Se aplicó la prueba de *Shapiro–Wilk* para verificar la normalidad de las diferencias mensuales de área entre ambos métodos, considerando un total de 93 escenas satelitales. El resultado ($p = 0.1949$) fue mayor al umbral de significancia ($\alpha = 0.05$), aceptándose la hipótesis nula y confirmando que las

diferencias tienen distribución normal. Posteriormente, la prueba T de *Student* para muestras pareadas arrojó un p-valor de 5.54×10^{-9} , lo cual indica una diferencia estadísticamente significativa. Esta diferencia puede explicarse por la mayor capacidad del modelo *Random Forest* para detectar glaciares en condiciones complejas, como sombras, hielo cubierto por detritos o zonas parcialmente cubiertas de nieve. En contraste, el NDSI, al utilizar un umbral fijo de 0.4, presenta limitaciones para adaptarse a esa variabilidad espectral, lo que resulta en omisiones recurrentes en el mapeo.

Tabla 15

Prueba T para muestras relacionadas (T–Student pareada)

Estadístico	Valor
Media <i>Random Forest</i>	32.24 km ²
Media NDSI	29.76 km ²
Diferencia promedio	2.48 km ²
t (T– <i>Student</i> pareada)	6.433
Grados de libertad (df)	92
p-valor	5.54×10^{-9}
Intervalo de confianza (95%)	[1.714, 3.239] km ²

V. DISCUSIÓN

El mapeo de superficies glaciares en los ecosistemas de los Andes tropicales del Perú ha adquirido una importancia creciente, especialmente debido a la limitada frecuencia con la que se realiza su monitoreo a escalas temporales más cortas. Esta falta de seguimiento detallado limita nuestra capacidad para generar información oportuna y confiable. Lo cual hace que sea difícil tomar decisiones efectivas frente a los impactos del cambio climático en estos entornos frágiles.

5.1. Desempeño espacial del algoritmo de permanencia

Uno de los análisis clave de nuestra investigación es la comparación espacial entre nuestros resultados y el inventario de glaciares publicado por INAIGEM. Las métricas de validación espacial demostraron que el vector generado por el algoritmo de permanencia (AP) presentó el mejor desempeño tras alcanzar los valores más altos en el Índice de Intersección sobre Unión ($\text{IoU} = 0.883$) y en la puntuación espacial F1 (0.938) ([Tabla 14](#)). Además, el algoritmo de permanencia mapeó 26.42 km² de cobertura glaciar, mientras que el inventario reporta 26.44 km², lo que representa una diferencia de 0.08%, evidenciando una alta concordancia entre ambas áreas. Asimismo, el área de intersección entre el algoritmo de permanencia y el inventario de INAIGEM fue de 24.79 km², superando el área de intersección obtenida por el *Random Forest* (23.95 km²) y el método del NDSI (21.49 km²), lo que confirma la mayor coincidencia espacial del algoritmo desarrollado ([Tabla 13](#)).

La clasificación de la cobertura glaciar y de nieve a partir de la permanencia temporal de los píxeles se fundamenta en la integración de la dinámica natural de estos sistemas y las limitaciones propias de la resolución espacial de las imágenes satelitales Sentinel-2. En este estudio, la permanencia (P) se define como la proporción de escenas en las que un píxel es clasificado como glaciar respecto al total de observaciones, lo que permite incorporar la dimensión temporal al análisis. El umbral de probabilidad de que haya hielo glaciar es de al menos el 90%. Esto se utiliza para identificar hielo glaciar permanente. Un valor menor al 100% permite tolerar errores y variabilidad sin afectar la identificación de superficies consolidadas. El rango de probabilidad entre el 90% y el 35% indica un glaciar en retroceso. Esto refleja la naturaleza dinámica de estos cuerpos, que cambian

gradualmente con el tiempo. Este intervalo es coherente con el uso de aproximadamente 100 escenas satelitales, lo que permite identificar zonas con presencia significativa de hielo, aunque no constante. El rango de probabilidad entre el 35% y el 10% representa nieve acumulada estacional. Esto se asocia con eventos de precipitación sólida durante temporadas húmedas, y su persistencia depende de condiciones climáticas como la temperatura y la radiación. Los valores de probabilidad por debajo del 10% corresponden a nieve efímera, que dura poco tiempo y desaparece rápidamente debido a condiciones ambientales que favorecen su fusión. En conjunto, estos umbrales permiten discriminar entre hielo permanente, zonas de transición glaciar y coberturas nivales de distinta duración. Esto se logra integrando criterios físicos y consideraciones técnicas del análisis satelital.

La alta precisión del algoritmo de permanencia se debe a que considera exclusivamente aquellas áreas clasificadas como glaciares de forma persistente a lo largo de los meses. Descarta coberturas transitorias como la nieve estacional y las interferencias atmosféricas. Esta capacidad se ve fortalecida por la integración de imágenes satelitales preprocesadas y del modelo de clasificación *Random Forest*. Es importante señalar que, como cualquier enfoque basado en teledetección, existen limitaciones. La resolución espacial de 10 metros puede restringir la detección de glaciares muy pequeños o de bordes irregulares. La dificultad de identificar correctamente zonas con sombra topográfica densa es otro obstáculo, aunque el enfoque multitemporal atenúa parcialmente estos efectos. Pese a estas limitaciones, este enfoque metodológico ha demostrado ser eficiente y adaptable a variables del entorno tropical andino. Incorporar el comportamiento temporal en la clasificación mejora significativamente la confiabilidad en la detección de coberturas en imágenes satelitales. El algoritmo de permanencia demuestra su capacidad de automatización al no requerir correcciones manuales para la delimitación de glaciares y poder mapear el área glaciar para cualquier fecha definida. Esto lo convierte en una herramienta robusta y replicable para estudios a nivel de subcuencas o cordilleras.

5.2. Análisis de discrepancias visuales y zonales

Las comparaciones visuales en zonas específicas como A, B y C mostraron grandes diferencias entre las metodologías aplicadas. En general, el algoritmo de permanencia se ajustó mejor a la delimitación oficial de INAIGEM. Superó a los métodos *Random Forest* y NDSI en la coincidencia espacial de áreas glaciares ([Figura 21](#) y [Figura 22](#)). En la zona A, *Random Forest* tuvo una ligera sobreestimación. Clasificó áreas adicionales que no estaban reconocidas en el inventario. Mostró una coincidencia del 84.24%. Por otro lado, el NDSI subestimó la cobertura glaciar. Especialmente, en la parte superior de la masa de hielo, tuvo una coincidencia del 81.54%. El algoritmo de permanencia presentó una pequeña subestimación por omitir una lengua glaciar, pero logró la mayor correspondencia con un 87.62% de coincidencia. En la zona B, *Random Forest* evidenció buena concordancia (88.35%) aunque con algunos errores internos de dispersión de píxeles, mientras que el NDSI mostró una subestimación más acusada (76.49%) debido principalmente a las sombras en áreas elevadas. En contraste, el algoritmo de permanencia obtuvo la coincidencia más alta (95.48%), ajustándose con precisión al límite del inventario. No obstante, incluso este algoritmo presentó algunos errores de omisión en sectores con sombra muy densa, donde pequeñas áreas glaciares no fueron detectadas debido a la atenuación de la señal espectral en condiciones de baja reflectancia, lo que limita su identificación. En la zona C, *Random Forest* subestimó en los bordes alcanzando un 87.89%, mientras que el NDSI presentó la discrepancia más alta con solo un 74.56%. Por su parte, el algoritmo de permanencia mantuvo una elevada correspondencia (96.24%), mostrando únicamente una ligera sobreestimación en los márgenes superiores ([Figura 23](#)). Estos resultados se resumen en la [Tabla 12](#) y reflejan que, de manera consistente, el algoritmo de permanencia presentó la delimitación más precisa y estable entre las metodologías evaluadas.

Las diferencias que vemos entre los métodos se deben a cómo cada algoritmo entiende los datos espectrales y temporales. En la zona A, tanto *Random Forest* como NDSI clasificaron áreas que no estaban dentro del contorno de INAIGEM. Esto sucedió porque, según la imagen satelital de ese mes, esos píxeles tenían los valores de reflectancia o el umbral del índice NDSI que corresponden a nieve

temporal. Sin embargo, el algoritmo de permanencia no consideró estas áreas porque no mantuvieron la categoría de glaciar de manera constante durante el periodo que se analizó. Esto se acerca más a la definición real de un glaciar. En la zona B, *Random Forest* tuvo errores de dispersión debido a la nieve estacional cerca de la laguna Palcacocha y las sombras que proyectan las montañas. El NDSI, por otro lado, subestimó en zonas altas porque es sensible a las sombras topográficas, lo que reduce el valor del índice. El algoritmo de permanencia, aunque tuvo algunos errores en sombras densas o bordes oscuros, se vio menos afectado por estas condiciones y mantuvo la coherencia espacial. En la zona C, hubo discrepancias en *Random Forest* debido a la nieve temporal. Sin embargo, todos los modelos coincidieron bastante bien con la imagen satelital de septiembre de 2020. Esto sugiere que incluso la delimitación oficial de INAIGEM podría tener algunos márgenes de sobreestimación en este sector. En general, los resultados muestran que el algoritmo de permanencia es menos sensible a las interferencias transitorias y logra una mayor estabilidad al identificar áreas glaciares.

5.3. Comparación entre *Random Forest* y NDSI

La comparación entre las clasificaciones generadas por *Random Forest* y el NDSI muestra un patrón estacional claro en la cobertura glaciar y de nieve. Esto significa que la cobertura es más grande entre abril y julio, y más pequeña entre septiembre y diciembre ([Figura 24](#)). Esto coincide con lo que otros investigadores han encontrado en la Cordillera Blanca. El modelo *Random Forest* es más consistente y tiene menos variaciones mensuales, mientras que el NDSI tiene fluctuaciones más grandes ([Figura 27](#)). El NDSI puede subestimar o sobreestimar la cobertura glaciar debido a la presencia de sombras y lagunas de origen glaciar ([Figura 25](#) y [Figura 26](#)). Al comparar los valores medios mensuales de ambos métodos, se observaron diferencias persistentes en las estimaciones de superficie glaciar. La diferencia promedio es de 2.48 km² entre ambos enfoques ([Tabla 15](#)), lo que es estadísticamente significativo.

Estas diferencias se deben a las limitaciones del NDSI para identificar correctamente la nieve. El NDSI se basa en la diferencia entre las bandas verde e infrarrojo cercano, lo que lo hace sensible a las sombras y la nubosidad. En cambio,

el método *Random Forest* es más flexible y puede adaptarse a condiciones variables. Combina múltiples variables espectrales y un enfoque de aprendizaje supervisado que permite discriminar patrones con mayor precisión. Aunque el *Random Forest* puede sobreestimar ligeramente, su capacidad de integración multiespectral y su adaptabilidad lo convierten en una herramienta más robusta para la estimación de áreas glaciares. También puede detectar variaciones estacionales de nieve, lo que podría ser relevante para futuros estudios. En resumen, el *Random Forest* es un método más preciso y flexible para estimar la cobertura glaciar y de nieve en la Cordillera Blanca.

5.4. Desempeño del modelo *Random Forest*

El modelo *Random Forest* funcionó muy bien cuando se entrenó con 3,00 puntos de datos. Obtuvo una precisión de 0.986 para áreas que no son glaciares y de 0.939 para áreas que sí lo son. Además, su coeficiente *kappa* fue de 0.933, lo que muestra que el modelo es muy preciso en general ([Tabla 10](#)). Estos resultados confirman que *Random Forest* es bueno para distinguir entre diferentes tipos de terrenos en zonas montañosas, como ya se había visto en otros estudios. Por ejemplo, un estudio de Khan et al. (2020) encontró que *Random Forest* funciona mejor que otros modelos, con un coeficiente *kappa* de 0.95. Otro estudio de Bueno et al. (2023) también mostró que *Random Forest* es muy bueno para mapear glaciares, con un índice de *Matthews* de 0.97. Lo interesante es que aumentar la cantidad de puntos de entrenamiento más allá de 3,000 no mejoró mucho la precisión del modelo. Esto es importante porque, aunque algunos estudios dicen que mil puntos de entrenamiento pueden ser suficientes, no siempre es así, especialmente en zonas con glaciares tropicales.

Luego, se crearon series temporales mensuales desde 2026 hasta 2024 para ver cómo cambió la cobertura glaciar con detalle ([Figura 15](#)). Antes de analizar los datos, se corrigieron algunos valores extraños que no se comportaban como se esperaba. Estos errores se debían principalmente a problemas con el preprocesamiento de datos por parte de una librería *SatCube*. Una vez corregidos los datos, se vio que la tendencia era negativa, es decir, la superficie glaciar en la subcuenca del río Quillcay se estaba reduciendo ([Figura 16](#)). Esto coincide con lo

que otros estudios han encontrado. Por ejemplo, Jara et al. (2024) encontraron que la pérdida de hielo en esa zona ha sido acelerada en las últimas décadas. En resumen, estos hallazgos muestran que usar herramientas de aprendizaje automático junto con análisis multitemporales es muy útil para obtener información confiable sobre el monitoreo de glaciares.

5.5. Dinámica glaciar de la subcuenca Quillcay

Los resultados obtenidos mediante la integración de imágenes satelitales Sentinel-2 preprocesadas, el modelo de clasificación supervisada *Random Forest* y el algoritmo de permanencia permitieron estimar la superficie glaciar en distintos años. Para el año 2017, la superficie estimada fue de 27.25 km². En 2020 se calculó un área de 26.42 km². Esto difiere en un 0.08% respecto al dato reportado oficialmente por INAIGEM en el mismo año, que fue de 26.44 km². Finalmente, para 2024 se obtuvo una estimación de 26.23 km². Esto muestra una disminución progresiva de la cobertura glaciar a lo largo del periodo analizado. La [Figura 18](#) muestra estos resultados. Este patrón descendente coincide con la investigación de Jara et al. (2023). En su estudio, reportaron superficies de 32.89 km² en 2007, 31.39 km² en 2014 y 29.93 km² en 2021. Estos datos reflejan la tendencia de retroceso sostenido en las últimas décadas.

No obstante, al analizar en detalle la variabilidad interanual mostrada en la Figura 18, se puede ver un pequeño aumento en la superficie glaciar entre 2019 y 2022. En 2019, la superficie glaciar fue de 26.34 km², y en 2022 fue de 26.56 km². Luego, hubo una nueva disminución hacia 2024. Este comportamiento no significa que el glaciar se esté recuperando de manera estructural. En cambio, se debe a cambios normales año a año en las condiciones climáticas de los glaciares tropicales. En años con más nieve sólida o condiciones climáticas favorables, puede haber más nieve persistente, lo que aumenta temporalmente la superficie glaciar visible. Es importante tener en cuenta que el algoritmo utilizado para estimar la cobertura glaciar se basa en información espectral y su duración en el tiempo. Por lo tanto, es sensible a la presencia de nieve estacional o acumulaciones temporales. El aumento en la superficie glaciar fue de aproximadamente 0.22 km², lo que equivale a menos del 1% del área total. Esta variación se encuentra dentro del rango normal de

cambios en el sistema glaciar, por lo que no contradice la tendencia general de retroceso observada en la subcuenca.

Hay que destacar que el estudio de Jara et al. (2023) utilizó imágenes Landsat y nuevos índices espectrales. Estos índices son el Índice Diferencial de Nieve Normalizado sin información hídrica (NDSInw) y el Índice Diferencial de Agua Normalizado sin información de nieve (NDSIns). Esto podría explicar las grandes diferencias en las estimaciones de superficie glaciar. Sus resultados se usaron directamente para calcular el volumen glaciar. Sin embargo, no se informó una validación específica frente a datos de referencia oficiales. Aunque los períodos no coinciden exactamente, la metodología propuesta en este trabajo de investigación mostró una alta correspondencia con el inventario oficial más reciente de INAIGEM. Esto respalda su mayor fiabilidad y relevancia para generar información precisa a nivel de subcuencas. También tiene potencial para aplicarse en otras áreas de la Cordillera Blanca.

5.6. Limitaciones

A pesar de los resultados que se han obtenido, el algoritmo que se ha desarrollado tiene limitaciones que hay que tener en cuenta al interpretar los resultados. En primer lugar, el algoritmo funciona bien si las series de imágenes satelitales son de buena calidad y están completas. Si hay mucho tiempo nublado o faltan datos, esto puede afectar la estimación de la permanencia de glaciares. Otro problema es que la clasificación se basa en un método llamado *Random Forest*. Este método puede tener sesgos si los datos de entrenamiento no son representativos de todas las zonas. Además, el algoritmo no tiene en cuenta factores como la pendiente, la orientación o la temperatura. Estos factores son importantes para entender cómo cambian los glaciares y podrían hacer que el modelo sea más preciso. También hay un problema para detectar glaciares que están cubiertos de escombros. Esto se debe a que estos glaciares pueden parecerse a superficies que no son de hielo en las imágenes.

Por otro lado, el enfoque de permanencia es útil porque permite ver cómo cambian los píxeles con el tiempo. Sin embargo, este enfoque depende de definir umbrales de permanencia, que se expresan en porcentaje. Estos umbrales dependen de la cantidad y continuidad de los datos satelitales mensuales disponibles para el área

que se está estudiando. Esto puede afectar la consistencia de la clasificación y requiere un proceso de calibración antes de aplicarlo en otros contextos. En el futuro, sería interesante investigar cómo combinar variables de diferentes fuentes, como la topografía del terreno, el clima y los datos de sensores remotos. Por ejemplo, se podrían utilizar modelos digitales de elevación para obtener información sobre la pendiente, orientación y altitud del terreno. También se podrían utilizar datos climáticos como la temperatura y la precipitación, y datos de sensores remotos como imágenes de radar SAR para mejorar la detección en condiciones de nubosidad. Además, se podría explorar el desarrollo de modelos que combinen técnicas de aprendizaje automático con técnicas de *deep learning*, utilizando grandes cantidades de datos. El objetivo sería mejorar la capacidad predictiva y la generalización del algoritmo en diferentes entornos glaciares. Esto permitiría obtener resultados más precisos y fiables en la clasificación y predicción de los glaciares.

VI. CONCLUSIONES

La investigación permitió mejorar la forma en que se mapean las superficies glaciares en la subcuenca Quillcay. Para hacer esto, se utilizaron imágenes Sentinel-2 que ya habían sido procesadas, un modelo de clasificación llamado *Random Forest* y un algoritmo que se ejecuta en Python. Esto ayudó a distinguir de manera efectiva los píxeles que son permanentes y los que son temporales. De esta manera, se pueden delimitar los glaciares de forma precisa sin necesidad de hacer correcciones a mano. La forma en que se hizo esto funcionó muy bien. Se validó con algunas métricas importantes, como un índice de intersección sobre la unión de 0.883 y una puntuación F1 de 0.938. Esto muestra que la metodología es muy confiable y efectiva para monitorear los glaciares. El modelo *Random Forest* se aplicó a imágenes Sentinel-2 que ya habían sido procesadas por una librería llamada *SatCube*. Esto permitió estimar de manera precisa cómo cambian los glaciares en la subcuenca Quillcay cada mes. Con un conjunto de 3,000 puntos de entrenamiento, el modelo funcionó muy bien, alcanzando una puntuación F1 de 0.956 y un coeficiente de *kappa* de 0.933. Esto muestra que el modelo es muy capaz de delimitar las áreas glaciares de forma robusta. La metodología utilizada permitió crear mapas mensuales de cómo cambian los glaciares. Esto dio una herramienta útil y de confianza para seguir su evolución en el tiempo. Se creó un algoritmo en *Python* que podía clasificar los píxeles de los glaciares según cuánto tiempo permanecían como glaciares. Este algoritmo mostró que la superficie glaciar en la zona estudiada disminuyó con el tiempo. En 2020, la superficie glaciar era de 26.42 km², pero para 2024 había disminuido a 26.23 km². Estas cifras coinciden con las reportadas por INAIGEM, que fue de 26.44 km² en 2020. Esto demuestra que el algoritmo no solo clasifica con precisión, sino que también puede detectar cambios en la cobertura a lo largo del tiempo. La comparación de los resultados con el inventario oficial de INAIGEM confirmó que el algoritmo funciona muy bien. El método de clasificación basado en cuánto tiempo permanece los glaciares funcionó mejor que usar un modelo de bosque aleatorio (*Random Forest*) o un índice llamado NDSI por separado. Los resultados mostraron que el algoritmo coincidía en un 87.62%, 95.48% y 96.24% con la información oficial en áreas donde había diferencias. Además, la diferencia en la superficie glaciar reportada fue de solo un 0.08% respecto a INAIGEM. Esto confirma que el método es preciso y útil para

delimitar y mapear glaciares. Es importante destacar que el algoritmo tiene algunas limitaciones. Su funcionamiento depende de la calidad y continuidad de las imágenes satelitales tomadas en diferentes momentos. La presencia de nubes o la falta de información puede afectar la estimación de la permanencia de los glaciares. La clasificación se hace mediante un método llamado *Random Forest*. Sin embargo, esto depende de la representatividad de los datos de entrenamiento. Si los datos no son representativos, puede haber sesgos en áreas con características únicas. Otro problema es que la metodología no tiene en cuenta variables como la pendiente u orientación del terreno, ni las condiciones climáticas. Estas variables podrían mejorar la precisión del modelo. Además, es difícil detectar glaciares cubiertos por escombros debido a que se parecen a otras superficies. Finalmente, la permanencia de los glaciares depende de la definición de umbrales. Esto limita su aplicación en otras regiones, ya que se necesita un proceso de calibración previo.

VII. RECOMENDACIONES

En base a lo que se encontró y se observó en este estudio sobre la cobertura glaciar en la subcuenca Quillcay, se hacen las siguientes recomendaciones:

- Se sugiere seguir explorando cómo determinar los rangos óptimos de conjuntos de datos para entrenar modelos de aprendizaje automático. Esto se debe a que cada área de estudio tiene características únicas. Al hacer esto, se puede mejorar cómo se clasifican las imágenes satelitales y se puede ser más preciso al delimitar las superficies glaciares.
- Es importante fomentar el uso de herramientas como *SatCube*, que ofrecen datos de alta calidad para hacer diferentes tipos de clasificaciones. Esto es importante porque al monitorear con intervalos más cortos, se puede entender mejor cómo cambian los glaciares debido al cambio climático. Sería valioso incluir las variaciones mensuales en un mapa interactivo en línea que permita visualizar los datos de manera fácil.
- Se debe usar este método en futuras investigaciones sobre lagunas de origen glaciar para entender cómo cambian cada mes y evaluar los riesgos en las fuentes de los ríos.
- Sería útil repetir este estudio en otras áreas para comparar los beneficios de analizar la permanencia en el monitoreo de estos ecosistemas.
- Es importante comparar los resultados con mediciones reales tomadas en el campo o con fotografías aéreas para asegurarse de que el método propuesto sea válido y confiable.
- La integración de detalles sobre el terreno y el clima, como la inclinación del terreno, su orientación, altura, temperatura y lluvia, mejoraría la precisión del algoritmo en situaciones complejas. Esto sería especialmente útil en áreas con escombros o cambios significativos en el paisaje.
- Un paso importante sería crear un método para ajustar los límites de tiempo que se utilizan para clasificar los datos. Para ello, habría que tener en cuenta cuántos datos satelitales mensuales se tienen y cómo de continuos son. El objetivo es asegurar que la clasificación sea coherente y que el algoritmo se pueda aplicar fácilmente en distintas regiones con glaciares.

VIII. REFERENCIAS BIBLIOGRÁFICAS

- Abbas, F., Shoaib, M., Abbas, A., Ismail, M., Alrefaei, A. F., Albeshr, M. F., & Cai, Z. (2024). Mapping Glacier Lake Susceptibility in Pakistan's Gilgit-Baltistan Using Glof Data, Geospatial Techniques, and Machine Learning (SSRN Scholarly Paper No. 4899334). Social Science Research Network. <https://doi.org/10.2139/ssrn.4899334>
- Aedo, M., & Montecinos, T. (2011). Glaciares andinos, recursos hídricos y cambio climático: desafío para la justicia climática en el Cono Sur. Programa Chile Sustentable. https://www.researchgate.net/publication/327211812_Glaciares_andinos_recursos_hidricos_y_cambio_climatico_desafios_para_la_justicia_climatica_en_el_Cono_Sur
- Alonso, C., Moreno, V., & Rodríguez, E. (1999, September). Determinación experimental de la firma espectral de la vegetación. Una sencilla práctica de introducción a la teledetección. In TELEDETECCIÓN. Avances y Aplicaciones. VIII Congreso Nacional de Teledetección. Albacete, España (pp. 429-43).
- Alpaydin, E. (2016). Machine Learning: The New AI. MIT Press.
- Andina (SGCAN). (2008). El cambio climático no tiene fronteras: Impacto del cambio climático en la Comunidad Andina. Repositorio Institucional - ANA. <https://repositorio.ana.gob.pe/handle/20.500.12543/4600>
- Aniya M. (2024). The Use of Satellite and Airborne Imagery to Inventory Outlet Glaciers of the Southern Patagonia Icefield, South America. ResearchGate. https://www.researchgate.net/publication/265629924_The_Use_of_Satellite_and_Airborne_Imagery_to_Inventory_Outlet_Glaciers_of_the_Southern_Patagonia_Icefield_South_America
- Aberle, R., Enderlin, E., O'Neel, S., Florentine, C., Sass, L., Dickson, A., Marshall, H. P. & Flores, A. (2024). Automated snow cover detection on mountain glaciers using space-borne imagery. 10.5194/egusphere-2024-548.

- Arias, A., Núñez, N., Rau, P., & Venail, P. (2024). Development of a spatial projection map of glacial retreat based on vulnerability maps in the Central Cordillera, Peru. *Journal of Water and Climate Change*, 15(6), 2863-2884. <https://doi.org/10.2166/wcc.2024.151>
- Arsuza Olaechea, H. (2006). Glosario básico de términos estadísticos. *Centro de Investigación y Desarrollo Talleres de la Oficina Técnica de Administración (OTA) del Instituto Nacional de Estadística e Informática (INEI)* (pp. 32). https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib0900/Libro.pdf
- Autoridad Nacional del Agua (ANA), Consorcio Typsa - Tecnomia - Engecorps, & Grupo Inclam. (2015, Noviembre). Evaluación de recursos hídricos en la cuenca Santa. Ministerio de Desarrollo Agrario y Riego (MIDAGRI). <https://repositorio.ana.gob.pe/handle/20.500.12543/23>
- Autoridad Nacional del Agua (ANA). (2014). Inventario nacional de glaciares y lagunas. <https://repositorio.ana.gob.pe/handle/20.500.12543/199>
- Autoridad Nacional del Agua (ANA). (2017). El futuro del clima y de los glaciares en el Perú. <https://repositorio.ana.gob.pe/handle/20.500.12543/4137>
- Autoridad Nacional del Agua (ANA). (2019, Febrero). Glaciares: Reservas de agua. Dirección de Calidad y Evaluación de Recursos Hídricos. Área de Evaluación de Glaciares y Lagunas. <https://hdl.handle.net/20.500.12543/3621>
- Aybar, C., Bautista, L., Montero, D., Contreras, J., Ayala, D., Prudencio, F., Loja, J., Ysuhuaylas, L., Herrera, F., Gonzales, K., Valladares, J., Flores, L. A., Mamani, E., Quiñonez, M., Fajardo, R., Espinoza, W., Limas, A., Yali, R., Alcántara, A., ... Gómez-Chova, L. (2024). CloudSEN12+: The largest dataset of expert-labeled pixels for cloud and cloud shadow detection in Sentinel-2. *Data in Brief*, 56, 110852. <https://doi.org/10.1016/j.dib.2024.110852>
- Banerjee, A., Kang, S., Guo, W., Meadows, M. E., Wang, W., Sengupta, D., & Zhang, T. (2024). Glacier retreat and lake outburst floods in the central

- Himalayan region from 2000 to 2022. *Natural Hazards*, 120(6), 5485-5508. <https://doi.org/10.1007/s11069-024-06415-5>
- Barzycka, B., Grabiec, M., Jania, J. Błaszczuk, M., Pálsson, F., Laska, M., Ignatiuk, D. & Aðalgeirsdóttir, G. (2023). Comparison of Three Methods for Distinguishing Glacier Zones Using Satellite SAR Data. *Remote Sensing*, 15, 690. <https://doi.org/10.3390/rs15030690>
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Baraer, M., Mark, B. G., McKenzie, J. M., Condom, T., Bury, J., Huh, K.-I., Portocarrero, C., Gómez, J., & Rathay, S. (2017, September 08). Glacier recession and water resources in Peru's Cordillera Blanca. *Journal of Glaciology*, 58(207), 134-150. DOI:10.3189/2012JoG11J186
- Bevington, A. R., & Menounos, B. (2022). Accelerated change in the glaciated environments of western Canada revealed through trend analysis of optical satellite imagery. *Remote Sensing of Environment*, 270, 112862. <https://doi.org/10.1016/j.rse.2021.112862>
- Bonilla, E. X., Mickley, L. J., Beaudon, E. G., Thompson, L. G., Rodriguez, W. E., Encarnación, R. C., Whicker, C. A., Flanner, M. G., Schmitt, C. G., & Ginot, P. (2023). Contribution of biomass burning to black carbon deposition on Andean glaciers: Consequences for radiative forcing. *Environmental Research Letters*, 18(2), 024031. <https://doi.org/10.1088/1748-9326/acb371>
- Bouchayer, C., Aiken, J. M., Thøgersen, K., Renard, F., & Schuler, T. V. (2022). A Machine Learning Framework to Automate the Classification of Surge-Type Glaciers in Svalbard. *Journal of Geophysical Research: Earth Surface*, 127(7), e2022JF006597. <https://doi.org/10.1029/2022JF006597>
- Boyano Sotillo, P. D. (2017, Agosto 09). Servicios ecosistémicos de la criósfera y los páramos de la Cordillera Blanca, Perú. SIAR Ancash. Retrieved Marzo 22, 2025, from <https://sinia.minam.gob.pe/documentos/servicios-ecosistemicos-criosfera-paramos-cordillera-blanca-peru>

- Bradley, R. S., Vuille, M., Diaz, H. F., & Vergara, W. (2006, July 16). Threats to Water Supplies in the Tropical Andes. *Science*, 312(5781), 1755-1756. DOI:10.1126/science.1128087
- Bueno, M., Macera, B., & Montoya, N. (2023). A Comparative Analysis of Machine Learning Techniques for National Glacier Mapping: Evaluating Performance through Spatial Cross-Validation in Perú. *Water*, 15(24), Article 24. <https://doi.org/10.3390/w15244214>
- Bulege-Gutierrez, W., & Custodio, M. (2020). Climate change and glacier retreat in the Huaytapallana Mountain Range, Peru. *Universidad Continental*. <https://doi.org/10.24850/j-tyca-2020-02-06>
- Burger, F., Ayala, A., Farias, D., Shaw, T. E., MacDonell, S., Brock, B., McPhee, J., & Pellicciotti, F. (2018, November 26). Interannual variability in glacier contribution to runoff from a high-elevation Andean catchment: Understanding the role of debris cover in glacier hydrology. *Hydrological Processes*, 33(2), 214-229. <https://doi.org/10.1002/hyp.13354>
- Bury, J. T., Mark, B. G., McKenzie, J. M., Frendh, A., Baraer, M., Hub, K. I., Zapata Luyo, M. A., & JesúsGómez López, R. J. (2011, June 15). Glacier recession and human vulnerability in the Yanamarey watershed of the Cordillera Blanca, Peru. *Climatic Change*, 105, 179-206. <https://link.springer.com/article/10.1007/s10584-010-9870-1>
- Buytaert, W., Moulds, S., Acosta, L., De Bièvre, B., Olmos, C., Villacis, M., Tovar, C., & Verbist, K. M. J. (2017, November 2). Glacial melt content of water use in the tropical Andes. *Environmental Research Letters*, 12(11), 1-9. DOI:10.1088/1748-9326/aa926c
- Carey, M. (2005, July 25). Living and dying with glaciers: people's historical vulnerability to avalanches and outburst floods in Peru. *Global and Planetary Change*, 47(2-4), 122-134. <https://doi.org/10.1016/j.gloplacha.2004.10.007>.
- Carey, M. (2010). *In the Shadow of Melting Glaciers: Climate Change and Andean Society*. Oxford University Press, USA. <https://doi.org/10.1093/acprof:oso/9780195396065.001.0001>

- Carvalho, M., Cardoso-Fernandes, J., González, F. J., & Teodoro, A. C. (2025). Comparative Performance of Sentinel-2 and Landsat-9 Data for Raw Materials' Exploration Onshore and in Coastal Areas. *Remote Sensing*, 17(2), Article 2. <https://doi.org/10.3390/rs17020305>
- Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres (CENEPRED). (2018, Abril). Informe Técnico N° 05: Investigación para la elaboración del mapa de peligros, reducción del riesgo y la adaptación al cambio climático en ambientes de Subcuencas Glaciares del Perú. Subcuenca del río Quillcay, Huaraz, Ancash. Repositorio del Sistema de Información para la Gestión del Riesgo de Desastres (SIGRID). <https://sigrid.cenepred.gob.pe/sigridv3/documento/10559>
- Chacón A., N., Jacay H., J., & Moreno C., I. (2005). PROCESOS GEODINÁMICOS EN EL ÁREA RÍO QUILLCAY, HUARAZ - ANCASH. *Revista del Instituto de Investigación FIGMMG*, 8(16), 22-28. https://sisbib.unmsm.edu.pe/bibvirtualdata/publicaciones/geologia/vol8_n16/a03.pdf
- Chamorro, J., & Mera, E. (2025, Enero 10). Estudio de la crisis energética en el Ecuador por la dependencia en la generación de energía hidráulica. “INGENIAR”: Ingeniería, Tecnología e Investigación, 8(15), 168-186. <https://doi.org/10.46296/ig.v8i15.0240>
- Chevallier, P., Pouyaud, B., Suarez, W., & Condom, T. (2010, November 14). Climate change threats to environment in the tropical Andes: Glaciers and water resources. *Regional Environmental Change*, 11, 179-187. DOI:10.1007/s10113-010-0177-6
- Chuvieco, E. (2002). Fundamentos de teledetección espacial. Ariel Ciencia.
- Colque, P. (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. <http://repositorioslatinoamericanos.uchile.cl/handle/2250/3279796>

- Contreras & Aybar (s.f.). Satcube: A Python package for managing Sentinel-2 satellite data cubes. GitHub. <https://pypi.org/project/satcube/>
- Cook, D., Malinauskaite, L., Davíðsdóttir, B., & Ögmundardóttir, H. (2021, August). Co-production processes underpinning the ecosystem services of glaciers and adaptive management in the era of climate change. *Ecosystem Services*, 50. <https://doi.org/10.1016/j.ecoser.2021.101342>
- Copernicus, 2018. El componente espacio Copernicus. Instituto Geográfico Nacional. https://www.ign.es/web/resources/docs/IGNCnig/actividades/OBS/Programa_Marco_Copernicus_User_Uptake/3_componente_espacio_Copernicus.pdf
- Copernicus (s. f.). Sentinel-2 | Ecosistema de datos espaciales de Copernicus. Recuperado 23 de marzo de 2025, de <https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2>
- Crisanto Rojas, N., & Iannaccone, J. (2023, Noviembre 10). Evaluación del impacto de la acidificación en la calidad del agua de la quebrada Quilcayhuanca, Ancash, Perú. *Revista de la Academia Colombiana de Ciencias Exactas Físicas y Naturales*, 1-18. DOI:10.18257/raccefyn.1950
- De Piérola C., J. N., & Cámara de Comercio Peruano-Alemana. (2017). El agua y su uso en minería y agricultura en el Perú, una primera aproximación. In (pp. 1-24). Asociación Peruana de Ingeniería Hidráulica y Ambiental (APIHA). Retrieved Marzo 17, 2025, from <https://www.collegesidekick.com/study-docs/13945519>
- Dematteis, N., Troilo, F., Scotti, R., Colombarolli, D., Giordan, D., & Maggi, V. (2024). The use of terrestrial monoscopic time-lapse cameras for surveying glacier flow velocity. *Cold Regions Science and Technology*, 222, 104185. <https://doi.org/10.1016/j.coldregions.2024.104185>
- Dudley, R. (2012, September 12). *THE SHAPIRO–WILK TEST FOR NORMALITY*. MIT Mathematics. <https://math.mit.edu/~rmd/46512/shapiro.pdf#page=1.07>

- Dozier, J. (1989). Spectral signature of alpine snow cover from the landsat thematic mapper. *Remote Sensing of Environment*, 28, 9-22. [https://doi.org/10.1016/0034-4257\(89\)90101-6](https://doi.org/10.1016/0034-4257(89)90101-6)
- Emmer, A., & Vilímek, V. (2013, Junio 18). Review Article: Lake and breach hazard assessment for moraine-dammed lakes: an example from the Cordillera Blanca (Peru). *Natural Hazards Earth System Sciences*, 13(6), 1551-1565. <https://doi.org/10.5194/nhess-13-1551-2013>
- Escalante-Ramirez, B. (2012). Remote Sensing - Applications. En S. Ambinakudige & K. Joshi (Eds.), *Remote Sensing of Cryosphere* (pp. 369 - 380). <https://doi.org/10.5772/2670>
- Francou, B., Rabatel, A., Cueva, A., Sicart, J. E., Silvestre, E., Ginot, P., Cáceres, B., Condom, T., Villacis, M., Ceballos, J. L., Anthelme, F., Dangles, O., Favier, V., Maisincho, L., Jomelli, V., Vuille, M., Wagnon, P., Lejeune, Y., Ramallo, C., & Mendoza Rodríguez, J. (2013). Glaciares de los Andes Tropicales Víctimas del Cambio Climático. DOI:10.13140/RG.2.1.1255.4082
- Fyffe, C. L., Potter, E., Fugger, S., Orr, A., Fatichi, S., Loarte, E., Medina, K., Hellström, R. Å., Bernat, M., Aubry-Wake, C., Gurgiser, W., Perry, L. B., Suarez, W., Quincey, D. J., & Pellicciotti, F. (2021). The Energy and Mass Balance of Peruvian Glaciers. *Journal of Geophysical Research: Atmospheres*, 126(23), e2021JD034911. <https://doi.org/10.1029/2021JD034911>
- Garreaud Salazar, R., Álvarez Carretón, C., Barichivich, J., Boisier, J. P., Christie, D., Galleguillos, M., LeQuesne, C., McPhee, J., & Zambrano Bigiarini, M. (2017, December 13). The 2010-2015 megadrought in central Chile: Impacts on regional hydroclimate and vegetation. *Hydrology and Earth System Sciences*, 21(12), 6307 - 6327. DOI:10.5194/hess-21-6307-2017
- Garzón Quiroz, M. Q., & Villota Oyarvide, W. R. (2020). Prueba t para muestras relacionadas e independientes usando Rstudio, para que sirve y cómo aplicarlo. In *Convergencias y divergencias en investigación* (1st ed., pp. 192-203). Enseñanza de la investigación, Investigación Social, Investigación

Educativa, Fontaines-Ruiz Tomás, MazaCórdova Jorge, Johann Pirela Morillo y Yameli Armaza Franco. <http://tendin.risei.org>

Gascoin, S., Monteiro, D., & Morin, S. (2022). Reanalysis-based contextualization of real-time snow cover monitoring from space. *Environmental Research Letters*, 17(11), 114044. <https://doi.org/10.1088/1748-9326/ac9e6a>

Gilardoni, S., Di Mauro, B., & Bonasoni, P. (2022). Black carbon, organic carbon, and mineral dust in South American tropical glaciers: A review. *Global and Planetary Change*, 213, 103837. <https://doi.org/10.1016/j.gloplacha.2022.103837>

Gonda, C. M. (2019). El Cambio Climático y La Criosfera Andina. Fundación Ambiente y Recursos Naturales (FARN). https://www.airclim.org/sites/default/files/documents/report_andes_-_cryosphere_and_climate_change.pdf

González Estrada, E., & Cosmes, W. (2019, August 27). Shapiro–Wilk test for skew normal distributions based on data transformations. *Journal of Statistical Computation and Simulation*, 89(17), 3258-3272. <https://doi.org/10.1080/00949655.2019.1658763>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Hall, D. K., & Riggs, G. A. (2011). Normalized-Difference Snow Index (NDSI). En V. P. Singh, P. Singh, & U. K. Haritashya (Eds.), *Encyclopedia of Snow, Ice and Glaciers* (pp. 779-780). Springer Netherlands. https://doi.org/10.1007/978-90-481-2642-2_376

Hall, D. K., Riggs, G. A., & Salomonson, V. V. (1995). Development of methods for mapping global snow cover using moderate resolution imaging spectroradiometer data. *Remote Sensing of Environment*, 54(2), 127-140. [https://doi.org/10.1016/0034-4257\(95\)00137-P](https://doi.org/10.1016/0034-4257(95)00137-P)

Hassan, S. N. ul, Reba, M. N. M., & Ahmed, A. (2025). Extracting clear ice surface of mountainous glaciers of Karakoram Range using Machine Learning for

different Band Ratio compositions of OLI: Case Study of Hunza Sub-Basin. *Journal of Himalayan Earth Sciences*, 58(1), Article 1.

He, Q., Zhang, Z., Ma, G., & Wu, J. (2020). GLACIER IDENTIFICATION FROM LANDSAT8 OLI IMAGERY USING DEEP U-NET. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-3-2020, 381-386. XXIV ISPRS Congress, Commission III (Volume V-3-2020) - 2020 edition. <https://doi.org/10.5194/isprs-annals-V-3-2020-381-2020>

Hernández, F. (2024). Modelos Predictivos. Recuperado 16 de abril de 2025, de https://fhernanb.github.io/libro_mod_pred/index.html

Hewitt, K. (2011). Glacier Change, Concentration, and Elevation Effects in the Karakoram Himalaya, Upper Indus Basin. *Mountain Research and Development*, 31(3), 188-200. <https://doi.org/10.1659/MRD-JOURNAL-D-11-00020.1>

Huggel, C., Carey, M., Emmer, A., Frey, H., Walker Crawford, N., & Wallimann Helmer, I. (2020, August 13). Anthropogenic climate change and glacier lake outburst flood risk: local and global drivers and responsibilities for the case of lake Palcacocha, Peru. *Natural Hazards and Earth System*, 20(8), 2175-2193. <https://doi.org/10.5194/nhess-20-2175-2020>, 2020.

Iniciativa Andina de Montañas, Proyecto Adaptación al Cambio Climático, & CONDESAN. (2022, Noviembre 10). Gente de Los Andes: Diferentes, pero con tanto en común. https://iam-andes.org/wp-content/uploads/2022/08/INFOGRAFIA-Gente_de_los_Andes.pdf

Inoue Velarde, J. H. (2018). Evolución de la cobertura glaciar y su influencia en la disponibilidad hídrica de la subcuenca blanco – Río Santa. Repositorio institucional de la Universidad Nacional Federico Villarreal. Retrieved Marzo 20, 2025, from <https://hdl.handle.net/20.500.13084/2706>

Instituto Nacional de Defensa Civil (INDECI). (2017, Junio 05). PELIGRO POR EMBALSE DE LAGUNA PALCACOCHA EN EL DISTRITO DE INDEPENDENCIA – ANCASH. Centro de Operaciones de Emergencia Nacional (COEN). <https://portal.indeci.gob.pe/wp->

content/uploads/2021/04/REPORTE-DE-PELIGRO-N%C2%BA-026-05062017-COEN-INDECI-1150-HORAS-Reporte-N%C2%B0-03-PELIGRO-POR-EMBALSE-DE-LAGUNA-PALCACOCHA-EN-EL-DISTRITO-DE-INDEPENDENCIA-%E2%80%93-ANCASH.pdf

Instituto Nacional de Estadística e Informática (INEI). (2017a). Resultados definitivos de los Censos Nacionales 2017. <https://censo2017.inei.gob.pe/resultados-definitivos-de-los-censos-nacionales-2017/>

Instituto Nacional de Estadística e Informática (INEI). (2017b). *Glosario de Términos del Compendio Estadístico. Perú 2017* (pp. 31). https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib1483/glosario1.pdf

Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña, Huaraz (INAIGEM). (2018b, Abril). Informe Técnico N° 01 Subcuenca Quillcay. Ministerio del Ambiente (MINAM). <https://repositorio.inaigem.gob.pe/items/008ad8cc-0c35-420b-bbeb-0e7763eda5a8>

Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM). (2018a, Marzo). Inventario Nacional de Glaciares Las Cordilleras Glaciares del Perú 2018. Ministerio del Ambiente (MINAM). <https://repositorio.inaigem.gob.pe/items/69842963-64e0-4de9-9c24-f886a5c5a40d>

Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM). (2023). Inventario Nacional de Glaciares y Lagunas de Origen Glaciar 2023. Ministerio del Ambiente (MINAM). <https://repositorio.inaigem.gob.pe/items/7029db53-5118-4e93-8b2a-71e6e26db5f6>

Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM). (2017). Manual Metodológico de Inventario Nacional de Glaciares. <https://hdl.handle.net/20.500.12748/63>

Intergovernmental Panel on Climate Change (IPCC). (2013). Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change (T. F. Stocker, D. Qin, G. K. Plattner, M. M. B. Tignor, S. K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex, & P. M. Midgley, Eds.). Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1585. <https://www.ipcc.ch/report/ar5/wg1/>

Intergovernmental Panel on Climate Change (IPCC). (2019a). *Informe especial sobre los océanos y la criosfera en un clima cambiante del IPCC: Resumen para responsable de políticas* (H. O. Pörtner, D. C. Roberts, V. Masson Delmotte, P. Zhai, M. Tignor, E. Poloczanska, K. Mintenbeck, A. Alegría, M. Nicolai, A. Okem, J. Petzold, B. Rama, & N. M. Weyes, Eds.). https://www.ipcc.ch/site/assets/uploads/sites/3/2020/07/SROCC_SPM_es.pdf

Intergovernmental Panel on Climate Change (IPCC). (2019b). Climate Change and Land. <https://www.ipcc.ch/site/assets/uploads/2019/11/SRCCL-Full-Report-Compiled-191128.pdf>

Izaguirre Liviach, M. F., Drenkhan, F., Timaná, M. E., Izaguirre Liviach, M. F., Drenkhan, F., & Timaná, M. E. (2024). Actual y futura disponibilidad del agua en un contexto de inseguridad hídrica en la subcuenca de Parón, cuenca del río Santa, Perú. *Revista Kawsaypacha: Sociedad y Medio Ambiente*, 13. <https://doi.org/10.18800/kawsaypacha.202401.a001>

Jara, F., Mejía, A., Mejía, T., & Revelo, G. (2023). Estimation of Deglaciation in the Quillcay River Sub-Basin-Peru, in the Face of Climate Change. *Migration Letters*, 20(S2), Article S2. <https://doi.org/10.59670/ml.v20iS2.3884>

Jara Remigio, F. A. (2024). Respuesta hidrológica de la subcuenca del río Quillcay respecto a la variabilidad climática andina en un contexto de cambio climático. Repositorio Institucional Universidad Nacional Agraria La Molina. <https://hdl.handle.net/20.500.12996/6722>

- Jia, P., He, W., Hu, Y., Liang, Y., Liang, Y., Xue, L., Zamanian, K., & Zhao, X. (2024). Inversion of coastal cultivated soil salt content based on multi-source spectra and environmental variables. *Soil and Tillage Research*, 241, 106124. <https://doi.org/10.1016/j.still.2024.106124>
- Johansen, K. S., Alfthan, B., Baker, E., Hespings, M., Schoolmeester, T., & Verbist, K. (2018). The Andean Glacier and Water Atlas: The Impact of Glacier Retreat on Water Resources. UNESCO - Base de Datos sobre Recursos Mundiales. <https://unesdoc.unesco.org/ark:/48223/pf0000265810>
- Kari, J., et al. (2018). El Atlas de Glaciares y Aguas Andinos: El impacto del retroceso de los glaciares sobre los recursos hídricos—UNESCO Biblioteca Digital. (s. f.). Recuperado 26 de septiembre de 2024, de <https://unesdoc.unesco.org/ark:/48223/pf0000266209>
- Keshri, A. K., Shukla, A., & Gupta, R. P. (2009). ASTER ratio indices for supraglacial terrain mapping. *International Journal of Remote Sensing*, 30(2), 519-524. <https://doi.org/10.1080/01431160802385459>
- Khan, A. A., Jamil, A., Hussain, D., Ali, I., & Hameed, A. A. (2023). Deep learning-based framework for monitoring of debris-covered glacier from remotely sensed images. *Advances in Space Research*, 71(7), 2978-2989. <https://doi.org/10.1016/j.asr.2022.05.060>
- Khan, A. A., Jamil, A., Hussain, D., Taj, M., Jabeen, G., & Malik, M. K. (2020). Machine-Learning Algorithms for Mapping Debris-Covered Glaciers: The Hunza Basin Case Study. *IEEE Access*, 8, 12725-12734. <https://doi.org/10.1109/ACCESS.2020.2965768>
- Klusak, J. (2019). The Implementation of UAS-Photogrammetry in Extreme Altitude Tropical Glacier Surveying – A Field Study in the Bolivian Andes. *Geophysical Research Abstracts*, 21. https://openurl.ebsco.com/EPDB%3Agcd%3A3%3A148595/detailv2?sid=ebsco%3Aplink%3Ascholar&id=ebsco%3Agcd%3A140485591&crl=c&link_origin=none

- Kundu R. (2022). F1 Score in Machine Learning: Intro & Calculation. Recuperado 20 de abril de 2025, de <https://www.v7labs.com/blog/f1-score-guide>
- Kwak, S. G., & Park, S. H. (2019, January). Normality Test in Clinical Research. *Journal of Rheumatic Diseases*, 26(1), 5-11. <https://doi.org/10.4078/jrd.2019.26.1.5>
- Laboratorio de Glaciología. (2025). Glosario. <https://glaciologia.cl/glosario/>
- La Matta Romero, F. P. (2020). "INFLUENCIA DEL DRENAJE ÁCIDO DE ROCA EN LA COMUNIDAD DE MACROINVERTEBRADOS BENTÓNICOS, ÍNDICES BIÓTICOS DE CALIDAD DE AGUA Y GRUPOS FUNCIONALES ALIMENTICIOS EN RÍOS Y CABECERAS DE LA CORDILLERA BLANCA (SUBCUENCA DE QUILLCAY, ANCASH)". Repositorio Institucional Universidad Peruana Cayetano Heredia. https://repositorio.upch.edu.pe/bitstream/handle/20.500.12866/8533/Influencia_LaMattaRomero_Fiorella.pdf?sequence=1&isAllowed=y
- Leon Chavez, E. P. (2022). Influencia de la temperatura y la precipitación en el balance de masa glaciar en la cordillera blanca, 1962 – 2020. https://alicia.concytec.gob.pe/vufind/Record/RUNM_c289529ced0e43732cf6436f7f49b4bf/Details
- Loarte Cadenas, E., Rabatel, A., & Gómez López, J. (2015). Determinación de la variación espacio-temporal de la altura de la línea de equilibrio de los glaciares de la Cordillera Blanca, Perú. Autoridad Nacional del Agua. <https://repositorio.ana.gob.pe/handle/20.500.12543/3193>
- Loayza Muro, R. (2014, Marzo). Nota Técnica 2: CALIDAD DE AGUA EN CABECERAS DE CUENCAS ALTOANDINAS EN EL CONTEXTO DE CAMBIO CLIMÁTICO. Una aproximación para evaluar la calidad del agua y potencial remediación en la subcuenca de Quillcay. Ministerio del Ambiente (MINAM). https://sinia.minam.gob.pe/sites/default/files/siar-ancash/archivos/public/docs/nota_tecnica_02.pdf

- Mark, B. G., French, A., Baraer, M., Carey, M., Bury, J., Young, K. R., Polk, M. H., Wigmore, O., Lagos, P., Crumley, R., McKenzie, J. M., & Lautz, L. (2017, December). Glacier loss and hydro-social risks in the Peruvian Andes. *Global and Planetary Change*, 159, 61-76. <https://doi.org/10.1016/j.gloplacha.2017.10.003>
- Mark, B. G., McKenzie, J. M., & Gómez López, J. (2005). Hydrochemical evaluation of changing glacier meltwater contribution to stream discharge: Callejon de Huaylas, Peru. *Autoridad Nacional del Agua (ANA)*. <https://repositorio.ana.gob.pe/handle/20.500.12543/3336>
- Marr, P., Winkler, S., & Löffler, J. (2022). Environmental and Socio-Economic Consequences of Recent Mountain Glacier Fluctuations in Norway. *Mountain Landscapes in Transition*, 289-314. https://doi.org/10.1007/978-3-030-70238-0_10
- Martel Valverde, G., Torres Lázaro, J. C., & Jara Infantes, W. H. (2018). Variación del pH en Aguas Superficiales Debido a Drenajes Ácidos de Roca en la Subcuenca Quillcay, Huaraz, Ancash. *Boletín Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña, Huaraz, Ancash (INAIGEM)*, 5, 57-68. <https://doi.org/10.36580/rgem.i5.57-68>
- Mashford Mahute (24 de octubre de 2024) Landsat 9 vs Sentinel-2 [Publicación]. *Linkedin*. https://www.linkedin.com/posts/mashford-mahute-012487178_landsat9-sentinel2-earthobservation-activity-7245714992686153728-eL2Q/
- 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>
- Mellit, A., & Kalogirou, S. A. (2008). Artificial intelligence techniques for photovoltaic applications: A review. *Progress in Energy and Combustion Science*, 34(5), 574-632. <https://doi.org/10.1016/j.pecs.2008.01.001>

- Ministerio del Ambiente (MINAM). (2014). Nota Técnica 02—Calidad de agua en cabeceras de cuencas altoandinas en el contexto de Cambio Climático. | SINIA. (s. f.). Recuperado 18 de septiembre de 2024, de <https://sinia.minam.gob.pe/documentos/nota-tecnica-02-calidad-agua-cabeceras-cuencas-altoandinas-contexto>
- Mojica-Moncada, D. F., Cárdenas, C., Mojica-Moncada, J. F., Brondi, F., Barragán-Barrera, D. C., Marangunic, C., Holland, D., Franco Herrera, A., Casassa, G., Mojica-Moncada, D. F., Cárdenas, C., Mojica-Moncada, J. F., Brondi, F., Barragán-Barrera, D. C., Marangunic, C., Holland, D., Franco Herrera, A., & Casassa, G. (2021). Estudio del glaciar Lange y su impacto debido al aumento de temperatura en la bahía Almirantazgo, isla Rey Jorge, Antártica. *Boletín de Investigaciones Marinas y Costeras - INVEMAR*, 50, 59-84. <https://doi.org/10.25268/bimc.invemar.2021.50.suplesp.949>
- Municipalidad Distrital de Independencia & Municipalidad Provincial de Huaraz. (2017). PLAN DE PREVENCIÓN Y REDUCCIÓN DEL RIESGO DE DESASTRES DE LA SUBCUENCA QUILLCAY 2018-2021. Centro Nacional De Estimación, Prevención y Reducción del Riesgo de Desastres (CENEPRED). https://sigrid.cenepred.gob.pe/sigridv3/storage/biblioteca/4592_plan-de-prevencion-y-reduccion-del-riesgo-de-desastres-de-la-subcuenca-quillcay-2018-2021.pdf
- Musie, W., & Gonfa, G. (2023, August). Fresh water resource, scarcity, water salinity challenges and possible remedies: A review. *Heliyon*, 9(8), 1-18. <https://doi.org/10.1016/j.heliyon.2023.e18685>
- NASA (2022). Landsat cumple 50 años observando la Tierra desde el espacio—NASA Ciencia. (2022, julio 25). <https://ciencia.nasa.gov/ciencias-terrestres/landsat-cumple-medio-siglo-observando-la-tierra-desde-el-espacio/>
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E. & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change, *Remote Sensing of Environment*, 148, 42–57, <https://doi.org/10.1016/j.rse.2014.02.015>

- Organismo Supervisor de la Inversión en Energía y Minería (OSINERGMIN). (2022, Julio). FICHAS TÉCNICAS PROYECTOS DE GENERACIÓN Y TRANSMISIÓN DE ENERGÍA ELÉCTRICA EN OPERACIÓN. https://www.osinergmin.gob.pe/seccion/centro_documental/electricidad/Documentos/generacion/1.Fichas_Tecnicas_Centrales_Operacion.pdf
- Organización de las Naciones Unidas (ONU). (2023, Abril 26). El turismo puede beneficiar a las montañas y sus habitantes, especialmente en América Latina. Naciones Unidas - Mirada Global Historias Humanas. <https://news.un.org/es/story/2023/04/1520417>
- Palanisamy, P. A., Jain, K., & Bonafoni, S. (2023). Machine Learning Classifier Evaluation for Different Input Combinations: A Case Study with Landsat 9 and Sentinel-2 Data. *Remote Sensing*, 15(13), Article 13. <https://doi.org/10.3390/rs15133241>
- Pandey, A. C., Ghosh, Swagata, & Nathawat, M. S. (2011). Evaluating patterns of temporal glacier changes in Greater Himalayan Range, Jammu & Kashmir, India. *Geocarto International*, 26(4), 321-338. <https://doi.org/10.1080/10106049.2011.554611>
- Panel Intergubernamental de Cambio Climático (IPCC). (2001). Cambio Climático y Biodiversidad.
- Panuntun, I. A., Chen, Y.-N., Jamaluddin, I., & Tran, T. L. C. (2024). *Evaluation of Deep Learning Semantic Segmentation for Land Cover Mapping on Multispectral, Hyperspectral and High Spatial Aerial Imagery*. <https://doi.org/10.48550/arXiv.2406.14220>
- Parente, C., Alcaras, E., & Figliomeni, F. G. (2024). Coastline Automatic Extraction from Medium-Resolution Satellite Images Using Principal Component Analysis (PCA)-Based Approach. *Remote Sensing*, 16(10), Article 10. <https://doi.org/10.3390/rs16101817>
- Paul, F., Rastner, P., Azzoni, R. S., Diolaiuti, G., Fugazza, D., Le Bris, R., Nemec, J., Rabatel, A., Ramusovic, M., Schwaizer, G., & Smiraglia, C. (2020). Glacier

- shrinkage in the Alpes continues unabated as revealed by a new glacier inventory from Sentinel-2. *Earth System Science Data*, 12(3), 1805-1821. <https://doi.org/10.5194/essd-12-1805-2020>
- Pekel, J.F., Cottam, A., Gorelick, N. & Belward, A.S (2016). High-resolution mapping of global surface water and its long-term changes. *Nature* 540, 418–422. <https://doi.org/10.1038/nature20584>
- Pellikka, P., & Rees, W. G. (Eds.). (2009). *Remote Sensing of Glaciers: Techniques for Topographic, Spatial and Thematic Mapping of Glaciers*. CRC Press. <https://doi.org/10.1201/b10155>
- Pérez, C., & Muñoz, A. (2002). *Teledetección: Nociones y aplicaciones*. Universidad de Salamanca. <https://dialnet.unirioja.es/servlet/libro?codigo=5256>
- Pozada Rengifo, R., Bravo Toledo, L., & Iparraguirre Ayala, J. (2023). Retroceso glaciar y el valor de los servicios ecosistémicos asociados con el recurso hídrico en la cuenca Parón-Parque Nacional Huascarán (Cordillera Blanca), 2009-2018. *Tecnología y Ciencias del Agua*, 14(6), 76-121. <https://doi.org/10.24850/j-tyca-14-06-03>
- Programa Nacional de Investigación Científica y Estudios Avanzados – PROCIENCIA. (2023). 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 (Código de proyecto: PE501083135-2023). <https://observatorio.prociencia.gob.pe/DetalleSubvencion/11987>
- Quispe Coica, A., Fernández, S., Acharte Lume, L., & Pérez Foguet, A. (2020, April 27). Status of Water Quality for Human Consumption in High-Andean Rural Communities: Discrepancies between Techniques for Identifying Trace Metals. *Multidisciplinary Scientific Journal*, 3(2), 162-180. <https://doi.org/10.3390/j3020014>

- Quispe Estofanero, G. E. (2015). Análisis cuantitativo del retroceso glaciar de la cordillera de Huayhuash, periodo 1976—2007. <https://repositorio.unap.edu.pe/handle/20.500.14082/20395>
- Rabatel, A., Ducasse, E., Ramseier, V., & Millan, R. (2023). State and Fate of Glaciers in the Val Veny (Mont-Blanc Range, Italy): Contribution of Optical Satellite Products. *Journal of Alpine Research | Revue de Géographie Alpine*, 111-2, Article 111-2. <https://doi.org/10.4000/rga.11619>
- Rabatel, A., Francou, B., Soruco, A., Gomez, J., Caceres, B., Ceballos, J. L., Basantes R., Vuille M., Sicart J. E., Huggel C., Scheel M., Lejeune, Y., Arnaud Y., Collet M., Condom T., Consoli G., Favier V., Jomelli V., Galárraga R. H., Guinot P., Maisincho L., Mendoza J. A., Ménéguez M., Ramirez E., Ribstein P., Suarez W., Villacis M. & Wagnon P. (2013). Current state of glaciers in the tropical Andes: a multi-century perspective on glacier evolution and climate change. *The Cryosphere*, 7(1), 81–102. <https://doi.org/10.5194/tc-7-81-2013>
- Rajat, S., Rajeshwar Singh, B., Prakash, C., & Anita, S. (2022). Glacier retreat in Himachal from 1994 to 2021 using deep learning. *Remote Sensing Applications: Society and Environment*, 28, 100870. <https://doi.org/10.1016/j.rsase.2022.100870>
- Rios Recra, R. del P. (2024). Metodología para el mapeamiento detallado de ecosistemas de montaña en el Parque Nacional Huascarán. <https://hdl.handle.net/20.500.12996/6377>
- Ritse, V., Hazarika, N., Kulnu, A. S., & Jamir, L. (2025). Shrinking Himalayan glaciers: Glacier inventory, glacial cover mapping and changes in Eastern Himalayas, India. *Journal of Earth System Science*, 134(1), 27. <https://doi.org/10.1007/s12040-024-02490-1>
- Rivas, D. S., Somos Valenzuela, M. A., Hodges, B. R., & McKinney, D. C. (2015, June 09). Predicting outflow induced by moraine failure in glacial lakes: the Lake Palcacocha case from an uncertainty perspective. *Natural Hazards and Earth System Sciences*, 15(6), 1163-1179. DOI:10.5194/nhess-15-1163-2015

- Rojas Granda, L., & Rengifo Cortavarría, R. C. (2022). Potenciales efectos en la salud de las comunidades situadas en la subcuenca de Quillcay tras exposición a metales pesados (As, Cd, Pb) originados por drenaje ácido de rocas producto del retroceso glaciar - Áncash (Perú). In Repositorio Institucional - Universidad Peruana Cayetano Heredia. https://repositorio.upch.edu.pe/bitstream/handle/20.500.12866/11364/Potenciales_RojasGranda_Luciana.pdf?sequence=1&isAllowed=y
- Salcedo, A. (2011). ESTIMACIÓN DE ÁREA CUBIERTA DE NIEVE EN CUENCAS CON ELEVADO APOORTE DE FUSIÓN UTILIZANDO DATOS ERS-2. [Tesis de maestría, Instituto de Altos Estudios Espaciales Mario Gulich]. Repositorio Mario Gulich. <https://www.famaf.unc.edu.ar/documents/1316/8-Gulich-Salcedo.pdf>
- Santiago Bazan, F., Mallqui Meza, H., & Rios Recra, R. (2021). Mapeo de la cobertura vegetal en la subcuenca Quillcay (Ancash – Perú) con el clasificador de Árbol de decisiones. *Aporte Santiaguino*, 14(1), 78-91. <https://doi.org/10.32911/as.2021.v14.n1.761>
- Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI). (2011). Nota Técnica - Retroceso glaciar en los Andes del centro y sur del Perú: Mecanismos atmosféricos asociados. Repositorio Institucional - SENAMHI. <http://repositorio.senamhi.gob.pe/handle/20.500.12542/3358>
- Sharda, S., & Srivastava, M. (2024). Mapping of Debris-Covered Glaciers Using Object-Based Machine Learning Technique. *Journal of the Indian Society of Remote Sensing*, 52(2), 399-411. <https://doi.org/10.1007/s12524-024-01832-2>
- Sharma, A., Prakash, C. & Thakur, D. (2024). Glacier lakes detection utilizing remote sensing integration with satellite imagery and advanced deep learning methods. *Applied Geomatics* 16, 829–850 . <https://doi.org/10.1007/s12518-024-00594-3>
- Shaw, T. (2019). ¿Qué impactos puede tener la visita turística a un glaciar? Fundación Glaciares Chilenos. Retrieved Marzo 18, 2025, from

<https://www.glaciareschilenos.org/que-impactos-puede-tener-la-visita-turistica-a-un-glaciar/>

Shekinskaya, N. (2025, Enero 21). Año Internacional de los Glaciares: La crucial protección de las reservas de agua del mundo. Organización de las Naciones Unidas (ONU). <https://news.un.org/es/story/2025/01/1535871>

Shrestha, S., & Nepal, S. (2019, May 29). Water Balance Assessment under Different Glacier Coverage Scenarios in the Hunza Basin. *Water*, 11(6), 1-18. <https://doi.org/10.3390/w11061124>

Sibandze, P., Mhangara, P., Odindi, J., & Kganyago, M. (2014). A comparison of Normalised Difference Snow Index (NDSI) and Normalised Difference Principal Component Snow Index (NDPCSI) techniques in distinguishing snow from related land cover types. *South African Journal of Geomatics*, 3(2), 197. <https://doi.org/10.4314/sajg.v3i2.6>

Sicart, J. E., Hock, R., & Six, D. (2008). Glacier melt, air temperature, and energy balance in different climates: The Bolivian Tropics, the French Alps, and northern Sweden. *Journal of Geophysical Research: Atmospheres*, 113(D24). <https://doi.org/10.1029/2008JD010406>

Singh, V. P., Singh, P., & Haritashya, U. K. (Eds.). (2011). *Encyclopedia of snow, ice and glaciers* Springer. <https://doi.org/10.1007/978-90-481-2642-2>

Sistema de Información para la Gestión del Riesgo de Desastres (SIGRID). (2018). *Plan de prevención y reducción del riesgo de desastres de la subcuenca Quillcay 2018 - 2021*. CENEPRED. <https://sigrid.cenepred.gob.pe/sigridv3/documento/4592>

Sistema Nacional de Información Ambiental (SINIA), Geo-ecological Systems Peru, Böskén, J., & Van der Meulen, M. (2012, October 15). Hydrochemical assessment of the Canray Chico catchment in the Cordillera Blanca. Repositorio Ministerio del Ambiente - MINAM. https://sinia.minam.gob.pe/sites/default/files/siar-ancash/archivos/public/docs/report_hydrochemical_assessment_canray_chico.pdf

- Somos Valenzuela, M. A., Chisolm, R. E., McKinney, D. C., & Rivas, D. (2014, Mayo). MODELO DE INUNDACIÓN POR POTENCIAL ALUVIÓN DESDE LA LAGUNA PALCACOCHA, HUARAZ, PERÚ. Nota Técnica 3. Ministerio del Ambiente (MINAM). https://sinia.minam.gob.pe/sites/default/files/siar-ancash/archivos/public/docs/nota_tecnica_03.pdf
- Sruthy. (2025, 6 de marzo). Difference in Data Mining Vs Machine Learning Vs Artificial Intelligence. Software Testing Help. Recuperado 29 de marzo de 2025, de <https://www.softwaretestinghelp.com/data-mining-vs-machine-learning-vs-ai/>
- Stitelmann, O. Y. (2024). Loss and damage of climate change in tropical glacierized areas: From changes in water availability to GLOFs. [Master's Thesis, University of Zurich]. En Stitelmann, Olafur Yngvi. Loss and damage of climate change in tropical glacierized areas: From changes in water availability to GLOFs. 2024, University of Zurich, Faculty of Science. <https://doi.org/10.5167/uzh-259354>
- Sussmann M. (2024, 23 de abril). Discover the differences between AI, ML and Deep Learning. Sumo Logic. Recuperado 29 de marzo de 2025, de <https://www.sumologic.com/blog/machine-learning-deep-learning/>
- Taylor, L. S., Quincey, D. J., Smith, M. W., Potter, E. R., Castro, J., & Fyffe, C. L. (2022). Multi-Decadal Glacier Area and Mass Balance Change in the Southern Peruvian Andes. *Frontiers in Earth Science*, 10. <https://doi.org/10.3389/feart.2022.863933>
- Thompson, L. G., Mosley Thompson, E., Davis, M. E., & Brecher, H. H. (2017, September 14). Tropical glaciers, recorders and indicators of climate change, are disappearing globally. *Annals of Glaciology*, 52(59), 23-34. DOI:10.3189/172756411799096231
- Thompson, L. G., Mosley Thompson, E., Heinz Brecher, H., Davis, M. E., León, B., Les, D. H., Lin, P. N., Mashiotta, T., & Mountain, K. (2006, August).

Abrupt tropical climate change: Past and present. Proceedings of the National Academy of Sciences, 103(28), 10536-10543. DOI:10.1073/pnas.0603900103

Toledo, M., Ibañez Palacios, G. P., & Lía Ahumada, A. (2024, enero 1). Mapeo espacial-temporal de la cobertura nival en la Sierra del Aconquija, provincias de Tucumán y Catamarca, Argentina, de 2014 a 2021. | EBSCOhost. <https://doi.org/10.35424/rcarto.i108.4099>

Turpo Cayo, E. Y., Borja, M. O., Moreno, N., Camargo, R. (2024). Apéndice – Glaciares. Tema transversal en colección 5.0. MAPBIOMAS. <https://peru.mapbiomas.org/wp-content/uploads/sites/14/2024/02/Apendice-8-Glaciares-Coleccion-5.0.pdf>

Úbeda Palenque, J., & Palacios Estremera, D. (2008). El clima de la vertiente del Pacífico de los Andes Centrales y sus implicaciones geomorfológicas. Espacio y Desarrollo, 20, 31-56. <https://revistas.pucp.edu.pe/index.php/espacioydesarrollo/article/view/5438/5435>

United National Environment Programme (UNEP). (2018, November 12). ¿Por qué los glaciares son tan importantes? News UNEP. <https://www.unep.org/noticias-y-reportajes/reportajes/por-que-los-glaciares-son-tan-importantes>

United States Agency for International Development (USAID). (2014, Diciembre). QUILLCAY PLAN DE ACCION LOCAL PARA LA ADAPTACIÓN AL CAMBIO CLIMATICO. SUBCUENCA DE QUILLCAY, MANCOMUNIDAD MUNICIPAL WARAQ. Ministerio del Ambiente (MINAM). https://sinia.minam.gob.pe/sites/default/files/siar-ancash/archivos/public/docs/quillcay_-_plan_de_accion_local_para_la_adaptacion_al_cambio_climatico.pdf#:~:text=La%20ciudad%20de%20Huaraz%20recibe%20su%20aporte,por%20desglaciaci%C3%B3n%20afectando%20su

- Veettil, B. K. (2018). Glacier mapping in the Cordillera Blanca, Peru, tropical Andes, using Sentinel-2 and Landsat data. *Singapore Journal of Tropical Geography*, 39(3), 351-363. <https://doi.org/10.1111/sjtg.12247>
- Veettil, B. K., & Kamp, U. (2019). Global Disappearance of Tropical Mountain Glaciers:
- Veettil, B. K., Ruiz Pereira, S. F., Wang, S., Teixeira Valente, P., Bica Grondona, A. E., Becerra Rondón, A. C., Rekowsky, I. C., De Souza, S. F., Bianchini, N., Bremer, U. F., & Simões, J. C. (2016, Junio 21). Un análisis comparativo del retroceso glaciar en los Andes Tropicales usando teledetección. *Investigaciones geográficas (Chile)*, 51(3), 3-36. https://www.researchgate.net/publication/305730330_Un_analisis_comparativo_del_retroceso_glaciar_en_los_AndesTropicales_usando_teledeccion
- Vergara, W., Deeb, A., Valencia, A., Bradley, R., Francou, B., Zarzar, A., Grünwaldt, A., & Haeussling, S. (2007, June 19). Economic Impacts of Rapid Glacier Retreat in the Andes. *Eos, Transactions American Geophysical Union*, 88, 261-268. DOI:10.1029/2007EO250001
- Villalobos, R. (2008, Junio). Cambio climático y recursos hídricos. *Revista de Ciencias Ambientales*, 35(1), 20-26. <http://dx.doi.org/10.15359/rca.35-1.5>
- Vuille, M., Carey, M., Huggel, C., Buytaert, W., Rabatel, A., Jacobsen, D., Soruco, A., Villacis, M., Yarleque, C., Elison Timm, O., Condom, T., Salzmann, N., & Sicart, J.-E. (2018). Rapid decline of snow and ice in the tropical Andes – Impacts, uncertainties and challenges ahead. *Earth-Science Reviews*, 176, 195-213. <https://doi.org/10.1016/j.earscirev.2017.09.019>
- Vuille, M., Francou, B., Wagnon, P., Juen, I., Kaser, G., Mark, B. G., & Bradley, R. S. (2008, August). Climate change and tropical Andean glaciers: Past, present and future. *Earth-Science Reviews*, 89(3-4), 79-96. <https://doi.org/10.1016/j.earscirev.2008.04.002>
- Vuille, M., Juen, I., Kaser, G. (2008). Glacier mass balance variability in the Cordillera Blanca, Peru and its relationship with climate and the large-scale

circulation. *Global and Planetary Change*, 62(1-2), 14-28.
<https://doi.org/10.1016/j.gloplacha.2007.11.003>

Willige, A. (2023, October 26). What are tropical glaciers and how is climate change affecting them? The World Economic Forum. Retrieved February 16, 2025, from <https://www.weforum.org/stories/2023/10/tropical-glacier-climate-change-elnino-indonesia/>

Wolfewicz A. (2024, 30 de septiembre) Deep Learning vs. Machine Learning – What’s The Difference? Levity. Recuperado 29 de marzo de 2025, de <https://levity.ai/blog/difference-machine-learning-deep-learning>

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), 1339. <https://doi.org/10.3390/w12051339>


Zeller, L., McGrath, D., McCoy, S. W., & Jacquet, J. (2024). Seasonal to decadal dynamics of supraglacial lakes on debris-covered glaciers in the Khumbu region, Nepal. *The Cryosphere*, 18(2), 525-541. <https://doi.org/10.5194/tc-18-525-2024>

Zimmer, A. (2016, Mayo). Diagnóstico de la subcuenca Quillcay. INSTITUTO DE MONTAÑA CONSERVACIÓN, CULTURA, COMUNIDAD. <https://mountain.pe/recursos/attachments/article/151/18.-Diagnostico-Rural-Rapido-MMW.pdf>

ANEXOS

ANEXO 1: Serie temporal completa del área glaciaria estimada incluyendo valores afectados por nubosidad (enero 2016 – septiembre 2024)

El anexo 1 manifiesta la serie temporal inicial de la extensión glaciaria calculada mensualmente, comprendiendo desde enero de 2016 hasta septiembre de 2024. Esta representación conformó una primera aproximación de la capa glaciaria mediante las imágenes Sentinel-2 tratadas con el modelo *Random Forest*. Desde un panorama global, la serie de tiempo demostró unas oscilaciones mensuales y picos atípicos en ciertos meses del área glaciaria. Los primeros resultados identificaron valores irregulares en los años 2016, 2017, 2018 y 2023 con valores puntuales superiores a 40 km². Posteriormente, mediante una inspección visual, se reveló que estos errores se debieron a imágenes satelitales con niveles elevados de nubosidad, las cuales no fueron correctamente preprocesadas por el algoritmo de la librería *SatCube*. De esta manera afectó la calidad de la clasificación del modelo para esos puntos en específico.



ANEXO 2: Medias mensuales del área estimada por el modelo *Random Forest* (2016–2024)

En cuanto a los valores medios expuestos en el Anexo 2, los meses de abril (35.7 km²) y mayo (35.1 km²) fueron las áreas más extensas. Mientras que, los meses de octubre (28.6 km²) y noviembre (29.0 km²) fueron las superficies mínimas. Por último, los puntos fuera del rango corresponden a valores atípicos, presentados en los intervalos mensuales de marzo, mayo, julio, septiembre y octubre.

Mes	Media estimada (km ²)
Enero	31.9
Febrero	33.4
Marzo	32.1
Abril	35.7
Mayo	35.1
Junio	32.7
Julio	32.1
Agosto	32.1
Setiembre	31.5
Octubre	28.6
Noviembre	29.0
Diciembre	31.7

ANEXO 3: Mapas anuales de área glaciar según su permanencia del 2016–2023

Se aplicó el algoritmo de permanencia de forma acumulativa, tomando como punto de corte cada año desde 2016–2023. Es decir, para estimar la permanencia en el 2020, se usaron todas las imágenes desde 2016 hasta diciembre de 2020, y así continuamente. Esta actividad permitió obtener 8 mapas anuales, donde se observó cómo se ha cambiado la permanencia de las tres categorías (glaciar, en retroceso, y nieve acumulada) año tras año. Estos resultados evidenciaron que la clase “glaciar en retroceso” y “nieve acumulada” se han ampliado desde 2016, extendiendo las dimensiones del área de color azul. Mientras que, la clase “glaciar permanente” se ha mantenido estable, pero con ligeros descensos (disminuyendo la extensión celeste). La figura permite visualizar una transición progresiva del glaciar hacia estados más temporales, evidenciando el retroceso sostenido en sectores vulnerables.

Año	Glaciar (km ²)	Glaciar en retroceso (km ²)	Nieve acumulada (km ²)
2016	26.26	6.29	5.55
2017	27.25	6.99	7.66
2018	26.68	8.22	7.41
2019	26.34	8.47	6.99
2020	26.42	7.54	5.74
2021	26.50	7.17	5.80
2022	26.56	7.10	5.64
2023	26.47	7.08	5.71
2024	26.23	7.11	5.72

