



Universidad Nacional Mayor de San Marcos
Universidad del Perú. Decana de América
Facultad de Ingeniería Geológica, Minera, Metalúrgica y Geográfica
Escuela Profesional de Ingeniería Geográfica

**Análisis comparativo de conjuntos de datos de
cobertura de tierra para el mapeo de área glaciar en
los Andes del Perú para el año 2020**

TESIS

Para optar el Título Profesional de Ingeniera Geógrafa

AUTORES

Wendy Jimena ESPINOZA BUSTOS

ASESOR

Francisco Alejandro ALCANTARA BOZA

Lima, Perú

2024



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

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

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

Referencia bibliográfica

Espinoza, W. (2024). *Análisis comparativo de conjuntos de datos de cobertura de tierra para el mapeo de área glaciaria en los Andes del Perú para el año 2020*. [Tesis de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería Geológica, Minera, Metalúrgica y Geográfica, Escuela Profesional de Ingeniería Geográfica]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor	
Nombres y apellidos	Wendy Jimena Espinoza Bustos
Tipo de documento de identidad	DNI
Número de documento de identidad	75358080
URL de ORCID	https://orcid.org/0000-0002-6061-814X
Datos de asesor	
Nombres y apellidos	Francisco Alejandro Alcantara Boza
Tipo de documento de identidad	DNI
Número de documento de identidad	27074721
URL de ORCID	https://orcid.org/0000-0001-9127-4450
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Dante Horacio Loayza Alatrística
Tipo de documento de identidad	DNI
Número de documento de identidad	07564915
Miembro del jurado 1	
Nombres y apellidos	José Luis Quispe Vilchez
Tipo de documento de identidad	DNI
Número de documento de identidad	08119070
Datos de investigación	
Línea de investigación	C.0.3.16. Procesamiento de Imágenes y Visión por computadora
Grupo de investigación	Glaciares y Ecosistemas de Alta Montaña

Agencia de financiamiento	Perú. Consejo Nacional de Ciencia, Tecnología e Innovación (CONCYTEC). Programa PROCIENCIA en el marco del concurso “PROYECTOS DE INVESTIGACIÓN BÁSICA– 2023-01”. PE501083135-2023-PROCIENCIA.
Ubicación geográfica de la investigación	País: Perú Departamento: Áncash, Huánuco, Lima, Ica, Pasco, Junín, Huancavelica, Ayacucho, Apurímac, Arequipa, Arequipa, Cusco, Puno, Moquegua, Tacna. Latitud: -13.235826 Longitud: -73.577469
Año o rango de años en que se realizó la investigación	2020
URL de disciplinas OCDE	Geociencias, Multidisciplinar https://purl.org/pe-repo/ocde/ford#1.05.01 Sensores remotos https://purl.org/pe-repo/ocde/ford#2.07.04



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS

Universidad del Perú, DECANA DE AMÉRICA

FACULTAD DE INGENIERÍA GEOLÓGICA, MINERA, METALÚRGICA Y GEOGRÁFICA

ESCUELA PROFESIONAL DE INGENIERÍA GEOGRÁFICA

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

En el Salón de Grados y Títulos de la Escuela Profesional de Ingeniería Geográfica de la Facultad de Ingeniería Geológica, Minera, Metalúrgica y Geográfica de la Universidad Nacional Mayor de San Marcos, el miércoles 20 de noviembre del 2024, siendo las 16:00 horas, en presencia de los Señores Docentes designados como Miembros del Jurado Calificador:

ING. DANTE HORACIO LOAYZA ALATRISTA
ING. JOSE LUIS QUISPE VILCHEZ

Presidente
Miembro

Reunidos en Acto Académico Público de Sustentación de la Tesis titulada: «ANÁLISIS COMPARATIVO DE CONJUNTOS DE DATOS DE COBERTURA DE TIERRA PARA EL MAPEO DE ÁREA GLACIAR EN LOS ANDES DEL PERÚ PARA EL AÑO 2020», para optar el Título Profesional de Ingeniera Geógrafa.

Expuesta la Tesis; los miembros del Jurado plantearon a la Bachiller las preguntas pertinentes, que fueron absueltas por la tesista: *...A... SATISFACTORIA*


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

Habiendo sido aprobada la Sustentación de la Tesis por el Jurado Calificador, el presidente del Jurado recomienda que la Facultad de Ingeniería Geológica, Minera, Metalúrgica y Geográfica, otorgue el TÍTULO PROFESIONAL DE INGENIERA GEÓGRAFA, a Doña **WENDY JIMENA ESPINOZA BUSTOS**.

Siendo las *17:15* horas, se dio por concluido el acto académico, expidiéndose cinco (05) Actas Originales de la Sustentación de Tesis, firmadas por el Jurado Calificador.

Ciudad Universitaria, 20 de noviembre del 2024


ING. DANTE HORACIO LOAYZA ALATRISTA
PRESIDENTE


ING. JOSE LUIS QUISPE VILCHEZ
MIEMBRO


ING. FRANCISCO ALEJANDRO ALCANTARA BOZA
ASESOR DE TESIS



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Vicerrectorado de Investigación y Posgrado



CERTIFICADO DE SIMILITUD

Yo Francisco Alejandro Alcántara Boza, en mi condición de asesor acreditado con la Resolución Decanal N° 000550-2024-D-FIGMMG/UNMSM, de la tesis, cuyo título es **“Análisis comparativo de conjuntos de datos de cobertura de tierra para el mapeo de área glaciario en los Andes del Perú para el año 2020”**, presentado por la bachiller Wendy Jimena ESPINOZA BUSTOS para optar el título de Ingeniero Geógrafo, CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante el software de similitud textual, el documento evaluado cuenta con el porcentaje de 11 % de similitud, nivel **PERMITIDO** para continuar con los trámites correspondientes y para su **publicación en el repositorio institucional**.

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

Firma del Asesor: _____

DNI: 27074721

Nombres y apellidos del asesor: Francisco Alejandro Alcántara Boza



Resumen

La cordillera de los Andes en el Perú alberga importantes recursos hídricos que abastecen tanto a poblaciones urbanas como a ecosistemas naturales. Sin embargo, el retroceso de la superficie glaciar es alarmante, habiéndose perdido más de la mitad del área glaciar en las últimas seis décadas, lo cual hace imprescindible un monitoreo constante. A pesar de los avances en la evaluación de estas áreas y la disponibilidad de datos de cobertura terrestre, persisten desafíos significativos en la delimitación precisa de las superficies glaciares debido a su alta sensibilidad a cambios climáticos y ambientales. Por ello, es fundamental identificar qué producto se adapta mejor a las condiciones de las cordilleras glaciares en el Perú.

Este estudio se propone evaluar y comparar las métricas de exactitud temática de cuatro conjuntos de datos de cobertura terrestre (ESRI Land Cover, ESA World Cover, Dynamic World e INGLOG II) para el mapeo del área glaciar en los Andes del Perú para el año 2020, utilizando tablas de confusión y el análisis de intervalos de confianza Bootstrap.

Los resultados indican que el valor de precisión general e índice kappa más alto fue INGLOG II, con 87.6% y 0.72 respectivamente. El mayor valor de Score F1 lo presenta ESRI Land Cover, con 0.899. Por su parte, los intervalos de confianza Bootstrap muestran que ESA World Cover vendría a tener una diferencia significativa a comparación de las métricas de exactitud de los otros conjuntos de datos analizados. Dynamic World presentó una cobertura insuficiente en zonas glaciares, con hasta un 67.17% de “No Data” en la cordillera Blanca, por lo cual fue excluido del análisis de precisión, pues ocasionaría sesgos considerables que no representen de manera justa y estandarizada el mapeo de superficie glaciar en el área de estudio.

Palabras Clave: ESRI Land Cover, ESA World Cover, Dynamic World e INGLOG II, Andes del Perú, cordillera, glaciar.

Reconocimiento

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

Con apoyo de Cesar Aybar y Fernando Prudencio, quienes me apoyaron, mentorearon y brindaron sugerencias para la realización de la presente tesis.

Dedicatoria

A mi madre y padre, por su sacrificio, apoyo y amor incondicional. Ustedes me enseñaron el valor del esfuerzo, la paciencia y la perseverancia, permitiéndome seguir adelante con fuerza y temple. Gracias por abrir sus corazones a los michiverduras, quienes brindan alegría, compañía y alivian el estrés del día a día.

A mi hermano, por ser un ejemplo a seguir y un pilar en mi vida, inspirándome a ser mejor cada día.

A mi compañero de vida, por su amor, apoyo en los momentos difíciles y comprensión durante estos años.

*En memoria de Gregoria, quien siempre me
acompaña y cuida de mí.*

Índice General

1. INTRODUCCIÓN	1
1.1. Introducción	1
1.2. Planteamiento del problema	2
1.2.1. Descripción de la problemática	2
1.2.2. Formulación del problema.....	4
1.2.3. Formulación de problemas específicos.....	4
1.3. Objetivos de la investigación	4
1.3.1. Objetivo general	4
1.3.2. Objetivos específicos.....	4
1.4. Importancia y alcance de la investigación.....	4
1.5. Limitaciones de la investigación	5
2. EL MARCO TEÓRICO.....	7
2.1. Antecedentes de la investigación.....	7
2.1.1. Antecedentes internacionales.....	7
2.1.2. Antecedentes nacionales	8
2.2. Bases teóricas	9
2.2.1. Área glaciaria en los Andes del Perú.....	9
2.2.2. Aspectos básicos de teledetección	15
2.2.3. Conjuntos de datos de cobertura terrestre.....	20
2.3.3. Aspectos estadísticos	27
2.3. Definición de términos	33
3. HIPÓTESIS Y VARIABLES	35
3.1. Las hipótesis.....	35
3.1.1. Hipótesis general	35
3.1.2. Hipótesis específicas.....	35
3.2. Las variables.....	35
3.2.1. Variable dependiente.....	35
3.2.2. Variable independiente	35
3.3. Operacionalización de variables.....	36
4. MATERIALES Y MÉTODOS.....	37
4.1. Área de estudio.....	37

4.1.1. Ubicación.....	37
4.1.2. Climatología	39
4.1.3. Formaciones geológicas y geomorfológicas.....	39
4.1.3. Hidrografía.....	40
4.2. Diseño de Investigación	41
4.2.1. Tipo.....	41
4.2.2. Nivel	41
4.2.3. Enfoque.....	41
4.2.4. Diseño.....	41
4.3. Población y muestra	42
4.3.1. Población	42
4.3.2. Muestra	42
4.4. Procedimiento, técnicas e instrumentos de recolección de información.....	42
4.4.1. Materiales	42
4.4.2. Software y servicios.....	42
4.4.3. Etapa I.....	43
4.4.4. Etapa II	43
4.4.5. Etapa III	45
4.4.6. Procedimiento.....	47
5. RESULTADOS	49
5.1. Etapa I: Generación de composite anual 2020	49
5.2. Etapa II: Estandarización de conjuntos de datos.....	51
5.3. Etapa III: Evaluación de precisión temática.....	57
6. DISCUSIÓN DE RESULTADOS.....	63
7. CONCLUSIÓN Y RECOMENDACIONES	65
7.1. CONCLUSIÓN	65
7.2. RECOMENDACIONES	66
8. REFERENCIAS BIBLIOGRÁFICAS.....	67
9. ANEXOS.....	79

Índice de Tablas

Tabla N° 1: Cantidad de glaciares por cordillera en los Andes del Perú en 2020.....	14
Tabla N° 2: Características de bandas Sentinel-2	18
Tabla N° 3: Valores del coeficiente Kappa	30
Tabla N° 4: Operacionalización de variables	36
Tabla N° 5: Leyenda de clases ESA WC	52
Tabla N° 6: Leyenda de clases ESRI LC	53
Tabla N° 7: Matriz de confusión - ESA WC.....	60
Tabla N° 8: Matriz de confusión - ESRI LC.....	61
Tabla N° 9: Matriz de confusión - INGLOG II.....	61
Tabla N° 10: Caracterización de las 3 regiones de los Andes del Perú.....	79
Tabla N° 11: Cálculo de cantidad de píxeles de muestreo	88
Tabla N° 12: Código GEE para generación de composites	89

Índice de Figuras

Figura N° 1: Mapa de glaciares de la cordillera de los Andes	10
Figura N° 2: Estructura de un glaciar	11
Figura N° 3: Lengua glaciar.....	12
Figura N° 4: Morrena lateral.....	12
Figura N° 5: Nunataks o picos rocosos.....	13
Figura N° 6: Crevasses o grietas de ablación	13
Figura N° 7: Espectro electromagnético	16
Figura N° 8: Diferenciación visual entre NDSI y combinación de las bandas B1, B11, B12 .17	
Figura N° 9: Productos Sentinel-2	19
Figura N° 10: Plataforma de descarga de imágenes ALOS PALSAR	20
Figura N° 11: Cobertura LULC global Dynamic World.....	22
Figura N° 12: Cobertura LULC global con ESRI Land Cover.....	23
Figura N° 13: Cobertura LULC global con ESA WorldCover	24
Figura N° 14: Flujograma metodológico de INGLOG II	26
Figura N° 15: Matriz de tabulación, error o confusión.....	28
Figura N° 16: Mapa de ubicación del área de estudio	¡Error! Marcador no definido.

Figura N° 17: Reclasificación de clases a Glaciar y No Glaciar	44
Figura N° 18: Diagrama de flujo de la metodología.....	48
Figura N° 19: Cantidad de pixeles del compuesto RGB	49
Figura N° 20: Porcentaje de área por cordillera.....	50
Figura N° 21: Zonas con alta reflectancia	50
Figura N° 22: Mapa de cobertura en la cordillera de los Andes de Perú con ESA WC	51
Figura N° 23: Porcentaje por clasificación - ESA WC	52
Figura N° 24: Mapa de cobertura en la cordillera de los Andes del Perú con ESRI LC	53
Figura N° 25: Porcentaje por clase - ESRI LC	54
Figura N° 26: Mapa de cobertura en la cordillera de los Andes del Perú con DW	54
Figura N° 27: Reclasificación de mapeo DW	55
Figura N° 28: Mapeo de cordillera Huanzo con DW	56
Figura N° 29: Mapeo glaciar presentado por INGLOG	56
Figura N° 30: Cantidad de pixeles para el estrato Glaciar.....	57
Figura N° 31: Porcentaje de pixeles para el estrato Glaciar	57
Figura N° 32: Cantidad de pixeles para el estrato No Glaciar	58
Figura N° 33: Porcentaje de pixeles para el estrato No Glaciar	58
Figura N° 34: Distribución de puntos de muestreo.....	59
Figura N° 35: Comparación de métricas de exactitud temática.....	62
Figura N° 36: Mapa de promedio anual de temperaturas máximas.....	82
Figura N° 37: Mapa de promedio anual de temperaturas máximas.....	83
Figura N° 38: Mapa de promedio anual de precipitaciones.....	84
Figura N° 39: Mapa geomorfológico	85
Figura N° 40: Mapa geológico.....	86
Figura N° 41: Mapa hidrológico	87
Figura N° 42: RGB por cordillera.....	91
Figura N° 43: Combinación de bandas B1, B11, B12 por cordillera.....	92
Figura N° 44: NDSI por cordillera	93
Figura N° 45: Cobertura LULC con DW por cordillera	94
Figura N° 46: Cobertura LULC con ESA WC por cordillera.....	95
Figura N° 47: Cobertura LULC con ESRI LC por cordillera.....	96
Figura N° 48: Mapeo INGLOG II por cordillera.....	97

CAPÍTULO I

1. INTRODUCCIÓN

1.1. Introducción

La cordillera de los Andes del Perú desempeña un rol vital en la dinámica socioeconómica y en el desarrollo de ecosistemas. Sus glaciares son fundamentales para la provisión de agua dulce y la estabilidad ecológica, sirviendo como indicadores sensibles del cambio climático, en el que es fácilmente tangible su retroceso ante variaciones climáticas globales.

Su retroceso glaciar observado en las últimas décadas ha generado preocupación sobre la disponibilidad futura de recurso hídrico y el incremento de riesgos de desastres. Afecta el suministro de agua para consumo humano, agrícola e industrial; repercutiendo en comunidades locales cuya economía y modo de vida están intrínsecamente ligados a estos recursos.

Asimismo, al alimentar otros cuerpos de agua como ríos, lagos y lagunas; las fluctuaciones y aumento en el volumen de agua representan un riesgo significativo de inundaciones, aluviones o huaycos. Lo que puede ocasionar destrucción de infraestructuras, cultivos y pone en peligro vidas humanas.

Los glaciares desempeñan un papel esencial en la regulación del clima local y en la modulación del ciclo hidrológico, teniendo un impacto directo en la biodiversidad de la región. Los cambios drásticos en los ecosistemas de alta montaña pueden llevar a la pérdida de especies endémicas y la alteración de hábitats naturales.

La metodología para monitorear y medir la cobertura glaciar ha evolucionado significativamente, con avances en tecnologías de teledetección y Sistemas de Información Geográfica (SIG). La utilización de imágenes satelitales de alta resolución y técnicas avanzadas de procesamiento de datos permite una evaluación más precisa y detallada de los cambios en la cobertura glaciar. No obstante, la disparidad entre los distintos conjuntos de datos disponibles plantea un desafío para el cálculo exacto del área glaciar, dado que estos ecosistemas experimentan variaciones significativas a lo largo del tiempo. Por ello, se requiere un análisis crítico para identificar el conjunto de datos que ofrezca la mejor precisión y la aplicabilidad en la región andina peruana.

1.2. Planteamiento del problema

1.2.1. Descripción de la problemática

A pesar de la disponibilidad de diversos conjuntos de datos de cobertura terrestre y de los avances realizados en la evaluación de las zonas glaciares, aún existen deficiencias que se encuentran propensas a errores posicionales, de procesamiento, conceptuales y de clasificación, además del elevado consumo de tiempo para la delimitación automatizada de borde glaciar en imágenes satelitales (Crawford et al., 2013; Racoviteanu et al., 2008; Ramírez et al., 2020).

Las variaciones en la topografía, albedo, la cubierta vegetal o clima, dan como resultado, características particulares para cada ubicación a nivel global y regional (Sellers et al., 1997), donde “es importante considerar los efectos de la atmósfera en los sistemas de teledetección con amplios campos de visión en los que habrá una apreciable diferencia en la longitud del camino atmosférico entre el nadir y los extremos de la franja”(Jia & Richards, 2006, p. 31). La absorción y dispersión de la radiación electromagnética por gases y aerosoles, la división de la radiación solar en componentes difusa y directa, o la variabilidad temporal y espacial de las condiciones atmosféricas, constituyen desafíos para la realización de teledetección con imágenes satelitales (Jensen, 2009; Schott, 2007). La presencia de nubosidad podría impedir la obtención de imágenes del área de interés, sin embargo, el aprovechamiento de datos ópticos podría mejorarse de existir un consenso para la división de nubes en dos subclases (Foga et al., 2017; Qiu et al., 2020). Una de nubes gruesas, que impiden la visión completa del terreno debajo de ellas (Ebel et al., 2021); y otra de nubes delgadas, donde aún pueda visualizarse de manera distorsionada la superficie (Chen et al., 2017; Lynch et al., 2002). Estos factores limitan la calidad de los datos capturados, afectando la precisión espectral y reduciendo la cantidad de señal que llega al sensor. Esto puede resultar en imágenes con áreas donde la reflectancia está subestimada, un menor contraste ciertos elementos y distorsiones en el color, lo cual complica el análisis de imágenes satelitales (Jensen, 2009; Jia & Richards, 2006; Song et al., 2001).

Los glaciares, al ser susceptibles a factores hidrológicos como precipitación y circulación atmosférica, dificultan su delimitación entre glaciares permanentes y los estacionales. Si bien los sensores radar son una alternativa para la creación de Modelos de Elevación Digital (DEM), presentan limitaciones en los efectos de escala de radar y errores en el desenvolvimiento de fase en terrenos empinados. Asimismo, la capacidad de penetración en

el hielo depende de la frecuencia del radar; para bandas de baja frecuencia (como L y P) permiten mayor penetración en el hielo, aunque con menor resolución espacial, mientras que las bandas de alta frecuencia (como C o X) ofrecen una mejor resolución de superficie, pero con menor penetración (Conway et al., 2009; Page & Ramseier, 1975; Piermattei et al., 2024). La obtención de datos radar de alta precisión implica costos elevados, lo que restringe el acceso público a este tipo de información.

Otra técnica para estudiar zonas glaciares consiste en el análisis de variaciones en el campo gravitatorio terrestre, como la misión del satélite GRACE (Gravity Recovery and Climate Experiment). Al estar influida principalmente por señales hidrológicas (no de hielo), usan el ajuste isostático glacial (GIA), modelos de la pequeña edad de hielo (LIA) y cambios de masa mensuales del Sistema Global de Asimilación de Datos de Tierras Versión 2.1. para evaluar el cambio de masa glaciar global (Caron et al., 2018). Mapea el área glaciada de 100 km² a más, ya que para extensiones menores no detectaron de forma clara señales significativas. Es decir, las estimaciones de límite glaciar no se encontraron dentro del rango aceptable de $\pm 1000 \text{ kg m}^{-2} \text{ yr}^{-1}$ de incertidumbre (Wouters et al., 2019).

En el Perú, la cordillera con mayor extensión glaciar para el año 2016 es la cordillera Blanca con 449.75 km², seguido de la cordillera Vilcanota (255.51 km²) y la cordillera Vilcabamba (101.25 km²), las restantes cadenas montañosas no pasan de los 100 km² (INAIGEM, 2018). Por ello, el uso de imágenes multiespectrales es una alternativa viable para el monitoreo continuo de glaciares.

INAIGEM ha llevado a cabo INGLOG I y II mediante visitas de campo y análisis de imágenes satelitales para el mapeo de zonas glaciares, aunque esta actualización se realizó en 5 años. En este contexto, para lograr un monitoreo continuo de zonas glaciares, es crucial abordar la falta de datos precisos de cobertura terrestre para el mapeo de áreas glaciares.

El presente trabajo propone una comparativa de métricas de exactitud temática entre distintos conjuntos de datos de cobertura terrestre, el cual permita identificar cuál de estas se adapta mejor a las condiciones y características que presentan las zonas glaciares en la cordillera de los Andes en Perú. Identificar el conjunto de datos que delimite con mayor precisión las áreas glaciares permitirá un monitoreo constante, es esencial para una gestión óptima del recurso hídrico.

1.2.2. Formulación del problema

¿Qué conjunto de datos de cobertura terrestre tiene mejores métricas de exactitud temática para el mapeo de área glaciar en los Andes del Perú para el año 2020?

1.2.3. Formulación de problemas específicos

- ¿Cómo generar el mapeo de cobertura glaciar en los Andes del Perú para el año 2020 para el conjunto de datos de Dynamic World?
- ¿Cómo realizar la conversión del mapa de cobertura glaciar del INGLOG II a una resolución de 10 metros en el área glaciar de los Andes del Perú para el año 2020?
- ¿Qué método es adecuado para la comparación de métricas de exactitud temática del mapeo de área glaciar en los Andes del Perú para el año 2020?

1.3. Objetivos de la investigación

1.3.1. Objetivo general

Evaluar y comparar las métricas de exactitud temática de conjuntos de datos de cobertura terrestre para el mapeo del área glaciar en los Andes del Perú para el año 2020.

1.3.2. Objetivos específicos

- Generar el mapeo de cobertura glaciar en los Andes del Perú para el año 2020 para el conjunto de datos de Dynamic World en la plataforma GEE.
- Rasterizar el mapa de cobertura glaciar de INGLOG II a una resolución de 10 metros del área glaciar en los Andes del Perú para el año 2020.
- Formular el diseño de muestreo y de respuesta para la comparación de métricas de exactitud temática del mapeo de área glaciar en los Andes del Perú para el año 2020.

1.4. Importancia y alcance de la investigación

La cordillera de los Andes del Perú abastece de agua a tres vertientes: Pacífico, Atlántico y el Titicaca. La región sierra alberga 71% de los glaciares tropicales del mundo, conformado por 18 cordilleras glaciares y 2 cordilleras extintas; que al ser cabeceras de cuencas, tanto la región costa como selva dependen del recurso hídrico que proporciona esta zona altoandina (INAIGEM, 2018; Kaser & Osmaston, 2002; Veettil, 2018).

Tanto ciudades como zonas rurales se abastecen de estos glaciares, por ejemplo el consumo del líquido como agua potable o para la realización de proyectos para abastecimiento

de energía en centrales hidroeléctricas. Al tener varios sistemas socioeconómicos que dependen de la cordillera de los Andes y al estar localizado en una zona tropical, lo hace altamente sensible a los cambios globales del clima, siendo evidente el proceso de retroceso glaciar que viene provocando cambios del paisaje y el surgimiento de nuevos cuerpos de agua de origen glaciar (proglaciar) (Mark & Seltzer, 2005).

Si bien, mediante el sensoramiento remoto el estudio del retroceso glaciar se ha ido facilitando, la carencia de datos precisos sobre la cobertura glaciar es un obstáculo significativo para la toma de decisiones informadas y la gestión eficaz de estos recursos.

1.5. Limitaciones de la investigación

La interpretación de imágenes satelitales para la clasificación de cobertura glaciar a través de imágenes satelitales puede verse afectada por las condiciones climáticas y geográficas del ámbito de estudio. Factores como la nubosidad, las sombras proyectadas por el relieve del terreno, la variabilidad estacional y la presencia de nieve reciente o derretimiento parcial dificultan la identificación precisa de área glaciar.

El uso de imágenes Sentinel-2 influye en la clasificación de coberturas en la superficie terrestre. Su resolución de 10 metros permite capturar un nivel considerable de detalle, lo cual es favorable para el mapeo del terreno, ya que facilita la identificación de ciertas características de superficie. Sin embargo, esta resolución intermedia también puede introducir desafíos, ya que los píxeles suelen mezclar diferentes tipos de cobertura de terreno, como hielo, nieve entre otros elementos. Esto puede generar píxeles que dificultan una clasificación precisa, creando confusión entre las distintas categorías de cobertura, lo cual afecta la exactitud en la identificación de áreas glaciares.

El diseño de muestreo y de respuesta puede presentar limitaciones en la representatividad de las muestras seleccionadas, incidiendo en la generalización de los resultados en la extensión completa del ámbito de estudio. Las características heterogéneas del terreno y distribución desigual de clases en el terreno pueden hacer que algunos estratos estén subrepresentados, así como la variabilidad espacial de los glaciares, condicionan a que los resultados puedan globalizarse para toda el área de investigación.

Asimismo, las métricas de exactitud temática se verán influenciadas por errores en la clasificación de cobertura glaciar. Estos pueden provenir de la confusión entre diferentes tipos de cobertura de suelo, la resolución de la imagen y los modelos de clasificación usados. La

variabilidad entre diferentes conjuntos de datos podría generar diferencias significativas que influyan en los resultados, dificultando la comparación directa.

El presente estudio considera el mapeo nacional de glaciares en el Perú realizado por INAIGEM, cuyo registro más reciente corresponde al año 2020. Este antecedente resulta fundamental, ya que el mapeo de área glaciar realizado en campo ofrece resultados más cercanos a la realidad. Por ello, se decidió utilizar conjuntos de datos de cobertura terrestre que también correspondieran al año 2020, lo que permite una comparación adecuada. No obstante, dado que los glaciares son sensibles a cambios ambientales y climáticos, pueden experimentar variaciones significativas, lo que limita la extrapolación de los resultados a periodos de tiempo más largos. Aunque es posible extrapolar los resultados a periodos cortos, como 5 años, los hallazgos y conclusiones de este estudio podrían no ser aplicables a periodos más extensos.

CAPÍTULO II

2. EL MARCO TEÓRICO

2.1. Antecedentes de la investigación

2.1.1. Antecedentes internacionales

La investigación de Sekertekin et al. (2017) analizó la precisión de las clasificaciones de uso de la tierra y cobertura del suelo (LULC) de los datos de Landsat-8 the Operational Land Imager (OLI) y Sentinel-2 Multispectral Instrument (MSI). Utilizaron el método de clasificación supervisada de Máxima Verosimilitud (MLC) basado en píxeles para el área de la ciudad de Zonguldak y sus alrededores. Las estadísticas kappa para los datos de Sentinel-2 fue de 0.85 y para Landsat-8 de 0.78. Si bien los resultados las imágenes LULC de Sentinel-2 MSI fueron mejores comparación a Landsat-8; para zonas de mar, fue Landsat-8 el que tuvo un mejor desempeño.

Venter et al. (2022) realizó la evaluación y comparación cruzada entre tres conjuntos de datos mapeo de cobertura terrestre: Dynamic World de Google (DW), World Cover de la ESA (ESA WC) y ESRI Land Cover (ESRI LC). Usaron datos globales verdaderos con una unidad de mapeo mínima de 250m², 75%; en donde se obtuvo una fuerte correspondencia para la clase agua, resultando en 92% de coincidencias. Asimismo utilizaron datos de verdad de tierra europeos de LUCAS (Land Use/Cover Area Frame Survey) con una unidad de mapeo mínima de <100 m², 71%; en donde DW estimó significativamente más nieve y cubierta de hielo a comparación de ESA WC y ESRI LC en el hemisferio norte, considerando a las áreas que están cubiertas con nieve permanente o sin nieve.

Por su parte, Turpo Cayo et al. (2022) tuvo como objetivo reconstruir la cobertura glaciar de los Andes Tropicales usando imágenes Landsat de la plataforma Google Earth Engine en el periodo de 1990 a 2020. Mediante métodos semiautomáticos, como el uso del Índice de Nieve de Diferencia Normalizada (NDSI); se obtuvo que los glaciares andinos tropicales (TAG) redujeron su área de 2429.48 km² a 1409.11km² (pérdida del 42% del área total glaciar). Siendo que para el año 2020, el área glaciar en Perú represente el 72.76% del área total de TAG. Además, agrega que para el monitoreo y estudio de áreas glaciares es necesario un registro temporal comparable.

2.1.2. Antecedentes nacionales

Veetil (2018) realizó el mapeo de glaciares en la cordillera Blanca para estimar su área en el año 2016. Empleó imágenes Sentinel-2 MSI y Landsat OLI, para luego comparar el rendimiento de cada uno. Usando de referencia el área glaciar de los años de 1975 y 1994, considera que el NDSI = 0.2 y la relación de banda (NIR/SWIR) son eficientes para el mapeo; no obstante, encontró diversas limitantes. Requería de imágenes despejadas ya que los métodos automáticos son sensibles a la cobertura de nubes y la presencia de nieve estacional. Asimismo, el terreno empinado que proyecta sombras y las rocas desnudas dificultan el mapeo de límite glaciar. Dado ello, mediante edición manual tuvo que corregirse estas falencias. Dando como resultado un área glaciar ligeramente menor para imágenes Landsat (475.7 km^2) en comparación a Sentinel-2 MSI (482.8 km^2). Esto debido a que las imágenes MSI brindan una mejor cobertura bajo sombras proyectadas por terrenos empinados.

Kochtitzky et al. (2018) evaluó las discrepancias de cambio de área de hielo en el nevado Coropuna, que se encuentra en la cordillera Ampato. Realiza el mapeo manual del borde de hielo con una imagen SPOT (de resolución 1.5m) para obtener el recorte del área de estudio, luego toma 259 imágenes Landsat de 1980 a 2014 y construye una serie de temporal de hielo usando un umbral $\text{NDSI} \geq 0.5567$. El área glaciar calculada mediante NDSI fue de 44.95 km^2 , y de forma manual fue 44.85 km^2 , obteniendo una incertidumbre menor al 1%. No obstante, indica que la tasa de retroceso se ha sobreestimado a causa de la presencia de cubierta transitoria, siendo la tasa de pérdida de área promedio de $0.409 \text{ km}^2 \text{ a}^{-1}$ ($\sim 0.71\% \text{ a}^{-1}$) desde 1980.

Seehaus et al. (2019) estudia los cambios de los glaciares tropicales del Perú entre 2000 y 2016 mediante balance de masa y fluctuaciones de área. Recopila imágenes radar de apertura sintética (SAR) para la obtención de modelos de elevación digital (DEM); mapeando el área glaciar cubierta de escombros. El balance de masa promedio fue de $296 \pm 41 \text{ kg m}^{-2} \text{ a}^{-1}$, que varía entre 45 ± 97 a $752 \pm 452 \text{ kg m}^{-2} \text{ a}^{-1}$, dependiendo la región y temporalidad. La pérdida total de área glaciar fue de $548.5 \pm 65.7 \text{ km}^2$ (-29% , $-34.3 \text{ km}^2 \text{ a}^{-1}$), con un mayor retroceso entre 2013-2016, con una desglaciación de $203.8 \pm 65.7 \text{ km}^2$ (-16% , $-101.9 \text{ km}^2 \text{ a}^{-1}$), encontrando mayores tasas de cambios en glaciares bajos y pequeños. Fundamentan que podría deberse a la intensa actividad de fenómeno El Niño para los años 2015/16, siendo que sus hallazgos encontrados puedan verse sesgados para periodos cortos, indicando la necesidad de un mayor monitoreo de la recesión glaciar en los Andes tropicales.

2.2. Bases teóricas

2.2.1. Área glaciaria en los Andes del Perú


2.2.1.1. Cordillera de los Andes

Los Andes es la cordillera continental más larga del mundo, con un área que sobrepasa los 7.000 km de longitud, extendiéndose desde el norte de Venezuela hasta el sur de Argentina, y se encuentra dividida en tres secciones. Los Andes septentrionales abarcan los países de Venezuela, Colombia y Ecuador; los Andes centrales abarcan a Perú y Bolivia, al conjunto de ambas es llamada los Andes tropicales. La zona norte de esta se caracteriza por no presentar cambios drásticos de temperatura, con lluvias abundantes que alimentan a bosques higrofiticos nubosos, generando un ambiente húmedo. Por el contrario, la zona sur es de clima seco, con precipitaciones en verano y su época de estiaje va desde el mes de abril hasta septiembre. Y por último, los Andes meridionales o llamados Andes extratropicales, que se extienden por Chile y Argentina (Espinoza et al., 2015; Johansen et al., 2018).

En la vertiente occidental de los Andes, al sur de la línea ecuatorial. Las aguas frías oceánicas junto al movimiento descendente de masas de aire a gran escala generan condiciones frías y secas. Esta combinación impide eficazmente que la humedad penetre hacia el interior y se desplace hacia los Andes. En contraste, hacia el este, el transporte de humedad abundante desde el Atlántico tropical resulta en condiciones extremadamente húmedas y tasas elevadas de precipitación en la cuenca del Amazonas (Vuille, 2013).

No obstante, las variaciones interanuales en la precipitación pueden ser considerables, ocurriendo principalmente durante el acontecimiento del fenómeno El Niño-Oscilación del Sur (ENOS). Durante este fenómeno, las aguas cálidas superficiales frente a la costa del Ecuador y Perú a menudo ocasionan lluvias torrenciales en los desiertos costeros (Garreaud et al., 2009).

Figura N° 1: Mapa de glaciares de la cordillera de los Andes



Nota: Muestra las características de longitud (km) y superficie (km²) de los glaciares en los Andes. Tomado de *El Atlas de Glaciares y Aguas Andinos: El impacto del retroceso de los glaciares sobre los recursos hídricos*, por Johansen et al., 2018.


2.2.1.2. Glaciares tropicales

Los glaciares se originan de nieve que está compactada y recrystalizada, que van formando masas de hielo hasta convertirse en terreno firme. Se caracterizan por el movimiento lento que se impulsa por el peso que ejerce su propia masa y la acción de la gravedad (Rivera, 2005).

Este proceso puede suceder en diferentes zonas climáticas, siendo frecuente en glaciares que se encuentran latitudes altas, lados occidentales de los continentes y elevadas montañas (Huddart & Stott, 2010). Aspectos como la latitud, la altitud y la precipitación anual hacen que la formación de glaciares en los Andes solo se encuentre por encima de la línea de nieve (Johansen et al., 2018).

Los elementos que componen un glaciar influyen en su dinámica y estructura. A diferencia de la línea de nieve que indica la altitud mínima de hielo permanente, la línea de equilibrio divide la zona de acumulación, que es la fuente principal de masa glaciar acumulada, y la zona de ablación, donde la pérdida de hielo supera la acumulación de masa glaciar (Cuffey & Paterson, 2006).

Figura N° 2: Estructura de un glaciar




Nota: Variación de las facies de nieve con la altitud. Tomado de *Principles of Glacier Mechanics, Second Edition*, por Hooke, 2005.

En el frente glaciar se produce la fusión o desprendimiento de icebergs, ubicándose en la terminación de glaciar. La lengua del glaciar es la extensión donde el glaciar fluye desde la zona de acumulación hacia la zona de ablación. Las morrenas, que vienen a ser acumulaciones de sedimentos y rocas transportadas por el glaciar, pueden encontrarse distintos tipos. La morrena lateral, que se forma en los bordes del

glaciar; la morrena terminal, acumulando sedimentos en el extremo frontal del glaciar; y la morrena medial, que se forma por la unión de dos lenguas glaciares. Los nunataks son cimas de montaña que sobresalen de la superficie glaciar pero no tienen cubierta de hielo. Los crevasses son fracturas profundas en la superficie del glaciar a causa del movimiento diferencial del hielo (Cuffey & Paterson, 2006).

Figura N° 3: Lengua glaciar



Nota: A la izquierda muestra la zona de acumulación en la lengua de glaciar Huilca, a la derecha muestra la zona de ablación del mismo glaciar. Tomado de *Investigación glaciológica en el glaciar Huilca*, por Portocarrero Rodríguez et al., 2016.

Figura N° 4: Morrena lateral




Nota: Laguna a Artesoncocha represada por una morrena (M1) y laguna Parón flanqueada por una morrena (M2). Tomado de *El registro geomorfológico glaciar de los cambios climáticos en la Cordillera Blanca*, por Portocarrero Concha Niño de Guzmán et al., 2023.

Figura N° 5: Nunataks o picos rocosos



Nota: Ubicados en los casquetes polares de la región de la Península Antártica. Tomado de *Ice thinning on nunataks during the glacial to interglacial transition in the Antarctic peninsula region according to Cosmic-Ray Exposure dating: Evidence and uncertainties*, por Fernández-Fernández et al., 2021.

Figura N° 6: Crevasses o grietas de ablación



Nota: Crevasses en forma de “V” (a) o con cavidades más profundas y amplias en el área de acumulación de glaciares alpinos (b y c). Tomado de *Variability in the vertical temperature profile within crevasses at an alpine glacier*, por Purdie et al., 2022.

2.2.1.3. Glaciares en los Andes del Perú

El Perú alberga 68% de los glaciares tropicales del mundo, donde 56% de su superficie glaciaria se ha perdido a lo largo de 6 décadas (INAIGEM, 2023). Su ubicación en regiones tropicales los hace sensibles a variaciones climáticas, acelerando el retroceso glaciario.

Se pueden encontrar diferentes tipos de glaciares. Los glaciares libres de detritos o “glaciares limpios” son aquellos cuya superficie está compuesta mayormente por hielo y nieve, sin una cobertura significativa de rocas o sedimentos. En contraste, los glaciares cubiertos de detritos presentan una capa irregular de fragmentos de roca sobre su superficie, aunque esta no cubre por completo el glaciar. Los glaciares rocosos se diferencian de estos últimos ya que contienen una mayor proporción de sedimentos y hielo que se encuentra mezclado con los escombros rocosos desde el núcleo hasta la superficie (Barsch, 1996; Benn & Evans, 2010).

Tabla N° 1: Cantidad de glaciares por cordillera en los Andes del Perú en 2020

Cordillera	N° de glaciares libre y cubierto por detritos	N° de glaciares rocosos
Blanca	511	-
Huallanca	28	-
Huayhuash	86	10
Raura	76	2
Huagoruncho	35	-
La Viuda	45	19
Huaytapallana	122	18
Central	90	-
Chonta	4	6
Ampato	48	186
Vilcabamba	319	1
Urubamba	95	2
Huanzo	17	474
Chila	2	429
La Raya	20	9
Vilcanota	380	58
Carabaya	132	-
Apolobamba	74	4
Barroso	-	718
Volcánica	-	211

Tomado de *Inventario Nacional de Glaciares y Lagunas de Origen Glaciario (INGLOG II)* por INAIGEM, 2023.

En 1970, los 722 glaciares de la cordillera Blanca aún cubrían una superficie de 723.4 km², pero para fines del siglo XX esa cifra se redujo a menos de 600 km². Entre este año y 2003, estimaron una disminución de 22.4% de la superficie glaciar total. Además, observaron grandes tasas de retroceso en glaciares individuales de la cordillera Blanca, Ampato y Vilcanota (Georges, 2004; Racoviteanu et al., 2008).

Para el año 2020, cinco cordilleras presentaron un receso mayor del 80%, siendo la cordillera Chila la de mayor porcentaje de reducción glaciar con 99.79% (INAIGEM, 2023). Siendo esta cordillera que tiene menor cantidad de glaciares limpios y cubiertos de detritos, seguida de la cordillera Chonta. Asimismo, se puede apreciar que la cordillera Barroso y Volcánica no tienen glaciares limpios y cubiertos de detritos, considerándose como cordilleras extintas (INAIGEM, 2019). En contraparte, se tiene a la cordillera Blanca, que alberga la mayor cantidad de glaciares, con un total de 511. Para el caso de los glaciares rocosos, la cordillera Barroso alberga la mayor cantidad, con un total de 718, seguida de la cordillera Huanzo y Chila (Véase la Tabla N° 1).

2.2.2. Aspectos básicos de teledetección

La teledetección es el método en el cual se recopila información de la superficie terrestre. Sigue el proceso que involucra la interacción entre el objeto de interés y el sensor, dividiéndose en activos (energía propia) y pasivos (energía externa).

Chuvieco Salinero (2010) explica que la adquisición de información de un sensor remoto se puede realizar por emisión, por reflexión o ambas (emisión-reflexión). Siendo la primera la primordial ya que deriva de la principal fuente de energía, la luz solar.


2.2.2.1. Energía electromagnética

La radiación electromagnética viaja a través del espacio debido a la aceleración de campos eléctricos y magnéticos que al oscilar de forma simultánea van generando perturbaciones periódicas en planos perpendiculares entre sí y en la dirección de propagación a través del espacio a la velocidad de la luz (Camps-Valls, 2011).

Por tanto, la energía electromagnética se desplaza a través de ondas que viajan a la velocidad de la luz en un amplio espectro de ondas muy largas a muy cortas, como las ondas de radio y rayos gamma respectivamente. En donde, el ojo humano sólo puede percibir la luz visible, que es un pequeño porcentaje de ese espectro (NASA, 2010).

La luz visible se encuentra entre las longitudes de onda de 400 a 700nm (azul a rojo). Hacia el extremo rojo de la región visible se encuentra el infrarrojo cercano (IR), infrarrojo de onda corta (SWIR), infrarrojo medio (MIR) y el infrarrojo térmico (TIR) (Camps-Valls, 2011).

Figura N° 7: Espectro electromagnético



Nota: Rango de longitudes de onda desde rayos gamma hasta ondas de radio. Tomado de *Remote Sensing Image Processing*, por Camps-Valls et al., (2011).

2.2.2.2. Reflectancia espectral

La reflectancia espectral viene a ser “la fracción de radiación reflejada en cada zona del espectro electromagnético, magnitud que determina el color del objeto en cuestión” (García Alonso, 2016, p. 26).

La curva de reflectancia ilustra la porción de la cantidad de energía reflejada en relación a su longitud de onda, y cada material posee su propia curva de reflectancia (Tempfli et al., 2009).

2.2.2.3. Combinación de bandas e índices espectrales

Vienen a ser combinaciones entre diferentes canales espectrales que se condensan en una fórmula, diseñados para mejorar la detección de características biofísicas, como el contenido de agua o el verdor de la vegetación (Camps-Valls, 2011).

Dozier (1989) desarrolló el Índice Diferencial de Nieve Normalizado como un método simple para la identificación de área glaciar en imágenes multiespectrales, siendo útil para estimar capas de nieve fraccionada, el cual está definido por la siguiente ecuación:


$$NDSI = (Green0.53 - SWIR1.65) / (Green0.53 + SWIR1.65)$$

Donde:

- Green0.53: Reflectancia en el canal verde.
- SWIR1.65: Reflectancia en el canal del infrarrojo de onda corta.

Por otro lado, existen otras combinaciones de bandas para visualizar zonas de nieve en falso color. La Banda 12 (SMWIR 2) y Banda 11 (SMWIR 1) de Sentinel-2 están diseñados para captar longitudes de onda infrarrojas, lo que permite diferenciar mejor la nieve y la nube a comparación de otras bandas. La Banda 1 tiene longitudes de onda que forman parte del espectro azul, además de corregir los efectos de aerosoles y partículas atmosféricas, lo que ayuda a la detección de nieve. La combinación entre estas 3 bandas permite una mejor diferenciación de glaciares, presentándose en tonalidades rojizas muy intensas (Wang et al., 2022).

Figura N° 8: Diferenciación visual entre NDSI y combinación de las bandas B1, B11, B12



Nota: Se visualiza en la imagen RGB áreas con alta reflectancia (a), donde el NDSI (b) y la combinación de las bandas B1, B11, B12 (c) permiten discernir mejor la cubierta glaciar. *Elaboración propia.*

2.2.2.4. Imágenes Sentinel-2

El programa Copernicus, de la Agencia Espacial Europea (ESA), proporciona imágenes Sentinel-2 de sus satélites gemelos Sentinel 2A y Sentinel 2B, siendo sus años de lanzamiento en 2015 y 2017 respectivamente. Estas orbitan con un desfase de 180° entre sí, ubicados en extremos opuestos del globo terrestre, lo que permite una disponibilidad recurrente de imágenes, con una resolución temporal de 10 días por satélite o 5 días considerando ambos (ESA, 2015).

Cada satélite está equipado con el instrumento multiespectral (MSI), capturando imágenes que abarcan 290 km de ancho en 13 bandas espectrales que varían en resolución espacial de 10, 20 y 60 metros (véase Tabla 1).

Tabla N° 2: Características de bandas Sentinel-2

Bandas	Descripción	Longitud de onda (nm)	Resolución
B1	Aerosol costero	443	60 m
B2	Azul	490	10 m
B3	Verde	560	10 m
B4	Rojo	665	10 m
B5	Infrarrojo cercano (NIR)	705	20 m
B6	Infrarrojo cercano (NIR)	740	20 m
B7	Infrarrojo cercano (NIR)	783	20 m
B8	Infrarrojo cercano (NIR)	842	10 m
B8A	Infrarrojo cercano (NIR)	865	20 m
B9	Vapor de agua	945	60 m
B10	Cirrus	1375	60 m
B11	Infrarrojo de onda corta (SWIR)	1610	20 m
B12	Infrarrojo de onda corta (SWIR)	2190	20 m


Elaboración propia.

Las bandas de 10 metros están diseñadas para aplicaciones de precisión, como el monitoreo de vegetación, agricultura y cartografía de la cobertura de suelo. Las bandas de 20 metros son utilizadas en estudios como la identificación tipos de suelo o la detección de humedad, estas brindan información en falso color, ya sea usando índices espectrales o combinación de bandas. Para las bandas de 60 metros están diseñadas para la corrección atmosférica, monitoreo de aerosoles y vapor de agua (ESA, 2015; Gascon et al., 2016)

Los productos que proporciona Sentinel-2 se dividen en dos niveles de procesamiento. El Nivel 1C (L1C) son imágenes ortorectificadas y georreferenciadas en formato UTM/WGS84, las cuales contienen datos de reflectancia de la capa superior de la atmósfera (TOA o Top of Atmosphere). La corrección geométrica que aplican a los píxeles elimina distorsiones causada por la topografía y la inclinación del sensor. Este tipo de producto es adecuado para aplicaciones o estudios que no requieran de corrección atmosférica (Drusch et al., 2012; ESA, 2015; Gascon et al., 2016).

Por otro lado, el Nivel 2A (L2A) son imágenes con corrección atmosférica que permite obtener la reflectancia en superficie (BOA o Bottom of Atmosphere). Los datos que contiene están corregidos para eliminar aerosoles y vapor de agua. Este producto ofrece imágenes con datos de reflectancia más próximos a la realidad, ajustando las tonalidades de color, contraste y textura (Drusch et al., 2012; ESA, 2015).

Figura N° 9: Productos Sentinel-2



Nota: Imágenes del volcán Eyjafjallajökull en agosto de 2017 visualizado con el producto L1C (a) y L2A (b). Tomado de *Release of sentinelhub Python Package 2.0* por Aleksandrov M., 2018.

La obtención de datos L2A pueden realizarse mediante la conversión de imágenes L1C utilizando Sentinel-2 Atmospheric Correction (Sen2Cor). Las imágenes Sentinel-2 son gratuitos y se encuentran disponibles a través de la plataforma GEE o Copernicus Open Access Hub (ESA, 2015).

2.2.2.5. Imágenes ALOS PALSAR


La Agencia Espacial Japonesa (JAXA) lanza en 2006 el satélite de observación japonés ALOS (dejando de operar en mayo del 2011), que está compuesto de tres sistemas independientes, Panchromatic Remote-Sensing Instrument for Stereo Mapping (PRSIM), Advanced Visible and Near Infrared Radiometer typ (AVNIR-2) y Phased Array L-band Synthetic Aperture Radar (PALSAR) (JAXA, 2007).

Este último proporciona imágenes radar de cobertura global y tiene una frecuencia de 46 días, dependiendo la latitud y el modo de operación. Utiliza SAR para la obtención de imágenes de la superficie terrestre, operando en la banda L del espectro de microondas (1.2 GHz). Asimismo, opera en varias polarizaciones, que incluyen

Horizontal-Horizontal (HH), Horizontal-Vertical (HV), Vertical-Horizontal (VH) y Vertical-vertical (VV). Es decir, cuando el radar emite una onda electromagnética con polarización horizontal y se recibe la onda reflejada en la misma polarización (HH) (Rosenqvist et al., 2007).

Sus modos de operación son tres, el Fino (Fine Beam) que proporciona imágenes con un ancho de franja de aproximadamente 70 km, con alta resolución de hasta 10 metros. ScanSAR obtiene imágenes con ancho de franja de hasta 350 km con una resolución de 100 metros aproximadamente. Y por último, el polarimétrico, que proporciona datos a una resolución de 30 metros aproximadamente (JAXA, 2007; Rosenqvist et al., 2007).

Figura N° 10: Plataforma de descarga de imágenes ALOS PALSAR



Nota: Visualización de imágenes ALOS PALSAR en la cordillera Blanca, Perú. Tomado de *Alaska Satellite Facility* (<https://search.asf.alaska.edu/#/>) por EarthData Open Access for Open Science, visitado en junio de 2024.

2.2.3. Conjuntos de datos de cobertura terrestre

Si bien el uso de la tierra y cobertura de la tierra (LULC) vienen a ser términos parecidos, en realidad tienen su propio significado. El uso de tierra se refiere a la utilización que se le da, de qué sirve la tierra; por su parte, la cobertura de tierra viene a ser la cubierta de la superficie del suelo. Al usar ambas expresiones juntas, Land Use / Land Cover (LULC), generalmente se refiere a la clasificación o categorización de actividades humanas y de los elementos del paisaje, dentro de un periodo de tiempo determinado, que están basados en

métodos científicos y estadísticos establecidos del análisis de fuentes de datos pertinentes (Congalton & Green, 2019).

La generación de estos productos implica adquirir imágenes satelitales para ser sometidas a un preprocesamiento, donde se corrigen distorsiones radiométricas y geométricas. Luego pasan a ser clasificadas, en donde se presentan métodos supervisados y/o no supervisados. Para verificar la calidad del producto generado pasan por un proceso de validación, donde evalúan la precisión del modelo (Foody, 2002; Lu, 2007).

2.2.3.1. Dynamic World

Desarrollado por Google AI, es un conjunto de datos global que se actualiza casi en tiempo real (NRT), con una resolución de 10 metros. Utiliza imágenes Sentinel-2 que se actualizan cada 5 días y cuenta con 9 clases de cobertura terrestre (Venter et al., 2022).


Su metodología inicia con la selección de imágenes Sentinel-2 basándose en metadatos de nubosidad de la banda QA60, donde extrajeron mosaicos individuales de 510x510 píxeles centrados en los sitios de muestra.

El conjunto de entrenamiento contó anotadores expertos que etiquetaron 4 000 imágenes, y no expertos, quienes etiquetaron 20 000 baldosas adicionales. Para la validación y control de calidad se tuvo un conjunto final de 409 baldosas, anotadas por tres expertos y un no experto.

Usaron la Red Neuronal Convolutiva Totalmente Convolutiva (FCNN), que permite mantener la estructura espacial de la imagen, siendo importante para la clasificación precisa de cada píxel.

Para el proceso de productos NRT usaron `ee.Model.predictImage`, el cual se inicia automáticamente con la disponibilidad de nuevas imágenes Sentinel-2 L1C y S2C, tomando un tiempo de 45 minutos para completar un mosaico completo (100km x 100km). Diariamente evalúan 12000 escenas aproximadamente, tomando cerca de 14.4 segundos procesar una nueva imagen (Brown et al., 2022).

Figura N° 11: Cobertura LULC global Dynamic World



Nota: Compuesto de todos los productos Dynamic World NRT del 2021-04-01 al 2021-05-01, donde las áreas en negro son No Data (ocasionada por la nubosidad). Tomado de *Dynamic World, Near real-time global 10m land use land cover mapping*, por Brown et al., 2022.

2.2.3.2. ESRI Land Cover

ESRI en asociación de Impact Observatory (IO) y Microsoft AI for Earth desarrollaron los productos LULC globales de forma anual (2017-2023), con resolución de 10 metros, y contando con 9 clases (Karra et al., 2021; Roy, 2024).


Su metodología inicia con la recolección de imágenes Sentinel-2, donde mapearon 24 000 sitios de entrenamiento, con dimensiones de 5 km x 5 km, repartidos en los 14 biomas principales.

La fase de etiquetado fue en colaboración con National Geographic Society, en que se dividieron en dos grupos de etiquetadores. Los etiquetadores expertos en cada bioma realizaron la anotación de un subconjunto de datos que, posteriormente, fueron utilizados para capacitar a los etiquetadores no expertos.

Mediante el modelo de aprendizaje profundo de redes neuronales convolucionales (CNN) con arquitectura U-net, desarrollaron la identificación de patrones en los datos de entrada para luego clasificar cada imagen individual con las 9 clases de LULC.

El proceso de validación constó de un conjunto de datos elegido mediante muestreo aleatorio estratificado, dando 398 áreas de interés, donde para cada imagen etiquetaron 510 x 510 píxeles. Estuvo a cargo de 3 anotadores expertos que formaron un “estándar de oro” para la validación de resultados del modelo, en el que usaron 2 métodos: estricto consenso y consenso mayoritario. En el primer método consideraron solo los píxeles donde los tres expertos concordaban, representando menos del 30% de la totalidad de píxeles, proporcionando un conjunto limitado pero con alta confianza. En el segundo método consideraron píxeles si al menos 2 expertos coincidían o cuando un experto está seguro y los otros 2 no opinan, abarcando el 80% de píxeles y capturando áreas de difícil categorización tanto para el humano como para el modelo (Impact Observatory, 2022; Karra et al., 2021).

Figura N° 12: Cobertura LULC global con ESRI Land Cover



Nota: Mapa global de cobertura de suelo para el año 2023. Tomado de *Google Earth Engine*, 2024.

2.2.3.3. ESA WorldCover

Proporciona mapas globales de cobertura de suelo para los años 2020 y 2021, con una resolución de 10m, contando con 11 clases (Van De Kerchove et al., 2020).


Usaron imágenes Sentinel-2 Nivel 2A, donde la selección y filtrado se basó en la nubosidad. Generaron compuestos medianos de 10 días usando las series temporales de bandas limpias para adicionalmente calcular índices de vegetación (VI) en cada intervalo de la serie.

Para las Sentinel-1 usaron el producto Ground Range Detected (GRD), siendo preprocesadas para ser convertidas en series temporales de retrodispersión Gamma 0. Aplicaron un filtro multitemporal de manchas antes de la composición de las series temporales.

El entrenamiento se basó en modelos de clasificación mediante el algoritmo de árbol de decisión de gradiente Catboost, transformando de manera óptima las características categóricas en números, mitigando etapas de preprocesamiento extensos. Incluyeron conjuntos de datos auxiliares como OpenStreetMap para ajustar las probabilidades de las clasificaciones inferidas y mejorando la predicción final. El mapa de cobertura anual final se divide en teselas de 3x3 grados en el sistema de coordenadas EPSG:4326.

El conjunto de datos de validación consta de 21 752 unidades de muestreo primario (PSU), cada una con cien píxeles de referencia de resolución 10x10m, distribuidos en 7 (sub)continentes. Como productos LULC para comparar ESA Worldcover fueron el FROM-GLC10, con 340 000 datos de entrenamiento ubicadas en 93 000 sitios a nivel global, y ESRI Land Cover 2020. Obteniendo una precisión general de $74.4 \pm 0.1\%$, y en Sudamérica de $76.1 \pm 0.2\%$ (CEOS, 2022; Van De Kerchove et al., 2020).

Figura N° 13: Cobertura LULC global con ESA WorldCover



Nota: Mapa global de cobertura de suelo para el año 2023. Tomado de *Google Earth Engine*, 2024.

2.2.3.4. Inventario Nacional de Glaciares y Lagunas de Origen Glaciar (INGLOG II)

INAIGEM presenta su segundo inventario de glaciares y lagunas de origen glaciar correspondientes al año 2020, teniendo como ámbito de intervención las 20 cordilleras glaciares de los Andes del Perú, distribuyéndose en 14 departamentos.

Fue elaborado a base de imágenes Sentinel-2, con una unidad mínima cartografiable de 5000 m² y a una escala de interpretación de 1:25 000, utilizando como insumos a imágenes Sentinel-2 y los DEM ALOS PALSAR para observar el terreno libre de nubes.


Recopilados los datos, pasaron a la generación de NDWI para cobertura de lagunas y NDSI min para cobertura glaciar. Utilizaron la colección de imágenes Sentinel-2A del 2020 para evaluar la presencia y persistencia de nieve temporal en las cordilleras, tomando el valor mínimo anual como umbral de NDSI ($NDSI_{min} \geq 0.1$). Este proceso lo realizaron en la plataforma de GEE e implementaron scripts en Python.

Luego de aplicar los índices espectrales, depuraron zonas incorrectamente identificadas como glaciar mediante análisis multitemporal con ayuda de imágenes Planet y Google Earth. Este proceso fue manual para reducir márgenes de error, donde aplicaron el criterio de área mínima cartografiable.

El proceso de validación de coberturas de los productos generados consistió en la distribución estratificada y aleatoria de puntos de muestra en cada cordillera; exceptuando la cordillera Volcánica y Barroso en la evaluación de cobertura de glaciares limpios, ya que estas se consideraron extintas desde el primer Inventario Nacional de Glaciares publicado por Hidrandina en 1989. No obstante, estas fueron mapeadas y se incluyen en el producto final mostrado en el repositorio de acceso abierto de INAIGEM.

La generación de matrices de confusión lo llevaron a cabo en la plataforma QGIS. El resultado de la evaluación temática para cobertura de glaciares limpios tiene índice Kappa de 0.96, precisión general de 0.98, y Score F1 de 0.97. Para lagunas, obtienen un índice Kappa 0.98, precisión general de 0.99 y Score F1 de 0.98 (INAIGEM, 2023).

Figura N° 14: Flujograma metodológico de INGLOG II



Tomado de *Inventario Nacional de Glaciares y Lagunas de Origen Glaciar (INGLOG II)* por INAIGEM, 2023.

2.3.3. Aspectos estadísticos

2.3.3.1. Muestreo aleatorio por estratos

Es un tipo de muestreo probabilístico utilizado en evaluaciones de precisión, definiendo los estratos por las etiquetas o clases de un mapa (Stehman, 2014). Para Cochran (1977), a esos también llamados subpoblaciones, que no se superponen; por lo que al juntarse conformarán la población total, el cual es representado de la siguiente manera:

$$N_1 + N_2 + \dots + N_L = N$$

Donde:

- N : Población
- N₁, N₂...: Subpoblaciones o estratos

Si el muestreo dentro de cada estrato es simple, se denomina muestreo aleatorio estratificado. Este método permite obtener una mayor precisión en las estimaciones correspondientes a cada estrato, ya que la clasificación que se realiza va a contener características similares para las variables que se estén estudiando.

2.2.3.2. Matriz de tabulación, error o confusión

Es una tabla de doble entrada en donde se expresa la cantidad de unidades de muestra que corresponde a una clase de una clasificación y su relación con la cantidad de unidades de muestra de una clase de otra clasificación, la cual puede ser los datos de referencia. Estos suelen ubicarse en las columnas, mientras que en las filas están las clasificaciones correspondientes al mapa que se va a evaluar (Congalton & Green, 2019).

Conformado por cuatro componentes. Los verdaderos positivos (VP) son aquellos elementos que el algoritmo identificó de forma correcta como positivas; mientras que los verdaderos negativos (VN) cuando identifica correctamente como negativas. Por otro lado, los falsos negativos (FN) son aquellos elementos que el algoritmo identificó de forma incorrecta como negativas; y los falsos positivos (FP) cuando identifica incorrectamente como positivas (Chicco et al., 2021).

La matriz de confusión representa la precisión de un mapa temático, especificando en las clases que lo conforman. Además de identificar los errores de inclusión o de comisión y los errores de exclusión o de omisión (Congalton & Green, 2019).

Figura N° 15: Matriz de tabulación, error o confusión

		j = Columns (Reference)			Row Total
		1	2	k	n_{i+}
i = Rows (Classification)	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Column Total n_{+j}		n_{+1}	n_{+2}	n_{+k}	n

Nota: Siendo n el número de muestras distribuidas en k^2 celdas, donde se asigna k clases por cada muestra en el mapa de clasificación (filas) y k clases para el mapa de referencia (columnas). Tomado de *Assessing the Accuracy of Remotely Sensed Data Principles and Practices, Third Edition*, por Congalton & Green, 2019.

Donde:

- n_{ij} : Número de muestras clasificadas en la clase i ($i = 1, 2, \dots, k$) en el mapa y clase j ($j = 1, 2, \dots, k$).

2.3.3.3. Error de omisión y comisión

Para Boschetti et al. (2004), el error de omisión viene a ser el porcentaje de píxeles que pertenecen a una clase en el mapa de referencia, pero que no han sido clasificados como tal. Este tipo de errores conlleva a subestimar la superficie de una clase en particular. Se representa matemáticamente de la siguiente manera:

$$O_e = \frac{p_{21}}{p_{11} + p_{21}}$$

Donde:

- p_{21} : Cuantificación de errores en la fila 1 y columna 2 de la matriz de confusión
- O_e : Error de omisión

Por otro lado, el error de comisión es el porcentaje de píxeles que han sido clasificados con cierta clase, pero que no debería ser ésta según el mapa de referencia. Esto conlleva a sobreestimar la superficie de una clase en particular. Puede representarse de la siguiente manera:

$$C_e = \frac{p_{12}}{p_{11} + p_{12}}$$

Donde:

- p_{12} : Cuantificación de errores en la fila 2 y columna 1 de la matriz de confusión
- C_e : Error de comisión

2.3.3.4. Análisis Kappa

Es una técnica multivariada discreta que determina estadísticamente la concordancia entre las predicciones de un modelo y el terreno o mapa de referencia. El resultado es una estadística KHAT, que se calcula con los valores de la concordancia observada y la concordancia esperada (Bishop et al., 1977; Cohen, 1960).

La concordancia observada representa la proporción de casos en los que los clasificados coinciden exactamente (Congalton & Green, 2019). Calculándose de la siguiente manera:

$$p_o = \sum_{i=1}^k p_{ii}$$

Donde:

- p_o : Concordancia observada
- p_{ii} : Proporción de observaciones que están en la categoría i para la clasificación observada como predicha.
- k : Número total de categorías

La concordancia esperada es la proporción entre casos en que se espera que los clasificadores coincidan por azar (Congalton & Green, 2019). Siendo calculado con la ecuación:

$$p_e = \sum_{i=1}^k p_{i+} p_{+j}$$

Donde:

- p_e : Concordancia esperada
- p_{i+} : Proporción de observaciones en la categoría i según el clasificador 1 (suma de la fila i en la matriz de confusión).
- p_{+j} : Proporción de observaciones en la categoría j según el clasificador 2 (suma de la columna j en la matriz de confusión).

Para calcular el índice Kappa se usa la siguiente ecuación (Congalton & Green, 2019):

$$\hat{K} = \frac{p_o - p_e}{1 - p_e}$$

Donde:

- $\hat{K}$: Índice Kappa
- p_o : Concordancia observada
- p_e : Concordancia esperada

Tabla N° 3: Valores del coeficiente Kappa

Coeficiente Kappa	Fuerza de la concordancia
0.00	Pobre (Poor)
0.01 – 0.20	Leve (Slight)
0.21 – 0.40	Aceptable (Fair)
0.41 – 0.60	Moderada (Moderate)
0.61 – 0.80	Considerable (Substantial)
0.81 – 1.00	Casi perfecta (Almost perfect)

Nota: Su valor varía entre -1 a 1, donde 0 es la concordancia no mejor que la esperada por azar, 1 indica una concordancia perfecta y -1 para una concordancia más débil de lo esperado. Tomado de *The measurement of observer agreement for categorical data*, por Landis & Koch, 1977.

2.3.3.5. Score F1

La precisión determina si la cantidad de falsos positivos es alta, centrándose en la exactitud de predicciones positivas. Se calcula como la proporción entre VP y el total de píxeles de predicciones positivas, donde una alta precisión significa que el modelo tiene una baja tasa de falsos positivos (Manning et al., 2009).

$$P = \frac{VP}{VP + FP}$$

Donde:

- P: Valor de precisión
- VP: Verdadero positivo
- FP: Falso positivo

La sensibilidad evalúa la capacidad de un modelo a identificar correctamente todos los casos positivos, centrándose en la capacidad del modelo a identificar todos los casos positivos reales. Se calcula como la proporción de VP y el total de píxeles positivos reales, donde una alta sensibilidad indica que el modelo detecta la mayoría de píxeles de forma correcta (Manning et al., 2009).

$$R = \frac{VP}{VP + FN}$$

Donde:

- R: Valor de sensibilidad
- VP: Verdadero positivo
- FN: Falso negativo

La media armónica entre la precisión y la sensibilidad es el Score F1, sirviendo de un valor que equilibra ambas métricas en la evaluación de rendimiento de clasificaciones binarias y multiclase. Su valor oscila entre 0 y 1, donde 0 indica un bajo rendimiento y 1 el mejor rendimiento (Manning et al., 2009; Powers, 2008). Se calcula de la siguiente manera:

$$Score\ F1 = 2 * \left(\frac{P * R}{P + R} \right)$$

2.3.3.6. Precisión de productor, usuario y general

Son métricas de exactitud temática calculadas a partir de la matriz de confusión. La precisión de usuario mide la proporción de píxeles que fueron clasificados correctamente en una cierta clase con respecto al total de píxeles asignados a esa misma clase en el mapa de clasificación (Congalton & Green, 2019). Se calcula mediante la siguiente ecuación:

$$\text{Precisión de usuario} = \frac{n_{ii}}{n_{i+}}$$

Donde:

- n_{ii} : Número de píxeles correctamente clasificados en la clase i
- n_{i+} : Total de píxeles clasificados en la clase i en la imagen

La precisión de productor es la proporción de píxeles que han sido correctamente clasificados para cierta clase con respecto al total de píxeles que realmente pertenecen a esa clase en el terreno o mapa de referencia (Congalton & Green, 2019). Se calcula de la siguiente forma:

$$\text{Precisión de productor} = \frac{n_{jj}}{n_{j+}}$$

Donde:

- n_{jj} : Número de píxeles correctamente clasificados en la clase j
- n_{j+} : Total de píxeles clasificados en la clase j en la imagen

La precisión general mide la proporción total de píxeles que han sido correctamente clasificados con respecto al total de píxeles que se tomaron para la realización de la matriz de confusión (Congalton & Green, 2019).

$$\text{Precisión general} = \frac{\sum_{i=1}^k n_{ii}}{n}$$

Donde:

- n : Número de píxeles correctamente clasificados en la clase j
- k : Total de píxeles clasificados en la clase j en la imagen

2.3.3.7. Intervalo de confianza Bootstrap

Viene a ser el proceso para construir regiones de confianza para parámetros de interés. Estos se basan en la estimación de la distribución muestral de una característica, seleccionando de forma aleatoriamente los puntos de datos del conjunto original, permitiendo cuantificar la precisión de las estimaciones (Efron, 1987).

$$\hat{\theta}_i = f(X_i^*)$$

Donde:

- $f(X_i^*)$: Función de la estadística de interés.
- $\hat{\theta}_i$: Estimaciones Bootstrap.

Si los intervalos de confianza de dos o más estimaciones no se superponen, es una señal de que las diferencias entre datos son significativas (Efron, 1987). Para el cálculo de intervalos de confianza es el siguiente:

$$IC_{(1-\alpha)} = [\hat{\theta}_{(\alpha/2)}, \hat{\theta}_{(1-\alpha/2)}]$$

Donde:

- $\hat{\theta}_{(\alpha/2)}$: Percentil $\alpha/2$ de la distribución de las estimaciones Bootstrap.
- $\hat{\theta}_{(1-\alpha/2)}$: Percentil $1-\alpha/2$ de la distribución de las estimaciones Bootstrap.

2.3. Definición de términos

- European Space Agency (ESA): Agencial Espacial Europea en español, es una organización intergubernamental enfocada en la exploración espacial, con el objetivo de desarrollar la capacidad espacial y asegurar que su inversión sea de beneficio global.
- Environmental Systems Research Institute (ESRI): Traducido al español como Instituto de Investigación de Sistemas Ambientales, es una empresa tecnológica orientada al desarrollo de servicios en el marco de los Sistemas de Información Geográfica (SIG).
- Dynamic World (DW): Traducido al español como Mundo Dinámico, desarrollado por Google, es un conjunto de datos de cobertura del suelo global y resolución de 10 m, basado en imágenes Sentinel-2, producido mediante aprendizaje profundo, disponible gratuitamente y con licencia abierta mediante Google Earth Engine (Véase en el apartado 2.2.3.1.).

- ESRI Land Cover (ESRI LC): Es un proyecto desarrollado por ESRI, que proporciona productos globales de cobertura terrestre para los años 2017 al 2023, con resolución de 10 metros, utilizando imágenes Sentinel-2 (Véase en el apartado 2.2.3.2.).
- ESA World Cover (ESA WC): Es un proyecto realizado por la ESA que proporciona productos globales de cobertura terrestre para los años 2020 y 2021 con una resolución de 10 m, desarrollados y validados casi en tiempo real basándose en datos Sentinel-1 y Sentinel-2 (Véase en el apartado 2.3.3.3.).
- Instituto Nacional de Investigación de Glaciares y Ecosistemas de Montaña (INAIGEM): Es un organismo nacional que genera tecnología e información científica aplicada sobre glaciares y ecosistemas de montaña.
- Inventario Nacional de Glaciares y Lagunas de Origen Glaciar (INGLOG): Realizada por INAIGEM, es el registro de glaciares y lagunas glaciares en Perú. Cuenta con la edición INGLOG I (2018), basada en estudios del 2016; y la edición INGLOG II (2023), resultado de sus estudios realizados en 2020 (Véase en el apartado 2.2.3.4.).
- Google Earth Engine (GEE): Traducido al español como Motor Terrestre de Google, es una plataforma informática que permite a los usuarios ejecutar análisis geoespaciales en la infraestructura de Google.
- Synthetic Aperture Radar (SAR): Radar de Apertura Sintética en español, es una tecnología que genera imágenes detalladas de la superficie terrestre, que puede operar en condiciones de visibilidad nula, como de noche o nubes densas.
- Digital Elevation Model (DEM): Al español como Modelo Digital de Elevación, es una representación digital de la topografía de la superficie terrestre, mostrando la elevación del terreno en formato raster o grid.
- Land Use / Land Cover (LULC): Traducido al español como Uso de Suelo / Cobertura de Suelo, viene a ser la descripción y clasificación de características de la superficie terrestre (Véase en el apartado 2.2.3.).
- Normalized-Difference Snow Index (NDSI): Traducido al español como índice Normalizado de Diferencia de Nieve, es un índice comúnmente utilizado en teledetección para identificar la presencia de nieve en la superficie terrestre (Véase el apartado 2.2.2.3.).
- Normalized-Difference Water Index (NDWI): Traducido al español como Índice Normalizado de Diferencia de Agua, utilizado para la identificación de cuerpos de agua en imágenes satelitales.

CAPÍTULO III

3. HIPÓTESIS Y VARIABLES

3.1. Las hipótesis

3.1.1. *Hipótesis general*

Existen diferencias significativas entre las métricas de exactitud temática de conjuntos de datos de cobertura terrestre para el mapeo del área glaciar en los Andes del Perú para el año 2020.

3.1.2. *Hipótesis específicas*

- El mapa de cobertura para Dynamic World se puede generar de manera factible en GEE para el área glaciar en los Andes del Perú para el año 2020.
- Es posible rasterizar el mapa de cobertura glaciar de INGLOG II a una resolución de 10 metros en el área glaciar en los Andes del Perú para el año 2020.
- El muestreo estratificado y la generación de matrices de confusión son adecuados para la comparativa entre métricas de exactitud temática para mapeo de área glaciar en los Andes del Perú para el año 2020.

3.2. Las variables

3.2.1. *Variable dependiente*

Área glaciar en los Andes del Perú para el año 2020.

Esta variable representa la extensión medida de las masas de hielo en zonas glaciares. Su cálculo está influenciado por las características capturadas en los distintos modelos de cobertura terrestre, ya que cada modelo presenta variaciones específicas de delimitación y mapeo de la extensión glaciar.

3.2.2. *Variable independiente*

Conjunto de datos de cobertura terrestre.

Esta variable representa a los tres modelos que están dedicados al mapeo de cobertura terrestre (ESA WC, ESRI LC, DW) y al conjunto de datos de área glaciar en INGLOG II, que fueron utilizados en la presente investigación.

3.3. Operacionalización de variables

Tabla N° 4: Operacionalización de variables

Tipo de variable	Variable	Dimensión	Indicadores
Variable dependiente	Área glaciar en los Andes del Perú para el año 2020	Distribución de cobertura glaciar en los Andes del Perú para el año 2020	Área glaciar por cordillera de los Andes del Perú para el año 2020
Variable independiente	Conjunto de datos de cobertura terrestre	INGLOG II	Clase Glaciar
		Dynamic World	Clase Snow and Ice
		ESA World Cover	Clase Snow and Ice
		ESRI Land Cover	Clase Snow and Ice

Nota: INGLOG II mapea específicamente glaciares y lagunas, por el contrario, los restantes conjuntos de datos tienen una clasificación llamada Snow and Ice siendo esta clase considerada para la clasificación de cubierta glaciar. *Elaboración propia.*

CAPÍTULO IV

4. MATERIALES Y MÉTODOS


4.1. Área de estudio

4.1.1. Ubicación

La cadena montañosa glaciaria del Perú se encuentra en los Andes tropicales, entre las coordenadas 77°32'1" – 16°48'52" latitud Sur y 68°56'54" – 80°27'25" longitud Oeste, con una altitud mínima promedio de 4800 m.s.n.m., y una máxima de 6768 m.s.n.m. Está subdividido en tres regiones: Andes norte, centro y sur. Se extiende a lo largo de catorce departamentos: Áncash, Apurímac, Arequipa, Ayacucho, Cusco, Huancavelica, Huánuco, Junín, Lima, Moquegua, Pasco, Puno, Tacna e Ica. Hidrológicamente se localizan en las vertientes del Pacífico, Atlántico y Titicaca (INAIGEM, 2018).

Si bien para registros previos, las cordilleras Barroso y Volcánica se consideraban extintas, fueron incluidas en el presente estudio, ya que se mapeará toda la cordillera de los Andes en el Perú, obteniendo un total de 20 cordilleras. Cuatro corresponden a los Andes norte, cinco a los Andes centro y once a los Andes sur (véase Tabla N° 10).

Figura N° 16: Mapa de ubicación del área de estudio



Nota: Desde el primer inventario publicado por Hidrandina en 1989 no se considera a las cordilleras Volcánica y Barroso, catalogándose como extintas. *Elaboración propia.*

4.1.2. Climatología

En las cordilleras influyen condiciones climáticas que se encuentran regidas por configuraciones atmosféricas causadas por la división continental y oceánica, dinámicas en las capas atmosféricas y la incidencia de luz solar; así también por la amplia variación altitudinal y geográfica (Drenkhan et al., 2015; Garreaud et al., 2009). Esta región se caracteriza por un clima de montaña con grandes diferencias de temperatura entre el día y la noche y una variabilidad significativa en las precipitaciones (Vuille et al., 2008).

El calentamiento del océano Atlántico y la cuenca del Amazonas generan mayor evaporación y transpiración, aumentando la humedad en la atmósfera. Esta es transportada por los vientos y, a medida que la masa del aire se satura y se va elevando en las montañas, se enfría y condensa, provocando precipitaciones intensas. A esta es llamada la estación húmeda o lluviosa, que abarca de diciembre a marzo, concentrando la mayor parte de las precipitaciones y donde se presentan las temperaturas mínimas (Garreaud et al., 2003).

Por el contrario, el aire sobre la zona continental se enfría más rápidamente que en el océano, reforzando las zonas de alta presión e interfiere con la elevación de la humedad restante. Esto conduce a la reducción de nubosidad, disminuyendo el bloqueo de radiación solar, lo que genera mayores temperaturas y la escasez de lluvias en las montañas. A esta es llamada la estación seca, que va de mayo a setiembre, donde el deshielo glaciar se convierte en una fuente de agua crucial, siendo particularmente vital en periodos de sequía (Buytaert et al., 2017; Drenkhan et al., 2015; Gilford et al., 1992).

4.1.3. Formaciones geológicas y geomorfológicas

Las formaciones geológicas están ligadas a procesos tectónicos de la subducción de las placas tectónicas de Nazca y Sudamericana, produciendo actividad volcánica y sísmica, además de originar la cordillera de Los Andes. Presentan basamento rocoso constituido por rocas intrusivas, encontrándose batolito en la cordillera Blanca; rocas metamórficas precámbricas (esquistos y gneis) y rocas sedimentarias, encontrándose en la cordillera Huayhuash estratos sedimentarios cretácicos y rocas volcánicas cenozoicas (Cobbing et al., 1996; Wilson et al., 1995). Se hallan plegamientos y sobreescurrecimientos debido a la interacción de las placas tectónicas, además de mostrar una orientación con estructuras anticlinales y sinclinales.; generando nevados y volcanes como Ampato, Sara Sara, Coropuna y Sabancaya, que reflejan la intensa actividad volcánica (Carlotto Caillaux et al., 1999; De la Cruz Wetzell et al., 1996).

Su geomorfología está caracterizada por laderas empinadas que pueden superar los 5000 m.s.n.m., como el nevado Huaytapallana (5 546 m.s.n.m.) o el Huascarán en la cordillera Blanca (6768 m.s.n.m.), el punto más alto de Perú. Estas altitudes generan condiciones propicias para la formación de glaciares y permafrost, experimentando acumulación de nieve que permite el desarrollo de geomorfología glaciar activa. En altitudes intermedias (2000 a 4000 m.s.n.m.), predominan quebradas y cañones profundos. Estas formaciones son resultado de procesos geodinámicos que incluyen la erosión por acción glaciar, hídrica y la influencia gravitacional. Las altas pendientes de las laderas contribuyen a la inestabilidad de terrenos, aumentando la susceptibilidad a fenómenos como deslizamientos y flujo de detritos (Carlotto Caillaux et al., 1999; Cobbing et al., 1996; Palacios Moncayo et al., 1992).

Los depósitos glaciares como fluvioglaciares cubren el basamento rocoso, indicativos de los ciclos de avance y retroceso glaciar. La intensificación de los procesos de erosión fluvial genera depósitos que se exhiben en valles en forma de U y amplios fondos de valle; así como la formación de cañones, como Cañón del Colca o cañón de Cotahuasi (INAIGEM, 2018).

4.1.3. Hidrografía

El Perú está distribuido en 3 vertientes: Pacífico, Atlántico y Titicaca, conformando una totalidad de 159 cuencas, de las cuales 36 intersecan por las cordilleras glaciares.

Para la vertiente del Pacífico destacan los ríos de Camaná, Cañete, Chillón, Lurín, Mala, Ocoña, Pativilca, Rímac, Santa y Yauca; que presentan una pendiente notable y su régimen estacional es de importancia para la hidrología regional, tanto para las dinámicas naturales como antrópicas. De esta vertiente, son 20 unidades hidrográficas dentro de las áreas glaciares.

La vertiente del Atlántico incluye cuencas como Apurímac, Huallaga, Madre de Dios, Marañón, Inambari, Mantaro, Perené y Urubamba; que presentan una pendiente pronunciada en la parte sierra. Por su lado, en la llanura amazónica la pendiente disminuye notablemente, generando sinuosidades en su recorrido, originando en ríos más largos con caudales continuos, formando parte de la red hidrográfica del río Amazonas. Esta vertiente cuenta con doce cuencas en las áreas glaciares.

En cuanto a la vertiente del Titicaca, se identifican cuencas como Azángaro, Huancané, Pucará y Suches. Caracterizadas por menor longitud en comparación a otras vertientes y de su pendiente pronunciada en las zonas altas que disminuyen a medida se acercan para desembocar en la laguna Titicaca. Esta vertiente abarca 4 cuencas dentro de las áreas glaciares.

4.2. Diseño de Investigación

4.2.1. Tipo

El presente estudio tiene como objetivo comparar las métricas de exactitud temática para el mapeo del área glaciar en los Andes del Perú, teniendo como finalidad el poder obtener estadísticas concisas para poder saber cuál de los conjuntos de datos planteados tienen un mejor desempeño al realizar el mapeo de cobertura glaciar. De forma que se pueda tener un monitoreo mediante imágenes satelitales que sea eficaz para la prevención ante riesgos de desastre y la planificación de la gestión de los recursos hídricos.

Por tanto, el tipo de investigación sería aplicada; que, según Sabino (1992) es aquella enfocada a propósitos inmediatos, que evalúa los recursos naturales en una zona para lograr optimizar su uso.

4.2.2. Nivel

El nivel vendría a ser descriptivo, que según Carlessi y Meza (2015), está dirigida a comprender una situación en una circunstancia espacio-temporal. El estudio requiere detallar sobre las métricas utilizadas y los resultados obtenidos, dando una representación de la exactitud de los conjuntos de datos de cobertura terrestre para el mapeo de área glaciar en los Andes del Perú en el año 2020.

4.2.3. Enfoque

El enfoque será cuantitativo, en el que “se caracteriza por utilizar métodos y técnicas cuantitativas y por ende tiene que ver con la medición, el uso de magnitudes, la observación y medición de las unidades de análisis, el muestreo, el tratamiento estadístico” (Ñaupas Paitán et al., 2013, p. 97).

Mediante este enfoque se realizará la comparativa de precisión de los conjuntos de datos de mapeo de cobertura terrestre a través de un análisis y evaluación estadística.

4.2.4. Diseño

El diseño de investigación vendría a ser no experimental, ya que no se interviene en las condiciones de estudio, es decir, que no hay manipulación en las variables. Centrándose en la recopilación y análisis de datos existentes.

4.3. Población y muestra

4.3.1. Población

La población es la extensión conformada por las imágenes Sentinel-2 correspondientes al año 2020, ubicadas en las cordilleras de los Andes del Perú, que abarcan un área total de 157764.871 km² (Véase Tabla N° 11).

4.3.2. Muestra

La muestra consiste en un subconjunto representativo de píxeles con una resolución de 10 metros, correspondientes a los estratos de Glaciar y No Glaciar dentro de las cordilleras de los Andes del Perú para el año 2020 (Véase Figura N° 34).

4.4. Procedimiento, técnicas e instrumentos de recolección de información

4.4.1. Materiales

- Imágenes satelitales ópticas Sentinel (2A y 2B)
- Carta Nacional IGN escala 1:100 000
- Cartas geológicas y geomorfológicas INGEMMET escala 1:100 000
- Red hidrográfica ANA-CENEPRED escala 1:100 000
- DEM ALOS PALSAR resolución 12.5 metros
- Mapa global ESRI Land Cover
- Mapa global ES WorldCover
- Código LULC de Dynamic World
- Datos vectoriales INGLOG II

4.4.2. Software y servicios

- Python
- Javascript
- ArcGIS Desktop
- Microsoft Word 2016
- Microsoft Excel 2016
- Google Earth Engine
- Google Drive

Se utilizó principalmente la plataforma de GEE para la realización de los procesos de la Etapa I y la primera parte de la Etapa II (véase 4.4.3.1. y 4.4.4.1.). Las imágenes generadas se exportaron en el almacenamiento de Google Drive, que luego fueron descargados al ordenador para los posteriores procesos.

Para lo restante de la Etapa II (véase 4.4.4.2.) y el proceso de la Etapa III (véase 4.4.5.) se utilizó el software ArcGIS Desktop, se usaron funciones de ArcToolBox y comandos en el prompt de Python para manejo de imágenes ráster, generación de puntos aleatorios y la edición manual de estos para el muestreo. Asimismo se usó este programa para la creación de mapas didácticos para visualizar mejor los procesos llevados a cabo.

4.4.3. Etapa I

4.4.3.1. Creación del compuesto espectral anual Sentinel-2 para el año 2020

Se utilizó el producto Sentinel-2 Hamonized (S2-SR), consistentes entre Sentinel-2A y Sentinel-2B, permitiendo la combinación y comparación de ambos productos, minimizando variaciones atmosféricas que mejoran la precisión de mediciones de reflectancia.

Para el enmascaramiento de nubes se usó Cloud Probability, que a diferencia de la banda QA60, utiliza una medida de probabilidad de que un píxel contenga una nube, mejorando la capacidad de ajuste de bordes de nube para zonas con alta reflectividad. Esta metodología proporciona una clasificación más precisa y reduce los falsos positivos de nubes, siendo esencial para el estudio de áreas con alta reflectancia.

Para el presente estudio se usó un 65% de probabilidad de nubes, mostrando imágenes más limpias en las zonas glaciares. Se filtraron para las fechas del 01-01-2020 al 31-12-2020, generando el composite anual RGB, la visualización de falso color de las bandas B1, B11 y B12, y el NDSI, utilizando por convención un umbral de 0.4.

4.4.4. Etapa II

4.4.4.1. Adaptación de bases de datos

Para DW, al ser un mapa dinámico, se utilizó el composite anual RGB del 2020 para cada polígono de las cordilleras glaciares, obteniendo el mapa con las clases correspondientes que brinda este conjunto de datos. Por su lado, para los conjuntos de datos de ESA WC y ESRI LC, al ser mapas globales anuales, se pasaron a recortar a los límites de los 20 polígonos de las cordilleras glaciares.

El repositorio de INAIGEM publica el producto INGLOG II para realizar su descarga en formato shapefile. Por lo que para realizar una uniformización de los datos, se pasó a rasterizar a una resolución de 10m mediante la metodología de interpolación de vecino natural.


4.4.4.2. Reclasificación de clases

En el proceso de análisis comparativo de áreas glaciares, es esencial establecer dos categorías: glaciar y no glaciar. Esta clasificación dual permite una cuantificación simplificada y precisa de los píxeles, representando de forma clara las áreas glaciares dentro del conjunto de datos.

Los conjuntos de datos de DW, ESA y ESRI tienen la clase de “Ice and Snow”, el cual representaría las áreas glaciares, siendo categorizadas como “Glaciar”; y para las clases restantes vendrían a ser recategorizadas como “No Glaciar”.

Para INAIGEM, se tomó en cuenta los vectores rasterizados como clase “Glaciar” y para el área restante de cada polígono de cordillera como “No Glaciar”.

Figura N° 17: Reclasificación de clases a Glaciar y No Glaciar



Nota: Cordillera Huanzo mapeada por ESA WC (a) y reclasificación (b) a Glaciar (celeste) y No Glaciar (verde). *Elaboración propia.*

4.4.5. Etapa III

4.4.5.1. Diseño de muestreo

Considerando la heterogeneidad de los conjuntos de datos en el mapeo de cobertura glaciar en los Andes, se realizará un diseño de muestreo estratificado. Dividiéndose en dos categorías o estratos, “Glaciar” y “No Glaciar”, para la generación de una matriz de muestra.

Para ello usará el mapeo generado de NDSI, donde se podrá obtener una proporción guía entre la zona glaciar y no glaciar. Por convención se toma el umbral 0.4 permite, pero no logra mapear específicamente el área glaciar, por lo que se generó una capa para lagunas mayores a 4km², dado que estas son fácilmente distinguibles visualmente. Además, en el caso específico del departamento de Arequipa, se mapeará el salar ubicado en la Reserva de Salinas.

Posteriormente se pasará a generar un conteo de pixeles excluyendo tanto las lagunas como las salinas, obteniendo la cantidad de pixeles del estrato Glaciar como No Glaciar.

Tomando un nivel de confianza del 95% y 0.05 de error, el tamaño de muestra mínimo se calculó mediante la siguiente ecuación:

$$n = \frac{N * Z^2 * p * (1 - p)}{e^2 * (N - 1) + Z^2 * p * (1 + p)}$$

Donde:

- n: Tamaño de muestra mínimo
- N: Tamaño total de la población
- Z: Valor crítico de la distribución normal estándar para un nivel de confianza dado
- P: Proporción esperada de la característica de interés en la población
- e: Error de estimación deseado

Según las proporciones calculadas para cada estrato, se llevará a cabo un muestreo aleatorio para generar los puntos de muestreo, los cuales serán independientes

para cada conjunto de datos. Esto implica que se tomarán muestras según las distribuciones presentes en cada conjunto de datos.

Una vez completado este proceso, se reubicó los puntos manualmente hacia zonas de mayor interés. Principalmente áreas con alta reflectividad, que pueden corresponder a relaves mineros, cuerpos de agua, techos de cascos urbanos o rurales, y salares; siendo confundibles con áreas glaciares. La cantidad de los puntos reubicados fue inferior al 3% del total de cada estrato, ya que a partir de este umbral, los resultados mostraban variaciones significativas. Este ajuste se realizó de manera iterativa, mediante un proceso de prueba y error, hasta identificar un punto en el que las diferencias entre los datos eran mínimas.

Los DEM ALOS PALSAR correspondientes a los años 2010 y 2011 se utilizaron para ubicar aquellas zonas mapeadas como área glaciar en los distintos conjuntos de datos. En donde se generaron recortes con el ráster de la clase “Ice and Snow” de ESA WC y ESRI LC; y el recorte con el shapefile de INGLOG II.

4.4.5.2. Diseño de respuesta

Para generar la matriz de error se comparan el mapeo realizado por cada conjunto de datos y la revisión realizada del composite anual 2020, que será tomado de mapa de referencia permitiendo determinar la exactitud de cada conjunto de datos.

Al ser una clasificación binaria, se analizan los verdaderos positivos (instancias clasificadas correctamente como glaciar), los verdaderos negativos (instancias clasificadas correctamente como no glaciar), los falsos positivos (instancias clasificadas incorrectamente como glaciar) y los falsos negativos (instancias clasificadas incorrectamente como no glaciar).

Esta matriz proporciona una visión detallada del rendimiento del modelo, permitiendo calcular métricas como el índice de Kappa, precisión general y Score F1, que son fundamentales para evaluar la calidad de los conjuntos de datos para mapeo de cobertura glaciar.

Para saber si las diferencias entre las métricas eran significativas, se usó intervalos de confianza Bootstrap . En el que si los intervalos de dos conjuntos de datos no se superponen, es que la diferencia es significativa.

4.4.6. Procedimiento

Primero se descargó los límites de las 20 cordilleras glaciares que INAIGEM (en fomato shapefile) en la página de ArcGIS Online (INAIGEM, 2024). Se importan a GEE, abreviando los nombres al escribir código (véase Tabla N°10 y Tabla N°11). Se generan los composites, posteriormente se exportan a Google Drive y luego se pasan a descargar al ordenador. Hasta aquí corresponde a la Etapa I.

Para los mapas de LULC, se pasó a abrir en GEE el mapa global de ESA WC (Earth Engine Code Editor, 2024a) y ESRI LC (Earth Engine Code Editor, 2024b) para recortarlo y luego pasar a descargar al ordenador. No obstante, también se puede descargar los tiles de estos conjuntos de datos en sus páginas; The European Space Agency (ESA, 2024) y ArcGIS Livin Atlas (ArcGIS Living Atlas of the World, 2024), para ESA WC y ESRI LC respectivamente.

Para DW (Earth Engine Data Catalog, 2024), luego de generar el mapeo en GEE, se pasó a cambiar la numeración de la clasificación Agua, pues al ser '0' se confundía con los pixeles que no han sido clasificados, los 'No Data'. Concluido ello se pasó a exportar a Google Drive para su posterior descarga.


Las imágenes fueron abiertas en ArcGIS, donde se realizó la reclasificación para uniformizar a las clases de 'Glaciar' y 'No Glaciar'. Para INGLOG II se pasó a rasterizar a la resolución de 10 metros. Hasta aquí culminando con la Etapa II.

Luego de la descarga de las imágenes ALOS PALSAR, se pasó a realizar la unión de rasters para luego poder cortarlo a la forma de la clasificación 'Glaciar' de los conjuntos de datos utilizados.

Para el diseño de muestreo, se contabilizó los pixeles del composite NDSI sin considerar las lagunas y salares (véase Tabla N°10), esto se realizó utilizando la API de GEE para Python.

Al tener listo el tamaño de muestras, se generaron los puntos aleatorios en ArcGIS (Create Random Points) para cada estrato correspondiente a cada conjunto de datos. Se pasó a editar los puntos hacia áreas de interés, donde se usaron las imágenes DEM recortadas y el criterio visual. Por último, se pasó a la revisión para la generación de matrices de error, cálculo de las métricas y generar intervalos de confianza Bootstrap en Python para evaluar si existen diferencias significativas entre los conjuntos de datos. Hasta aquí la Etapa III.

Figura N° 18: Diagrama de flujo de la metodología



Elaboración propia.

CAPÍTULO V


5. RESULTADOS

5.1. Etapa I: Generación de composite anual 2020

La generación del compuesto RGB de las 20 cordilleras glaciares, que van desde el norte de Áncash hacia el departamento de Tacna, arrojó un total de 1 577 648 712 píxeles, con una extensión de 157764.871 km². Siendo la cordillera Chonta la de mayor extensión, con 9.88% del total (15588.8326 km²), y la cordillera Huallanca la de menor extensión con 0.63% (995.0484 km²), véase Figura 20.


Para las zonas con alta reflectividad, la combinación de las bandas B1, B11, B12 ha facilitado el trabajo de diferenciación entre zonas glaciares de las que no lo son (Figura N° 8). No obstante, se hallaron zonas con suelo desnudo o cuerpos de agua que presentan una fuerte reflectancia a las bandas SWIR, tomando tonalidades rojizas o durazno intenso que puedan ser confundidas con áreas glaciares. Visualizándose principalmente áreas aledañas al volcán Sabancaya (cordillera Ampato) y en la laguna Taptapa ubicada en la cordillera La Viuda (ver Figura N° 21).

Figura N° 19: Cantidad de píxeles del compuesto RGB




Nota: La diferencia de píxeles entre la cordillera Chonta y Huallanca es de 145937842 píxeles, representando 9.25% del total de píxeles. *Elaboración propia.*

Figura N° 20: Porcentaje de área por cordillera



Elaboración propia.

Figura N° 21: Zonas con alta reflectancia




Nota: Laguna Taptapa RGB (a) y su combinación de bandas B1, B11, B12 (b); volcán Sabancaya entre el nevado Ampato y Hualca Hualca RGB (c) y su combinación de bandas B1, B11, B12 (d). *Elaboración propia.*

Con respecto al NDSI, las cordilleras Ampato, La Raya, Volcánica y Barroso representaron más del 30% con umbrales mayores a 0.4 que no son área glaciar. La proporción que presenta entre el umbral mayor y menor a 0.4 en estas condiciones es de 1 a 95 pixeles respectivamente.

5.2. Etapa II: Estandarización de conjuntos de datos

La Figura 20 corresponden a ESA WorldCover, donde predomina de la clase Grassland o Pradera con 59.43%; seguido de la clase Bare / sparse vegetation o Vegetación desnuda / escasa con 22.66%.

Figura N° 22: Mapa de cobertura en la cordillera de los Andes de Perú con ESA WC




Elaboración propia.

Tabla N° 5: Leyenda de clases ESA WC

Valor	Descripción	Color	Código
1	Cobertura arbórea (Tree cover)		#006400
2	Matorral (Shrubland)		#FFBB22
3	Pastizales (Grassland)		#FFFF4C
4	Terreno agrícola (Cropland)		#F096FF
5	Área urbanizada (Built-up)		#FA0000
6	Vegetación escasa o desnuda (Bare / sparse vegetation)		#B4B4B4
7	Nieve y hielo (Snow and ice)		#F0F0F0
8	Cuerpos de agua permanentes (Permanent water bodies)		#0064C8
9	Humedal herbáceo (Herbaceous wetland)		#0096A0
10	Manglares (Mangroves)		#00CF75
11	Musgo y líquenes (Moss and lichen)		#FAE6A0

Nota: Los colores y descripción correspondiente son aquellos los utilizados por la misma plataforma de WorldCover V2 2021. Tomado de *ESA WorldCover 10m V100*, por Zanaga et al., 2021.


Figura N° 23: Porcentaje por clasificación - ESA WC



Elaboración propia.

La Figura 20 muestra que la clase de Rangeland o Pastizales es predominante en ESRI Land Cover, con 77.47%; seguida de la clase Bare Ground o Suelo desnudo, con 10.29%.

Figura N° 24: Mapa de cobertura en la cordillera de los Andes del Perú con ESRI LC




Elaboración propia.

Tabla N° 6: Leyenda de clases ESRI LC

Valor	Descripción	Color	Código
1	Agua (Water)		#1A5BAB
2	Árboles (Trees)		#358221
3	Vegetación inundada (Flooded vegetation)		#87D19E
4	Cultivos (Crops)		#FFDB5C
5	Área construida (Built Area)		#ED022A
6	Suelo desnudo (Bare Ground)		#EDE9E4
7	Nieve y hielo (Snow and ice)		#F2FAFF
8	Nubes (Cloud)		#C8C8C8
9	Pastizales (Rangeland)		#C6AD8D

Nota: Los colores, valores y su descripción correspondiente son aquellos utilizados por la misma plataforma de Esri|Sentinel-2 Land Cover Explorer. Tomado de *ESRI 10m Annual Land Use Land Cover (2017-2022)*, por Roy S., 2024.


Figura N° 25: Porcentaje por clase - ESRI LC



Elaboración propia.

La Figura N° 23 muestra que DW presenta limitaciones al no mapear de forma completa las cordilleras, tanto en las áreas glaciares como no glaciares.


Figura N° 26: Mapa de cobertura en la cordillera de los Andes del Perú con DW



Elaboración propia.

Se observa que para las cordilleras Blanca, Huallanca, Huayhuash y Urubamba, la cantidad de píxeles mapeados como glaciar son menores a la cantidad guía de píxeles que se toma para la generación de proporciones por estrato, representando 67.17%, 9.90%, 47.21% y 33.37% respectivamente.

Figura N° 27: Reclasificación de mapeo DW




Nota: Cordillera Blanca (a), cordillera Urubamba (b), cordillera Huayhuash (c) y cordillera Huallanca (d).
Elaboración propia.

Con las cordilleras restantes se tiene una diferencia mayor a la observada, con 4920012 píxeles de diferencia en la cordillera Huanzo, donde la zona de actividad minera del proyecto Azuca y el terreno erosionado lo clasifica como “Glaciar” o es “No Data” (ver Figura N°25).

Por lo que al tener variaciones significativas, no se consideró al conjunto de datos de DW en la comparativa para evaluación de precisión, pues el análisis posterior presentaría sesgos considerables que no representarían de manera justa y estandarizada el mapeo de zonas glaciares en el ámbito de la cordillera de los Andes en Perú.


Figura N° 28: Mapeo de cordillera Huanzo con DW



Nota: RGB de la cordillera Huanzo (a) y mapeo con DW (b). Tomado de ESRI 10m Annual Land Use Land Cover (2017-2022), por Roy S., 2024.

INGLOG II, al ser un inventario en formato shapefile con un área de 155309.6465 km², pasó a rasterizarse en la plataforma ArcGIS, siendo la cordillera La Viuda la de mayor extensión, representando 8% del total.

Figura N° 29: Mapeo glaciar presentado por INGLOG




Elaboración propia.

5.3. Etapa III: Evaluación de precisión temática

Considerando el cálculo de NDSI, además del mapeo de lagunas de extensión mayor a 4km² y el salar, se obtuvo la separación por estrato, siendo que para cada pixel de Glaciar se hallan 113 pixeles de No Glaciar aproximadamente.


La clase Glaciar al ser un porcentaje minoritario en comparación a la totalidad de la población, se pasó generar la proporción con respecto a cada estrato correspondiente. Encontrándose a la cordillera Blanca con mayor representación (34.08%) y la cordillera Chonta con menor representación (0.268%) con respecto al estrato Glaciar.

Figura N° 30: Cantidad de pixeles para el estrato Glaciar



Elaboración propia.


Figura N° 31: Porcentaje de pixeles para el estrato Glaciar



Elaboración propia.


Para el estrato No Glaciar se encuentra con mayor representación la cordillera Chonta (9.96%) y la cordillera Huayhuash (0.633%) con menor representación respecto a su propio estrato.

Figura N° 32: Cantidad de pixeles para el estrato No Glaciar



Elaboración propia.

Figura N° 33: Porcentaje de pixeles para el estrato No Glaciar




Elaboración propia.

El tamaño de muestra se halló con la totalidad del conteo de pixeles, de donde se obtuvo $n = 13.6$, tomándose un mínimo de 20 puntos de muestreo para la cordillera de cada estrato con menor porcentaje de representación.

La generación de puntos de muestreo se realizó de forma aleatoria en ArcGIS Desktop, siendo un total de 10618 píxeles (7458 para Glaciar y 3160 para No Glaciar). Posteriormente se reubicaron aquellos puntos con una distancia menor a 50m hacia zonas de mayor interés para el estudio para luego generar matrices de confusión por cada conjunto de datos.

Figura N° 34: Distribución de puntos de muestreo



Nota: Puntos de muestreo por estratos para ESA WC (a), ESRI LC (b) e INGLOG II (c). Elaboración propia.

La Tabla N° 5 muestra los resultados de evaluación temática de la cobertura de glaciar para ESA WC. La cordillera Barroso presentó mayores casos de FN, con 95% del total de píxeles para el estrato Glaciar en el mapa de referencia, calculando una sobreestimación de 26.2% (error de comisión) y un índice Kappa con concordancia deficiente, donde las clasificaciones del modelo y las hechas en el mapa de referencia son moderadas cuando se ajusta el acuerdo esperado por azar.

El análisis Score F1 y la precisión general se consideran “Buenas”, con una precisión de productor con bajo nivel de FN (error de omisión 4.68%).

Tabla N° 7: Matriz de confusión - ESA WC

		Referencia				
Clasificación		Glacier (# píxeles)	No Glacier (# píxeles)	Total (# píxeles)	Exactitud de usuario	Error de comisión
	Glacier (# píxeles)	5499	1959	7458	0.742	0.262
	No Glacier (# píxeles)	270	2890	3160	0.916	0.085
	Total (# píxeles)	5769	4849	10618		
	Exactitud de productor	0.953	0.596	Kappa	Score-F1	Precisión general
	Error de omisión	0.047	0.404	0.564	0.831	0.790

Elaboración propia.

Para el conjunto de datos de ESRI LC, se muestra en la Tabla N° 6 el valor de índice Kappa con concordancia considerable o sustancial. La cordillera con mayor FN con respecto al estrato Glaciar en el mapa de referencia fue La Viuda (35.62%). La precisión de usuario (85.25%) y de productor (89.74%) resultaron con valores altos.

Por otro lado, el análisis Score F1 y la precisión general mostraron resultados “Muy buenos”, presentando un error de omisión de 4.84%. La precisión de usuario y de productor resultaron con valores altos.

Tabla N° 8: Matriz de confusión - ESRI LC

Referencia						
Clasificación		Glacier (# pixeles)	No Glacier (# pixeles)	Total (# pixeles)	Exactitud de usuario	Error de comisión
	Glacier (# pixeles)	6358	1100	7458	0.853	0.147
	No Glacier (# pixeles)	324	2836	3160	0.897	0.103
	Total (# pixeles)	6682	3936	10618		
	Exactitud de productor	0.952	0.721	Kappa	Score-F1	Precisión general
	Error de omisión	0.0485	0.279	0.700	0.899	0.866

Elaboración propia.

Los resultados para INGLOG II (ver Tabla N° 7) presenta un índice de Kappa con concordancia considerable o sustancial. Con un sobremuestreo de 15.19% (error de comisión), presentando mayor cantidad de FN en la cordillera Huanzo; por el contrario, el error de omisión obtuvo un valor de 2.76%.


Para la precisión de usuario fue de 84.79% y la precisión de productor de 93.53%, presentando VP mayores a 96% en las cordilleras Huagoruncho, Huaytapallana y Carabaya. El valor Score F1 y la precisión general mostraron resultados “Muy buenos”.

Tabla N° 9: Matriz de confusión - INGLOG II

Referencia						
Clasificación		Glacier (# pixeles)	No Glacier (# pixeles)	Total (# pixeles)	Exactitud de usuario	Error de comisión
	Glacier (# pixeles)	6324	1134	7458	0.848	0.152
	No Glacier (# pixeles)	187	2973	3160	0.941	0.059
	Total (# pixeles)	6761	3857	10618		
	Exactitud de productor	0.935	0.771	Kappa	Score-F1	Precisión general
	Error de omisión	0.028	0.294	0.720	0.889	0.875

Elaboración propia.

Figura N° 35: Comparación de métricas de exactitud temática



Elaboración propia.

El valor de precisión general e índice kappa más alto fue INGLOG II. El mayor valor de Score F1 lo presenta ESRI LC. La exactitud de productor y error de comisión más alta lo presenta ESA WC, con una diferencia mínima de 0.01 al valor de ESRI LC.

Los resultados de intervalos de confianza Bootstrap muestran para el Score F1, INGLOG II (0.900 – 0.910), ESRI LC (0.893 – 0.904) y ESA WC (0.824 – 0.837); para la precisión general muestra INGLOG II (0.869 – 0.881), ESRI LC (0.858 – 0.872) y ESA WC (0.782 – 0.797); y para Kappa, INGLOG II (0.713 – 0.738), ESRI LC (0.685 – 0.714) y ESA WC (0.551 – 0.579). Mostrando superposición entre INGLOG II con ESRI LC para todas las métricas, siendo ESA WC la que no tiene ninguna superposición con los otros conjuntos de datos. Por lo que ESA WC vendría a tener una diferencia significativa a comparación de las métricas de exactitud de los otros conjuntos de datos analizados.

6. DISCUSIÓN DE RESULTADOS

El mapeo de glaciares es esencial para preservar recursos hídricos, requiriendo de un monitoreo periódico. La teledetección y los algoritmos facilitan el seguimiento en zonas de difícil acceso, pero el desempeño de los modelos varía según el contexto a mapear

Dynamic World proporciona un algoritmo útil para el monitoreo casi en tiempo real, pero también tiene algunas deficiencias que podrían ser corregidas. El modelo confunde áreas de alta reflectancia, llegando a no clasificarlas. La causa de este problema es el enmascaramiento de nubes, que usa el algoritmo de árbol KD para distinguir entre nubes de agua y tierra. Sin embargo, tiene problemas con la comisión de objetos de alta reflectancia o alta textura suave (Melchiorre et al., 2020; Stillinger et al., 2019). Esto, agregado a las condiciones climatológicas de Perú, dificulta el mapeo de cobertura glaciar en la cordillera de los Andes. No obstante, este conjunto de datos podría ser útil si se implementara otros algoritmos para mejorar el enmascaramiento de nubes.

Bautista y Calvo (2024) utilizan DW para el mapeo de la cordillera Blanca, implementando el algoritmo de enmascaramiento de nubes CloudSEN12. Con esta metodología lograron el mapeo completo de la cordillera, donde la extensión de área glaciar varía en 1.7% a comparación del área obtenida en INGLOG II, con 424.86 km². Este resultado representa un gran contraste, ya que sin el algoritmo CloudSEN12, DW mapea 154.92 km² de extensión glaciar, representando una variación de 36.46% con respecto a INGLOG II. Este estudio es una muestra de que es posible adecuar el conjunto de datos de DW a zonas de estudio ubicadas en las cordilleras glaciares en los Andes del Perú.

Por otro lado, a nivel global, Venter et al. (2022) indica en su investigación que ESA WorldCover sobreestima la cubierta de hierba, presentando sesgo en su mapeo. El presente estudio concuerda con ello, pues su baja precisión se debe a que clasifica principalmente las zonas centrales o de mayor reflectancia de los glaciares como VP, pero confunde sombras de glaciar y lenguas en la zona de acumulación con vegetación escasa o pastizales, como se observó en la cordillera Huayhuash. Además, clasifica erróneamente las zonas de ablación, sedimentación o lagunas como área glaciar, aumentando la presencia de FN en el mapeo.

ESRI Land Cover muestra un mejor desempeño al clasificar los bordes de los glaciares. No obstante, al intentar agrupar áreas con características similares, tiende a generalizar las clases. Este fenómeno se observa en las cordilleras Blanca, Vilcabamba y Vilcanota, donde la

zona glaciar no es necesariamente continua debido a la presencia de crevasses, nunataks y morrenas que no contienen nieve. Esta generalización puede llevar a discrepancias al clasificar estas zonas de manera grupal, lo que conllevaría a una sobreestimación de presencia de glaciares.

Para el caso de INGLOG II, presenta problemas al mapear cobertura de glaciar en las cordilleras Barroso y Volcánica, con 5078.1 m² de extensión glaciar mínima y 6143.13 m² de extensión glaciar mínima respectivamente. Caso contrario para los restantes, donde logra mapear 91.15 m² de glaciar como mínimo, incluyendo las cordilleras La Viuda, Chonta, Huanzo, Chila y La Raya, que presentan un retroceso glaciar mayor al 80%. Esto ocurre por la distribución de áreas glaciares, pues al ser colindantes con regiones de cobertura glaciar más extensas, facilitan la identificación de estas.

El análisis comparativo de los conjuntos de datos ha proporcionado una visión más clara del desempeño de cada uno al ser aplicados en la cordillera glaciar de los Andes en Perú. Este estudio ha permitido identificar las fortalezas y debilidades de cada conjunto de datos, destacando cómo se comportan en diferentes condiciones geográficas y determinando qué conjuntos de datos ofrecen una mayor precisión en la detección de áreas glaciares y cuáles presentan limitaciones significativas.

Este enfoque comparativo facilita la selección de los conjuntos de datos más adecuados para el mapeo glaciar en regiones específicas, optimizando la precisión y relevancia de los resultados. Asimismo, permite ajustar y mejorar los métodos de análisis y los algoritmos utilizados, contribuyendo a una mejor planificación y gestión de recursos hídricos en zonas de difícil accesibilidad. En última instancia, la evaluación detallada respalda la toma de decisiones informada y la implementación efectiva de estrategias de monitoreo y conservación.

7. CONCLUSIÓN Y RECOMENDACIONES

7.1. CONCLUSIÓN

La evaluación y comparación de métricas de exactitud temática muestra una precisión general obtenida para INGLOG II fue “Muy Bueno” (87.6%), para ESRI LC fue “Buena” (86.6%), mientras que ESA WC alcanzó el 79%, siendo clasificada como “Buena”. INGLOG II tiene valores más altos en las métricas de exactitud, alcanzando un índice de Kappa de 0.72 (concordancia considerable o sustancial) y un Score-F1 de 0.889. En el caso de ESRI LC se obtuvo el Score-F1 más alto con 0.899, lo cual indica un rendimiento favorable en sensibilidad y precisión. Por su parte, ESA WC presentó valores más bajos en las métricas, con un índice Kappa de 0.57 y un Score de 0.83, lo que implica que parte de la concordancia observada podría explicarse por azar en lugar de por la capacidad real del modelo para clasificar correctamente. Asimismo, los resultados de intervalos de confianza Bootstrap muestra que ESA WC vendría a tener una diferencia significativa a comparación de las métricas de exactitud de los otros conjuntos de datos analizados.

Por otro lado, mediante el composite RGB para el 2020 se logró generar el mapeo con DW, no obstante presentó deficiencias para clasificar completamente la cordillera de los Andes del Perú, generando áreas de “No Data” que llegaron a ocupar el 67.17% en la zona glaciar de la cordillera Blanca. Por lo que al tener variaciones significativas, no se consideró este conjunto de datos en la evaluación de precisión, pues el análisis posterior presentaría sesgos considerables que no representarían de manera justa y estandarizada el mapeo de zonas glaciares en el ámbito de estudio.

Por su parte, la rasterización del mapa de cobertura glaciar de INGLOG II fue posible a una resolución de 10 metros, permitiendo que la comparación entre conjuntos de datos se uniformice para realizar un análisis a nivel de píxel. La generación de su matriz de error presentó VP mayores a 96% en las cordilleras Huagoruncho, Huaytapallana y Carabaya.

Finalmente, debido a la heterogeneidad entre el área Glaciar y No glaciar, donde se encontró una proporción de 1 a 113 píxeles, el diseño de muestreo estratificado permitió representar adecuadamente las características de la población, disminuyendo la variabilidad entre subpoblaciones y generando análisis diferenciados. Para la comparativa entre métricas de precisión, el uso de matrices de confusión y los intervalos de confianza Bootstrap posibilitaron la evaluación de las métricas precisión entre todos los conjuntos de datos utilizados.

7.2. RECOMENDACIONES

Dado que ESRI LC presentó mejores resultados luego de INGLOG II, es importante que, para obtener resultados generalizados y reducir sesgos temporales, realizar estudios alternos para sus productos de otros años, asegurando que estos mapas globales pueden aplicarse en diferentes periodos de tiempo y en otras condiciones climáticas o estacionales en los Andes del Perú.

Para el caso de Dynamic World, si bien cuenta con deficiencias, podría tener un mejor desempeño si se implementara otro modelo de enmascaramiento de nubes. En Perú, debido a su clima tropical, la cobertura nubosa frecuente complica el mapeo de áreas glaciares. La adopción de algoritmos de enmascaramiento de nubes más sofisticados que puedan diferenciar entre nubes gruesas (como cúmulos), nubes delgadas (como cirros) y sombras de nube (que suele confundirse con la sombra proyectada por el glaciar) podría mejorar significativamente la precisión en el mapeo de áreas glaciares en la cordillera de los Andes

Respecto al proceso de rasterización, es fundamental considerar los objetivos y metodología del estudio para determinar la resolución adecuada en la conversión, ya que una resolución insuficiente podría no capturar adecuadamente zonas de transición del terreno. Por ello, es ideal trabajar con imágenes de alta resolución que permitan una visualización óptima de este tipo de superficies.

Si bien el diseño de muestreo estratificado fue útil para las áreas Glaciar y No Glaciar, dada su gran heterogeneidad, puede afectar la representatividad del muestreo en zonas con menor variabilidad de su superficie. Por lo que para futuras investigaciones, es importante ajustar y reevaluar el diseño de muestreo en función de las características específicas de cada área de estudio, permitiendo generar análisis diferenciados y minimizar las limitaciones en la representatividad.

8. REFERENCIAS BIBLIOGRÁFICAS

ArcGIS Living Atlas of the World. (2024). *Esri | Sentinel-2 Land Cover Explorer*.

<https://livingatlas.arcgis.com/landcoverexplorer/>

Barsch, D. (1996). *Rockglaciers: Indicators for the Present and Former Geoecology in High Mountain Environments: Vol. XIV* (1a ed.). Springer Berlin.

<https://link.springer.com/book/10.1007/978-3-642-80093-1>

Bautista, L. A., & Calvo, J. A. (2024). *Estimación del área glaciar mediante inteligencia artificial y cubos de datos. Caso de Estudio: Parque Nacional Huascarán, Ancash – Perú del 2018-2022*. Universidad Nacional Mayor de San Marcos.

Benn, D., & Evans, D. J. A. (2010). *Glaciers and Glaciation, 2nd edition* (2a ed.). Routledge.

<https://doi.org/10.4324/9780203785010>

Bishop, Y., Fienberg, S., Holland, P., Light, R., & Mosteller, F. (1977). Discrete Multivariate Analysis: Theory and Practice. *Applied Psychological Measurement, 1*.

<https://doi.org/10.1177/014662167700100218>

Boschetti, L., Flasse, S. P., & Brivio, P. A. (2004). Analysis of the conflict between omission and commission in low spatial resolution dichotomic thematic products: The Pareto Boundary. *Remote Sensing of Environment, 91*(3), 280–292.

<https://doi.org/10.1016/j.rse.2004.02.015>

Brown, C. F., Brumby, S. P., Guzder-Williams, B., Birch, T., Hyde, S. B., Mazzariello, J., Czerwinski, W., Pasquarella, V. J., Haertel, R., Ilyushchenko, S., Schwehr, K., Weisse, M., Stolle, F., Hanson, C., Guinan, O., Moore, R., & Tait, A. M. (2022). Dynamic World, Near real-time global 10 m land use land cover mapping. *Scientific Data, 9*(1), 251. <https://doi.org/10.1038/s41597-022-01307-4>

- Buytaert, W., Moulds, S., Acosta, L., De Bièvre, B., Olmos, C., Villacis, M., Tovar Ingar, C., & Verbist, K. (2017). Glacier melt content of water use in the tropical Andes. *Environmental Research Letters*, 12. <https://doi.org/10.1088/1748-9326/aa926c>
- Camps-Valls, G. (2011). Remote Sensing Image Processing. *Synthesis Lectures on Image, Video, and Multimedia Processing*.
https://www.academia.edu/81571329/Remote_Sensing_Image_Processing
- Carlessi, H. S., & Meza, C. R. (2015). *Metodología y diseños en la investigación científica*. Educativa del INIDE.
https://scholar.google.com.pe/citations?view_op=view_citation&hl=es&user=3qroxJAAAAAJ&citation_for_view=3qroxJAAAAAJ:pyW8ca7W8N0C
- Carlotto Caillaux, V. S., Cárdenas Roque, J. D., Romero Fernández, D., Valdivia Vera, W., & Tintaya Aguilar, D. D. (1999). *Geología de los cuadrángulos de Quillabamba y Machu Picchu, hojas: 26-q y 27-q – [Boletín A 127]*. Instituto Geológico, Minero y Metalúrgico - INGEMMET.
<https://repositorio.ingemmet.gob.pe/handle/20.500.12544/87>
- Caron, L., Ivins, E. R., Larour, E., Adhikari, S., Nilsson, J., & Blewitt, G. (2018). GIA Model Statistics for GRACE Hydrology, Cryosphere, and Ocean Science. *Geophysical Research Letters*, 45(5), 2203–2212. <https://doi.org/10.1002/2017GL076644>
- CEOS. (2022). *El CEOS y el balance mundial de la CMNUCC*.
<https://ceos.org/gst/es/worldcover.html>
- Chen, B., Huang, B., Chen, L., & Xu, B. (2017). Spatially and Temporally Weighted Regression: A Novel Method to Produce Continuous Cloud-Free Landsat Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 55(1), 27–37. IEEE Transactions on Geoscience and Remote Sensing.
<https://doi.org/10.1109/TGRS.2016.2580576>

- Chicco, D., Tötsch, N., & Jurman, G. (2021). The Matthews correlation coefficient (MCC) is more reliable than balanced accuracy, bookmaker informedness, and markedness in two-class confusion matrix evaluation. *BioData Mining*, 14(1), 13.
<https://doi.org/10.1186/s13040-021-00244-z>
- Chuvieco Salinero, E. (2010). *Teledetección ambiental: La observación de la Tierra desde el espacio*. (1a ed.). Ariel.
- Cobbing, E. J., Sánchez Fernández, A. W., Martínez Valladares, W., & Zárate Olazabal, H. (1996). *Geología de los cuadrángulos de Huaraz, Recuay, La Unión, Chiquián y Yanahuanca. Hojas: 20-h, 20-i, 20-j, 21-i, 21-j – [Boletín A 76]*. Instituto Geológico, Minero y Metalúrgico - INGEMMET.
<https://repositorio.ingemmet.gob.pe/handle/20.500.12544/199>
- Cochran, W. G. (1977). *Sampling Techniques* (3a ed.). John Wiley & Sons.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37–46.
<https://doi.org/10.1177/001316446002000104>
- Congalton, R., & Green, K. (2019). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, Third Edition*. <https://doi.org/10.1201/9780429052729>
- Conway, H., Smith, B., Vaswani, P., Matsuoka, K., Rignot, E., & Claus, P. (2009). A low-frequency ice-penetrating radar system adapted for use from an airplane: Test results from Bering and Malaspina Glaciers, Alaska, USA. *Annals of Glaciology*, 50(51), 93–97. <https://doi.org/10.3189/172756409789097487>
- Crawford, C., Manson, S., Bauer, M., & Hall, D. (2013). Multitemporal snow cover mapping in mountainous terrain for Landsat climate data record development. *Remote Sensing of Environment*, 135, 224–233. <https://doi.org/10.1016/j.rse.2013.04.004>

- Cuffey, K. M., & Paterson, W. S. B. (2006). *The Physics of Glaciers* (4a ed.). Elsevier.
<https://shop.elsevier.com/books/the-physics-of-glaciers/cuffey/978-0-12-369461-4>
- De la Cruz Wetzell, J. S., Valencia Muñoz, M. M., & Boulanger Rondoy, E. (1996).
Geología de los cuadrángulos de Aguaytía, Panao y Pozuzo. Hoja: 19-I, 20-I, 21-I – [Boletín A 80]. Instituto Geológico, Minero y Metalúrgico - INGEMMET.
<https://repositorio.ingemmet.gob.pe/handle/20.500.12544/36>
- 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)
- Drenkhan, F., Carey, M., Huggel, C., Seidel, J., & Oré, M. T. (2015). The changing water cycle: Climatic and socioeconomic drivers of water-related changes in the Andes of Peru. *WIREs Water*, 2(6), 715–733. <https://doi.org/10.1002/wat2.1105>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., & Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25–36.
<https://doi.org/10.1016/j.rse.2011.11.026>
- Earth Engine Code Editor. (2024a). *ESA_WorldCover_v100*.
https://code.earthengine.google.com/?scriptPath=Examples%3ADatasets%2FESA%2FESA_WorldCover_v100
- Earth Engine Code Editor. (2024b). *ESRI-10m-LandCover*.
<https://code.earthengine.google.com/?scriptPath=users%2Fsat-io%2Fawesome-gee-catalog-examples%3Aglobal-landuse-landcover%2FESRI-10M-LANDCOVER>
- Ebel, P., Meraner, A., Schmitt, M., & Zhu, X. X. (2021). Multisensor Data Fusion for Cloud Removal in Global and All-Season Sentinel-2 Imagery. *IEEE Transactions on*

- Geoscience and Remote Sensing*, 59(7), 5866–5878. IEEE Transactions on Geoscience and Remote Sensing. <https://doi.org/10.1109/TGRS.2020.3024744>
- Efron, B. (1987). Better Bootstrap Confidence Intervals. *Journal of the American Statistical Association*, 82(397), 171–185. <https://doi.org/10.1080/01621459.1987.10478410>
- ESA. (2015). *Sentinel-2 User Handbook*. European Spatial Agency (ESA). https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2_User_Handbook
- ESA. (2024). *ESA WorldCover 2020*. The European Space Agency. <https://worldcover2020.esa.int/downloader>
- Espinoza, J. C., Chávez Jara, S. P., Ronchail, J., Junquas, C., Takahashi, K., & Lavado, W. (2015). *Rainfall hotspots over the southern tropical Andes: Spatial distribution, rainfall intensity, and relations with large-scale atmospheric circulation*. <http://hdl.handle.net/20.500.12816/2890>
- Foga, S., Scaramuzza, P. L., Guo, S., Zhu, Z., Dilley, R. D., Beckmann, T., Schmidt, G. L., Dwyer, J. L., Joseph Hughes, M., & Laue, B. (2017). Cloud detection algorithm comparison and validation for operational Landsat data products. *Remote Sensing of Environment*, 194, 379–390. <https://doi.org/10.1016/j.rse.2017.03.026>
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185–201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- García Alonso, A. (2016). *Estudio de la reflectancia espectral y modelos de predicción de color en mosaicos vítreos*. <https://repositorio.unican.es/xmlui/handle/10902/9203>
- Garreaud, R., Vuille, M., & Clement, A. (2003). The climate of the Altiplano: Observed current conditions and mechanisms of past changes. *Palaeogeography, Palaeoclimatology, Palaeoecology* 194: 5-22. *Palaeogeography Palaeoclimatology*

- Palaeoecology - PALAEOGEOGR PALAEOCLIMATOL*, 194, 5–22.
[https://doi.org/10.1016/S0031-0182\(03\)00269-4](https://doi.org/10.1016/S0031-0182(03)00269-4)
- Garreaud, R., Vuille, M., Compagnucci, R., & Marengo, J. (2009). Present-day South American Climate. *Palaeogeography Palaeoclimatology Palaeoecology*, 281.
<https://doi.org/10.1016/j.palaeo.2007.10.032>
- Gascon, F., Thepaut, O., Jung, M., Francesconi, B., Louis, J., Lonjou, V., Lafrance, B., Massera, S., Gaudel-Vacaresse, A., Languille, F., Alhammoud, B., Viallefont, F., Bieniarz, J., Pflug, B., Clerc, S., Pessiot, L., Trémas, T., Cadau, E., Bonis, R., & Fernandez, V. (2016). *Copernicus Sentinel-2 Calibration and Products Validation Status*. <https://doi.org/10.20944/preprints201610.0078.v1>
- Georges, C. (2004). 20th-Century Glacier Fluctuations in the Tropical Cordillera Blanca, Perú. *Arctic, Antarctic, and Alpine Research*, 36(1), 100–107.
- Gilford, M. T., Wojtesak, M. J., Myles, G., Bonam, R. C., & Martens, D. L. (1992, julio 1). *South America South of the Amazon River: A Climatological Study*.
<https://apps.dtic.mil/sti/citations/ADA259541>
- Huddart, D., & Stott, T. (2010). *Earth Environments: Past, Present and Future*.
- Impact Observatory. (2022). *Methodology & Accuracy Summary: 10m Global Land Use Land Cover Maps* (p. 4).
<https://www.impactobservatory.com/static/c033eb846160f6a0a35c63a64ef45e52/lulc-methodology-accuracy.pdf>
- INAIGEM. (2018). *Inventario Nacional de Glaciares: Las Cordilleras Glaciares Del Perú*. Insituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña.
- INAIGEM. (2019). *Informe de la Situación de los Glaciares y Ecosistemas de Montaña en el Perú 2017* (p. 124). Instituto Nacional de Investigación en Glaciares y Ecosistemas de

- Montaña. <https://www.inaigem.gob.pe/wp-content/uploads/2019/04/Interiores-Informe-anual-2017.pdf>
- INAIGEM. (2023). *Inventario Nacional de Glaciares y Lagunas de Origen Glaciar* (2a ed.). Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña. <https://repositorio.inaigem.gob.pe/handle/16072021/499>
- INAIGEM. (2024). *Limite Cordilleras Glaciares del Perú—Información general*. ArcGIS Online. <https://www.arcgis.com/home/item.html?id=8a8295ba14df43d98f976871ddda3ed3>
- JAXA. (2007). *ALOS User Handbook*. https://www.eorc.jaxa.jp/ALOS/en/doc/alos_userhb_en.pdf
- Jensen, J. R. (2009). *Remote Sensing of the Environment: An Earth Resource Perspective* (2a ed.). Pearson Education.
- Jia, X., & Richards, J. A. (2006). Remote Sensing Digital Image Analysis: An Introduction. En *Remote Sensing Digital Image Analysis: An Introduction: Vol. XXV* (4a ed.). Springer Berlin. <https://doi.org/10.1007/3-540-29711-1>
- Johansen, K. S., Alfthan, B., Baker, E., Hespings, M., Schoolmeester, T., & Verbist, K. (2018). *El Atlas de Glaciares y Aguas Andinos: El impacto del retroceso de los glaciares sobre los recursos hídricos*. UNESCO Biblioteca Digital. <https://unesdoc.unesco.org/ark:/48223/pf0000266209>
- Karra, K., Kontgis, C., Statman-Weil, Z., Mazzariello, J. C., Mathis, M., & Brumby, S. P. (2021). Global land use / land cover with Sentinel 2 and deep learning. *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 4704–4707. <https://doi.org/10.1109/IGARSS47720.2021.9553499>
- Kaser, G., & Osmaston, H. (2002). *Tropical Glaciers*. UNESCO.

- Kochtitzky, W. H., Edwards, B. R., Enderlin, E. M., Mariño Salazar, J., & Manrique Llerena, N. (2018). Improved estimates of glacier change rates at Nevado Coropuna Ice Cap, Peru. *Instituto Geológico, Minero y Metalúrgico – INGEMMET*.
<https://doi.org/10.1017/jog.2018.2>
- Lu, D. (2007). A Survey of Image Classification Methods and Techniques for Improving Classification Performance. *International Journal of Remote Sensing*, 28, 823–870.
<https://doi.org/10.1080/01431160600746456>
- Lynch, E. by D. K., Sassen, K., Starr, D. O., & Stephens, and G. (Eds.). (2002). *Cirrus*. Oxford University Press.
- Manning, C., Raghavan, P., & Schuetze, H. (2009). *Introduction to Information Retrieval*.
- Mark, B. G., & Seltzer, G. O. (2005). Evaluation of recent glacier recession in the Cordillera Blanca, Peru (AD 1962–1999): Spatial distribution of mass loss and climatic forcing. *Autoridad Nacional Del Agua*. <https://doi.org/10.1016/j.quascirev.2005.01.003>
- Melchiorre, A., Boschetti, L., & Roy, D. P. (2020). Global Evaluation of the Suitability of MODIS-Terra Detected Cloud Cover as a Proxy for Landsat 7 Cloud Conditions. *Remote Sensing*, 12(2), Article 2. <https://doi.org/10.3390/rs12020202>
- NASA. (2010). *Introduction to the Electromagnetic Spectrum—NASA Science*.
https://science.nasa.gov/ems/01_intro/
- Ñaupas Paitán, H., Mejía Mejía, E., Novoa Ramírez, E., & Villagómez Paucar, A. (2013). *Metodología de la investigación Cuantitativa—Cualitativa y Redacción de la Tesis* (4a ed.). Ediciones de la U.
- Page, D. F., & Ramseier, R. O. (1975). Application of Radar Techniques to Ice and Snow Studies. *Journal of Glaciology*, 15(73), 171–191.
<https://doi.org/10.3189/S0022143000034365>

- Palacios Moncayo, O., Caldas Vidal, J., & Vela Velásquez, C. (1992). *Geología de los cuadrángulos de Lima, Lurín, Chancay y Chosica. Hojas 25-i, 25-j. 24-i, 24-j— [Boletín A 43]*. Instituto Geológico, Minero y Metalúrgico - INGEMMET.
<https://repositorio.ingemmet.gob.pe/handle/20.500.12544/163>
- Piermattei, L., Zemp, M., Sommer, C., Brun, F., Braun, M. H., Andreassen, L. M., Belart, J. M. C., Berthier, E., Bhattacharya, A., Boehm Vock, L., Bolch, T., Dehecq, A., Dussailant, I., Falaschi, D., Florentine, C., Floricioiu, D., Ginzler, C., Guillet, G., Hugonnet, R., ... Yang, R. (2024). Observing glacier elevation changes from spaceborne optical and radar sensors – an inter-comparison experiment using ASTER and TanDEM-X data. *The Cryosphere*, 18(7), 3195–3230. <https://doi.org/10.5194/tc-18-3195-2024>
- Powers, D. (2008). Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation. *Mach. Learn. Technol.*, 2.
- Qiu, S., Zhu, Z., & Woodcock, C. E. (2020). Cirrus clouds that adversely affect Landsat 8 images: What are they and how to detect them? *Remote Sensing of Environment*, 246, 111884. <https://doi.org/10.1016/j.rse.2020.111884>
- Racoviteanu, A. E., Arnaud, Y., Williams, M. W., & Ordoñez, J. (2008). Decadal changes in glacier parameters in the Cordillera Blanca, Peru, derived from remote sensing. *Journal of Glaciology*, 54(186), 499–510.
<https://doi.org/10.3189/002214308785836922>
- Ramírez, N., Melfo, A., Resler, L. M., & Llambí, L. D. (2020). The end of the eternal snows: Integrative mapping of 100 years of glacier retreat in the Venezuelan Andes. *Arctic, Antarctic, and Alpine Research*, 52(1), 563–581.
<https://doi.org/10.1080/15230430.2020.1822728>

- Rivera, H. (2005). *Geología general*. Universidad Nacional Mayor de San Marcos.
- https://scholar.google.es/citations?view_op=view_citation&hl=es&user=FdKkrsoAAAJ&citation_for_view=FdKkrsoAAAAJ:UeHWp8X0CEIC
- Rosenqvist, A., Shimada, M., Ito, N., & Watanabe, M. (2007). ALOS PALSAR: A Pathfinder mission for global-scale monitoring of the environment. *Geoscience and Remote Sensing, IEEE Transactions on*, 45, 3307–3316.
- <https://doi.org/10.1109/TGRS.2007.901027>
- Roy, S. (2024). *ESRI 10m Annual Land Cover (2017-2023)*. awesome-gee-community-catalog. <https://gee-community-catalog.org/projects/S2TSLULC/>
- Sabino, C. (1992). *El proceso de investigación*. Panapo.
- Schott, J. R. (2007). *Remote Sensing: The Image Chain Approach* (Second Edition, Second Edition). Oxford University Press.
- Seehaus, T., Malz, P., Sommer, C., Lippl, S., Cochachin, A., & Braun, M. (2019). Changes of the tropical glaciers throughout Peru between 2000 and 2016 – mass balance and area fluctuations. *The Cryosphere*, 13(10), 2537–2556. <https://doi.org/10.5194/tc-13-2537-2019>
- Sekertekin, A., Marangoz, A. M., & Akcin, H. (2017). Pixel-Based Classification Analysis of Land Use Land Cover Using Sentinel-2 And Landsat-8 Data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-4-W6*, 91–93. WG IV/1
4th International GeoAdvances Workshop – GeoAdvances 2017: ISPRS Workshop on Multi-dimensional & Multi-scale Spatial Data Modeling (Volume XLII-4/W6) - 14–15 October 2017, Safranbolu, Karabuk, Turkey. <https://doi.org/10.5194/isprs-archives-XLII-4-W6-91-2017>
- Sellers, P. J., Dickinson, R. E., Randall, D. A., Betts, A. K., Hall, F. G., Berry, J. A., Collatz, G. J., Denning, A. S., Mooney, H. A., Nobre, C. A., Sato, N., Field, C. B., &

- Henderson-Sellers, A. (1997). Modeling the Exchanges of Energy, Water, and Carbon between Continents and the Atmosphere. *Science*, 275(5299), 502–509.
- Song, C., Woodcock, C. E., Seto, K. C., Lenney, M. P., & Macomber, S. A. (2001). Classification and Change Detection Using Landsat TM Data: When and How to Correct Atmospheric Effects? *Remote Sensing of Environment*, 75(2), 230–244.
[https://doi.org/10.1016/S0034-4257\(00\)00169-3](https://doi.org/10.1016/S0034-4257(00)00169-3)
- Stehman, S. V. (2014). Estimating area and map accuracy for stratified random sampling when the strata are different from the map classes. *International Journal of Remote Sensing*, 35(13), 4923–4939. <https://doi.org/10.1080/01431161.2014.930207>
- Stillinger, T., Roberts, D. A., Collar, N. M., & Dozier, J. (2019). Cloud Masking for Landsat 8 and MODIS Terra Over Snow-Covered Terrain: Error Analysis and Spectral Similarity Between Snow and Cloud. *Water Resources Research*, 55(7), 6169–6184.
<https://doi.org/10.1029/2019WR024932>
- Tempfli, K., Huurneman, G. C., Bakker, W., Janssen, L. L. F., Feringa, W. F., Gieske, A., Grabmaier, K. A., Hecker, C., Horn, J., Kerle, N., Meer, F. D., Parodi, G., Pohl, C., Reeves, C. V., Ruitenbeek, F. J. A., Schetselaar, E., Weir, M., Westinga, E., & Woldai, T. (2009). *Principles of remote sensing: An introductory textbook*. (pp. 56–85).
- Turpo Cayo, E. Y., Borja, M., Villar, R., Moreno, N., Camargo Arce, R., Almeida, C., Hopfgartner, K., Yarleque, C., & Souza Jr, C. (2022). Mapping Three Decades of Changes in the Tropical Andean Glaciers Using Landsat Data Processed in the Earth Engine. *Remote Sensing*, 14, 1974. <https://doi.org/10.3390/rs14091974>
- Van De Kerchove, R., De Keersmaecker, W., Li, L., Tsendbazar, N., & Lesiv, M. (2020). *WorldCover Product User Manual v1.0* (p. 23).
https://worldcover2020.esa.int/data/docs/WorldCover_PUM_V1.1.pdf

- Veettil, B. (2018). Glacier mapping in the Cordillera Blanca, Peru, tropical Andes, using Sentinel-2 and Landsat data. *Singapore Journal of Tropical Geography*, 39.
<https://doi.org/10.1111/sjtg.12247>
- Venter, Z., Barton, D., Chakraborty, T., Simensen, T., & Singh, G. (2022). Global 10 m Land Use Land Cover Datasets: A Comparison of Dynamic World, World Cover and Esri Land Cover. *Remote Sensing*, 14, 4101. <https://doi.org/10.3390/rs14164101>
- Vuille, M. (2013). *El Cambio Climático y los Recursos Hídricos en los Andes Tropicales* (517; IDB Technical Note, p. 35). Banco Interamericano de Desarrollo.
<https://publications.iadb.org/es/publicacion/15334/el-cambio-climatico-y-los-recursos-hidricos-en-los-andes-tropicales>
- Vuille, M., Francou, B., Wagnon, P., Juen, I., Kaser, G., Mark, B., & Bradley, R. (2008). Climate change and tropical Andean glaciers: Past, present and future. *Earth-Science Reviews*, 89, 79–96. <https://doi.org/10.1016/j.earscirev.2008.04.002>
- Wang, Y., Su, J., Zhai, X., Meng, F., & Liu, C. (2022). Snow Coverage Mapping by Learning from Sentinel-2 Satellite Multispectral Images via Machine Learning Algorithms. *Remote Sensing*, 14(3), Article 3. <https://doi.org/10.3390/rs14030782>
- Wilson, J. J., Reyes Rivera, L., & Garayar S., J. (1995). *Geología de los cuadrángulos de Pallasca, Tayabamba, Corongo, Pomabamba, Carhuaz y Huari. Hojas: 17-h, 17-i, 18-h, 18-i, 19-h, y 19-i – [Boletín A 60]*. Instituto Geológico, Minero y Metalúrgico - INGEMMET. <https://repositorio.ingemmet.gob.pe/handle/20.500.12544/182>
- Wouters, B., Gardner, A., & Moholdt, G. (2019). Global Glacier Mass Loss During the GRACE Satellite Mission (2002-2016). *Frontiers in Earth Science*, 7.
<https://doi.org/10.3389/feart.2019.00096>

9. ANEXOS

Tabla N° 10: Caracterización de las 3 regiones de los Andes del Perú


	Cordillera glaciar	Coordenadas		Pico más alto		Límites políticos
		Latitud sur	Longitud oeste	Nombre	Altitud máxima (m.s.n.m)	
Andes norte	Blanca	10°12'22.09" 7°55'55.71"	78°24'7.65" 76°30'47.90"	Nevado Huascarán	6,757	Comprende todas las provincias del departamento de Áncash.
	Huallanca	10°15'39.79" 9°48'28.34"	77°10'44.64"	Nevado El Burro	5,277	Se extiende por la provincia de Bolognesi (Áncash), distritos de Huallanca, Aquia y Huasta (Huánuco).
	Huayhuash	10°34'31.21" 10°03'18.23"	77°16'51.99" 76°40'18.30"	Nevado Yerupajá	6,617	Abarca la provincia de Cajatambo (Lima), provincia de Bolognesi (Áncash) y provincia de Lauricocha (Huánuco).
	Raura	10°44'56.82" 10°10'51.44"	77°5'44.59" 76°30'39.40"	Nevado Santa Rosa	5,701	Ocupa las provincias de Cajatambo y Oyón (Lima), provincia de Lauricocha (Huánuco) y la provincia Daniel Alcides Carrión (Pasco)
Andes centro	Huagoruncho	10°57'10.12" 09°40'7.01"	76°17'27.97" 75°16'42.05"	Nevado Tarata	5,723	Se extiende parcialmente por las provincias de Huánuco, Ambo y Pachitea (Huánuco), y las provincias de Pasco y Oxapampa (Pasco).
	La Viuda	11°58'42.97" 10°17'43.47"	77°10'54.98" 75°50'58.61"	Nevado Alcay	5,412	Abarca las provincias de Oyón, Huaraura, Huaral, Canta y Huarochirí (Lima), la la provincia de Yauli (Junín) y las provincias Pasco y Daniel Alcides Carrión (Pasco).
	Huaytapallana	12°25'39.08" 10°49'07.24"	75°58'33.63" 74°15'34.34"	Nevado Huatapallana	5,557	Ocupa las provincias de Huancayo y Concepción (Junín).
	Central	13°00'50.40" 11°23'48.74"	76°41'01.56" 75°09'06.44"	Nevado Pariacaca	5,750	Se extiende por las provincias de Huarochirí y Yauyos (Lima), y en las provincias de Yauli, Jauja, Concepción y Chupaca (Junín).

Andes sur	Chonta	12°10'06.34" 14°07'14.24"	74°07'10.16" 76°07'45.30"	Glaciar Condoray	5,255	Abarca las provincias de Angaraes, Castrovirreyna, Huancavelica y Huaytara (Huancavelica), la provincia de Huancayo (Junín), la provincia de Yauyos (Lima), la provincia de Chincha (Ica), las provincias de Cangallo y Huamanga (Ayacucho).
	Ampato	16°16'36.85" 14°47'28.28"	73°53'57.21" 71°13'46.68"	Nevado Coropuna	6,377	Ocupa las provincias de Parinacochas, Paucar del Sara Sara (Ayacucho) y las provincias de Condesuyos, Castilla, Caylloma, Caravelí y la Unión (Arequipa).
	Vilcabamba	13°41'43.34" 12°58'57.26"	73°27'30.22" 72°09'33.46"	Nevado Salcantay	6,271	Se extiende por las provincias de La Convención, Urubamba y Anta (Cusco), y la provincia de Abancay (Apurímac).
	Urubamba	12°30'46.02" 13°39'52.53"	71°37'23.55" 72°50'28.42"	Nevado Ccolque Cruz	5,823	Abarca las provincias de Anta, Calca, Cusco, La Convención, Paucartambo y Urubamba (Cusco).
	Huanzo	15°21'07.48" 14°03'17.54"	73°24'12.55" 71°46' 43.38"	Nevado Huanzo	5,400	Ocupa las provincias de Antabamba, Cotabambas y Grau (Apurímac), las provincias de Castilla, Caylloma, Condesuyos y La Unión (Arequipa), la provincia de Chumbivilcas (Cusco) y las provincias de Parinacochas y Paucar del Sara Sara (Ayacucho).
	Chila	15°39'41.36" 15°09'29.37"	72°24'10.03" 71°27'13.20"	Glaciar Choquepirhua y Huillcayo	5,585	Se extiende por los distritos de Choco, Chachas, Orcopampa, Chilcaymarca, Andagua y Ayo en la provincia de Castilla y los distritos de Tapay, Caylloma, Tuti, Sibayo, Tisco, Lari, Coporaque, Ichupampa y Madrigal en la provincia de Caylloma (Arequipa)
	La Raya	13°52'2.02" 15°07'48.02"	70°33'29.48" 71°42'24.50"	Nevado Chimbolla	5,488	Abarca las provincias de Acomayo, Canas, Canchis y Espinar (Cusco) y la provincia de Melgar (Puno)
	Vilcanota	14°33'08.86" 13°07'23.82"	71°45'11.64" 70°28'14.91"	Nevado Ausangate	6,372	Ocupa parcialmente las provincias de Paucartambo, Quispicanchi y Canchis (Cusco) y las provincias de Carabaya y Melgar (Puno)
	Carabaya	13°07'13.02" 14°52'07.62"	69°14'44.13" 71°16'12.67"	Nevado Allin Capac	5,805	Se extiende por la provincia de Quispicanchi (Cusco) y las provincias de Azángaro, Carabaya, Melgar y Sandia (Puno)

Apolobamba	14°55'14.23" 14°09'19.80"	69°43'57.90"	Nevado Viscachani	6,074	Abarca los distritos de Ananea y Sina en la provincia de San Antonio de Putina; los distritos de Cuyocuyo, Quiaca, Yanahuaya, Sandia en la provincia de Sandia y el distrito de Cojata en la provincia de Huancané (Puno)
Volcánica	15°36'59.43" 16°51'19.22"	70°28'44.59" 71°47'43.77"	-	-	Ocupa los distritos de Alto Selva Alegre, Cayma, Cerro Colorado, Characato, Chiguata, Miraflores, Pócsi, San Juan de Tarucani y Yura, provincia de Arequipa; los distritos de distritos de San Antonio de Chauca y Yanque, provincia de Caylloma (Arequipa); y los distritos de Coalaque, Matalaque, Omate, Puquina, Quinistaquilla y Ubinas, provincia de General Sánchez (Moquegua)
Barroso	16°37'29.21" 17°50'12.98"	69°48'02.09" 70°45'09.54"	-	-	Se extiende por los distritos de Carumas, Chuchumbaya, San Cristobal y Torata, provincia de Mariscal Nieto (Moquegua); los distritos de distritos de Capazo y Santa Rosa, provincia El Collao (Puno); los distritos de Candarabe, provincia de Tacna, y los distritos de Cairani, Canilaca, Candarave, Huanuara, Quilahuani, Pachia, Palca, Estique, Héroes Albarracín, Sitajara, Susapaya, Tarata, Tarucachi y Ticao, provincia de Tarata (Tacna).


Nota: En la tabla se caracterizan las 20 cordilleras que constituyen el área de estudio. Adaptado de Inventario Nacional de Glaciares Las Cordilleras Glaciares del Perú 2018. *Elaboración propia.*

Figura N° 36: Mapa de promedio anual de temperaturas máximas




Nota: Las temperaturas mínimas varían entre -5 a 11 °C. Elaboración propia

Figura N° 37: Mapa de promedio anual de temperaturas máximas




Nota: Las temperaturas máximas varían entre 9 a 21 °C. Elaboración propia

Figura N° 38: Mapa de promedio anual de precipitaciones




Nota: Las precipitaciones anuales varían entre 700 a 1500 mm. Elaboración propia.

Figura N° 39: Mapa geomorfológico




Elaboración propia.

Figura N° 40: Mapa geológico



Elaboración propia.

Figura N° 41: Mapa hidrológico



Elaboración propia.

Tabla N° 11: Cálculo de cantidad de pixeles de muestreo

	Cordillera	# Píxeles totales		Proporción por estrato (%)		# Píxeles de muestreo	
		Glaciar	No glaciar	Glaciar	No glaciar	Glaciar	No glaciar
C1	Blanca	4718334	131576679	34.088%	8.414%	2543	266
C2	Huallanca	51579	9898905	0.373%	0.633%	28	20
C3	Huayhuash	592230	11131666	4.279%	0.712%	319	22
C4	Raura	262156	10803311	1.894%	0.691%	141	22
C5	Huagoruncho	70755	59208659	0.511%	3.786%	38	120
C6	La Viuda	134653	106233843	0.973%	6.793%	73	215
C7	Central	556259	116073055	4.019%	7.422%	300	235
C8	Huaytapallana	258830	109144852	1.870%	6.979%	139	221
C9	Chonta	37114	155851212	0.268%	9.966%	20	315
C10	Ampato	1026602	128305231	7.417%	8.205%	553	259
C11	Vilcabamba	1110369	57027836	8.022%	3.647%	598	115
C12	Urubamba	306318	53143590	2.213%	3.398%	165	107
C13	Huanzo	181248	140062346	1.309%	8.956%	98	283
C14	Chila	217971	40246780	1.575%	2.574%	117	81
C15	La Raya	55270	61398137	0.399%	3.926%	30	124
C16	Vilcanota	2791010	74289949	20.164%	4.751%	1504	150
C17	Carabaya	367240	120468727	2.653%	7.704%	198	243
C18	Apolobamba	429506	24724930	3.103%	1.581%	231	50
C19	Volcánica	237360	59221882	1.715%	3.787%	128	120
C20	Barroso	436834	94995484	3.156%	6.075%	235	192

Elaboración propia.

Tabla N° 12: Código GEE para generación de composites

```
1 // Define una variable 'polygon' con el valor 'C1'
2 var polygon = 'C1';
3
4 // Carga la colección de imágenes Sentinel-2 Surface Reflectance
5 Harmonized en la variable 's2Sr'
6 var s2Sr = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED');
7
8 // Carga la colección de imágenes de probabilidad de nubes de
9 Sentinel-2 en la variable 's2Clouds' y define la probabilidad máxima
10 de nubes
11 var s2Clouds = ee.ImageCollection('COPERNICUS/S2_CLOUD_PROBABILITY');
12 var MAX_CLOUD_PROBABILITY = 65;
13
14 // Establece el centro del mapa en la cordillera especificadas con un
15 nivel de zoom de 10
16 Map.centerObject(polygon, 10);
17
18 // Define una función 'maskClouds' que aplica una máscara para
19 eliminar píxeles nublados en función de la probabilidad de nubes
20 function maskClouds(img) {
21   var clouds = ee.Image(img.get('cloud_mask')).select('probability');
22   var isNotCloud = clouds.lt(MAX_CLOUD_PROBABILITY);
23   return img.updateMask(isNotCloud);
24 }
25
26 // Define una función 'maskEdges' que aplica máscaras adicionales para
27 eliminar datos incorrectos en los bordes de la escena
28 function maskEdges(s2_img) {
29   return s2_img.updateMask(
30     s2_img.select('B8A').mask().updateMask(s2_img.select('B9').mask()));
31 }
32
33 // Define un criterio de filtrado y el rango de fechas, y lo aplica a
34 las colecciones 's2Sr' y 's2Clouds', aplicandola función 'maskEdges'
35 var criteria = ee.Filter.and(
36   ee.Filter.bounds(region), ee.Filter.date('2020-01-01', '2020-12-
37 31'));
38 s2Sr = s2Sr.filter(criteria).map(maskEdges);
39 s2Clouds = s2Clouds.filter(criteria);
40
41 // Une la colección 's2Sr' con 's2Clouds' para agregar una máscara de
42 nubes a las imágenes 's2Sr'
43 var s2SrWithCloudMask = ee.Join.saveFirst('cloud_mask').apply({
44   primary: s2Sr,
45   secondary: s2Clouds,
46   condition: ee.Filter.equals({leftField: 'system:index', rightField:
47 'system:index'})
48 });
49
50 // Aplica la máscara de nubes a la colección unida y calcula la
51 mediana de las imágenes resultantes
52 var s2CloudMasked =
53 ee.ImageCollection(s2SrWithCloudMask).map(maskClouds).median();
```


```

54
55 // Define una función 'resampleBand' para remuestrear una banda
56 específica de una imagen a una resolución de 10 metros
57 function resampleBand(bandName, image) {
58     return image.select([bandName])
59         .reproject({
60             crs: image.select([bandName]).projection(),
61             scale: 10
62         });
63 }
64
65 // Define una lista de bandas que serán remuestreadas
66 var bandsToResample = ['B1', 'B2', 'B3', 'B4', 'B8', 'B11', 'B12'];
67
68 // Aplica la función 'resampleBand' a cada banda en 'bandsToResample'
69 y almacena las bandas remuestreadas en 'resampledBands'
70 var resampledBands = bandsToResample.map(function(bandName) {
71     return resampleBand(bandName, s2CloudMasked);
72 });
73
74 // Combina las bandas remuestreadas en una sola imagen
75 var resampledImage = ee.Image.cat(resampledBands);
76
77 // Genera el composite SNOW y recorta al polígono 'C1'
78 var resampledImageSNOW = resampledImage.select(['B1', 'B11',
79 'B12']).clip(C1);
80
81 // Define las opciones de visualización para SNOW
82 var snowviz = {"bands": ["B1", "B11", "B12"], "min": 0, "max": 5000};
83 Map.addLayer(resampledImageSNOW, snowviz, 'SNOW');
84
85 // Genera el composite SNOW y recorta al polígono 'C1'
86 var resampledImageRGB = resampledImage.select(['B4', 'B3',
87 'B2']).clip(C1);
88
89 // Define las opciones de visualización RGB
90 var rgbVis = {min: 0, max: 3000, bands: ['B4', 'B3', 'B2']};
91 Map.addLayer(resampledImageRGB, rgbVis, 'RGB');
92
93 // Calcula el NDSI usando las bandas 'B3' y 'B11'
94 var green = resampledImage.select('B3');
95 var SWIR = resampledImage.select('B11');
96 var NDSI = green.subtract(SWIR).divide(green.add(SWIR));
97
98 // Recorta la imagen NDSI al polígono 'C1'
99 var NDSIClipped = NDSI.clip(C1);
100
101 // Define las opciones de visualización para la imagen NDSI y la
102 agrega al mapa con una paleta de colores específica
103 Map.addLayer(NDSIClipped, {
104     max: 1.0,
105     min: -1.0,
106     'palette': ['CE7E45', 'DF923D', 'F1B555', 'FCD163', '99B718',
107 '74A901', '66A000', '529400', '3E8601', '207401', '056201', '004C00',
108 '023B01', '012E01', '011D01', '011301'], 'índice NDSI');

```


Elaboración propia.

Figura N° 42: RGB por cordillera




Elaboración propia.

Figura N° 43: Combinación de bandas B1, B11, B12 por cordillera




Elaboración propia.

Figura N° 44: NDSI por cordillera




Elaboración propia.

Figura N° 45: Cobertura LULC con DW por cordillera




Elaboración propia.

Figura N° 46: Cobertura LULC con ESA WC por cordillera




Elaboración propia.

Figura N° 47: Cobertura LULC con ESRI LC por cordillera



Elaboración propia.

Figura N° 48: Mapeo INGLOG II por cordillera



Elaboración propia.