

**UNIVERSIDAD NACIONAL JORGE BASADRE GROHMANN**

**Facultad de Ingeniería Civil, Arquitectura y Geotecnia**

**Escuela Profesional de Ingeniería Geológica – Geotecnia**

**ANÁLISIS MULTITEMPORAL DE GLACIARES, BOFEDALES Y LAGUNAS  
GLACIARES Y SU PREDICCIÓN BASADO EN AUTÓMATAS CELULARES  
EN LA CORDILLERA DEL BARROSO – TACNA**

**TESIS**

**Presentada por:**

**Bach. German Huayna Felipe**

**Para optar el Título Profesional de:**

**Ingeniero Geólogo – Geotécnico**

**TACNA – PERÚ**

**2025**

UNIVERSIDAD NACIONAL JORGE BASADRE GROHMANN

Facultad de Ingeniería Civil, Arquitectura y Geotecnia

Escuela Profesional de Ingeniería Geológica - Geotecnia

HOJA DE JURADO

TESIS

“ANÁLISIS MULTITEMPORAL DE GLACIARES, BOFEDALES  
Y LAGUNAS GLACIARES Y SU PREDICCIÓN BASADO EN  
AUTÓMATAS CELULARES EN LA CORDILLERA  
DEL BARROSO – TACNA”

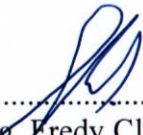
Presentado por el bachiller German Huayna Felipe

Para optar el título profesional de Ingeniero Geólogo – Geotécnico

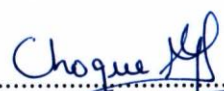
Tesis sustentada y aprobada el 14 de noviembre de 2025 (R.F. N°606-2025-  
FIAG/UNJBG)

Con el siguiente jurado:


Presidente

  
:.....  
Mgr. Ing. Fredy Cleto Cabrera Olivera

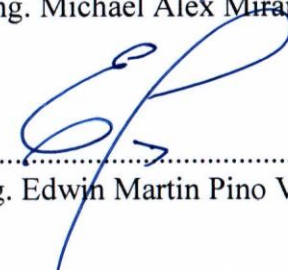
Miembro - Secretario

  
:.....  
Mgr. Ing. Gloria Marina Choque Machaca

Miembro – Vocal:

  
:.....  
Mstro. Ing. Michael Alex Miranda Choque

Asesor de Tesis:

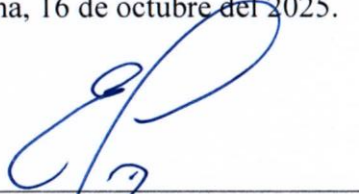
  
:.....  
Ph.D. Ing. Edwin Martin Pino Vargas

**CERTIFICADO DE SIMILITUD**

Yo, **Ph. D. Ing. Edwin Martin Pino Vargas**, en mi condición de ASESOR (A) acreditado con Resolución de Facultad y/o Postgrado N.º 1001-2024-FIAG/UNJBG del 27 de diciembre del 2024, del Trabajo de Tesis (Trabajo Informe, Trabajo Académico, Trabajo de Suficiencia Profesional, Examen Profesional) titulado: **“ANÁLISIS MULTITEMPORAL DE GLACIARES, BOFEDALES Y LAGUNAS GLACIARES Y SU PREDICCIÓN BASADO EN AUTÓMATAS CELULARES EN LA CORDILLERA DEL BARROSO – TACNA”**. Presentado por el (la) **Bach. GERMAN HUAYNA FELIPE**. Para optar el grado académico y/o título profesional de INGENIERO GEÓLOGO-GEOTÉCNICO.

Habiendo cumplido con lo establecido en el reglamento de originalidad y similitud de trabajos de investigación y producción intelectual de la UNJBG; considerando que según la revisión, evaluación y análisis realizado a través del software de similitud textual TURNITIN, cuenta con el nivel de similitud permitido cuyo porcentaje es **4 %**. Por lo que CERTIFICO LA SIMILARIDAD de la tesis y/o trabajo enunciado líneas arriba, la cual esta expedita para continuar con los trámites para optar el título profesional de **INGENIERO GEÓLOGO-GEOTÉCNICO**, según corresponda para su publicación en el Repositorio Institucional.

Tacna, 16 de octubre del 2025.



FIRMA ASESOR

Nombres y apellidos: **Ph.D. Ing. Edwin Martin Pino Vargas**

DNI: **00486621**



FIRMA AUTOR

Nombre y apellidos: **Bach. German Huayna Felipe**

DNI: **43412852**



### **Dedicatoria**

*"Dedico este trabajo a mis padres, por su amor inquebrantable y constante apoyo. A mi familia y amigos, por su apoyo emocional y aliento.*

*A mis profesores y mentores, por su invaluable guía y enseñanzas. A todos quienes han sido parte de este camino, ¡gracias por inspirarme!"*

## **Agradecimiento**

Doy gracias a Dios por otorgarme la fortaleza, sabiduría y la inspiración necesaria para completar esta tesis. Su guía y su protección han sido fundamentales en cada paso de este camino académico. Que este logro sea un testimonio de mi gratitud hacia Él y de mi compromiso continuo con el aprendizaje y el crecimiento.

A todos los docentes de la Escuela Profesional de Ingeniería Geológica-Geotecnia por sus enseñanzas que me guiaron durante mi formación académica. Un agradecimiento muy especial a mi asesor Ing. Edwin Martin Pino Vargas, por transmitirme sus conocimientos y experiencia, por su apoyo y su paciencia.

Se agradece a la Universidad Nacional Jorge Basadre Grohmann, Tacna, Perú, Vicerrectorado de Investigación e Instituto de Investigación por brindar los fondos de canon, sobre canon y regalías mineras para el desarrollo del proyecto “Mitigación del riesgo de desborde e inundación basado en una propuesta de valoración de espacio público sostenible en zonas áridas”, aprobado con R.R. N°13626-2024-UNJBG. Asimismo, a H2O UNJBG, Grupo de Investigación del Agua.

## Índice de contenido

<b>Portada .....</b>	<b>i</b>
<b>Hoja de jurados .....</b>	<b>ii</b>
<b>Certificado de similitud .....</b>	<b>iii</b>
<b>Dedicatoria.....</b>	<b>iv</b>
<b>Agradecimiento .....</b>	<b>v</b>
<b>Índice de contenido .....</b>	<b>vi</b>
<b>Índice de figuras .....</b>	<b>xii</b>
<b>Índice de tablas.....</b>	<b>xv</b>
<b>Índice de anexos .....</b>	<b>xvi</b>
<b>Resumen.....</b>	<b>xvii</b>
<b>Abstract.....</b>	<b>xviii</b>
<b>Introducción .....</b>	<b>1</b>
<b>Capítulo I: Aspectos generales.....</b>	<b>4</b>
1.1. Descripción del área de estudio .....	4
1.1.1. Ubicación.....	4
1.1.2. Accesibilidad .....	6
1.1.3. Clima .....	6

1.2.	Planteamiento del problema.....	8
1.2.1.	Descripción del problema.....	8
1.3.	Formulación del problema.....	9
1.3.1.	Problema general.....	9
1.3.2.	Problemas específicos.....	9
1.4.	Justificación.....	10
1.5.	Objetivos.....	11
1.5.1.	Objetivo general.....	11
1.5.2.	Objetivos específicos.....	11
1.6.	Hipótesis.....	12
1.6.1.	Hipótesis general.....	12
1.6.2.	Hipótesis específicas.....	12
<b>Capítulo II: Marco teórico.....</b>		<b>14</b>
2.1.	Antecedentes.....	14
2.1.1.	Antecedentes internacionales.....	14
2.1.2.	Antecedentes nacionales.....	16
2.2.	Fundamentos teóricos.....	17
2.3.	Criosfera.....	17

2.4.	Glaciar.....	19
2.4.1.	Partes de un glaciar.....	20
2.5.	Glaciares en Sudamérica.....	21
2.6.	Glaciares tropicales.....	22
2.7.	Clasificación de los glaciares tropicales.....	24
2.7.1.	Glaciar libre de detritos.....	25
2.7.2.	Glaciar cubierto por detritos.....	25
2.7.3.	Glaciares rocosos.....	26
2.8.	Glaciares en el Perú.....	26
2.9.	Humedales altoandinos (bofedales).....	30
2.10.	Lagunas glaciares.....	30
2.11.	Teledetección.....	31
2.11.1.	El Espectro electromagnético.....	32
2.11.2.	Firmas espectrales.....	34
2.12.	Misión Landsat.....	35
2.13.	Google Earth Engine.....	37
2.14.	Índices espectrales.....	38
2.15.	Modelado del cambio de cobertura y uso del suelo.....	42

2.16.	Modelos basados en autómatas celulares.....	43
2.17.	Módulo para simulaciones de cambio de uso del suelo (MOLUSCE).....	46
<b>Capítulo III: Metodología .....</b>		<b>47</b>
3.1.	Tipo de investigación.....	47
3.1.1.	Tipo .....	47
3.1.2.	Nivel .....	47
3.2.	Diseño de investigación .....	47
3.3.	Población y muestra de estudio .....	48
3.3.1.	Población .....	48
3.3.2.	Muestra .....	48
3.4.	Técnicas e instrumentos de recolección de datos .....	48
3.5.	Análisis de datos .....	49
3.5.1.	Etapa 1: Recopilación de datos .....	50
3.5.2.	Etapa 2: Clasificación de coberturas (LULC) mediante técnicas de teledetección .....	51
3.5.3.	Etapa 3: Validación e interpretación .....	51
3.5.4.	Etapa 4: Modelado de escenarios futuros (LULC) mediante autómatas celulares (CA-Markov).....	52

<b>Capítulo IV: Mapeo de glaciares, bofedales y lagunas mediante análisis satelital y evaluación de precisión.....</b>	<b>54</b>
4.1.    Identificación de glaciares .....	54
4.1.1.    Cálculo del índice de nieve de diferencia normalizada.....	54
4.2.    Identificación de lagunas .....	55
4.3.    Identificación de bofedales .....	56
4.4.    Tamaño de muestra.....	57
4.4.1.    Métricas de validación.....	58
<b>Capítulo V: Resultados .....</b>	<b>61</b>
5.1.    Resultados del primer objetivo .....	61
5.1.1.    Clasificación de series temporales .....	61
5.1.2.    Reflectancia en superficies naturales .....	65
5.1.3.    Exactitud de las metodologías en mapeo de coberturas .....	70
5.2.    Resultados del segundo objetivo.....	73
5.2.1.    Transformaciones históricas de cobertura glaciár, lagos y bofedales.....	73
5.3.    Resultados del tercer objetivo .....	83
5.3.1.    Evaluación de variables predictoras espaciales.....	83

5.3.2. Modelado del potencial de transición.....	86
5.3.3. Modelo de validación de escenario futuro .....	87
5.3.4. Estimación de los cambios futuros de cobertura .....	88
<b>Conclusiones .....</b>	<b>95</b>
<b>Recomendaciones .....</b>	<b>97</b>
<b>Bibliografía .....</b>	<b>98</b>
<b>Anexos .....</b>	<b>132</b>

## Índice de figuras

Figura 1 <i>Ubicación de la zona de estudio</i> .....	5
Figura 2 <i>Datos de precipitación de la zona de estudio</i> .....	7
Figura 3 <i>Visión general de la criósfera global</i> .....	19
Figura 4 <i>Partes de un glaciar</i> .....	21
Figura 5 <i>Glaciares tropicales</i> .....	23
Figura 6 <i>Distribución de glaciares en el Perú</i> .....	29
Figura 7 <i>Espectro Electromagnético</i> .....	33
Figura 8 <i>Firmas espectrales</i> .....	34
Figura 9 <i>Ilustración gráfica de la cronología de la misión Landsat</i> .....	36
Figura 10 <i>Aplicaciones Google Earth Engine</i> .....	38
Figura 11 <i>Vecindad de Autómata Celular</i> .....	44
Figura 12 <i>Configuración de un patrón específico, cuatro pasos de tiempo, color negro son las células vivas</i> .....	46
Figura 13 <i>Diagrama de flujo</i> .....	53
Figura 14 <i>Visualización temporal del Índice Diferenciado Normalizado de Nieve (NDSI)</i> .....	62
Figura 15 <i>Diagrama de caja Índice Diferenciado Normalizado de Nieve (NDSI)</i> .....	63
Figura 16 <i>Visualización temporal del Índice de Vegetación de Diferencia Normalizada (NDVI)</i> .....	64

Figura 17 <i>Diagrama de caja del Índice de Vegetación de Diferencia Normalizada (NDVI)</i> .....	65
Figura 18 <i>Puntos aleatorios de muestreo</i> .....	66
Figura 19 <i>Espectro de reflectancia de hielo</i> .....	67
Figura 20 <i>Espectro de reflectancia de la vegetación</i> .....	68
Figura 21 <i>Perdida de cobertura de glaciares en la Cordillera del Barroso</i> .....	69
Figura 22 <i>Visualización de puntos sorteados aleatoriamente</i> .....	71
Figura 23 <i>Precisión usuario de los mapas multianuales</i> .....	72
Figura 24 <i>Precisión productor de los mapas multianuales</i> .....	72
Figura 25 <i>Índice Kappa de los mapas multianuales</i> .....	73
Figura 26 <i>Regresión de deming de clases de coberturas</i> .....	74
Figura 27 <i>Evolución temporal de coberturas</i> .....	75
Figura 28 <i>Superficie de cobertura multitemporal</i> .....	76
Figura 29 <i>Cambio de cobertura de glaciares en altitudes</i> .....	79
Figura 30 <i>Pérdida multianual de cobertura glaciar en orientaciones</i> .....	80
Figura 31 <i>Diagrama polar</i> .....	81
Figura 32 <i>Ganancias y pérdidas históricas de cambio de cobertura y uso del suelo</i> .....	83
Figura 33 <i>Variables explicativas adoptadas en este estudio</i> .....	85
Figura 34 <i>Correlación de variables predictoras</i> .....	86
Figura 35 <i>Precisión de la validación</i> .....	87

Figura 36 <i>Curva de aprendizaje de la red neuronal</i> .....	88
Figura 37 <i>Escenarios futuros de cambio de cobertura y uso del suelo</i> .....	89
Figura 38 <i>Ganancias y pérdidas proyectados de cobertura y uso del suelo</i> .....	90
Figura 39 <i>Superficie de tendencias múltiples</i> .....	92
Figura 40 <i>Comparación proyectada en diagrama polar (2032–2042)</i> .....	93

### Índice de tablas

Tabla 1 <i>Límites de la zona de estudio</i> .....	5
Tabla 2 <i>Áreas de glaciares tropicales por región y país</i> .....	23
Tabla 3 <i>Cantidad y superficie de los glaciares por Cordillera</i> .....	28
Tabla 4 <i>Espectro electromagnético con rangos de longitud de onda y frecuencia</i> .....	33
Tabla 5 <i>Imágenes de reflectancia TOA del programa Landsat</i> .....	49
Tabla 6 <i>Matriz de confusión binaria</i> .....	59
Tabla 7 <i>Valores de coeficiente Kappa</i> .....	60

## Índice de anexos

<b>ANEXO I.</b> Matriz de Consistencia.....	133
<b>ANEXO II.</b> <i>Tabla de resultados de superficie glaciar, bofedales y cuerpos de agua en (km<sup>2</sup>) en la Cordillera del Barroso .....</i>	134
<b>ANEXO III.</b> <i>Matriz de probabilidad de transición, período 2012-2022, para la predicción al 2042.....</i>	135
<b>ANEXO IV.</b> <i>Matriz de tabulación cruzada, tasa de cambios para las cuatro clases en los cinco períodos de análisis observados .....</i>	136
<b>ANEXO V.</b> <i>Matriz de tabulación cruzada, tasa de cambios para las cuatro clases en los tres períodos de análisis predichos .....</i>	138
<b>ANEXO VI.</b> <i>Evaluación de la precisión del LULC 1986-2022.....</i>	140
<b>ANEXO VII.</b> <i>Mapa de ubicación del área de investigación .....</i>	141
<b>ANEXO VIII.</b> <i>Retroceso glaciar en la cordillera del Barroso.....</i>	142

## Resumen

Esta investigación analiza el retroceso glaciar, así como la dinámica de bofedales y lagunas de origen glaciar, y su impacto en los cambios de cobertura y uso del suelo (LULC) en la Cordillera del Barroso, Tacna, Perú. El estudio se basa en el procesamiento de imágenes satelitales mediante técnicas de teledetección y análisis geoespacial en sistemas de información geográfica (SIG), integradas con Autómatas Celulares (AC) para la proyección de escenarios futuros. Se empleó Google Earth Engine (GEE) para procesar series temporales anuales de imágenes Landsat 5 y 8 entre 1985 y 2022. A partir de índices normalizados, se generaron mapas de LULC para los años 1986, 2001, 2012 y 2022. Posteriormente, se empleó el complemento MOLUSCE de QGIS, integrando seis variables predictoras para simular la dinámica espacial de glaciares, bofedales y cuerpos de agua con proyección al año 2042. Los mapas alcanzaron una precisión general (OA) superior al 83%. Entre 1986 y 2022, la superficie glaciar se redujo de 44,7 km<sup>2</sup> a 7,4 km<sup>2</sup>, mientras que los bofedales aumentaron de 5,70 km<sup>2</sup> a 12,14 km<sup>2</sup> y los cuerpos de agua de 3,02 km<sup>2</sup> a 4,39 km<sup>2</sup>. La proyección para 2042, con una OA superior al 84%, estima una reducción glaciar a 3,07 km<sup>2</sup>, un aumento de bofedales a 18,8 km<sup>2</sup> y de cuerpos de agua a 4,63 km<sup>2</sup>. El modelado con MOLUSCE evidenció una drástica pérdida de glaciares y un notable crecimiento de bofedales en los escenarios proyectados.

Palabras clave: Sensores Remotos, Retroceso Glaciar, Autómatas Celulares

## **Abstract**

This study analyzes glacier retreat, as well as the dynamics of bofedales (high-Andean wetlands) and glacial-origin lakes, and their impact on land use and land cover (LULC) changes in the Barroso Mountain Range, Tacna, Peru. The research is based on the processing of satellite imagery using remote sensing techniques and geospatial analysis within geographic information systems (GIS), integrated with Cellular Automata (CA) for future scenario projections. Google Earth Engine (GEE) was used to process annual time series of Landsat 5 and 8 imagery from 1985 to 2022. Based on normalized indices, LULC maps were generated for the years 1986, 2001, 2012, and 2022. Subsequently, the MOLUSCE plugin in QGIS was used, integrating six predictive variables to simulate the spatial dynamics of glaciers, bofedales, and water bodies projected to the year 2042. The resulting maps achieved an overall accuracy (OA) greater than 83%. Between 1986 and 2022, glacier extent decreased from 44.7 km<sup>2</sup> to 7.4 km<sup>2</sup>, while bofedales expanded from 5.70 km<sup>2</sup> to 12.14 km<sup>2</sup>, and water bodies increased from 3.02 km<sup>2</sup> to 4.39 km<sup>2</sup>. The 2042 projection, with an OA above 84%, estimates a further glacier reduction to 3.07 km<sup>2</sup>, an expansion of bofedales to 18.8 km<sup>2</sup>, and an increase in water bodies to 4.63 km<sup>2</sup>. Modeling with MOLUSCE revealed a marked loss of glacier area and a significant growth in bofedales under projected scenarios.

**Keywords:** Remote Sensing, Glacial Retreat, Cellular Automata

## **Introducción**

Un glaciar es una masa permanente de hielo y nieve en movimiento formada por la acumulación, compactación y recristalización de la nieve (Francou & Pouyaud, 2008). Los glaciares juegan un papel fundamental en el sistema ambiental global y su dinámica está relacionada con los cambios en la circulación océano-atmósfera, el clima, el nivel del mar y la configuración del paisaje (Knight, 2004).

El incremento de la temperatura global, causado por las emisiones de gases de efecto invernadero de origen humano, ha disminuido la extensión de los glaciares, el hielo y la nieve, lo que ha resultado en fenómenos climáticos extremos (V. Kumar et al., 2021). Se estima que los glaciares perderán entre el  $26 \pm 6\%$  de su masa si la temperatura aumenta  $1,5 \text{ }^\circ\text{C}$  y el  $41 \pm 11\%$  si el aumento es de  $4 \text{ }^\circ\text{C}$  para el año 2100, lo cual tendrá un impacto en el nivel del mar y los recursos hídricos (Rounce et al., 2023).

Los glaciares tropicales de los Andes están disminuyendo rápidamente a causa del cambio climático, y algunos podrían desaparecer en las próximas décadas (Vuille et al., 2008), el acelerado retroceso de los glaciares tropicales andinos ha llevado a una reducción del 42% de su superficie total entre 1990 y 2020, evidenciando un impacto considerable del cambio climático (Turpo Cayo et al., 2022). Esta drástica pérdida de masa glaciar ha acelerado la disminución de la disponibilidad de recursos hídricos y repercute negativamente en las comunidades

locales, el turismo, la energía hidroeléctrica y la agricultura (Chevallier et al., 2011; Madrigal-Martínez et al., 2022). Además el acelerado deshielo glaciar ha creado lagos morrénicos, aumentando el riesgo de inundaciones repentinas (Bajracharya & Mool, 2009; Emmer et al., 2022; Sattar et al., 2021).

El 97 % de los glaciares del mundo se encuentra en los inlandsis de la Antártida y Groenlandia, mientras que el 3 % restante está disperso en diversas Cordilleras nevadas (de Guzmán & Fernando, 2015). Los Andes del Perú albergan el 71 % de los glaciares tropicales de América del Sur (Blanca & Llullán, 2014). Las temperaturas en el Perú han aumentado 0,75°C en los últimos 100 años y han tendido a incrementarse más fuertemente en los últimos 30 a 40 años (López-Moreno et al., 2016). Como consecuencia, el Perú es considerado uno de los países más vulnerables a los efectos del calentamiento global (Tarrillo-Ruiz, 2023).

En la región altoandina del Perú, especialmente en las áreas con montañas y nevados, los bofedales desempeñan un papel fundamental en el mantenimiento de los caudales base durante la estación seca y en la regulación del flujo de agua, liberando agua de manera continua a lo largo de esta temporada, lo cual es esencial para garantizar la seguridad hídrica río abajo (Yager et al., 2021). Asimismo, brindan servicios ecosistémicos, ingresos para la economía local, propiedades medicinales, alimentos y apoyan el ecoturismo (Leon et al., 2021). Estos sistemas son frágiles y vulnerables a la actividad humana y al cambio climático (Coayla-

Peñaloza et al., 2023). Su monitoreo y conservación son esenciales para entender el impacto del cambio climático y garantizar la seguridad hídrica en estas áreas.

Los métodos de teledetección, como Landsat, proporcionan una mayor comprensión de los procesos que afectan los cambios en los glaciares y el clima (Lenarduzzi & Pepe, 2017; Raup et al., 2015). Además, el análisis de series temporales con imágenes satelitales está ampliando los tipos de cambios en la superficie terrestre monitoreados, mejorando la calidad y la precisión, y permitiendo un monitoreo casi en tiempo real (Panuju et al., 2020; Woodcock et al., 2020). La integración de datos de Sentinel-1 y Sentinel-2 a través de algoritmos de aprendizaje automático en Google Earth Engine conduce a una mayor precisión cartográfica y una mejor clasificación de la cobertura de la superficie (W. Li et al., 2020).

GEE es una plataforma de computación en la nube que procesa grandes volúmenes de datos geográficos sobre grandes áreas y se utiliza para diversas aplicaciones, como clasificación de uso y cobertura del suelo, hidrología, planificación urbana, desastres naturales, análisis climáticos y procesamiento de imágenes (Amani et al., 2020; L. Kumar & Mutanga, 2018; Tamiminia et al., 2020; Velastegui-Montoya et al., 2023). Los modelos de autómatas celulares pueden aportar información sobre la evolución espacial de los procesos geográficos y la dinámica del uso de suelo, y pueden usarse para explorar resultados futuros a través de pruebas de escenarios alternativos (Liu et al., 2020).

## Capítulo I: Aspectos generales

### 1.1. Descripción del área de estudio

#### 1.1.1. Ubicación

La Cordillera Barroso es una de las cadenas montañosas que se encuentran en la región sur del Perú (Bellido Bravo, 1969). Forma parte de las cordilleras glaciares extintas. Presenta una extensión aproximada de 169 km y un área aproximada de 9 291 km<sup>2</sup> (INAIGEM, 2017). Sus límites geográficos van desde las coordenadas de 16°37'29,21" a 17°50'12,98" de latitud sur y de 69°48'02,09" a 70°45'09,54" de longitud oeste. Se extiende parcialmente sobre los territorios de los departamentos de Moquegua, Puno y Tacna. En el departamento de Tacna incluye a las provincias de Candarave, Tacna y Tarata.

El área de estudio se ubica dentro de los cuadrángulos de Palca (36X) y Río Mauri (35X), abarcando un área total de 1 450,19 km<sup>2</sup>. Comprende parte de las provincias de Tacna y Tarata, como se observa en la Figura 1. Hidrográficamente, se encuentra en:

vertiente del Pacífico: cuenca Caplina y cuenca Sama


vertiente del Atlántico: cuenca Uchusuma y cuenca Mauri.

La Tabla 1 presenta las coordenadas UTM (WGS 84) que delimitan geográficamente el área de estudio.

**Tabla 1***Límites de la zona de estudio*

Este	Norte
394 073 m	8 049 279 m
430 936 m	8 087 892 m

*Nota.* Coordenadas UTM (datum WGS 84) que delimitan el área de estudio.

**Figura 1***Ubicación de la zona de estudio*

*Nota.* (a) Ubicación del Perú en América del Sur, (b) Ubicación del área de estudio,

(c) vista panorámica de los glaciares de la Cordillera del Barroso. Fuente: Propia.

### **1.1.2. Accesibilidad**

El acceso a la cordillera se puede realizar desde las regiones de Moquegua y Tacna, así como a través diversas rutas que parten de la carretera Panamericana Sur, a la altura de Camiara, Tomasiri y otras localidades. Para alcanzar los picos de la cordillera, existen carreteras afirmadas y trochas carrozables, que conectan con posteriormente con caminos de herradura.

También es posible recorrer la cordillera en sentido este-oeste, partiendo desde las ciudades de Puno o Juliaca. Además, se cuenta con una ruta longitudinal que recorre el límite occidental de la cordillera, conectando Arequipa con Moquegua a través de la carretera 108.

### **1.1.3. Clima**

El clima se clasifica como semiárido a hiperárido, con una marcada variabilidad en temperatura y precipitación. La temperatura promedio oscila entre 13.4 °C y 18.1 °C, aunque en invierno puede descender hasta -15 °C, como se muestra en la Figura 2. La temperatura máxima se mantiene relativamente constante durante el año, mientras que la mínima varía considerablemente, alcanzando sus valores más bajos en la temporada invernal.

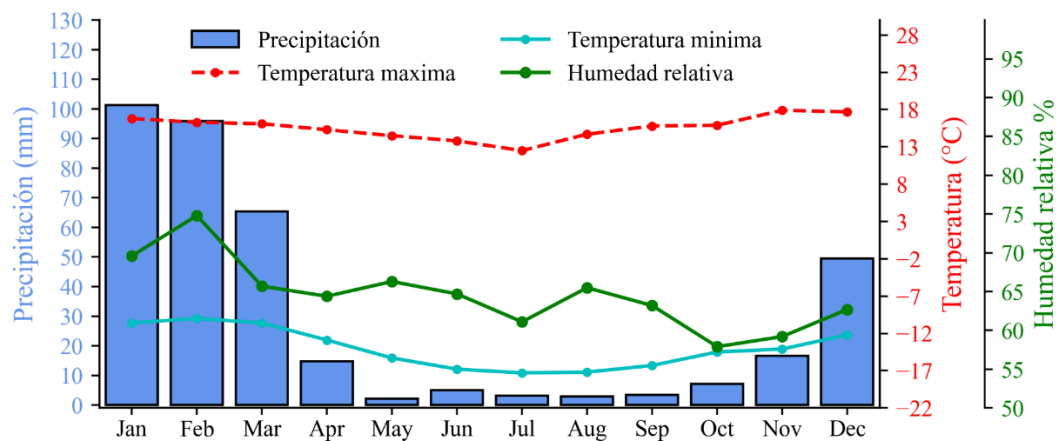
La precipitación anual promedio es de 360 mm, con el 78% de las lluvias ocurriendo entre diciembre y marzo, lo que indica una fuerte estacionalidad en las precipitaciones. Los meses más lluviosos son enero y febrero, con valores que se

acercan a los 100 mm. Por otro lado, en los meses de verano la precipitación es mínima, con valores cercanos a 5 mm, lo que refleja un período seco prolongado.

La humedad relativa sigue una tendencia marcada a lo largo del año, alcanzando valores más altos en los meses de mayor precipitación, llegando hasta el 80%, y disminuyendo en los meses más secos, rondando el 55%, lo que refleja una fuerte estacionalidad en la humedad atmosférica de la región.

**Figura 2**

*Datos de precipitación de la zona de estudio*



*Nota:* Estación Meteorológica de Paucarani, ubicada en las coordenadas 417 169 E y 8 061 319 N con elevación de 4 621 m.s.n.m. Fuente: Datos proporcionados por SENAMHI.

## **1.2. Planteamiento del problema**

### **1.2.1. Descripción del problema**

El cambio y la variabilidad climática están acelerando la pérdida de glaciares y alterando los ecosistemas de alta montaña a nivel global, afectando la disponibilidad de agua y aumentando la vulnerabilidad de las poblaciones (Wang et al., 2024). En Perú, donde se concentra la mayor parte de los glaciares tropicales de Sudamérica (Seehaus et al., 2019), estos impactos son particularmente severos, comprometiendo los recursos hídricos esenciales para la agricultura, el abastecimiento de agua y los ecosistemas.

En la cordillera del Barroso, ubicada en la región de Tacna, los glaciares, bofedales y lagunas glaciares constituyen fuentes estratégicas de agua para los ecosistemas altoandinos y las poblaciones humanas (Lizama et al., 2025). Sin embargo, en las últimas décadas estos sistemas han experimentado una acelerada transformación debido a los efectos del cambio y la variabilidad climática, que se manifiestan en el aumento sostenido de las temperaturas, en cambios en los patrones de precipitación y en eventos meteorológicos extremos (De la Cruz et al., 2025).

Actualmente, las metodologías convencionales de monitoreo presentan limitaciones para representar con precisión la dinámica espaciotemporal de estos ecosistemas, lo que dificulta una gestión informada y oportuna ante los escenarios proyectados de cambio climático. Esta brecha en el conocimiento impide una

evaluación adecuada de la vulnerabilidad y la resiliencia de los sistemas socioambientales de alta montaña.

Ante esta situación, se vuelve crucial implementar enfoques integradores que combinen análisis multitemporales mediante sensores remotos, modelamiento espacial y técnicas predictivas. Estas herramientas permiten caracterizar los cambios en glaciares, bofedales y lagunas glaciares con mayor resolución y anticipación, generando insumos clave para el diseño de estrategias de conservación, adaptación y manejo sostenible del recurso hídrico.

### **1.3. Formulación del problema**

#### **1.3.1. Problema general**

¿Cómo puede el uso de datos satelitales, mediante técnicas de teledetección, análisis multitemporales y modelos predictivos como los autómatas celulares, mejorar la precisión en la reconstrucción y proyección de la dinámica de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna?

#### **1.3.2. Problemas específicos**

- ¿Cuál es la cobertura actual de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, y cómo puede ser clasificada con precisión mediante técnicas de teledetección y análisis SIG?

- ¿Cómo ha cambiado la cobertura de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso a lo largo del tiempo, y qué patrones de transformación pueden identificarse mediante análisis multitemporales?
- ¿Qué grado de precisión y confiabilidad presentan los modelos predictivos, basados en autómatas celulares, al proyectar escenarios futuros de pérdida o transformación de estos ecosistemas?

#### **1.4. Justificación**

Basándonos en la problemática planteada anteriormente, la escasez de recursos hídricos en la región de Tacna se ve agravada por el retroceso de los glaciares, que inicialmente puede incrementar temporalmente la disponibilidad de agua. Sin embargo, esta condición conlleva una pérdida irreversible de los reservorios naturales que regulan el flujo hídrico a largo plazo, como glaciares, bofedales y lagunas glaciares, cuyo deterioro representa una amenaza creciente para la seguridad hídrica, la agricultura y la vida rural. En la cordillera del Barroso, estos sistemas naturales, que actúan como fuentes críticas de agua, están siendo alterados por los efectos del cambio y la variabilidad climática, lo que intensifica los riesgos para el equilibrio ambiental y socioeconómico de la región.

Comprender su transformación espaciotemporal es fundamental para prevenir impactos socioambientales y diseñar estrategias de adaptación. En este contexto, el uso de análisis multitemporal con datos satelitales y modelos

predictivos, como los autómatas celulares, permite mejorar la capacidad de monitoreo, identificar patrones de cambio y proyectar escenarios futuros con mayor precisión.

Esta investigación no solo aportará conocimiento técnico para la gestión ambiental en zonas vulnerables, sino que también proporcionará una base científica útil para los tomadores de decisiones, fortaleciendo la planificación territorial y las políticas frente al cambio climático.

## **1.5. Objetivos**

### **1.5.1. Objetivo general**

Realizar un análisis multitemporal de glaciares, bofedales y lagunas glaciares, y desarrollar un modelo predictivo basado en autómatas celulares para proyectar su evolución futura en la Cordillera del Barroso, Tacna.

### **1.5.2. Objetivos específicos**

- Identificar y clasificar la cobertura de glaciares, bofedales y lagunas glaciares mediante imágenes satelitales y técnicas de teledetección en SIG, evaluando la precisión de la clasificación en la Cordillera del Barroso, Tacna.
- Analizar la dinámica de cambio de cobertura en los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.

- Desarrollar un modelo predictivo basado en Autómatas Celulares para proyectar la evolución futura de los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.

## **1.6. Hipótesis**

### **1.6.1. Hipótesis general**

La integración de análisis multitemporales de datos satelitales, aplicando técnicas avanzadas de teledetección y modelado mediante autómatas celulares, permite proyectar de forma precisa y eficiente la evolución futura de los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.

### **1.6.2. Hipótesis específicas**

- El procesamiento de imágenes satelitales mediante técnicas de teledetección y análisis geoespacial en sistemas de información geográfica (SIG) permite identificar y clasificar con precisión la cobertura de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.
- El análisis multitemporal de datos satelitales revela patrones significativos en la dinámica de cambio de cobertura de los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.

- Un modelo predictivo basado en autómatas celulares es capaz de simular de manera efectiva la evolución futura de los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.

## Capítulo II: Marco teórico

### 2.1. Antecedentes

Para el desarrollo del presente estudio, se tomaron como referencia diversas investigaciones, tanto nacionales como internacionales, que se centran en el análisis del retroceso glaciar y la proyección de escenarios futuros mediante el modelo CA-Markov. A continuación, se presentan los trabajos más representativos en esta línea de investigación.

#### 2.1.1. Antecedentes internacionales

Rojas-Macedo et al. (2025) realizaron un estudio titulado "*Uso de imágenes satelitales para evaluar el retroceso de los glaciares en la Isla Rey Jorge, Antártida*", en el que emplearon imágenes Landsat (1989–2020) para cuantificar los cambios en la cobertura glaciar en la Isla Rey Jorge, ubicada en la Península Antártica. El análisis se centró en establecer relaciones entre el retroceso glaciar y fenómenos climáticos como El Niño–Oscilación del Sur (ENSO), mediante los índices ONI y SOI, así como variables como la temperatura y la precipitación. El estudio identificó una pérdida del 10 % de la cobertura glaciar en un periodo de 31 años, destacando que los glaciares de menor tamaño y aquellos con terminación marina fueron los más afectados.

Zhao et al. (2024) en el estudio titulado "***Vinculación del retroceso de los glaciares con el cambio climático en la meseta tibetana mediante teledetección por satélite***", realizado entre 1988 y 2022, emplearon un índice adaptativo de extracción de glaciares (AGEI) aplicado a imágenes multiespectrales Landsat, integradas con Google Earth Engine, para analizar patrones espaciotemporales de retroceso glaciar en la meseta tibetana. A partir del mapeo detallado de los glaciares y del análisis de datos climáticos, se identificó un retroceso heterogéneo, con tasas anuales de pérdida glaciar entre 0,14 % y 0,51 %, destacando un retroceso más acelerado entre 1990 y 2000, un ligero aumento entre 2000 y 2010 y una posterior estabilidad relativa. Además, se evidenció que la temperatura anual tuvo mayor impacto en el Himalaya meridional, mientras que la precipitación influyó más en el Karakórum durante la primavera.

Zhuang et al. (2023) en el estudio titulado "***Medición de los cambios en los glaciares de las montañas Tianshan durante los últimos 20 años mediante Google Earth Engine y aprendizaje automático***", emplearon la fusión de imágenes ópticas y de radar (SAR), junto con datos ERA-5 y diversos algoritmos de aprendizaje automático, para mapear la distribución y el retroceso de los glaciares en las montañas Tianshan en los años 2001, 2011 y 2021. El clasificador de bosque aleatorio mostró el mejor rendimiento, evidenciando un aumento en la tasa de retroceso glaciar de 0,87 % a 1,49 % anual. Se identificaron patrones espaciales

diferenciados entre subregiones, con mayor pérdida en zonas periféricas, valles y áreas cercanas a la línea de equilibrio glaciar.

### **2.1.2. Antecedentes nacionales**

Laqui et al. (2024) en el estudio titulado "*Dinámica temporal del retroceso glaciar y su relación con el clima local en la Cordillera Apolobamba, Perú*", evaluaron la pérdida de superficie glaciar entre 1986 y 2015 mediante imágenes satelitales Landsat y el Índice de Nieve de Diferencia Normalizada (NDSI), con análisis a intervalos de cinco años. Los resultados revelaron una reducción del 51,84 % de la cobertura glaciar original, con una tasa media de pérdida de 0,79 km<sup>2</sup> por año. Además, se identificaron relaciones significativas entre variables climáticas y el retroceso glaciar, evidenciando que el aumento de la temperatura impulsa directamente la pérdida de superficie, mientras que la precipitación influye de manera condicionante.

Turpo Cayo et al. (2022) en el estudio titulado "*Mapeo de tres décadas de cambios en los glaciares andinos tropicales utilizando datos Landsat procesados en Earth Engine*", reconstruyeron la cobertura de los glaciares andinos tropicales (GAT) desde 1985 hasta 2020 mediante imágenes satelitales Landsat y técnicas de clasificación digital implementadas en la plataforma Google Earth Engine. Utilizando reducciones anuales del Índice de Nieve de Diferencia Normalizada (NDSI) y bandas espectrales, el análisis multitemporal reveló una pérdida del 42 %

del área glaciar entre 1990 y 2020, con mayor retroceso en altitudes inferiores a los 5000 msnm. Además, se observaron diferencias significativas en la pérdida glaciar según la pendiente, la latitud, la longitud y el país, siendo más críticas en territorios con menor cobertura glaciar.

Soto-Carrión et al. (2022) en el estudio titulado "*Análisis multitemporal del retroceso de los glaciares mediante imágenes satelitales Landsat en el Nevado del Santuario Nacional de Ampay - Perú*", investigaron la disminución de la superficie glaciar del nevado Ampay entre 1991 y 2017, utilizando imágenes satelitales Landsat y el Índice de Nieve de Diferencia Normalizada (NDSI), junto con datos meteorológicos de las estaciones de Tamburco y Abancay. A través de técnicas de clasificación supervisada, se identificó una pérdida del 48,92 % del área glaciar, pasando de 2,13 km<sup>2</sup> a 1,09 km<sup>2</sup> en 26 años, atribuida principalmente al incremento de la temperatura y la variabilidad en la precipitación. Aunque en 2015 se registró una acumulación anómala de nieve, la tendencia general ha sido de retroceso continuo, lo que evidencia un riesgo creciente para la disponibilidad del recurso hídrico en la región.

## **2.2. Fundamentos teóricos**


### **2.3. Criosfera**

La criósfera es el sistema térmico de la Tierra que mantiene temperaturas por debajo de 0 °C y abarca diversos procesos físicos, químicos y biológicos

relacionados con los cambios de fase del agua y las diferentes formas de hielo (Melnikov et al., 2018). El término proviene del griego "kryos", que significa frío, Y los principales componentes de la criósfera son la nieve y el hielo, los cuales se presentan en diversas formas, tales como la capa de nieve, el hielo marino, el hielo de agua dulce, el permafrost y las grandes masas de hielo continentales como los glaciares y las capas de hielo (Ambinakudige & Joshi, 2012) , véase la Figura 3.

La criósfera desempeña un papel crucial en el equilibrio energético global, por lo que cualquier cambio en sus propiedades físicas o en su extensión afecta la circulación del aire a nivel mundial, las temperaturas del océano y del aire, el nivel del mar y los patrones de las corrientes oceánicas (Bhardwaj et al., 2016). Además, tiene un impacto significativo en los recursos hídricos.

En los Andes, la criosfera es responsable de abastecer agua a más de dos tercios de la población en ciertas regiones, siendo vital para la gestión de cuencas y el suministro de agua dulce (Hernández-Duarte et al., 2021). La criosfera sirve como un indicador sensible del cambio climático, con fluctuaciones en la nieve, el hielo y los glaciares que reflejan las tendencias del calentamiento global (Goodison et al., 1999).

**Figura 3***Visión general de la criósfera global*

*Nota.* Mapa global en el que se muestran los hielos glaciares, las banquisas, casquetes, permafrost y la cobertura de nieve. Tomado de Barry & Gan (2011).

#### **2.4. Glaciar**

Los glaciares son grandes acumulaciones de hielo formadas por la nieve que se deposita y acumula con el paso del tiempo y se desplazan de manera muy lenta, ya sea deslizándose desde altas montañas, como en los glaciares de valle, o bien emergiendo de áreas de acumulación, como en los glaciares continentales (Ayoub & Song, 2020), Aproximadamente el 10 % de la superficie de la Tierra está cubierta

de hielo glaciar, con el 99,9 % de este volumen atrapado en las capas de hielo polares y menos del 1 % que forma todos los demás glaciares y capas de hielo de montaña (Frezzotti & Orombelli, 2014).

#### **2.4.1. Partes de un glaciar**

En la Figura 4 se ilustra las principales partes de un glaciar.

Zona de acumulación: cantidad de nieve y hielo acumulados durante un año hidrológico, y ofrece datos sobre las precipitaciones que el glaciar ha recibido a lo largo de ese año (Francou & Pouyaud, 2004).

Zona de ablación: Es la parte del glaciar donde predominan los procesos de fusión (pérdida de hielo en forma líquida), evaporación, sublimación y desprendimiento de bloques de hielo (Francou & Pouyaud, 2004).


Altitud de la línea de equilibrio (ELA): Es la línea teórica que divide la zona de acumulación de la zona de ablación, donde la acumulación anual de nieve es igual a la ablación, de forma que el balance de masa es igual a 0 (Cañadas & Trueba, 2004; Porter, 2000). La altitud de la ELA rara vez es constante a lo largo de un glaciar, ya que varía debido a patrones de acumulación de nieve, zonas de sombra y otros factores, por lo que se ha adoptado el concepto de ELA estable (Benn & Ballantyne, 2005).

En la zona de acumulación, predominan los procesos de ganancia que permiten la conservación de la nieve y su transformación en hielo. En la zona de

ablación, prevalecen la fusión y la sublimación, favoreciendo la pérdida de masa glaciaria (Ubeda-Palencque, 2011).

#### Figura 4

*Partes de un glaciar*



*Nota.* Se muestra las partes de un glaciar: la zona de acumulación, la zona de ablación y la línea de equilibrio. Tomado de INAIGEM (2017).


### 2.5. Glaciares en Sudamérica

Estudios recientes sobre los glaciares sudamericanos revelan cambios significativos, incluida la contracción de los glaciares en los Andes, lo que contribuye al aumento del nivel del mar por unidad de área (Masiokas et al., 2020). El balance de masa de los glaciares está influenciado por varios factores climáticos, con distintos controles en diferentes regiones de América del Sur (Mutz &

Aschauer, 2022). En Sudamérica, los glaciares tropicales se encuentran entre Bolivia y Venezuela, abarcando una superficie aproximada de 2 758 km<sup>2</sup>; su distribución es la siguiente: Perú posee el 71 %, Bolivia el 20 %, Ecuador y Colombia cada uno el 4 %, y Venezuela el 1 % (Francou, 2013). Perú ha visto una reducción del 56 % en la extensión de sus glaciares durante los últimos sesenta años (Curo-Rosales et al., 2023). La disminución de los glaciares pone en riesgo la seguridad hídrica de las comunidades en las regiones de la costa del Pacífico, los Andes y la Amazonía (Vargas-Huanca et al., 2024).

## **2.6. Glaciares tropicales**

Los glaciares tropicales se localizan entre el Trópico de Cáncer y el Trópico de Capricornio (23°26'13,3" N y 23°26'13,3" S) dentro de la Zona de Convergencia Intertropical (ZCIT), y en lugares donde la variación de la temperatura diaria es igual a la variación de temperatura anual (Kaser & Osmaston, 2002). Los Andes tropicales de Venezuela, Colombia, Ecuador, Perú, Bolivia, el norte de Chile y el norte de Argentina representan más del 95% de todos los glaciares tropicales del mundo (Chevallier et al., 2011; Veettil & Kamp, 2017), estos se encuentran distribuidos en 20 Cordilleras glaciares que cubren el sector norte, centro y sur del país ver Tabla 2. Estos glaciares tropicales son vulnerables a las alteraciones climáticas y afectan a las comunidades y ecosistemas situados río abajo en los Andes centrales de Perú y Bolivia (Mark, 2008). Ver Figura 5.

**Figura 5***Glaciares tropicales*

*Nota.* Distribución de los glaciares tropicales a nivel mundial., tomado de Veettil & Kamp (2019).

**Tabla 2***Áreas de glaciares tropicales por región y país*

Región	País	Área (km <sup>2</sup> )
	Venezuela	0,79
	Colombia	66,19
Sudamérica	Ecuador	123,9
	Perú	1 602,96
	Bolivia	531,58

	Norte de Chile	11,81
	Norte de Argentina	0,32
	<b>Total</b>	<b>2 337,55</b>
África	Kenia	0,40
	Tanzania	2,87
	Uganda-República	1,14
	Democrática del Congo	
	<b>Total</b>	<b>4,41</b>
Irían Jaya	Indonesia	2,14
	<b>Total, en todos los trópicos</b>	<b>2 344,10</b>

*Nota.* Datos del inventario de glaciares Randolph a nivel mundial, tomado de Veettil & Kamp (2019).

## 2.7. Clasificación de los glaciares tropicales

Los glaciares se clasifican principalmente por su morfología, que considera el tamaño, la forma y la relación del glaciar con la topografía que lo rodea. Por otro lado, la clasificación térmica se basa en la temperatura interna del hielo, que puede ser templada, en el punto de fusión a presión (alrededor de 0 °C), fría, por debajo del punto de fusión a presión, y politérmica, es decir, una mezcla de zonas templadas y frías (Copland, 2022). Muchos glaciares muestran una combinación de estas características a lo largo de su extensión, lo que resulta en una gran diversidad de formas naturales.

### **2.7.1. Glaciar libre de detritos**

Estos glaciares tienen una superficie relativamente limpia, con pocas impurezas o material particulado. Se distinguen claramente por tener una zona de acumulación y una zona de ablación bien definidas. En algunos casos, pueden contener una pequeña cantidad de material detrítico, cenizas u otras impurezas (Lliboutry, 1956), que se acumulan en la superficie del glaciar debido a varios factores como la acción del viento, desprendimientos de laderas cercanas y la presencia de morrenas laterales o frontales, entre otros.

### **2.7.2. Glaciar cubierto por detritos**

Estos glaciares se caracterizan por estar parcial o completamente cubiertos por una capa de detritos que actúa como aislante. Pueden originarse a partir de un glaciar descubierto que, debido a un proceso de retroceso, adelgazamiento progresivo o aumento del recubrimiento, termina siendo cubierto por un manto de detritos de mayor espesor y extensión (Rivera et al., 2017). Además, estos glaciares presentan sistemas de drenaje y tasas de derretimiento que difieren de los glaciares limpios; la presencia de una capa continua de escombros genera redes de drenaje ineficientes y provoca altas tasas de derretimiento en las áreas no cubiertas por los escombros (Fyffe et al., 2019).

### **2.7.3. Glaciares rocosos**

También son llamados glaciares de escombros, glaciares de roca y glaciares rocosos (Brenning, 2003). Son elementos geomorfológicos de hielo y escombros gruesos y angulares que toman la forma de lóbulos o lenguas. Se desarrollan debajo de paredes rocosas empinadas y se desplazan lentamente a través de valles, y están típicamente asociados con terrenos montañosos de origen glacial (Hewitt, 2014).

Los glaciares de roca contienen volúmenes significativos de hielo que son hidrológicamente valiosos, especialmente en regiones áridas y semiáridas, y su relevancia está aumentando debido al calentamiento climático futuro (Jones et al., 2018, 2021).

## **2.8. Glaciares en el Perú**

En el Perú, la Unidad de Glaciología e Hidrología elaboró el primer inventario nacional de glaciares; ver Figura 6 y Tabla 3. Esta oficina pertenece al Instituto de Geología y Minería (INGEOMIN), al Instituto Geológico, Minero y Metalúrgico (INGEMMET) e Hidrandina, y reportó una extensión total de 2 041,85 km<sup>2</sup> de glaciares a nivel nacional (Hidrandina, 1989). El inventario se basó en el análisis de fotografías aéreas tomadas entre 1955 y 1962 de 18 Cordilleras glaciares.

Entre 1997 y 1998, el Instituto Andino de Glaciología y Geoambiente (INAGGA), realizó el segundo inventario de glaciares del Perú por encargo del Consejo Nacional del Ambiente (CONAM). Este estudio abarcó cuencas

seleccionadas de cinco Cordilleras y permitió hacer una proyección para las 18 Cordilleras a nivel nacional, el estudio estimó una superficie glaciaria de 1 595,59 km<sup>2</sup> (Iturregui, 2001).

En 2006, la Autoridad Nacional del Agua (ANA) comenzó el inventario nacional de glaciares y lagunas, el cual incluyó no solo las dieciocho cordilleras glaciares previamente estudiadas, sino también la Cordillera Volcánica, debido a la identificación de lagunas de origen glaciario, determinándose una superficie glaciaria de 1 298,59 km<sup>2</sup>.

En 2017, el Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña (INAIGEM) inició el inventario nacional de glaciares y lagunas de origen glaciario (INGLOG I), utilizando imágenes satelitales Sentinel-2 del 2016, con una resolución de 10 metros. Este inventario abarcó 20 cordilleras, incluyendo la Cordillera del Barroso. Se identificaron 2 259 glaciares, con una extensión total de 1 118,11 km<sup>2</sup>, así como 8 577 lagunas de origen glaciario, con una extensión de 1 022,3 km<sup>2</sup>. Además, se observó una reducción del 54 % en la superficie glaciaria en comparación con el primer inventario del año 1989, equivalente a una pérdida de 1 284,95 km<sup>2</sup> (INAIGEM, 2017).

En el 2023, el INAIGEM, en su inventario nacional de glaciares y lagunas de origen glaciario, ha registrado 2 084 glaciares libres y cubiertos por detritos, con una extensión de 1 050,32 km<sup>2</sup> y un volumen de 26,17 km<sup>3</sup>. Además, identificaron 8 466 lagunas de origen glaciario, que cubren 1 081,31 km<sup>2</sup> y tienen un volumen de

54 898 hm<sup>3</sup>. También se caracterizaron 2 147 glaciares rocosos, con una superficie de 107,49 km<sup>2</sup>. Esta información representa la primera base de datos para la evaluación de los glaciares rocosos en el país, un tipo de glaciar poco estudiado hasta la fecha (Curo Rosales et al., 2023).

**Tabla 3**

*Cantidad y superficie de los glaciares por Cordillera*


N°	Cordillera	Glaciares libre y cubierto por detritos		Glaciares rocosos	
		N° de Glaciares	Superficie (km <sup>2</sup> )	N° de Glaciares	Superficie (km <sup>2</sup> )
1	Blanca	511	424,86	-	-
2	Huallanca	28	4,64	-	-
3	Huayhuash	86	49,63	10	1,31
4	Raura	76	23,73	2	0,09
5	Huagoruncho	35	6,54	-	-
6	La Viuda	45	3,40	19	0,67
7	Central	122	39,61	18	0,68
8	Huaytapallana	90	19,29	-	-
9	Chonta	4	0,37	6	0,15
10	Ampato	48	51,98	186	15,51
11	Vilcabamba	319	94,06	1	0,18
12	Urubamba	95	22,06	2	0,16
13	Huanzo	17	2,31	474	22,11
14	Chila	2	0,07	429	15,76
15	La Raya	20	1,50	9	0,33
16	Vilcanota	380	243,29	58	1,71
17	Carabaya	132	27,89	-	-
18	Apolobamba	74	35,08	4	0,12

19	Barroso	-	-	718	38,78
20	Volcánica	-	-	211	9,92
Total		2 084	1 050,32	2 147	107,49

*Nota.* Inventario nacional de glaciares y lagunas de origen glaciar, tomado de Curo Rosales et al. (2023).

### Figura 6

*Distribución de glaciares en el Perú*



*Nota.* Tomado de Curo Rosales et al. (2023).

Los glaciares peruanos tienen formas únicas debido a su ubicación geográfica y el clima de la región. Al estar cerca del ecuador, estos glaciares son de tipo ecuatorial, y el clima cálido provoca una alta ablación en los ventisqueros, lo que impide que se forme hielo en altitudes más bajas (INAIGEM, 2017).

## **2.9. Humedales altoandinos (bofedales)**

Los humedales altoandinos tropicales, llamados localmente "bofedales", son ecosistemas esenciales que apoyan la biodiversidad, el secuestro de carbono, el suministro de agua y la actividad ganadera (Ross et al., 2023). Estos ecosistemas formadores de turba de gran altitud en los Andes semiáridos almacenan una cantidad significativa de agua, lo que contribuye a la hidrología de la cuenca (Valois et al., 2020), al caudal base de la estación seca, además de regular y almacenar el caudal de agua con una alta variabilidad estacional en su área (Ross et al., 2023). Por lo tanto, los humedales naturales son más vulnerables al cambio climático, lo que pone de relieve la importancia de las prácticas de gestión de cuencas hidrográficas (Shin et al., 2023).

## **2.10. Lagunas glaciares**

Un lago glaciar se describe como un cuerpo de agua natural abastecido principalmente por el deshielo de glaciares contemporáneos o formado en depresiones causadas por morrenas de antiguos glaciares (Yao et al., 2018). Estos lagos son componentes dinámicos del almacenamiento de agua de deshielo

terrestre, y responden tanto al cambio climático como al retroceso de los glaciares (Bazilova & Kääb, 2022). Sin embargo, el rápido crecimiento de los lagos glaciares debido a estos factores no solo contribuye a la acumulación de agua, sino que también aumenta el riesgo de inundaciones repentinas, lo cual plantea serios peligros para las comunidades cercanas (Shugar et al., 2020).

Generalmente, los lagos glaciares se clasifican en dos grupos principales: los lagos en contacto directo con el hielo, que se caracterizan por la presencia de hielo glaciar que llega hasta el agua del lago, y los lagos distales, que se encuentran a cierta distancia del hielo, pero siguen siendo influenciados por la presencia de glaciares o capas de hielo (Fitzsimons & Howarth, 2018).

### **2.11. Teledetección**

El término teledetección proviene de raíces griegas y latinas y hace referencia a la identificación y estudio a distancia de las propiedades de la superficie terrestre (Riart, 1987). Esta palabra es una adaptación del inglés Remote Sensing y se refiere tanto a la adquisición de datos desde el aire o el espacio como a su posterior procesamiento y análisis (Cardozo & Da Silva, 2013). Esta técnica, que comenzó con la fotografía aérea, ha experimentado un notable desarrollo a lo largo de los años (Santana-Rodríguez, 2016).

La teledetección incluye una variedad de tecnologías y métodos, como el uso de satélites, drones y sensores aéreos, para recolectar información sobre la

Tierra y gestionar los recursos naturales (Machireddy, 2023); estos datos pueden aplicarse en múltiples áreas, como la gestión de recursos naturales, la agricultura de precisión, la elaboración de mapas, el monitoreo ambiental y la respuesta a desastres (Huang et al., 2018; Melesse et al., 2007; Sishodia et al., 2020; Verma et al., 2023).

El avance de los sensores y plataformas de teledetección ha posibilitado la obtención de imágenes con una resolución espacial, temporal y espectral superior, lo que ha mejorado notablemente la capacidad de analizar y comprender los fenómenos naturales y antropogénicos (Jiao et al., 2021). Además, el procesamiento y análisis de datos de teledetección incluyen técnicas avanzadas de tratamiento de imágenes, algoritmos de clasificación y modelos predictivos (Li et al., 2018; Sheykhmousa et al., 2020).

### **2.11.1. El Espectro electromagnético**


En la Figura 7 y Tabla 4, el espectro electromagnético abarca todas las frecuencias de radiación electromagnética, desde las ondas de radio y microondas hasta el infrarrojo, la luz visible, el ultravioleta, los rayos X y los rayos gamma (Mandava, 2019; Norgard, 2007), cada tipo de radiación tiene diferentes longitudes de onda y frecuencias, lo que distingue una forma de otra (Elliott, 2000).

La luz visible representa solo una pequeña fracción del espectro electromagnético, comprendida entre de 400 a 780 nm, y es la única parte que los

seres humanos pueden percibir, mientras que el resto del espectro, fuera de este rango, no es visible para el ojo humano (Court, 2012; Palczewski, 2012).

**Figura 7**

*Espectro Electromagnético*



*Nota.* tomado de García et al. (2012).

**Tabla 4**

*Espectro electromagnético con rangos de longitud de onda y frecuencia*

Rango	Longitud de Onda (m)	Frecuencia (Hz)
Radiación Gamma	$<10^{-11}$	$>3 \times 10^{19}$
Radiación X	$10^{-9} - 10^{-11}$	$3 \times 10^{17} - 3 \times 10^{19}$
Radiación Ultravioleta	$4 \times 10^{-7} - 10^{-9}$	$7,5 \times 10^{14} - 3 \times 10^{17}$
Radiación Visible	$7 \times 10^{-7} - 4 \times 10^{-7}$	$4,3 \times 10^{14} - 7,5 \times 10^{14}$
Radiación Infrarroja	$1 \times 10^{-5} - 7 \times 10^{-7}$	$3 \times 10^{12} - 4,3 \times 10^{14}$
Radiación de Microondas	$0,01 - 1 \times 10^{-5}$	$3 \times 10^9 - 3 \times 10^{12}$
Ondas de Radio	$>0,01$	$<3 \times 10^9$


*Nota.* tomado de Sankaran & Ehsani (2014).

### 2.11.2. Firmas espectrales

En la Figura 8 se observa el esquema de una firma espectral también conocido como perfil espectral, la cual es una representación gráfica de la variación de la reflectancia o emisión de un objeto o superficie a lo largo de diferentes longitudes de onda del espectro electromagnético (Lara et al., 2024). Esta firma es única para diferentes materiales y tipos de cobertura terrestre, como vegetación, agua, suelo, y otros (Aldana et al., 2022).

**Figura 8**

*Firmas espectrales*



*Nota.* Curvas típicas de reflectancia espectral del agua, suelo, nieve y vegetación, tomado de Klein et al. (1998).

## 2.12. Misión Landsat

La Figura 9 describe la serie temporal de la misión Landsat, iniciada en 1972, fue pionero de observación de la Tierra y lideró los esfuerzos en los Estados Unidos, como líder en el campo de la teledetección (Goward et al., 2006). Inicialmente llamado, Earth Resources Technology Satellite (ERTS), tenía como objetivo proporcionar imágenes no clasificadas de la Tierra para una variedad de aplicaciones científicas y de gestión de recursos (Hughes, 1992). La historia de la misión está marcada por los avances tecnológicos, con una resolución y una calidad de datos mejoradas en los sucesivos lanzamientos de satélites (Lulla et al., 2021).

En este programa, los satélites de una serie específica se enumeran de manera individual, siguiendo intervalos de tiempo irregulares. El Landsat 1 fue lanzado el 23 de julio de 1971, seguido por los lanzamientos del Landsat 2 en 1975, el Landsat 3 en 1978 y el Landsat 4 en 1982. El Landsat 5 fue lanzado en 1984, proporcionando datos globales de la Tierra durante 28 años y 10 meses, mientras que el Landsat 6 no logró orbitar en 1993. El Landsat 7 fue lanzado con éxito en 1999, luego Landsat 8 fue lanzado en 2013 (Zanter, 2016; Zhu, 2017).


El lanzamiento de Landsat 9 en 2021 celebra 50 años de colaboración entre National Aeronautics and Space Administration (NASA) y el United States Geological Survey (USGS), manteniendo el legado de monitoreo terrestre con

instrumentos mejorados, como el OLI-2 y el TIRS-2 (Lulla et al., 2021; Micijevic et al., 2022).

Las imágenes Landsat son una herramienta valiosa para mapear la capa de nieve y hielo con alta precisión, lo que permite estudiar la dinámica de los glaciares (Rasouli et al., 2022; Zhang & Jiang, 2022). gracias a sus sensores operacionales (OLI) y su sensor infrarrojo térmico (TIRS) que emplean bandas de infrarrojo azul, infrarrojo cercano, infrarrojo de onda corta e infrarrojo térmico (Bhardwaj et al., 2015), Además, la resolución espectral y radiométrica mejorada del Landsat 8 permite estimar las velocidades de la superficie de los glaciares (Sam et al., 2016).

### Figura 9

*Ilustración gráfica de la cronología de la misión Landsat*



*Nota.* Misión Landsat que muestra los satélites lanzados anteriormente desde Landsat-1 a Landsat-9, tomado de USGS, (2024).

### **2.13. Google Earth Engine**

Google Earth Engine (GEE), fue lanzada en el 2010 por (Amani et al., 2020). Google es una plataforma en la nube diseñada para el procesamiento y análisis de datos geoespaciales a escala planetaria (Tamiminia et al., 2020). Además, GEE proporciona acceso a petabytes de imágenes de dominio público, permitiendo a los usuarios analizar y visualizar información sin requerir supercomputadoras ni conocimientos avanzados de programación (Hatakeyama et al., 2022; Tamiminia et al., 2020).


La plataforma GEE, se ha convertido en una herramienta esencial para investigadores de todo el mundo, destacándose las contribuciones de China y Estados Unidos (Vlastegui-Montoya et al., 2023). Su capacidad para gestionar grandes volúmenes de datos y realizar análisis de series temporales lo hace especialmente útil para aplicaciones de teledetección (Zhao et al., 2021). Como plataforma multidisciplinaria, GEE sigue evolucionando, enfrentando desafíos globales en el monitoreo ambiental y el procesamiento de datos geoespaciales (Tamiminia et al., 2020).

GEE proporciona algoritmos de aprendizaje automático y procesamiento paralelo de alta velocidad, compatibles con Application Programming Interface (API) de JavaScript y Python (Montero, 2021; Tamiminia et al., 2020), las principales aplicaciones de GEE, son estudios de vegetación, agricultura,

hidrología, cobertura del suelo, planificación urbana, desastres naturales, atmósfera y análisis climático (Amani et al., 2020). Ver Figura 10.

**Figura 10**

*Aplicaciones Google Earth Engine*



*Nota.* Tomado de Amani et al. (2020).

## 2.14. Índices espectrales

Los índices espectrales son combinaciones matemáticas de bandas espectrales utilizadas en la teledetección para detectar, cuantificar y analizar los

fenómenos del sistema terrestre (Montero et al., 2023; Silva Júnior & Pacheco, 2023; W. Yao et al., 2023). Desempeñan un papel crucial en aplicaciones como el monitoreo de la vegetación, la evaluación de las masas de agua y la evaluación de la cobertura de nieve, entre otros, y cada índice tiene atributos que incluyen la fórmula, las bandas y las plataformas (Montero et al., 2023).

#### **2.14.1. Índice de vegetación de diferencia normalizada**

El índice de diferencia normalizado de vegetación (NDVI) inicialmente propuesto por (Rouse et al., 1974), es un indicador clave derivado de los datos de teledetección, que se utiliza para monitorear la salud y las condiciones de la vegetación (Eisfelder et al., 2023). Este índice emplea los valores de reflectancia de la luz roja y del infrarrojo cercano para cuantificar el verdor de la vegetación (Hameed et al., 2021). El NDVI mide eficazmente la densidad y la salud de la vegetación, con valores que van de -1 a +1, donde los valores más altos indican una vegetación más densa y sana (Martinez & Labib, 2022).

El NDVI es un índice utilizado para la detección de vegetación, con la siguiente ecuación.

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (1)$$

donde NIR es la reflectancia del infrarrojo cercano y el RED es la reflectancia de la luz roja.

### 2.14.2. Índice de diferencia normalizada de nieve

El índice de diferencia normalizado de nieve (NDSI) se documentó por primera vez a mediados de la década de 1970, principalmente a través de investigaciones en el Laboratorio de Geofísica de la Fuerza Aérea (AFGL) (Hall & Riggs, 2010). El NDSI es un índice normalizado que se utiliza para identificar la capa de nieve y su dinámica en los paisajes (Deng et al., 2024; Kollert et al., 2024; Mohammadi et al., 2023). Se obtiene de imágenes de satélite, y desempeña un papel importante en el monitoreo ambiental, la hidrología y los estudios climáticos.

El NDSI es un índice utilizado para la detección de glaciares con la siguiente ecuación.

$$NDSI = \frac{(GREEN - SWIR)}{(GREEN + SWIR)} \quad (2)$$

donde GREEN es la reflectancia de la banda verde y el SWIR es la reflectancia de la banda de infrarrojo de onda corto (Kulkarni et al., 2002).

### 2.14.3. Índice de diferencia normalizada de agua

El índice de agua por diferencia normalizada (NDWI) es un método de teledetección utilizado para delinear cuerpos de agua y evaluar el contenido de agua en la vegetación (McFeeters, 1996). Este enfoque utiliza bandas verdes e infrarrojo cercano para resaltar las características del agua mientras suprime el suelo y la vegetación, siendo efectivo para identificar cuerpos de agua, aunque puede

confundir suelo húmedo y vegetación baja (Pereira et al., 2018). Por otro lado, el NDWI de Gao, que utiliza bandas infrarrojas cercanas e infrarrojas de onda corta para detectar el agua líquida en la vegetación, es menos sensible a los efectos atmosféricos que el NDVI y más eficaz para detectar cambios en el contenido de agua de la vegetación (Gao, 1995; Pereira et al., 2018).

La ecuación propuesta por (McFeeters, 1996) es:

$$NDWI_{(McFeeters)} = \frac{(GREEN - NIR)}{(GREEN + NIR)} \quad (3)$$

La ecuación propuesta por (Gao, 1995) es:

$$NDWI_{(Gao)} = \frac{(NIR - SWIR)}{(NIR + SWIR)} \quad (4)$$

donde GREEN es la reflectancia de la banda verde, NIR es la reflectancia del infrarrojo cercano y el SWIR es la reflectancia de la banda de infrarrojo de onda corto.

#### **2.14.4. Índice de infrarrojo por diferencia normalizada**

El índice infrarrojo de diferencia normalizada (NDII) fue propuesto por (Hardisky et al., 1983), es un índice espectral derivado de la metodología de diferencia normalizada, similar al conocido NDVI, utiliza principalmente en aplicaciones de teledetección para evaluar la salud de la vegetación y el contenido de humedad (Joiner et al., 2018). El NDII es particularmente sensible a los cambios en el contenido de agua en la vegetación, lo que lo convierte en una herramienta

valiosa para monitorear las condiciones ambientales (Hunt & Yilmaz, 2007). Este índice ayuda a evaluar la salud de la vegetación, especialmente en las regiones áridas y semiáridas, donde la disponibilidad de agua es crítica (Joiner et al., 2018).

El NDII es un índice utilizado para la detección de contenido de agua líquida en las copas de la vegetación siguiente ecuación.

$$NDII = \frac{(NIR - SWIR)}{(NIR + SWIR)} \quad (5)$$

donde NIR es la reflectancia de la banda infrarrojo cercano y el SWIR es la reflectancia de la banda de infrarrojo de onda corto (Ji et al., 2011).

### **2.15. Modelado del cambio de cobertura y uso del suelo**

El análisis de los cambios de cobertura y uso del suelo (LULC) en los últimos años es fundamental, ya que facilita la elaboración de estrategias y la toma de decisiones informadas para comprender las causas detrás de las transformaciones en la superficie terrestre (Paegelow et al., 2013). La predicción del LULC es crucial, ya que proporciona escenarios futuros de los posibles cambios, estas predicciones son esenciales para los planificadores y gestores, ya que permiten implementar acciones preventivas frente a los posibles impactos del LULC (Pijanowski et al., 2002).

Se han desarrollado varios modelos para proyectar escenarios futuros del (LULC), como UGM/SLEUTH, RAMCO, LOV, MODULUS, SIMULICA,

MOLUSCE y Land Change Modeler (LCM) (Eastman & Toledano, 2018; Veldkamp & Lambin, 2001; Verburg et al., 2004). Estos modelos se basan principalmente en enfoques basados en autómatas celulares (AC) o métodos estadísticos empíricos (Sardar & Samadder, 2021). No obstante, en los últimos años se han integrado modelos como CA-Markov con redes neuronales artificiales (RNA) para modelar cambios complejos de LULC (Mubako et al., 2022).

### **2.16. Modelos basados en autómatas celulares**

Los autómatas celulares (AC) son algoritmos discretos y deterministas que, mediante reglas simples, pueden generar una amplia variedad de comportamientos, que van desde lo periódico hasta lo caótico (Lazzari & Seriani, 2024; Liu et al., 2020). Por lo tanto, sería interesante poder clasificarlos según su comportamiento, también porque los autómatas celulares son omnipresentes en la ciencia y la tecnología (Lazzari & Seriani, 2024), fue desarrollado por (Von Neumann & Burks, 1966).

Un autómata celular simple "A" es definido por una estructura (células de diferentes formas y dimensiones) "L", un espacio de estado (estado discreto) "Q", un modelo de vecindad (diferentes formatos, influyen en los estados) "δ" y una función de transición local (reglas de transición) "f" (Balzter et al., 1998).


$$A = \langle L, Q, \delta, f \rangle \quad (6)$$

Cada célula de  $L$  puede asumir un estado discreto dentro de  $Q$  y puede vincularse de diversas maneras. En la forma más sencilla, se conectan de manera geométrica siguiendo un orden espacial, como en una cuadrícula unidimensional o bidimensional cuadrada, o en rejillas hexagonales.

Las células pueden cambiar de estado en intervalos de tiempo discretos. Generalmente, los autómatas celulares funcionan de manera síncrona, lo que significa que todas las células actualizan sus estados al mismo tiempo. El estado futuro de una célula depende de sus células vecinas y de la función de transición correspondiente  $f$ . Los modelos de vecindad más comunes para redes cuadradas bidimensionales son la vecindad de Moore, que incluye la célula central y sus ocho células adyacentes, y la vecindad de Von Neumann, que comprende la célula central y sus cuatro células adyacentes (Karamani et al., 2023), como se observa en la Figura 11.

**Figura 11**

*Vecindad de Autómata Celular*



*Nota.* Vecindad Moore (derecha) y vecindad Von Neumann (izquierda). Tomado de Karamani et al. (2023).

La Figura 12 describe que reglas de transición correspondientes pueden ser deterministas o estocásticas. En el ámbito de las aplicaciones a sistemas naturales, las reglas estocásticas suelen ofrecer una mejor representación del comportamiento real del sistema en comparación con las deterministas, aunque a veces puedan presentar un menor valor heurístico (Balzter et al., 1998).


El Juego de la Vida ("Game of Life") de John Conway popularizó el concepto de autómatas celulares (CA). En este juego, el espacio celular está formado por una cuadrícula bidimensional en la que cada célula tiene ocho vecinos (cuatro ortogonales y cuatro diagonales). Las células pueden estar vivas (CV) o muertas (CM), y siguen reglas simples para cambiar de estado (Gardner, 1970).

- $CV < 2$  vecinos vivos mueren por soledad.
- $CV > 3$  vecinos vivos mueren por superpoblación.
- CV con 2 o 3 vecinos vivos permanece viva.
- CM con 3 vecinos vivos revive.

Estas reglas permiten la creación de una gran variedad de patrones dinámicos, demostrando cómo reglas simples pueden generar comportamientos complejos (Almeida, 2003).

**Figura 12**

*Configuración de un patrón específico, cuatro pasos de tiempo, color negro son las células vivas*



*Nota.* Se muestra un ejemplo del autómatas celular, un patrón de cinco células vivas que, tras cuatro pasos, se desplaza una celda hacia arriba y a la derecha. Lo notable es que su comportamiento puede ser descrito sin necesidad de entender las reglas subyacentes, tomado de Almeida, 2003; O'Sullivan (2001).

### **2.17. Módulo para simulaciones de cambio de uso del suelo (MOLUSCE)**

Es un modelo que predice los cambios del uso del suelo pasado, presente y futuro (Gao et al., 2023). Este modelo se basa en una variedad de factores y datos espaciales para simular dinámicas y tendencias de cambio en el paisaje (Muhammad et al., 2022), utiliza datos multitemporales, variables independientes y una metodología Autómatas Celulares-Red Neuronal Artificial (CA-ANN) integrada para simular las transiciones de cambio y los patrones de uso del suelo (Abbas et al., 2021).

## **Capítulo III: Metodología**

### **3.1. Tipo de investigación**

#### **3.1.1. Tipo**

La investigación es aplicada porque busca generar conocimientos orientados a la solución de necesidades prácticas relacionadas con la identificación, clasificación de elementos naturales en un contexto geográfico específico, aportando información relevante para la gestión de recursos y la toma de decisiones ambientales.

#### **3.1.2. Nivel**

El nivel de investigación es descriptivo y predictivo, ya que se centra en la identificación y caracterización de los cambios multitemporales en elementos naturales (glaciares, bofedales, lagunas glaciares), y en predecir comportamientos futuros espaciales mediante la simulación con autómatas celulares.

### **3.2. Diseño de investigación**

El diseño es no experimental, debido a que no se manipulan variables independientes, sino que se analizan datos secundarios obtenidos de imágenes satelitales y se procesan mediante técnicas de teledetección y Sistemas de Información Geográfica (SIG). Este enfoque permite observar y analizar

fenómenos tal como se presentan en su contexto natural, sin intervención directa en el área de estudio.

### **3.3. Población y muestra de estudio**

#### **3.3.1. Población**

La población de estudio corresponde a una porción de la Cordillera del Barroso, conformada por los glaciares, bofedales y lagunas glaciares localizados en la Cordillera del Barroso, departamento de Tacna, la cual incluye las nacientes de las cuencas Caplina y Sama, pertenecientes a la vertiente del Pacífico, y la cuenca Uchusuma, perteneciente a la vertiente del Atlántico.

#### **3.3.2. Muestra**

La muestra está constituida por las coberturas derivadas del procesamiento de imágenes satelitales Landsat correspondientes a los años 1985 y 2022, seleccionadas mediante un muestreo no probabilístico por criterio, considerando únicamente las áreas clasificadas como glaciares, bofedales y lagunas glaciares dentro del ámbito de estudio.

### **3.4. Técnicas e instrumentos de recolección de datos**

El material principal utilizado en este estudio consiste en las imágenes del programa Landsat (Landsat-5 TM y Landsat-8 OLI), con sensores Landsat: Thematic Mapper (TM) y Operational Land Imager (OLI) (Wulder et al., 2016),

Las colecciones de imágenes fueron obtenidas a través de la plataforma Google Earth Engine (<https://earthengine.google.com>), y cubren el período de análisis multianual comprendido entre los años 1985 y 2022.

La Tabla 5 muestra las colecciones de imágenes satelitales al tope de la atmosfera (TOA). Estas imágenes son apropiadas para estudios de reflectancia, ya que representan la radiación reflejada por la superficie terrestre sin interferencias atmosféricas (Teixeira-Pinto et al., 2017), Además, cuentan con ortorrectificación y una resolución espacial de 30 metros en las bandas espectrales (Townshend et al., 2012).

**Tabla 5**

*Imágenes de reflectancia TOA del programa Landsat*

Colección	Sensor	Períodos
LANDSAT/LT05/C02/T1_TOA	TM	1984 - 2012
LANDSAT/LE07/C02/T1_TOA	ETM+	1999 - 2022
LANDSAT/LC08/C02/T1_TOA	OLI/TIRS	2013 - actualidad

*Nota.* Tomado de USGS (2024).

### **3.5. Análisis de datos**

La metodología para la identificación y clasificación de coberturas (glaciares, bofedales y lagunas glaciares) se estructuró en cuatro etapas, empleando un enfoque geoespacial basado en el análisis multitemporal de imágenes satelitales

y técnicas de procesamiento digital en un entorno SIG, como se detalla en la Figura 13.

### **3.5.1. Etapa 1: Recopilación de datos**

En esta etapa se recopiló la información geoespacial necesaria para el análisis multitemporal de la cobertura de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso. Para ello se utilizó la plataforma gratuita de computación en la nube Google Earth Engine (GEE), una herramienta diseñada para el procesamiento y análisis de datos geoespaciales a escala global (Gorelick et al., 2017). GEE permite acceder a grandes volúmenes de datos satelitales preprocesados de manera rápida y eficiente a través de su Interfaz de Programación de Aplicaciones (API), utilizando bibliotecas de cliente en lenguajes como JavaScript y Python (Markert, 2019).

La obtención de imágenes satelitales se enfocó en el periodo comprendido entre los días julianos 135 y 227, correspondiente a la estación seca en la zona de estudio. Esta ventana temporal fue seleccionada estratégicamente para reducir al mínimo la presencia de nubosidad y garantizar la obtención de imágenes de alta calidad. Posteriormente, se aplicó un algoritmo de enmascaramiento para eliminar nubes y sombras, optimizando así la claridad de los datos. Esta etapa culminó con la generación de imágenes compuestas libres de interferencias atmosféricas, que

constituyeron la base para el cálculo de índices espectrales y la posterior identificación y clasificación de las coberturas de interés.

### **3.5.2. Etapa 2: Clasificación de coberturas (LULC) mediante técnicas de teledetección**

Se utilizó métodos basados en umbrales de índices normalizados, los cuales pueden ser calculados directamente a partir de imágenes satelitales históricas y, al aplicar un umbral adecuado, permiten discriminar coberturas generales como bofedales, agua y glaciares de forma rápida y replicable en múltiples fechas. Esta metodología fue aplicada en la plataforma de Google Earth Engine y ArcGIS para el procesamiento y visualización de la información geoespacial.

### **3.5.3. Etapa 3: Validación e interpretación**

El proceso de validación se llevó a cabo en el software QGIS utilizando el complemento AcATaMa para la evaluación de precisión de cada mapa representativo. Se seleccionaron puntos de validación utilizando un enfoque de muestreo híbrido, que combina un 50 % de muestreo aleatorio y un 50 % de muestreo estratificado. Esta estrategia garantiza una distribución equilibrada: la mitad de los puntos se ubican aleatoriamente sobre la imagen clasificada, mientras que la otra mitad se distribuye proporcionalmente entre las diferentes clases de cobertura presentes. La validación de estos puntos se realizó mediante inspección visual, utilizando imágenes satelitales correspondientes a la misma fecha del

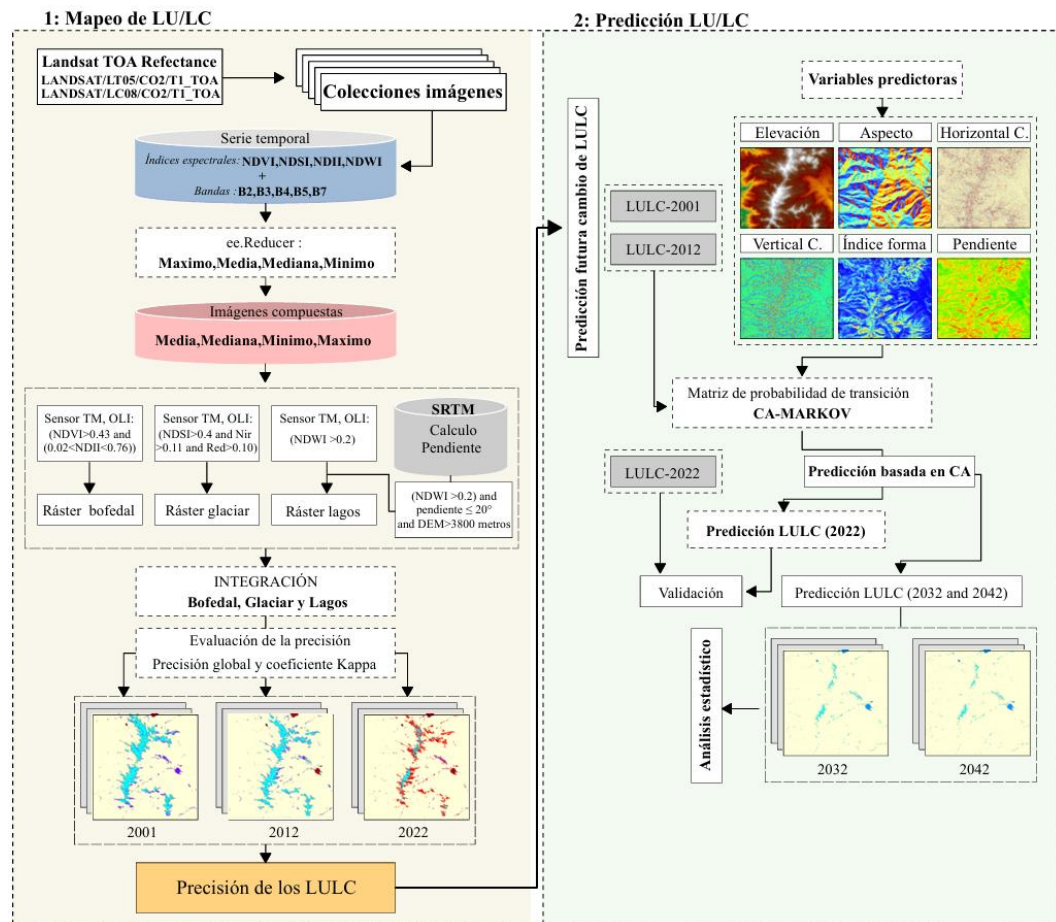
análisis. Con base en estos puntos, se elaboró una matriz de confusión a partir de la cual se calcularon métricas de precisión. El tamaño de muestra fue calculado para un nivel de confianza del 95 %, lo cual permite estimar la incertidumbre de la clasificación dentro de un margen de error aceptable. Estas métricas permitieron cuantificar tanto la fiabilidad del modelo como la incertidumbre inherente a la clasificación.

#### **3.5.4. Etapa 4: Modelado de escenarios futuros (LULC) mediante autómatas celulares (CA-Markov)**

En esta etapa se desarrolló el modelo predictivo de cambios en el uso y cobertura del suelo (LULC) utilizando la técnica combinada de cadenas de Markov y Autómatas Celulares (CA-Markov), implementada en el complemento MOLUSCE (Modules for Land Use Change Simulations) del software QGIS. Este enfoque permitió simular la evolución espacial y temporal de los patrones de cambio, considerando tanto las probabilidades de transición entre clases de cobertura como la influencia espacial de los parches existentes. Para fortalecer la predicción, se incorporaron variables topográficas predictoras relevantes tales como altitud, pendiente, aspecto, curvatura horizontal, curvatura vertical e índice de forma las cuales condicionan la dinámica de cambio en la cobertura del suelo.

Figura 13

Diagrama de flujo



Nota. Flujograma de la metodología usada, modificado de Turpo Cayo (2018).

## Capítulo IV: Mapeo de glaciares, bofedales y lagunas mediante análisis satelital y evaluación de precisión

### 4.1. Identificación de glaciares

La identificación de glaciares en el área de estudio permitió delimitar las superficies cubiertas por hielo de manera precisa, distinguiendo aquellas con mínima o nula presencia de detritos superficiales. Los resultados evidencian la distribución espacial de los glaciares limpios, que constituyen la mayor parte de las masas glaciares en la región, mientras que los glaciares con cobertura significativa de escombros representan un porcentaje muy reducido (alrededor del 5,4 % en zonas tropicales (Herreid & Pellicciotti, 2020)).

#### 4.1.1. Cálculo del índice de nieve de diferencia normalizada

El índice (NDSI) se utiliza para identificar la nieve en comparación con otras características de cobertura y estimar el área cubierta de nieve en imágenes satelitales (Salomonson & Appel, 2004). De esta manera, también se puede emplear para identificar la cobertura glaciaria. El índice NDSI fue calculado previamente seccionada y enmascarada; se aplicó la ecuación (6).

$$NDSI = \frac{(GREEN - SWIR)}{(GREEN + SWIR)} \quad (7)$$

donde GREEN es la reflectancia de la banda verde y el SWIR es la reflectancia de la banda de infrarrojo de onda corta.

Para la clasificación anual de glaciares se utilizó un árbol de decisión con un umbral del NDSI  $> 0,4$ . Con el fin de optimizar la detección y reducir los falsos positivos, se aplicaron criterios adicionales utilizando bandas espectrales, seleccionando únicamente aquellos píxeles con una reflectancia mayor a 0,11 en el infrarrojo cercano (NIR) y mayor a 0,10 en la banda roja (RED)(Turpo Cayo et al., 2022).

#### **4.2. Identificación de lagunas**

El método de extracción basado en NDWI extrae agua de forma completa y precisa de las imágenes de teledetección, con un rendimiento superior en comparación con otros métodos (Qiao et al., 2012), ofreciendo una evaluación más precisa de la disponibilidad de agua (Gao, 1996). El índice NDWI fue calculado previamente seccionada y enmascarada, se aplicó la ecuación (8).

$$NDWI_{(McFeeters)} = \frac{(GREEN - NIR)}{(GREEN + NIR)} \quad (8)$$

La Cordillera Occidental genera sombras en las imágenes satelitales debido a sus terrenos montañosos y bajos ángulos solares, especialmente fuera del verano. Se utilizó la modelización del terreno para identificar áreas en escenas Landsat afectadas por sombras, lo cual complica la detección de cuerpos de agua en el índice NDWI.

Los modelos digitales de elevación (DEM) son esenciales para calcular el ángulo de incidencia solar y la sombra producida por el relieve (Corripio, 2003). En este análisis, se empleó el DEM SRTM (Shuttle Radar Topography Mission) con una resolución de 1 segundo de arco equivalente a 30 metros de resolución espacial (Farr et al., 2007).

Para obtener el ráster de lagos, se clasificó el índice NDWI con el umbral  $NDWI > 0,2$  y se aplicaron restricciones adicionales con el fin de mejorar la precisión de la delimitación y excluir áreas sombreadas, seleccionando únicamente aquellos píxeles con pendientes  $\leq 20$  grados y elevaciones  $> 3\ 800$  metros sobre el nivel del mar. Lo que permitió reducir falsos positivos en regiones de alta complejidad geomorfológica.

#### **4.3. Identificación de bofedales**

La clasificación de los bofedales se llevó a cabo utilizando dos índices normalizados. El NDVI se utiliza para mapear y monitorear humedales, y para clasificar vegetación y otros contenidos presentes dentro de los límites de los humedales (Ashok et al., 2021; Kaplan & Avdan, 2017; White et al., 2016). El segundo índice infrarrojo de diferencia normalizada NDII, se emplea para identificar la humedad del suelo y la vegetación, permitiendo una evaluación más precisa de las áreas húmedas y secas dentro de los humedales (Hunt & Yilmaz, 2007; Sriwongsitanon et al., 2016; Xu et al., 2020).

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (9)$$

$$NDII = \frac{(NIR - SWIR)}{(NIR + SWIR)} \quad (10)$$

donde NIR es la reflectancia del infrarrojo cercano, el RED es la reflectancia de la banda roja y SWIR es la reflectancia de la banda de infrarrojo de onda corta.

Además de los índices NDVI y NDII, la clasificación de los bofedales se refinó utilizando datos de elevación, cobertura del suelo y pendiente. Se utilizó el modelo digital de elevación SRTM para obtener información sobre la altitud, considerando áreas situadas por encima de los 3 800 metros sobre nivel del mar.

Para obtener el ráster de bofedales, se clasificaron dos índices NDVI y NDII con los siguientes umbrales  $NDVI > 0,43$  y  $0,02 < NDII < 0,76$  (Garcia & Willems, 2015)

#### **4.4. Tamaño de muestra**

El procedimiento para determinar el tamaño de la muestra para variables continuas se utilizó la fórmula propuesta por (Cochran, 1977), incluida la fórmula para ajustar la corrección el tamaño de la muestra supera el 5% de la población.

$$n = \frac{Z^2 p(1 - p)}{e^2} \quad (11)$$

Donde:

Z, es el valor correspondiente al nivel de confianza (1.96 para el 95 %).

P, es la proporción esperada de la población

e, es el margen de error (0.05 para un margen del 5 %).

Ajuste para poblaciones finitas

$$n_{ajustado} = \frac{n}{1 + \left(\frac{n-1}{N}\right)} \quad (12)$$

Donde:

n, es el tamaño de muestra calculado.

N, es el tamaño de la población.

#### 4.4.1. Métricas de validación

Los mapas de uso del suelo obtenidos mediante la clasificación de imágenes a menudo presentan ciertos errores (Adam et al., 2014). Por esta razón, resulta fundamental evaluar la exactitud de los resultados de clasificación obtenidos (Li et al., 2021). La matriz de error/confusión en la evaluación de la precisión de la clasificación se basa en el acuerdo general, las precisiones del usuario y del productor, así como en nuevas medidas a nivel de categoría, como el desacuerdo en la cantidad y el desacuerdo en la asignación (Warrens, 2015). Las métricas empleadas fueron las siguientes ecuaciones (13-16) (Llactayo et al., 2013; Olofsson et al., 2014). Ver Tabla 6.

**Tabla 6***Matriz de confusión binaria*

Clase	Clasificación predicción		Total	Error de omisión
	1	2		
<b>1</b>	TP	FN	$T_{f1}=TP+FN$	$1 - (TP/T_{f1})$
<b>2</b>	FP	TN	$T_{f2}=FP+TN$	$1-(TN/T_{f2})$
<b>Total</b>	$T_{c1}=TP+FP$	$T_{c2}=FN+TN$		
<b>Error de comisión</b>	$1-(TP/ T_{c1})$	$1-(TN/ T_{c2})$		

*Nota.* Modificado de Turpo Cayo et al. (2022).

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} = P_0 \quad (13)$$

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Sensibilidad = \frac{TP}{TP + FN} \quad (15)$$

$$Indice Kappa = \frac{P_0 - P_E}{1 - P_E} \quad (16)$$

La Tabla 7 muestra valores del Índice kappa es considerada la medida más apropiada para evaluar la precisión de los mapas LUCC, debido a su capacidad para discriminar entre clases de manera más efectiva que la precisión general (Li et al., 2021).

**Tabla 7***Valores de coeficiente Kappa*

<b>Coeficiente de Kappa (K)</b>	<b>Fuerza de concordancia</b>
< 0.00	Pobre
0.00 – 0.20	Leve
0.21 – 0.40	Aceptable
0.41 – 0.60	Moderado
0.61 – 0.80	Considerable
0.81 – 1.00	Casi perfecta

*Nota:* tomado de Landis & Koch (1977).

## **Capítulo V: Resultados**

Los gráficos y mapas que representan los cambios multianuales en áreas glaciales fueron desarrollados a partir de los análisis realizados con la API de Google Earth Engine (GEE) en su plataforma de codificación. En el proceso, se aplicaron valores umbrales a distintos índices normalizados (NDSI, NDVI, NDWI, NDII) y se utilizaron algoritmos especializados para eliminar interferencias como nubes, sombras de nubes y sombras topográficas. A partir de la colección de imágenes Landsat (TM, ETM+ y OLI), se generaron composiciones medianas por año, enfocándose en la estación seca, durante el periodo 1984-2022. La revisión visual de los resultados y la clasificación de elementos como glaciares, bofedales y lagos mostraron un desempeño eficiente de los algoritmos en la Cordillera del Barroso.

### **5.1. Resultados del primer objetivo**

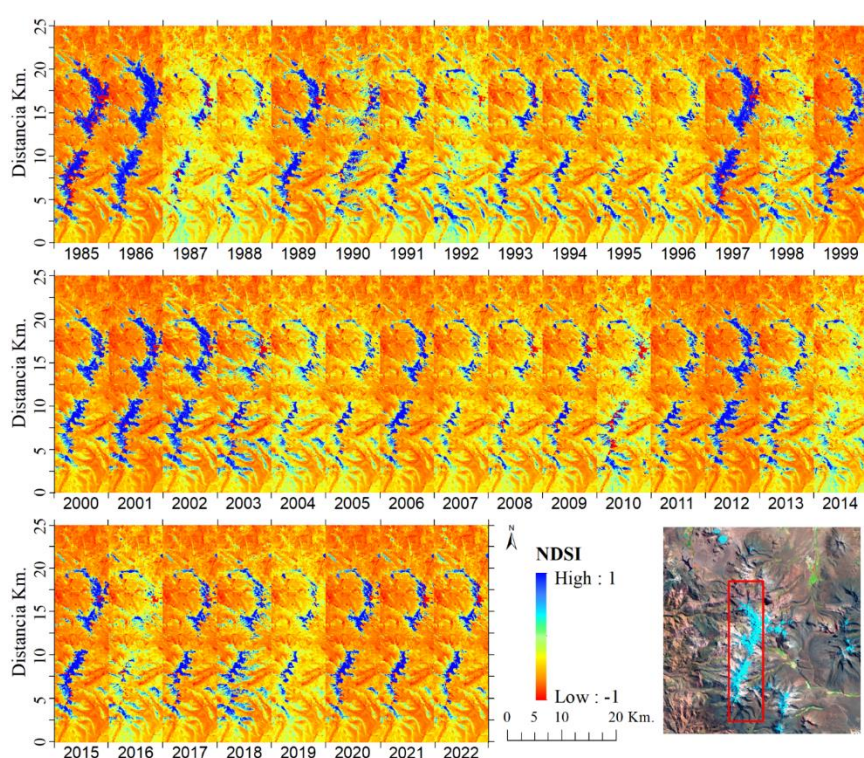
#### **5.1.1. Clasificación de series temporales**

La Figura 14 ilustra la serie temporal del índice NDSI y revela una mayor prevalencia de valores elevados en los años 1985, 1986, 1989, 1997, 2000, 2001, 2002 y 2012, lo que indica una mayor cobertura de nieve en dichos períodos. En contraste, en los demás años predominan los valores bajos, reflejando una menor cobertura de nieve. La variabilidad interanual evidencia que factores climáticos,

como la temperatura y las precipitaciones invernales, ejercen una influencia determinante sobre la cobertura y la altitud de la línea de nieve (Aranda et al., 2023).

**Figura 14**

*Visualización temporal del Índice Diferenciado Normalizado de Nieve (NDSI)*




*Nota.* Serie temporal multianual NDSI entre los años 1985 - 2022. Fuente: Propia.

La Figura 15 representa los diagramas de caja correspondientes a las series temporales del índice NDSI, los cuales permiten visualizar las características estadísticas de la cobertura de nieve a lo largo del tiempo. Se observa que los años con menor cobertura de nieve son 1992, 1998, 2014 y 2016, registrando una

mediana menor de 0,54 en cada caso. Estos resultados indican una disminución significativa en la cobertura de nieve durante estos periodos específicos.

**Figura 15**

*Diagrama de caja Índice Diferenciado Normalizado de Nieve (NDSI)*

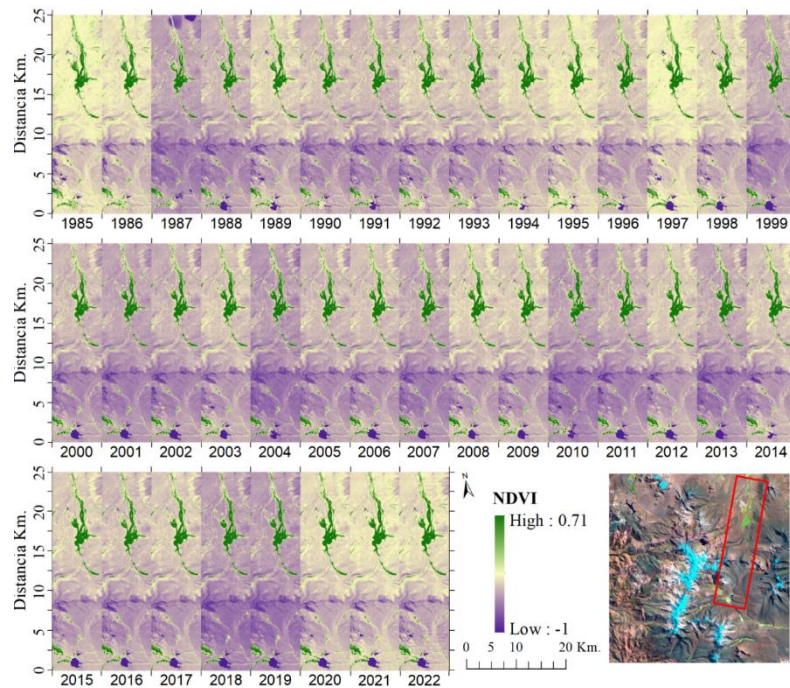


*Nota.* Estadísticos multianual del índice NDSI de la cobertura de glaciar. Fuente: Propia.

La Figura 16 representa la serie temporal del índice NDVI, cuyo rango de valor oscilan entre -1 y 0,71. Los Colores más verdes indican mayor densidad de vegetación, mientras que los colores púrpuras o amarillos representan menor vegetación o áreas sin cobertura vegetal. A lo largo de las series multianuales no se pueden identificar con claridad los patrones de pérdida o ganancia de vegetación, por ello se recurre al análisis de los diagramas de cajas (véase Figura 17).

**Figura 16**

*Visualización temporal del Índice de Vegetación de Diferencia Normalizada (NDVI)*




*Nota.* Serie temporal multianual NDVI entre los años 1985 - 2022. Fuente: Propia.

La Figura 17 describe un incremento gradual en el NDVI promedio a lo largo del período, lo que podría interpretarse como una mejora general en la densidad de vegetación o en las condiciones ecológicas de la región. En años recientes (a partir de 2000), las cajas son más altas y se encuentran desplazadas hacia valores superiores de NDVI. Asimismo, los bigotes muestran valores de mediana relativamente bajos en los años 1991 y 1992, lo que evidencia una correlación con el índice NDSI, y sugiere posibles condiciones desfavorables

(sequías, deforestación u otros eventos), así como fluctuaciones locales o eventos extremos que afectaron la cobertura vegetal.

**Figura 17**

*Diagrama de caja del Índice de Vegetación de Diferencia Normalizada (NDVI)*




*Nota.* Estadísticos multianual del índice NDVI de la cobertura de bofedales.

Fuente: Propia.

### 5.1.2. Reflectancia en superficies naturales

Se seleccionaron 250 puntos de manera aleatoria dentro de las capas correspondientes a glaciar, bofedal y cuerpos de agua con el propósito de extraer las reflectancias asociadas a cada tipo de cobertura. Posteriormente, se generaron gráficos de perfiles espectrales para analizar y contrastar la calidad de los píxeles en cada cobertura, ver Figura 18.

**Figura 18***Puntos aleatorios de muestreo*

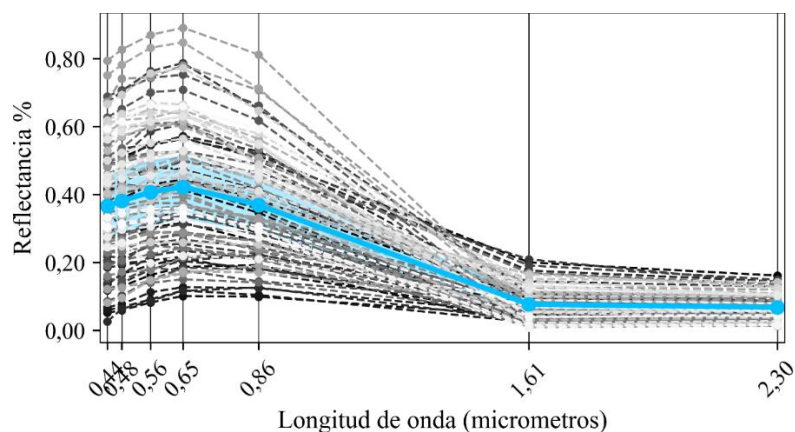
*Nota.* Los puntos de color celeste de glaciares, verdes de bofedales y azul de cuerpos de agua. Fuente: Propia.

La Figura 19 representa la relación entre la reflectancia (%) y la longitud de onda micrómetros ( $\mu\text{m}$ ) del hielo, destacando cómo varía bajo diferentes condiciones o escenarios. Se observa un pico de reflectancia en el rango del espectro visible (aproximadamente entre 0,45 y 0,67  $\mu\text{m}$ ), característico del hielo limpio y puro, donde se refleja una alta proporción de la luz incidente. Esta elevada reflectancia en el rango visible es responsable de la apariencia brillante y blanca del hielo, debido a la eficiencia con la que su superficie dispersa la luz (Xie et al., 2006).

En el rango del infrarrojo cercano (aproximadamente de 0,67 a 1,65  $\mu\text{m}$ ), el hielo absorbe más luz, lo que resulta en una menor reflectancia. Estos picos pueden estar relacionados con la presencia de burbujas de aire, impurezas o variaciones en la estructura cristalina (Guy-Preis et al., 2019).

### Figura 19

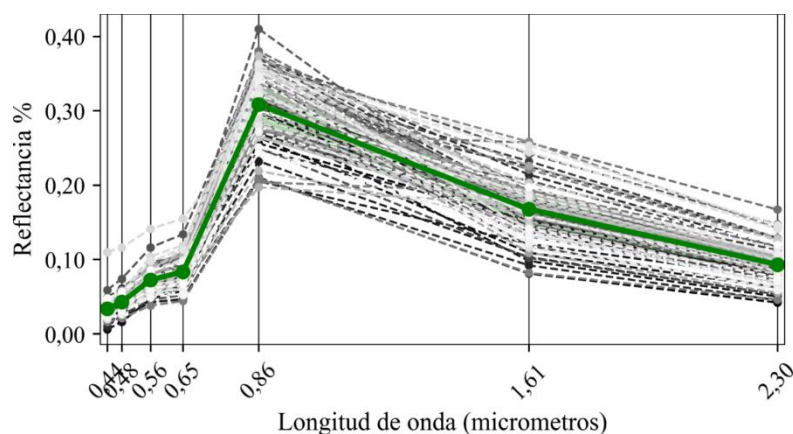
*Espectro de reflectancia de hielo*



Nota. Firma espectral extraída de los 100 puntos aleatorios de la cobertura de hielo.

Fuente: Propia.

La Figura 20 representa la vegetación de la cobertura bofedal, en el rango visible (0,45 – 0,67  $\mu\text{m}$ ) la reflectancia de la vegetación es baja debido a la absorción de la luz por los pigmentos, principalmente la clorofila (Knipling, 1970). El Pico verde aproximadamente 0,56  $\mu\text{m}$ . La vegetación refleja más luz en la banda verde, lo que le da su color característico.

**Figura 20***Espectro de reflectancia de la vegetación*


Nota. Firma espectral extraída de los 100 puntos aleatorios de la cobertura de bofedal. Fuente: Propia.

En el infrarrojo cercano 0,7 a 1,65  $\mu\text{m}$ . En esta región, la reflectancia es alta debido a la estructura interna de las hojas (mesófilo esponjoso), que dispersa la luz. Este comportamiento es una de las características más distintivas de la vegetación sana (Pamuji et al., 2023). La reflectancia en la longitud de onda 1,65 a 2,5  $\mu\text{m}$  disminuye debido a la absorción de agua contenida en las hojas.

Las variaciones entre las curvas pueden interpretarse como diferencias en la densidad foliar, contenido de clorofila, estrés hídrico, la curva verde representa el comportamiento espectral promedio de la vegetación en las distintas longitudes de onda, facilitando la comparación entre las muestras.

**Figura 21**

*Perdida de cobertura de glaciares en la Cordillera del Barroso*



*Nota.* Series multianuales de retroceso glaciar en la Cordillera del Barroso. Fuente: Propia.

La Figura 21 ilustra los mapas multitemporales de la Cordillera del Barroso entre 1986 y 2022, los cuales muestran un retroceso sostenido de la cobertura glaciar, que en 1986 ocupaba una extensión considerable y ha ido disminuyendo progresivamente en las décadas posteriores, alcanzando su mínima expresión en 2022. Este proceso ha dado lugar a la formación de nuevos cuerpos de agua en algunos sectores, lo que evidencia la aparición de lagunas de origen glaciar producto del deshielo, aunque su crecimiento ha sido localizado. En cuanto a los bofedales, estos se mantienen relativamente estables a lo largo del tiempo, con una ligera tendencia a la expansión en años recientes, probablemente como resultado de la redistribución hídrica asociada a la pérdida de masa glaciar. En conjunto, la dinámica observada refleja un cambio significativo en la cobertura de la alta montaña, caracterizado por la reducción de glaciares y la presencia creciente de bofedales y cuerpos de agua, lo que evidencia la influencia del cambio climático en los ecosistemas altoandinos de Tacna.

### **5.1.3. Exactitud de las metodologías en mapeo de coberturas**


La validación de los mapas anuales de glaciares, lagos de origen glaciar y bofedales a lo largo de los años de estudio (1986, 2001, 2012, 2018 y 2022) se muestra en el Anexo 4; se consideró un muestreo aleatorio de 384 puntos en el área de estudio, tomando en cuenta un nivel de confianza del 95 %, una distribución normal ( $Z = 1.96$ ), una proporción de aciertos ( $p = 95 \%$ ) y un error máximo tolerable ( $e = 1.4 \%$ ). La revisión de cada punto fue realizada con el software QGIS

y el plugin de evaluación de exactitud de mapas temáticos AcATaMa (Mas et al., 2014), a partir de la cual se generó la matriz de error.

El 50 % de los puntos aleatorios se seleccionaron dentro de la capa de referencia de glaciares, lagos y bofedales. La otra mitad de los puntos se seleccionó dentro del área total de estudio. Este enfoque se adoptó con el objetivo de equilibrar las muestras de validación de los mapas anuales, como se muestra en la Figura 22.

### Figura 22

*Visualización de puntos sorteados aleatoriamente*




*Nota.* 384 puntos aleatorios para validación de mapas anuales de cobertura de glaciar, lagos y bofedales. Fuente: Propia.

La Figura 23 representa la exactitud temática de los mapas anuales generados, mostró buenas concordancias entre los mapas clasificados de cada año y las imágenes de referencia utilizadas. La clase de glaciar y bofedal reportaron los

valores más bajos de exactitud de usuario de 0,78 y 0,80 para el año del 2001, respectivamente.

**Figura 23**

*Precisión usuario de los mapas multianuales*




*Nota.* Precisión de mapas de cobertura de exactitud de usuario. Fuente: Propia.

Por otro lado, en la Figura 24 describe los valores más bajos de exactitud de productor se reportaron en la clase de agua y glaciar con 0,78 y 0,80 para el año 2001 y en la clase de glaciar con 0,80 para el año 2022.

**Figura 24**

*Precisión productor de los mapas multianuales*




*Nota.* Precisión de mapas de cobertura de exactitud de productor. Fuente: Propia.

La Figura 25 describe el índice de Kappa con valores superiores al 0,83 de precisión, según (Llactayo et al., 2013), estos valores representan resultados casi perfectos. A su vez la OA reportaron valores superiores al 0,87, siendo estos considerados como aceptables.

**Figura 25**

*Índice Kappa de los mapas multianuales*




*Nota.* Precisión general e índice Kappa de mapas multianuales. Fuente: Propia.

## 5.2. Resultados del segundo objetivo

### 5.2.1. Transformaciones históricas de cobertura glaciar, lagos y bofedales

La Figura 26 describe cómo han cambiado diferentes variables relacionadas con el área a lo largo del tiempo en los glaciares, lagos y bofedales. Las líneas de regresión ayudan a visualizar la tendencia de los datos, mientras que las bandas de confianza del 95 % indican la variabilidad y la certeza de estas tendencias. Los datos muestran una tendencia negativa en el caso de los glaciares y una tendencia positiva en los bofedales y lagunas de origen glaciar.

**Figura 26***Regresión de deming de clases de coberturas*

*Nota.* (a) Regresión de cobertura glaciara, (b) regresión de cobertura de lagos y (c) regresión de cobertura de bofedales del área de estudio. Fuente: Propia.

La Figura 27 describe el área cubierta por glaciares mediante una tendencia polinómica compleja que indica variaciones en la superficie a lo largo del tiempo. A partir de las fluctuaciones y la forma de la curva, se observa que hubo períodos de disminución y aumento en la superficie glaciara, pero se mantiene una tendencia negativa.

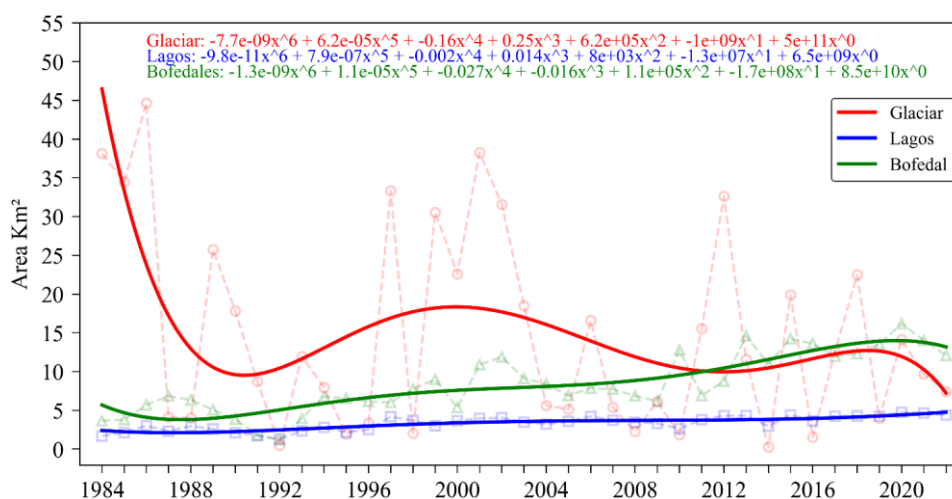
En el área cubierta por lagos, se observa una tendencia fluctuante en la superficie de los lagos, con una ligera disminución en algunos períodos, pero

también mantiene una tendencia positiva. En el caso de los bofedales, al igual que en los glaciares, los bofedales también muestran una variabilidad considerable en su área a lo largo del tiempo, manteniendo una tendencia positiva.

Estudios multitemporales realizados por otros investigadores en la Cordillera Blanca, indican que la reducción de los glaciares contribuye al incremento del nivel de agua en los bofedales, lo que podría estar generando su expansión (Polk et al., 2017). Por ello, se podría afirmar que existe una correlación inversa entre el retroceso glacial y el aumento de cobertura de bofedal.

**Figura 27**

*Evolución temporal de coberturas*




*Nota.* Las ecuaciones polinómicas de sexto grado proporcionan una mejor representación de las tendencias complejas y no lineales observadas. Fuente: Propia.

La Figura 28 resume la superficie de las clases de cobertura para los años de estudio (1986, 2001, 2012, 2018 y 2022). El análisis espacio temporal muestra que la clase de glaciar disminuyó progresivamente en los últimos 36 años de 44,7 km<sup>2</sup> en el año 1986 a 7,4 km<sup>2</sup> en el año 2022 haciendo un total de 6,4 km<sup>2</sup> de pérdida de su superficie, este dato subraya la significativa disminución de los glaciares. La superficie de los cuerpos de agua (lagos) aumentó aproximadamente de 3 km<sup>2</sup> a 4,4 km<sup>2</sup> haciendo un total de 1,4 km<sup>2</sup> entre 1986 y 2022, esto indica una expansión de la superficie de los lagos en ese período, este aumento puede deberse a varios factores, incluyendo cambios en los patrones de precipitación, y otras influencias ambientales.

**Figura 28**

*Superficie de cobertura multitemporal*



*Nota.* Variaciones de áreas multitemporales de coberturas de uso de suelo. Fuente: Propia.

La superficie de los bofedales aumentó aproximadamente de 5,7 km<sup>2</sup> a 12,1 km<sup>2</sup>, lo que representa un incremento de 6,4 km<sup>2</sup> entre 1986 y 2022. Este significativo incremento podría estar relacionado con la acelerada pérdida de cobertura glaciar, así como con diversos factores ambientales, tales como cambios en los patrones de precipitación.

La Figura 29 describe la distribución de la frecuencia absoluta de elevaciones en metros sobre el nivel del mar (m s. n. m.) para la cobertura glaciar en distintos años (1986, 2001, 2012, 2018 y 2022). En el año 1986, se observa una concentración significativa de elevaciones en los rangos entre 4950 m s. n. m. y 5750 m s. n. m., lo que podría indicar estabilidad glaciar en esos niveles de altitud. La frecuencia más alta sugiere que estas elevaciones eran predominantes.

En el año 2001, se observa una reducción en la superficie glaciar, con valores de píxeles menores en comparación con el año 1986, lo que sugiere el inicio de una tendencia de pérdida glaciar. A pesar de esta disminución, las elevaciones predominantes de la cobertura glaciar se mantuvieron similares a las de 1986.

Para el año 2012, la pérdida glaciar se vuelve más pronunciada, evidenciándose la completa desaparición de la cobertura glaciar en elevaciones de 4950 m s. n. m., con un ascenso en la cota mínima de presencia de hielo hasta los 5000 m s. n. m. Este periodo presenta una reducción aproximada de 50 metros en la elevación.

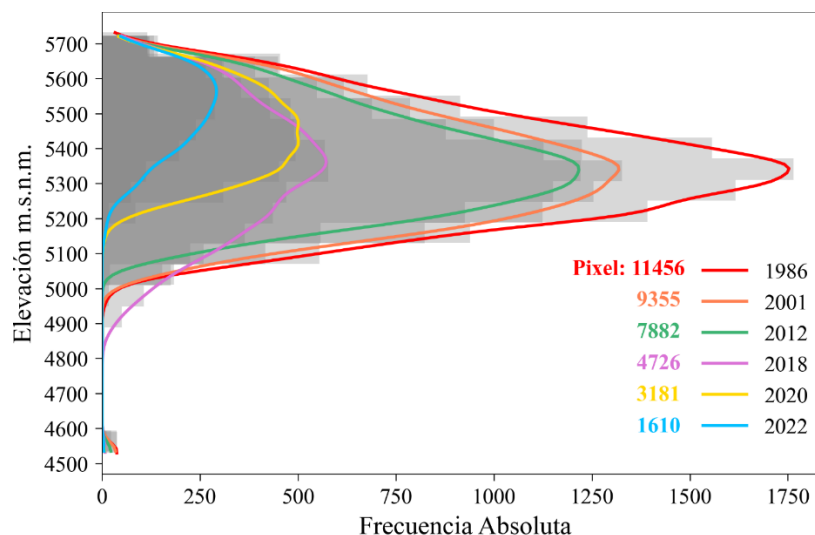
En 2018, la pérdida de superficie glaciar se aceleró considerablemente, evidenciándose una reducción notable en los píxeles en comparación con los años anteriores. No obstante, aún se observa una masa de cobertura de hielo a elevaciones inferiores a los 4900 m s. n. m. Este fenómeno podría estar influenciado por diversos factores climáticos recientes, como las variaciones en las temperaturas globales y los cambios en los patrones de precipitación, los cuales impactan directamente en la acumulación y el derretimiento de la masa glaciar.

La curva correspondiente al año 2022 revela una tendencia alarmante en el contexto general de la pérdida de cobertura glaciar. Esta curva se destaca en el gráfico debido a su frecuencia absoluta considerablemente menor en comparación con los años anteriores, lo que indica una reducción significativa en la extensión glaciar. Además, las elevaciones inferiores alcanzaron los 5150 m s. n. m., lo que representa una disminución aproximada de 200 metros en comparación con los valores registrados en 1986.

La reducción de la superficie glaciar es más pronunciada en las elevaciones más bajas, lo que sugiere que las áreas glaciares situadas a menores altitudes son las primeras en ser afectadas por el calentamiento y el derretimiento (Cao et al., 2019; Ganyushkin et al., 2023; Thompson et al., 2021). Esta tendencia refleja el impacto significativo del cambio climático y subraya la importancia de monitorear y analizar estos cambios para comprender mejor los procesos naturales y antropogénicos que afectan el paisaje.


**Figura 29**

*Cambio de cobertura de glaciares en altitudes*



*Nota.* Pérdida de área de los glaciares con el aumento de la altitud. Fuente: Propia.

La Figura 30 describe cómo se distribuyen los píxeles según su orientación (aspecto) en grados. El aspecto está dividido en intervalos de 22,5 grados, que corresponden a diferentes direcciones: Norte, Noreste, Este, Sureste, Sur, Suroeste, Oeste y Noroeste. En los histogramas se observa que la mayor cantidad de píxeles con pérdida glaciaria se concentra en orientaciones este, noroeste y sureste, lo que indica que estas laderas son más vulnerables al retroceso de glaciares debido a su mayor exposición a la radiación solar directa en las primeras horas del día. En contraste, las orientaciones oeste presentan una menor pérdida relativa, lo que sugiere que la menor radiación incidente y las condiciones más frías favorecen la persistencia del hielo en esas zonas.

**Figura 30***Pérdida multianual de cobertura glaciar en orientaciones*

Nota. Evolución de la pérdida de cobertura de área glaciar (a, b, c, d, e y f) (1986, 2001, 2012, 2018, 2020 y 2022). En diferentes orientaciones de paisaje. Fuente: Propia.


La Figura 31 presenta la disminución del área glaciar en función de las orientaciones polares. El análisis correspondiente al año 1986 muestra que la cobertura glaciar era insignificante en las orientaciones norte y este, mientras que en las orientaciones sur y oeste se registraba una mayor acumulación, alcanzando un total de 44,7 km<sup>2</sup>.

Para el año 2001, se evidenció un retroceso acelerado, con una reducción del 6,4 km<sup>2</sup> en la superficie glaciar en comparación con 1986. Este retroceso fue total en las orientaciones norte y leve en la orientación este. En los años posteriores,

la pérdida de superficie glaciaria continuó de manera gradual, alcanzando 5.7 km<sup>2</sup> de disminución total para el año 2012.

**Figura 31**

*Diagrama polar*



*Nota.* Evolución de la pérdida de cobertura glaciaria según sus orientaciones polares.

Fuente: Propia.

El análisis del año 2018 reveló un retroceso mucho más acelerado, con una pérdida de 10,1 km<sup>2</sup> en comparación con 2012. En este periodo, los glaciares desaparecieron completamente en las orientaciones oeste, concentrándose únicamente en la orientación sur.

Finalmente, para el año 2022, se observó una pérdida drástica de 15,1 km<sup>2</sup> de la superficie glaciaria en comparación con 2018, con la desaparición total en todas las orientaciones, quedando únicamente remanentes puntuales en la orientación sur.

En términos generales, la cobertura glaciar ha experimentado una disminución drástica en su extensión desde 1986 hasta 2022. Las orientaciones norte y este han registrado una pérdida total de cobertura, mientras que en las orientaciones sur y oeste persisten acumulaciones residuales de hielo.


La Figura 32 describe la superficie de ganancia y pérdida por cobertura según datos históricos, y revela que, en los periodos 1986-2001, la superficie de la clase bofedales (BO) mantuvo el mayor cambio neto (92,04 %), seguido por los cuerpos de agua (CA) (30,96 %) y glaciar (GL) (14,42 %), con ganancias de 106,29 %, 38,91 % y 16,63 %, respectivamente.

En el segundo periodo (2001-2012), el mayor cambio neto se dio en la clase BO (19,52 %), GL (15,18 %) y CA (8,13 %), con ganancias de 11,80 %, 11,11 % y 7,67 %, respectivamente. En el tercer periodo (2012-2022), las clases GL y BO reportaron los mayores cambios netos, con 77,17 % y 39,15 %, y las ganancias fueron 0,37 % y 55,96 %.

En el primer periodo, las clases GL, BO y CA reportaron pérdidas en sus superficies entre 7,95 % y 31,05 %. Esto podría estar relacionado con el cambio climático y con el hecho de encontrarse en una zona árida con una precipitación anual acumulada de 400 mm (Rau et al., 2017). En el segundo y tercer periodo, los patrones se repiten en las clases GL, con pérdidas de superficies de hasta 77,54 %. Para el caso de los CA y BO, esto podría estar relacionado con la dinámica de la cobertura de glaciares.

**Figura 32**

*Ganancias y pérdidas históricas de cambio de cobertura y uso del suelo*



*Nota.* Análisis por periodo de ganancia y pérdida observados de LULC. Fuente: Propia

### 5.3. Resultados del tercer objetivo

#### 5.3.1. Evaluación de variables predictoras espaciales


Se obtuvieron las variables espaciales predictoras de altitud, aspecto, curvatura horizontal, curvatura vertical, sombra de relieve y pendiente, las cuales

se presentan en la Figura 33. La Figura 34 presenta las relaciones entre seis variables topográficas. En la diagonal se observan histogramas que revelan la distribución de cada variable, permitiendo detectar sesgos o multimodalidad. Fuera de la diagonal, los diagramas de dispersión presentan relaciones bivariadas con líneas de regresión y bandas de confianza, mientras que en la parte superior se indican los coeficientes de correlación de Pearson, que cuantifican la fuerza y la dirección de las relaciones lineales.

La variable altitud muestra correlaciones muy bajas con todas las demás (máximo  $r = 0,22$  con la curvatura horizontal), lo que sugiere que no tiene una relación lineal significativa con el resto. Aspecto también presenta correlaciones débiles, posiblemente por su naturaleza circular. Las variables de curvatura horizontal, sombra y curvatura vertical tienen correlaciones moderadas entre sí ( $r \approx 0,48$ ), lo que indica una posible estructura común, como zonas con vegetación densa o relieve específico. La pendiente no se correlaciona con la altitud ( $r = 0,00$ ), lo que sugiere que la inclinación del terreno no depende directamente de la elevación en este conjunto de datos.

**Figura 33**


*Variables explicativas adoptadas en este estudio*



*Nota.* Variables de entrada de componente espacial para predecir. a) Altitud b) Aspecto c) Curvatura Horizontal d) Curvatura Vertical e) Sombra de relieve f) Pendiente. Fuente: Propia.

**Figura 34**

*Correlación de variables predictoras*



*Nota.* Regresión lineal de las variables predictoras. Fuente: Propia.

### 5.3.2. Modelado del potencial de transición

El modelado del potencial de transición en MOLUSCE produjo estadísticas de cambio de área y una matriz de probabilidad de transición para el área de estudio. Los resultados se adjuntan en (Anexo 5), los valores muestran disminución porcentual de la cobertura glaciara de 1,73 % entre 2012 y 2022. En contraste hubo mayor ganancia para la clase de bofedales en 0,22 %, así mismo la clase de cuerpos de agua incremento ligeramente con un 0,007 % y la clase de otras cubiertas tuvo

un incremento de 1,49 % respectivamente. A su vez, la matriz de probabilidad de transición también reveló que la clase de bofedal y cuerpos de agua fueron las más estables y mantuvieron su estado durante el período de análisis 2012-2022, reportando una probabilidad de cambio de 0,84, y 0,94.

### 5.3.3. Modelo de validación de escenario futuro

La Figura 35 describe el modelo para la simulación utilizando los mapas de uso de suelo de 2001 y 2012 para predecir el mapa de uso de suelo de 2022. El resultado de la predicción fue el mapa simulado para el 2022 y se validó con el mapa clasificado del mismo año, reportando una precisión de 84%.

#### Figura 35

##### *Precisión de la validación*

Input	Value	Output	Value
Reference Map	sktop/tiff_glaciar/TIFF/area1_BGA_2022_2022_135_227.tif	% of Correctness	97.80057
Simulated Map	UARIO/Desktop/tiff_glaciar/molusce2.8/prediccion_2022.tif	Kappa (overall)	0.53305
Validation Map	<input checked="" type="checkbox"/> Check persistent classes	Kappa (histo)	0.63627
Number of validation iterations	5	Kappa (loc)	0.83777


*Nota.* Validación entre mapa predicho y mapa observado del año 2022. Fuente: Propia.

El modelo MOLUSCE permitió realizar una comparación de ambos mapas. Para la predicción al 2032 y 2042, se utilizó un total de 4 000 puntos de muestreo estratificado y una vecindad de 3x3 para el proceso de aprendizaje de RNA. Se

utilizaron las siguientes entradas para personalizar el modelo. Tasa de aprendizaje de 0,001 impulsos de 0,05 y 100 iteraciones máximas y 10 capas ocultas. El coeficiente Kappa general logrado después de 100 iteraciones en MOLUSCE fue 72% según (Llactayo et al., 2013) se considera la precisión considerable ver Figura 36.

**Figura 36**

*Curva de aprendizaje de la red neuronal*



*Nota.* Curva de aprendizaje de la red neuronal para la predicción al 2032 y 2042.

Fuente: Propia.


#### 5.3.4. Estimación de los cambios futuros de cobertura

La Figura 37 ilustra una disminución en la extensión glaciar y una redistribución de los bofedales y cuerpos de agua, lo que evidencia

transformaciones en los sistemas glaciares debido a los efectos del cambio climático y sus implicaciones en los servicios ecosistémicos de la zona.

### Figura 37

*Escenarios futuros de cambio de cobertura y uso del suelo*



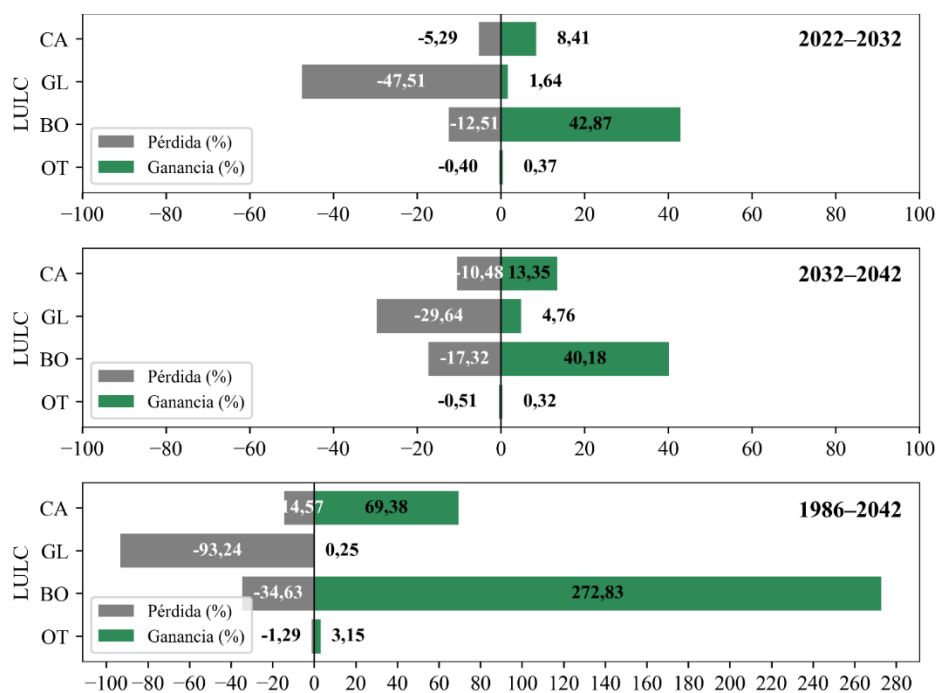
*Nota.* Proyección de cambios en glaciares, bofedales y cuerpos de agua. Fuente: Propia.

La Figura 38 y el Anexo 3 describen las métricas de ganancia y pérdida correspondientes a cada categoría de cobertura terrestre, obtenidas a partir de los datos predichos mediante el modelo, destacando los patrones de transformación más significativos a lo largo del período de estudio. En el período (2022-2032), la clase GL muestra una disminución significativa de superficie del 47,51%, mientras que la clase BO experimenta un incremento del 42,87%. Este escenario se repite en el período 2032-2042, con la pérdida adicional de la clase GL del 29,64% y un

aumento del 40,18% en la clase BO. Asimismo, en el escenario del período observado y predicho (1986-2042) se observa una drástica reducción del 93,24% en la superficie de GL, acompañada por un crecimiento notable del 272,83% en BO y del 69,38% en CA. Estos resultados proporcionan una base sólida para evaluar los impactos potenciales de dichos cambios y para diseñar estrategias de gestión sostenible de los recursos naturales.

**Figura 38**


*Ganancias y pérdidas proyectados de cobertura y uso del suelo*



*Nota.* Análisis por periodo de ganancia y pérdida proyectados de LULC. Fuente: Propia.

La Figura 39 ilustra la estimación de los cambios futuros en la superficie de los glaciares e indica que para el año 2032 esta será de 4,03 km<sup>2</sup>, mientras que para 2042 disminuirá a 3,07 km<sup>2</sup>, lo que representa una reducción total de 0,96 km<sup>2</sup>. En cuanto a los bofedales, se proyecta un incremento significativo: para 2032 su superficie aumentará a 15,47 km<sup>2</sup> y continuará creciendo hasta alcanzar un aumento acumulado de 18,80 km<sup>2</sup> en 2042. Por otro lado, los cuerpos de agua mostrarán un ligero incremento, pasando a tener una superficie de 4,52 km<sup>2</sup> en 2032 y alcanzando 4,63 km<sup>2</sup> en 2042.

Estos cambios reflejan un panorama de transformación en los ecosistemas debido al impacto de factores como el cambio climático. La reducción de los glaciares podría tener repercusiones en la disponibilidad de recursos hídricos, mientras que el crecimiento de los bofedales y cuerpos de agua sugiere modificaciones en los patrones de humedad y almacenamiento hídrico. Estos datos subrayan la necesidad de implementar estrategias de gestión sostenible para mitigar los efectos adversos y aprovechar los cambios de manera beneficiosa.

**Figura 39***Superficie de tendencias múltiples*

*Nota.* Superficie en kilómetros cuadrados del retroceso glaciar y crecimiento de cuerpos de agua y bofedales. Fuente: Propia.


En la Figura 40 ilustra el diagrama polar que muestra la pérdida de cobertura glaciar por orientaciones. Destaca una marcada orientación andina de noroeste a sureste, correspondiente al *divortium aquarum*, que divide al noreste la unidad hidrográfica del Atlántico y al sur la unidad hidrográfica del Pacífico. En esta última se encuentran las nacientes de la cuenca del río Caplina, que fluye predominantemente en dirección noreste-suroeste hasta su desembocadura en el Océano Pacífico.

El río Caplina se origina por la precipitación y el deshielo de los nevados de Achacollo, Huancune, Fraile, Chupiquiña y la Cordillera del Barroso. Según el gráfico, la orientación noreste muestra una disminución en la cobertura glaciar de 2032 a 2042, lo que sugiere una pérdida de masa glaciar que podría reducir el flujo

hídrico hacia el río Caplina, afectando su caudal, especialmente en temporadas de sequía, al disminuir el aporte de las quebradas y ríos tributarios nacidos en los nevados de esta Cordillera.

**Figura 40**

*Comparación proyectada en diagrama polar (2032–2042)*



*Nota.* Pérdida de cobertura Glaciar por orientaciones proyectadas. Fuente: Propia.

Históricamente, el río Caplina ha sido susceptible a inundaciones repentinas, especialmente durante períodos de lluvias (Vilcanqui-Alarcón et al., 2022). Las precipitaciones excepcionales provocan un incremento en los caudales de las quebradas principales de la cuenca. Los ríos Caplina y Uchusuma que confluyen detrás del cuartel Tarapacá, activan el río Seco, el cauce atraviesa los

distritos de Gregorio Albarracín y Los palos desembocan en el Balneario Los Palos y desemboca en el Océano Pacífico.

## Conclusiones

- El análisis multitemporal evidenció una transformación sustancial en los ecosistemas de la Cordillera del Barroso, caracterizada por un retroceso drástico de los glaciares y un crecimiento progresivo de bofedales y cuerpos de agua en los últimos 36 años. El modelo predictivo basado en autómatas celulares proyecta que esta tendencia continuará, estimando una reducción glacial superior al 90 % hacia 2042 y un incremento considerable en bofedales y lagunas, lo que confirma el marcado impacto del cambio climático en la dinámica ambiental de la zona.
- La clasificación multitemporal permitió delimitar tres clases principales de cobertura: glaciares, bofedales y cuerpos de agua. Los resultados muestran que los glaciares disminuyeron de 44,7 km<sup>2</sup> en 1986 a 7,4 km<sup>2</sup> en 2022, mientras que los bofedales y cuerpos de agua incrementaron sus áreas en 6,4 km<sup>2</sup> y 1,4 km<sup>2</sup>, respectivamente. La validación de la clasificación reflejó una precisión mayor al 83 %, lo cual evidencia una concordancia muy alta adecuada para el análisis.
- La dinámica de cambio evidenció una reducción sostenida de glaciares, con una pérdida más marcada en elevaciones bajas y en orientaciones este, noreste y sureste, donde los glaciares prácticamente desaparecieron. Paralelamente, se observó un crecimiento progresivo de bofedales y cuerpos de agua, lo que

demuestra un proceso de transformación ecosistémica influenciada por el retroceso glaciar y las variaciones climáticas.

- El modelamiento con MOLUSCE proyecta que, hacia 2042, la cobertura glaciar se reducirá en un 93,24 %, mientras que los bofedales crecerán en un 272,83 % y los cuerpos de agua en un 69,38 %. Estos resultados permiten anticipar la intensificación de los cambios ambientales en la Cordillera del Barroso y resaltan la necesidad de medidas de adaptación y gestión sostenible de los recursos hídricos.

### **Recomendaciones**

- Se recomienda la implementación de políticas de conservación y restauración en áreas clave, promoviendo prácticas sostenibles que favorezcan la resiliencia de estos ecosistemas ante los efectos del cambio climático.
- La implementación de modelos predictivos, como los utilizados en este estudio, debe ser incorporada a las políticas de gestión territorial y ambiental. Las proyecciones de cambios en la cobertura glaciar y los ecosistemas asociados proporcionan información valiosa para planificar el uso del suelo de manera sostenible y anticipar futuros desafíos ambientales.
- Dado que el cambio climático está jugando un papel central en la transformación de los ecosistemas de alta montaña, se recomienda intensificar la investigación local sobre los impactos climáticos específicos de la región, con el objetivo de desarrollar estrategias adaptativas para mitigar los efectos negativos y aprovechar las oportunidades emergentes, como el crecimiento de los bofedales.
- Se deben implementar programas de educación y sensibilización sobre el cambio climático, su impacto en los ecosistemas de alta montaña y la importancia de la conservación de los recursos hídricos. Estos programas pueden incluir tanto a la población local como a los actores clave del sector público y privado, para garantizar la colaboración y el entendimiento de la situación.

### Bibliografía

- Abbas, Z., Yang, G., Zhong, Y., & Zhao, Y. (2021). Spatiotemporal Change Analysis and Future Scenario of LULC Using the CA-ANN Approach: A Case Study of the Greater Bay Area, China. *Land*, *10*(6), 584. <https://doi.org/10.3390/land10060584>
- Adam, E., Mutanga, O., Odindi, J., & Abdel-Rahman, E. M. (2014). Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing*, *35*(10), 3440–3458. <https://doi.org/10.1080/01431161.2014.903435>
- Aldana, C., Moncada, W., Gonzales, J., Saavedra, Y., & Gálvez, D. (2022). Firmas espectrales de especies vegetales, suelo y agua de la cuenca del río Chira, región Piura. *Revista de Investigación Científica de La UNF–Aypate*, *1*(1), 28–47.
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M., Moghaddam, S. H. A., Mahdavi, S., Ghahremanloo, M., Parsian, S., Wu, Q., & Brisco, B. (2020). Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. *IEEE Journal of Selected Topics in Applied Earth*

*Observations and Remote Sensing*, 13, 5326–5350.  
<https://doi.org/10.1109/JSTARS.2020.3021052>

Ambinakudige, S., & Joshi, K. (2012). Remote sensing of cryosphere. *Remote Sensing-Applications, Dr. Boris Escalante (Ed.)*, 369–380.

Aranda, F., Medina, D., Castro, L., Ossandón, Á., Ovalle, R., Flores, R. P., & Bolaño-Ortiz, T. R. (2023). Snow Persistence and Snow Line Elevation Trends in a Snowmelt-Driven Basin in the Central Andes and Their Correlations with Hydroclimatic Variables. *Remote Sensing*, 15(23), 5556.  
<https://doi.org/10.3390/rs15235556>

Ashok, A., Rani, H. P., & Jayakumar, K. V. (2021). Monitoring of dynamic wetland changes using NDVI and NDWI based landsat imagery. *Remote Sensing Applications: Society and Environment*, 23, 100547.  
<https://doi.org/10.1016/j.rsase.2021.100547>

Ayoub, Anuor. A. T., & Song, Y. (2020). Radioactivity measurement in glacier and Polar ice-caps: An overview. *IOP Conference Series: Earth and Environmental Science*, 467(1), 012058. <https://doi.org/10.1088/1755-1315/467/1/012058>

Bajracharya, S. R., & Mool, P. (2009). Glaciers, glacial lakes and glacial lake outburst floods in the Mount Everest region, Nepal. *Annals of Glaciology*, 50(53), 81–86. <https://doi.org/10.3189/172756410790595895>

- Balzter, H., Braun, P. W., & Köhler, W. (1998). Cellular automata models for vegetation dynamics. *Ecological Modelling*, *107*(2–3), 113–125.
- Barry, R., & Gan, T. Y. (2011). *The Global Cryosphere*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511977947>
- Bazilova, V., & Kääb, A. (2022). Mapping Area Changes of Glacial Lakes Using Stacks of Optical Satellite Images. *Remote Sensing*, *14*(23), 5973. <https://doi.org/10.3390/rs14235973>
- Bellido Bravo, E. (1969). *Sinopsis de la Geología del Perú-[Boletín A 22]*.
- Benn, D. I., & Ballantyne, C. K. (2005). Palaeoclimatic reconstruction from Loch Lomond readvance glaciers in the west Drumochter Hills, Scotland. *Journal of Quaternary Science: Published for the Quaternary Research Association*, *20*(6), 577–592.
- Bhardwaj, A., Joshi, P., Snehmani, Sam, L., Singh, M. K., Singh, S., & Kumar, R. (2015). Applicability of Landsat 8 data for characterizing glacier facies and supraglacial debris. *International Journal of Applied Earth Observation and Geoinformation*, *38*, 51–64. <https://doi.org/10.1016/j.jag.2014.12.011>
- Bhardwaj, A., Sam, L., Bhardwaj, A., & Martín-Torres, F. J. (2016). LiDAR remote sensing of the cryosphere: Present applications and future prospects. *Remote Sensing of Environment*, *177*, 125–143. <https://doi.org/10.1016/j.rse.2016.02.031>

- Blanca, G. A., & Llullán, S. (2014). *Inventario de glaciares del Perú*.
- Brenning, A. (2003). La importancia de los glaciares de escombros en los sistemas geomorfológico e hidrológico de la Cordillera de Santiago: fundamentos y primeros resultados. *Revista de Geografía Norte Grande*, 30, 7–22.
- Cañadas, E. S., & Trueba, J. J. G. (2004). El método AAR para la determinación de paleo-ELAs: Análisis metodológico y aplicación en el Macizo de Valdecebollas (Cordillera Cantábrica). *Cuadernos de Investigación Geográfica*, 30, 7–34.
- Cao, B. O., Pan, B., Guan, W., Wen, Z., & Wang, J. I. E. (2019). Changes in glacier volume on Mt. Gongga, southeastern Tibetan Plateau, based on the analysis of multi-temporal DEMs from 1966 to 2015. *Journal of Glaciology*, 65(251), 366–375.
- Cardozo, O. D., & Da Silva, C. J. (2013). Aplicaciones urbanas de los sensores remotos. *Geográfica Digital*, 10(20), 1–6.
- Chevallier, P., Pouyaud, B., Suarez, W., & Condom, T. (2011). Climate change threats to environment in the tropical Andes: glaciers and water resources. *Regional Environmental Change*, 11(S1), 179–187. <https://doi.org/10.1007/s10113-010-0177-6>
- Coayla-Peñaloza, P., Chenaux-Díaz, A. A., Moreno-Salazar, C. V., Cruz-Remache, C. E., Colque-Rondón, E. W., & Damborenea, C. (2023). Benthic

macroinvertebrate communities and water quality assessment in high Andean Wetlands Callali-Oscollo, Arequipa-Cusco, Peru. *Revista Mexicana de Biodiversidad*, 94, e944206.  
<https://doi.org/10.22201/ib.20078706e.2023.94.4206>

Cochran, W. G. (1977). Sampling techniques. *Johan Wiley & Sons Inc.*

Copland, L. (2022). Properties of Glacial Ice and Glacier Classification. In *Treatise on Geomorphology* (pp. 52–62). Elsevier. <https://doi.org/10.1016/B978-0-12-818234-5.00014-6>

Corripio, J. G. (2003). Vectorial algebra algorithms for calculating terrain parameters from DEMs and solar radiation modelling in mountainous terrain. *International Journal of Geographical Information Science*, 17(1), 1–23.  
<https://doi.org/10.1080/713811744>

Court, L. (2012). Light and Visible Radiation. In *Electromagnetic Fields, Environment and Health* (pp. 97–108). Springer Paris.  
[https://doi.org/10.1007/978-2-8178-0363-0\\_9](https://doi.org/10.1007/978-2-8178-0363-0_9)

Curo Rosales, Y. A., Celmi Henostroza, G. T., Mejía Camones, M. D., & Fernández Vega, J. de D. (2023). *Inventario Nacional de Glaciares y Lagunas de Origen Glaciar 2023*. <https://doi.org/10.36580/inaigem.document17>

de Almeida, C. M. (2003). *Modelagem da dinâmica espacial como uma ferramenta auxiliar ao planejamento: simulação de mudanças de uso da terra em áreas urbanas para as cidades de Bauru e Piracicaba (SP), Brasil.*

de Guzmán, C. N., & Fernando, R. (2015). *Paisajes y geoformas glaciares y periglaciares en los Andes peruanos.*

De la Cruz, G., Huerta, A., Franco-León, P., Pino-Vargas, E., Ramos-Fernández, L., & Lavado-Casimiro, W. (2025). Future Climate Projections for Tacna, Peru: Assessing Changes in Temperature and Precipitation. *Atmosphere*, 16(2), 144. <https://doi.org/10.3390/atmos16020144>

Deng, G., Tang, Z., Dong, C., Shao, D., & Wang, X. (2024). Development and Evaluation of a Cloud-Gap-Filled MODIS Normalized Difference Snow Index Product over High Mountain Asia. *Remote Sensing*, 16(1), 192. <https://doi.org/10.3390/rs16010192>

Eastman, J. R., & Toledano, J. (2018). A short presentation of the Land Change Modeler (LCM). *Geomatic Approaches for Modeling Land Change Scenarios*, 499–505.

Eisfelder, C., Asam, S., Hirner, A., Reiners, P., Holzwarth, S., Bachmann, M., Gessner, U., Dietz, A., Huth, J., Bachofer, F., & Kuenzer, C. (2023). Seasonal Vegetation Trends for Europe over 30 Years from a Novel Normalised

- Difference Vegetation Index (NDVI) Time-Series—The TIMELINE NDVI Product. *Remote Sensing*, 15(14), 3616. <https://doi.org/10.3390/rs15143616>
- Elliott, B. J. (2000). Basic physics — optical. In *Cable Engineering for Local Area Networks* (pp. 26–30). Elsevier. <https://doi.org/10.1533/9781855738898.26>
- Emmer, A., Allen, S. K., Carey, M., Frey, H., Huggel, C., Korup, O., Mergili, M., Sattar, A., Veh, G., Chen, T. Y., Cook, S. J., Correias-Gonzalez, M., Das, S., Diaz Moreno, A., Drenkhan, F., Fischer, M., Immerzeel, W. W., Izagirre, E., Joshi, R. C., ... Yde, J. C. (2022). Progress and challenges in glacial lake outburst flood research (2017–2021): a research community perspective. *Natural Hazards and Earth System Sciences*, 22(9), 3041–3061. <https://doi.org/10.5194/nhess-22-3041-2022>
- Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., & Alsdorf, D. (2007). The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 45(2). <https://doi.org/10.1029/2005RG000183>
- Fitzsimons, S., & Howarth, J. (2018). Glaciolacustrine processes. In *Past glacial environments* (pp. 309–334). Elsevier.

- Francou, B. (2013). El rápido retroceso de los glaciares en los Andes tropicales: Un desafío para el estudio de la dinámica de los ecosistemas de alta montaña. *Ecología En Bolivia*, 48(2), 69–71.
- Francou, B., & Pouyaud, B. (2004). Métodos de observación de glaciares en los Andes tropicales. *Mediciones de Terreno y Procesamiento de Datos. Versión, 1*.
- Francou, B., & Pouyaud, B. (2008). Glaciares:¿ cómo y dónde estudiarlos? *Revista Virtual REDESMA*, 2, 9.
- Frezzotti, M., & Orombelli, G. (2014). Glaciers and ice sheets: current status and trends. *Rendiconti Lincei*, 25(1), 59–70. <https://doi.org/10.1007/s12210-013-0255-z>
- Fyffe, C. L., Brock, B. W., Kirkbride, M. P., Mair, D. W. F., Arnold, N. S., Smiraglia, C., Diolaiuti, G., & Diotri, F. (2019). Do debris-covered glaciers demonstrate distinctive hydrological behaviour compared to clean glaciers? *Journal of Hydrology*, 570, 584–597. <https://doi.org/10.1016/j.jhydrol.2018.12.069>
- Ganyushkin, D., Bantsev, D., Derkach, E., Agatova, A., Nepop, R., Griga, S., Rasputina, V., Ostanin, O., Dyakova, G., Pryakhina, G., Chistyakov, K., Kurochkin, Y., & Gorbunova, Y. (2023). Post-Little Ice Age Glacier Recession in the North-Chuya Ridge and Dynamics of the Bolshoi Maashei

- Glacier, Altai. *Remote Sensing*, 15(8), 2186.  
<https://doi.org/10.3390/rs15082186>
- Gao, B. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gao, B.-C. (1995). *Normalized difference water index for remote sensing of vegetation liquid water from space* (M. R. Descour, J. M. Mooney, D. L. Perry, & L. R. Illing, Eds.; p. 225). <https://doi.org/10.1117/12.210877>
- Gao, C., Cheng, D., Iqbal, J., & Yao, S. (2023). Spatiotemporal Change Analysis and Prediction of the Great Yellow River Region (GYRR) Land Cover and the Relationship Analysis with Mountain Hazards. *Land*, 12(2), 340. <https://doi.org/10.3390/land12020340>
- García, J., & Willems, B. L. (2015). Metodología para el Estudio de Bofedales en Cabeceras de Cuenca Usando Datos Imágenes de los Sensores TM, OLI a bordo de los Satélites Landsat-Caso Estudio: Bofedal Chunal, Cuenca Alta del río Chillón.: Avances. *Anais XVII Simpósio Brasileiro de Sensoriamento Remoto-SBSR, 1*, 5562–5569.
- García, M. L., Brondo, J. A. É., & Pérez, M. A. (2012). Satélites para detecção remota: aplicada à Gestão Territorial. *Consejería de Agricultura, Pesca y Aguas Del Gobierno de Canarias (Ed.)*, 65.

- Gardner, M. (1970). Mathematical games. *Scientific American*, 222(6), 132–140.
- Goodison, B. E., Brown, R. D., Brugman, M. M., Duguay, C. R., Flato, G. M., LeDrew, E. F., & Walker, A. E. (1999). CRYSYS - Use of the Cryospheric System to Monitor Global Change in Canada: Overview and Progress. *Canadian Journal of Remote Sensing*, 25(1), 3–11. <https://doi.org/10.1080/07038992.1999.10855258>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27.
- Goward, S. N., Arvidson, T., & Williams, D. L. (2006). Landsat: Yesterday, Today, and Tomorrow. *Photogrammetric Engineering and Remote Sensing*, 72, 1171–1178. <https://api.semanticscholar.org/CorpusID:42566280>
- Guy Preis, S., Chayet, H., Katz, A., Yashunsky, V., Kaner, A., Ullman, S., & Braslavsky, I. (2019). Labyrinth ice pattern formation induced by near-infrared irradiation. *Science Advances*, 5(3). <https://doi.org/10.1126/sciadv.aav1598>
- Hall, D. K., & Riggs, G. A. (2010). Normalized-difference snow index (NDSI). *Encyclopedia of Snow, Ice and Glaciers*.

- Hameed, R. Sh., Georg, L. E., & Sayyid, B. H. (2021). Modified Vegetation Detection Index Using Different-Spectral Signature. *Iraqi Journal of Science*, 4208–4217. <https://doi.org/10.24996/ij.s.2021.62.11.38>
- Hardisky, M. A., Smart, R. M., & Klemas, V. (1983). Seasonal spectral characteristics and aboveground biomass of the tidal marsh plant. *Spartina-Alterniflora Photogrammetric Engineering and Remote Sensing*, 49, 85–92.
- Hatakeyama, W., Kawakita, S., Izawa, R., & Kimura, M. (2022). GRASP EARTH: Intuitive Software for Discovering Changes on the Planet. *ArXiv Preprint ArXiv:2203.00955*.
- Hernández-Duarte, A., Francois Sepúlveda, J. P., Contreras Figueroa, V. I., Saud Valero, F. R., & Saavedra Pimentel, F. A. (2021). Cambios en la cobertura de nieve y su relación con el caudal para la caracterización, monitoreo y gestión de las cuencas de montaña en los Andes extratropicales de Chile entre los 29° y 37°S utilizando teledetección. *Boletín de Estudios Geográficos*, 116, 123–155. <https://doi.org/10.48162/rev.40.010>
- Herreid, S., & Pellicciotti, F. (2020). The state of rock debris covering Earth's glaciers. *Nature Geoscience*, 13(9), 621–627. <https://doi.org/10.1038/s41561-020-0615-0>
- Hewitt, K. (2014). *Rock Glaciers and Related Phenomena* (pp. 267–289). [https://doi.org/10.1007/978-94-007-6311-1\\_11](https://doi.org/10.1007/978-94-007-6311-1_11)

- Hidrandina, S. A. (1989). Inventario de glaciares del Perú. *Consejo Nacional de Ciencia y Tecnología (CONCYTEC)*.
- Huang, Y., Chen, Z., Yu, T., Huang, X., & Gu, X. (2018). Agricultural remote sensing big data: Management and applications. *Journal of Integrative Agriculture*, 17(9), 1915–1931. [https://doi.org/10.1016/S2095-3119\(17\)61859-8](https://doi.org/10.1016/S2095-3119(17)61859-8)
- Hughes, D. W. (1992). Pamela E. Mack. Viewing the Earth: The Social Construction of the Landsat Satellite System. Cambridge Mass, and London: MIT Press, 1990. Pp. xii+ 270. ISBN 0-262-13259-1.£ 24.75. *The British Journal for the History of Science*, 25(4), 499.
- Hunt, Jr. , E. R., & Yilmaz, M. T. (2007). *Remote sensing of vegetation water content using shortwave infrared reflectances* (W. Gao & S. L. Ustin, Eds.; p. 667902). <https://doi.org/10.1117/12.734730>
- INAIGEM. (2017). *Manual Metodológico de Inventario Nacional de Glaciares*. Instituto Nacional de Investigación en Glaciares y Ecosistemas de Montaña.
- Iturregui, P. (2001). *Comunicación Nacional del Perú a la Convención de Naciones Unidas sobre el cambio climático: Primera comunicación*.
- Ji, L., Zhang, L., Wylie, B. K., & Rover, J. (2011). On the terminology of the spectral vegetation index  $(NIR - SWIR)/(NIR + SWIR)$ . *International Journal*

*of Remote Sensing*, 32(21), 6901–6909.  
<https://doi.org/10.1080/01431161.2010.510811>

Jiao, W., Wang, L., & McCabe, M. F. (2021). Multi-sensor remote sensing for drought characterization: current status, opportunities and a roadmap for the future. *Remote Sensing of Environment*, 256, 112313.  
<https://doi.org/10.1016/j.rse.2021.112313>

Joiner, J., Yoshida, Y., Anderson, M., Holmes, T., Hain, C., Reichle, R., Koster, R., Middleton, E., & Zeng, F.-W. (2018). Global relationships among traditional reflectance vegetation indices (NDVI and NDII), evapotranspiration (ET), and soil moisture variability on weekly timescales. *Remote Sensing of Environment*, 219, 339–352. <https://doi.org/10.1016/j.rse.2018.10.020>

Jones, D. B., Harrison, S., Anderson, K., & Betts, R. A. (2018). Mountain rock glaciers contain globally significant water stores. *Scientific Reports*, 8(1), 2834. <https://doi.org/10.1038/s41598-018-21244-w>

Jones, D. B., Harrison, S., Anderson, K., & Betts, R. A. (2021). Author Correction: Mountain rock glaciers contain globally significant water stores. *Scientific Reports*, 11(1), 20997. <https://doi.org/10.1038/s41598-021-00027-w>

Kaplan, G., & Avdan, U. (2017). Mapping and Monitoring Wetlands using Sentinel-2 Satellite Imagery. *ISPRS Annals of the Photogrammetry, Remote*

*Sensing and Spatial Information Sciences, IV-4/W4, 271–277.*

<https://doi.org/10.5194/isprs-annals-IV-4-W4-271-2017>

Karamani, R.-E., Fyrigos, I.-A., Ntinis, V., Vourkas, I., Adamatzky, A., & Sirakoulis, G. Ch. (2023). Memristors in Cellular-Automata-Based Computing: A Review. *Electronics, 12*(16), 3523.

<https://doi.org/10.3390/electronics12163523>

Kaser, G., & Osmaston, H. (2002). *Tropical glaciers*. Cambridge University Press.

Klein, A. G., Hall, D. K., & Riggs, G. A. (1998). Improving snow cover mapping in forests through the use of a canopy reflectance model. *Hydrological Processes, 12*(10-11), 1723–1744.

Knight, P. G. (2004). Glaciers: art and history, science and uncertainty. *Interdisciplinary Science Reviews, 29*(4), 385–393.

<https://doi.org/10.1179/030801804225012527>

Knipling, E. B. (1970). Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment, 1*(3), 155–159. [https://doi.org/10.1016/S0034-4257\(70\)80021-9](https://doi.org/10.1016/S0034-4257(70)80021-9)

Kollert, A., Mayr, A., Dullinger, S., Hülber, K., Moser, D., Lhermitte, S., Gascoin, S., & Rutzinger, M. (2024). Downscaling MODIS NDSI to Sentinel-2 fractional snow cover by random forest regression. *Remote Sensing Letters, 15*(4), 363–372. <https://doi.org/10.1080/2150704X.2024.2327084>

- Kulkarni, A. V., Srinivasulu, J., Manjul, S. S., & P, M. (2002). Field based spectral reflectance studies to develop NDSI method for snow cover monitoring. *Journal of the Indian Society of Remote Sensing*, 30(1–2), 73–80. <https://doi.org/10.1007/BF02989978>
- Kumar, L., & Mutanga, O. (2018). Google Earth Engine Applications Since Inception: Usage, Trends, and Potential. *Remote Sensing*, 10(10), 1509. <https://doi.org/10.3390/rs10101509>
- Kumar, V., Ranjan, D., & Verma, K. (2021). Global climate change: the loop between cause and impact. In *Global Climate Change* (pp. 187–211). Elsevier. <https://doi.org/10.1016/B978-0-12-822928-6.00002-2>
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 159–174.
- Laqui, W., Zubieta, R., Laqui-Vilca, Y., Calizaya, E., & Laqui-Vilca, C. (2024). Temporal dynamics of glacier retreat and its relationship with local climate in Cordillera Apolobamba, Peru. *Modeling Earth Systems and Environment*, 10(2), 1647–1656. <https://doi.org/10.1007/s40808-023-01865-5>
- Lara, M. R., Hidalgo, K. A. Á., & Verdezoto, D. R. T. (2024). Análisis de firmas espectrales para la gestión del territorio y control de la expansión urbana. *Polo Del Conocimiento*, 9(3), 3341–3358.

- Lazzari, P., & Seriani, N. (2024). Two-dimensional cellular automata—Deterministic models of growth. *Chaos, Solitons & Fractals*, *185*, 114997. <https://doi.org/10.1016/j.chaos.2024.114997>
- Lenarduzzi, L., & Pepe, M. (2017). Enhancing and segmenting a remote sensing image of a glacier body. *Mathematics and Computers in Simulation*, *137*, 411–423. <https://doi.org/10.1016/j.matcom.2016.09.005>
- Leon, J. M., Yabar, H., Medina, E. L., Estraver, W. Z., Castillo, J. D. L. C., & Rivero, A. E. G. (2021). Identification, Mapping and Ethnobotany of Plant Species in the Peruvian High Andean Wetlands: Stimulating Biodiversity Conservation Efforts towards Sustainability. *Journal of Sustainable Development*, *14*(2), 66. <https://doi.org/10.5539/jsd.v14n2p66>
- Li, C., Ma, Z., Wang, L., Yu, W., Tan, D., Gao, B., Feng, Q., Guo, H., & Zhao, Y. (2021). Improving the Accuracy of Land Cover Mapping by Distributing Training Samples. *Remote Sensing*, *13*(22), 4594. <https://doi.org/10.3390/rs13224594>
- Li, W., Dong, R., Fu, H., Wang, J., Yu, L., & Gong, P. (2020). Integrating Google Earth imagery with Landsat data to improve 30-m resolution land cover mapping. *Remote Sensing of Environment*, *237*, 111563. <https://doi.org/10.1016/j.rse.2019.111563>

- Li, Y., Zhang, H., Xue, X., Jiang, Y., & Shen, Q. (2018). Deep learning for remote sensing image classification: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(6), e1264.
- Liu, Y., Corcoran, J., & Feng, Y. (2020). Cellular Automata. In *International Encyclopedia of Human Geography* (pp. 101–104). Elsevier. <https://doi.org/10.1016/B978-0-08-102295-5.10519-0>
- Lizama, E., Somos-Valenzuela, M., Rivera, D., Lillo, M., Morales, B., Baraër, M., & Fernández, A. (2025). Role of mountain glaciers in the hydrological dynamics of headwater basins in the Wet Andes. *Journal of Hydrology*, 649, 132413. <https://doi.org/10.1016/j.jhydrol.2024.132413>
- Llactayo, W., Salcedo, K., & Victoria, E. (2013). Evaluación de la exactitud temática del Mapa de Deforestación. *Dirección General de Ordenamiento Territorial (DGOT)*.
- Lliboutry, L. (1956). *Nieves y glaciares de Chile: fundamentos de glaciología*, 471.
- López-Moreno, J. I., Morán-Tejeda, E., Vicente-Serrano, S. M., Bazo, J., Azorin-Molina, C., Revuelto, J., Sánchez-Lorenzo, A., Navarro-Serrano, F., Aguilar, E., & Chura, O. (2016). Recent temperature variability and change in the Altiplano of Bolivia and Peru. *International Journal of Climatology*, 36(4), 1773–1796. <https://doi.org/10.1002/joc.4459>

- Lulla, K., Nellis, M. D., Rundquist, B., Srivastava, P. K., & Szabo, S. (2021). Mission to earth: LANDSAT 9 will continue to view the world. *Geocarto International*, 36(20), 2261–2263. <https://doi.org/10.1080/10106049.2021.1991634>
- Machireddy, S. R. (2023). Natural Resource Management using Remote Sensing and Geographic Information Systems. *Environmental Science and Engineering*, 2(2), 73–82.
- Madrigal-Martínez, S., Puga-Calderón, R. J., Bustínza Urviola, V., & Vilca Gómez, Ó. (2022). Spatiotemporal Changes in Land Use and Ecosystem Service Values Under the Influence of Glacier Retreat in a High-Andean Environment. *Frontiers in Environmental Science*, 10. <https://doi.org/10.3389/fenvs.2022.941887>
- Mandava, N. B. (2019). Introduction to Spectroscopy. In *Handbook of Natural Pesticides: Methods* (pp. 157–164). CRC Press.
- Mark, B. G. (2008). Tracing tropical Andean glaciers over space and time: Some lessons and transdisciplinary implications. *Global and Planetary Change*, 60(1–2), 101–114. <https://doi.org/10.1016/j.gloplacha.2006.07.032>
- Markert, K. (2019). cartoee: Publication quality maps using Earth Engine. *Journal of Open Source Software*, 4(33), 1207. <https://doi.org/10.21105/joss.01207>

- Martinez, A. de la I., & Labib, S. M. (2022). Demystifying Normalized Difference Vegetation Index (NDVI) for Greenness Exposure Assessments and Policy Interventions in Urban Greening. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4207665>
- Mas, J.-F., Pérez-Vega, A., Ghilardi, A., Martínez, S., Loya-Carrillo, J. O., & Vega, E. (2014). A Suite of Tools for Assessing Thematic Map Accuracy. *Geography Journal*, 2014, 1–10. <https://doi.org/10.1155/2014/372349>
- Masiokas, M. H., Rabatel, A., Rivera, A., Ruiz, L., Pitte, P., Ceballos, J. L., Barcaza, G., Soruco, A., Bown, F., Berthier, E., Dussailant, I., & MacDonell, S. (2020). A Review of the Current State and Recent Changes of the Andean Cryosphere. *Frontiers in Earth Science*, 8. <https://doi.org/10.3389/feart.2020.00099>
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
- Melesse, A. M., Weng, Q., Thenkabail, P. S., & Senay, G. B. (2007). Remote Sensing Sensors and Applications in Environmental Resources Mapping and Modelling. *Sensors*, 7(12), 3209–3241. <https://doi.org/10.3390/s7123209>

- Melnikov, V., Gennadinik, V., Kulmala, M., Lappalainen, H. K., Petäjä, T., & Zilitinkevich, S. (2018). Cryosphere: a kingdom of anomalies and diversity. *Atmospheric Chemistry and Physics*, 18(9), 6535–6542. <https://doi.org/10.5194/acp-18-6535-2018>
- Micijevic, E., Barsi, J. A., Haque, Md. O., Levy, R., Anderson, C., Thome, K., Czapla-Myers, J., & Helder, D. (2022). Radiometric performance of the Landsat 9 Operational Land Imager over the first 8 months on orbit. In J. J. Butler, X. (Jack) Xiong, & X. Gu (Eds.), *Earth Observing Systems XXVII* (p. 33). SPIE. <https://doi.org/10.1117/12.2634301>
- Mohammadi, B., Pilesjö, P., & Duan, Z. (2023). The superiority of the Adjusted Normalized Difference Snow Index (ANDSI) for mapping glaciers using Sentinel-2 multispectral satellite imagery. *GIScience & Remote Sensing*, 60(1). <https://doi.org/10.1080/15481603.2023.2257978>
- Montero, D. (2021). eemont: A Python package that extends Google Earth Engine. *Journal of Open Source Software*, 6(62), 3168. <https://doi.org/10.21105/joss.03168>
- Montero, D., Aybar, C., Mahecha, M. D., Martinuzzi, F., Söchting, M., & Wieneke, S. (2023). A standardized catalogue of spectral indices to advance the use of remote sensing in Earth system research. *Scientific Data*, 10(1), 197. <https://doi.org/10.1038/s41597-023-02096-0>

- Mubako, S., Nnko, H. J., Peter, K. H., & Msongaleli, B. (2022). Evaluating historical and predicted long-term land use/land-cover change in Dodoma Urban District, Tanzania: 1992–2029. *Physics and Chemistry of the Earth, Parts A/B/C*, 128, 103205. <https://doi.org/10.1016/j.pce.2022.103205>
- Muhammad, R., Zhang, W., Abbas, Z., Guo, F., & Gwiazdzinski, L. (2022). Spatiotemporal Change Analysis and Prediction of Future Land Use and Land Cover Changes Using QGIS MOLUSCE Plugin and Remote Sensing Big Data: A Case Study of Linyi, China. *Land*, 11(3), 419. <https://doi.org/10.3390/land11030419>
- Mutz, S. G., & Aschauer, J. (2022). Empirical glacier mass-balance models for South America. *Journal of Glaciology*, 1–15. <https://doi.org/10.1017/jog.2022.6>
- Norgard, J. (2007). The Electromagnetic Spectrum. In *National Association of Broadcasters Engineering Handbook* (pp. 3–10). Elsevier. <https://doi.org/10.1016/B978-0-240-80751-5.50008-4>
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>

- O'Sullivan, D. (2001). Exploring spatial process dynamics using irregular cellular automaton models. *Geographical Analysis*, 33(1), 1–18.
- Paegelow, M., Camacho Olmedo, M. T., Mas, J.-F., Houet, T., & Pontius Jr., R. G. (2013). Land change modelling: moving beyond projections. *International Journal of Geographical Information Science*, 27(9), 1691–1695. <https://doi.org/10.1080/13658816.2013.819104>
- Palczewski, K. (2012). Chemistry and Biology of Vision. *Journal of Biological Chemistry*, 287(3), 1612–1619. <https://doi.org/10.1074/jbc.R111.301150>
- Pamuji, R., Mahardika, A. I., Wiranda, N., Saputra, N. A. B., Adini, M. H., & Pramatasari, D. (2023). Utilizing Electromagnetic Radiation in Remote Sensing for Vegetation Health Analysis Using NDVI Approach with Sentinel-2 Imagery. *Kasuari: Physics Education Journal (KPEJ)*, 6(2), 127–135. <https://doi.org/10.37891/kpej.v6i2.486>
- Panuju, D. R., Paull, D. J., & Griffin, A. L. (2020). Change Detection Techniques Based on Multispectral Images for Investigating Land Cover Dynamics. *Remote Sensing*, 12(11), 1781. <https://doi.org/10.3390/rs12111781>
- Pereira, L. E., Amorim, G., Grigio, A. M., & Paranhos, A. C. (2018). Comparative Analysis of Normalized Difference Water Index (NDWI) Methods in Continental Wetland. *Anuário Do Instituto de Geociências - UFRJ*, 41(2), 654–662. [https://doi.org/10.11137/2018\\_2\\_654\\_662](https://doi.org/10.11137/2018_2_654_662)

- Pijanowski, B. C., Brown, D. G., Shellito, B. A., & Manik, G. A. (2002). Using neural networks and GIS to forecast land use changes: a Land Transformation Model. *Computers, Environment and Urban Systems*, 26(6), 553–575. [https://doi.org/10.1016/S0198-9715\(01\)00015-1](https://doi.org/10.1016/S0198-9715(01)00015-1)
- Polk, M. H., Young, K. R., Baraer, M., Mark, B. G., McKenzie, J. M., Bury, J., & Carey, M. (2017). Exploring hydrologic connections between tropical mountain wetlands and glacier recession in Peru's Cordillera Blanca. *Applied Geography*, 78, 94–103. <https://doi.org/10.1016/j.apgeog.2016.11.004>
- Porter, S. C. (2000). Snowline depression in the tropics during the Last Glaciation. *Quaternary Science Reviews*, 20(10), 1067–1091.
- Qiao, C., Luo, J., Sheng, Y., Shen, Z., Zhu, Z., & Ming, D. (2012). An Adaptive Water Extraction Method from Remote Sensing Image Based on NDWI. *Journal of the Indian Society of Remote Sensing*, 40(3), 421–433. <https://doi.org/10.1007/s12524-011-0162-7>
- Rasouli, A. A., Cheung, K. K. W., Mohammadzadeh Alajujeh, K., & Ji, F. (2022). On the Detection of Snow Cover Changes over the Australian Snowy Mountains Using a Dynamic OBIA Approach. *Atmosphere*, 13(5), 826. <https://doi.org/10.3390/atmos13050826>
- Rau, P., Bourrel, L., Labat, D., Melo, P., Dewitte, B., Frappart, F., Lavado, W., & Felipe, O. (2017). Regionalization of rainfall over the Peruvian Pacific slope

- and coast. *International Journal of Climatology*, 37(1), 143–158.  
<https://doi.org/10.1002/joc.4693>
- Raup, B. H., Andreassen, L. M., Bolch, T., & Bevan, S. (2015). Remote sensing of glaciers. In *Remote Sensing of the Cryosphere* (pp. 123–156). Wiley.  
<https://doi.org/10.1002/9781118368909.ch7>
- Riart, O. P. (1987). *Teledetección aplicada a la Arqueología*.  
<https://api.semanticscholar.org/CorpusID:172766496>
- Rivera, A., Bown González, F., Napoleoni, F., Muñoz, C., & Vuille, M. (2017). *Manual Balance de masa glaciár*. Centro de Estudios Científicos, CECs.
- Rojas-Macedo, I., Bello, C., Suarez, W., Loarte, E., Vega-Jacome, F., Bustamante Rosell, M. G., & Tapia, P. M. (2025). Using satellite imagery to assess the glacier retreat in King George Island, Antarctica. *Revista de Teledetección*, 65.  
<https://doi.org/10.4995/raet.2025.22317>
- Ross, A. C., Mendoza, M. M., Drenkhan, F., Montoya, N., Baiker, J. R., Mackay, J. D., Hannah, D. M., & Buytaert, W. (2023). Seasonal water storage and release dynamics of *bofedal* wetlands in the Central Andes. *Hydrological Processes*, 37(8). <https://doi.org/10.1002/hyp.14940>
- Rounce, D. R., Hock, R., Maussion, F., Hugonnet, R., Kochtitzky, W., Huss, M., Berthier, E., Brinkerhoff, D., Compagno, L., Copland, L., Farinotti, D., Menounos, B., & McNabb, R. W. (2023). Global glacier change in the 21st

century: Every increase in temperature matters. *Science*, 379(6627), 78–83.  
<https://doi.org/10.1126/science.abo1324>

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ*, 351(1), 309.

Salomonson, V. V., & Appel, I. (2004). Estimating fractional snow cover from MODIS using the normalized difference snow index. *Remote Sensing of Environment*, 89(3), 351–360. <https://doi.org/10.1016/j.rse.2003.10.016>

Sam, L., Bhardwaj, A., Singh, S., & Kumar, R. (2016). Remote sensing flow velocity of debris-covered glaciers using Landsat 8 data. *Progress in Physical Geography: Earth and Environment*, 40(2), 305–321.  
<https://doi.org/10.1177/0309133315593894>

Sankaran, S., & Ehsani, R. (2014). Introduction to the Electromagnetic Spectrum. In *Imaging with Electromagnetic Spectrum* (pp. 1–15). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-54888-8\\_1](https://doi.org/10.1007/978-3-642-54888-8_1)

Santana Rodriguez, L. M. (2016). Teledetección ambiental: La observación de la Tierra desde el Espacio. *Entorno Geográfico*, 3.  
<https://doi.org/10.25100/eg.v0i3.3579>

Sardar, P., & Samadder, S. R. (2021). Understanding the dynamics of landscape of greater Sundarban area using multi-layer perceptron Markov chain and

landscape statistics approach. *Ecological Indicators*, 121, 106914.  
<https://doi.org/10.1016/j.ecolind.2020.106914>

Sattar, A., Haritashya, U. K., Kargel, J. S., Leonard, G. J., Shugar, D. H., & Chase, D. V. (2021). Modeling lake outburst and downstream hazard assessment of the Lower Barun Glacial Lake, Nepal Himalaya. *Journal of Hydrology*, 598, 126208. <https://doi.org/10.1016/j.jhydrol.2021.126208>

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>

Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308–6325. <https://doi.org/10.1109/JSTARS.2020.3026724>

Shin, S., Her, Y., & Khare, Y. (2023). Evaluation of impacts of climate change on natural and managed wetland basins. *JAWRA Journal of the American Water Resources Association*, 59(6), 1549–1568. <https://doi.org/10.1111/1752-1688.13140>

- Shugar, D. H., Burr, A., Haritashya, U. K., Kargel, J. S., Watson, C. S., Kennedy, M. C., Bevington, A. R., Betts, R. A., Harrison, S., & Strattman, K. (2020). Rapid worldwide growth of glacial lakes since 1990. *Nature Climate Change*, *10*(10), 939–945. <https://doi.org/10.1038/s41558-020-0855-4>
- Silva Júnior, J. A. da, & Pacheco, A. da P. (2023). Evaluation of Spectral Indices for Mapping Burned Areas using Unsupervised Classification in Different Ecosystems using Spectral Indices from Sentinel-2 images. *Revista Brasileira de Cartografia*, *75*. <https://doi.org/10.14393/rbcv75n0a-68307>
- Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). Applications of Remote Sensing in Precision Agriculture: A Review. *Remote Sensing*, *12*(19), 3136. <https://doi.org/10.3390/rs12193136>
- Soto Carrión, C., Zuñiga Negrón, J. J., Paucar Ancco, J., Jiménez Mendoza, W., Ibarra Cabrera, M. J., Narváez Licerias, A., & Paucar Ancco, S. (2022). Multi-Temporal Analysis of the Glacier Retreat Using Landsat Satellite Images in the Nevado of the Ampay National Sanctuary, Peru. *Journal of Sustainable Development of Energy, Water and Environment Systems*, *10*(1), 1–15. <https://doi.org/10.13044/j.sdewes.d8.0380>
- Sriwongsitanon, N., Gao, H., Savenije, H. H. G., Maekan, E., Saengsawang, S., & Thianpopirug, S. (2016). Comparing the Normalized Difference Infrared Index (NDII) with root zone storage in a lumped conceptual model. *Hydrology*

*and Earth System Sciences*, 20(8), 3361–3377. <https://doi.org/10.5194/hess-20-3361-2016>

Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., & Brisco, B. (2020). Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 152–170. <https://doi.org/10.1016/j.isprsjprs.2020.04.001>

Tarrillo Ruiz, N. de los A. (2023). Deglaciación del nevado Palcaraju y probable desbordamiento de la laguna Palcacocha. Consecuencias futuras y posibles acciones. *Justicia Ambiental*, 3(3), 93–114. <https://doi.org/10.35292/justiciaambiental.v3i3.687>

Teixeira Pinto, C., Chittimalli, S., Leigh, L., Ruggles, T., & Helder, D. L. (2017). A reflectance-based cross calibration of the Landsat sensors. In J. J. Butler, X. (Jack) Xiong, & X. Gu (Eds.), *Earth Observing Systems XXII* (p. 21). SPIE. <https://doi.org/10.1117/12.2275993>

Thompson, L. G., Davis, M. E., Mosley-Thompson, E., Porter, S. E., Corrales, G. V., Shuman, C. A., & Tucker, C. J. (2021). The impacts of warming on rapidly retreating high-altitude, low-latitude glaciers and ice core-derived climate records. *Global and Planetary Change*, 203, 103538. <https://doi.org/10.1016/j.gloplacha.2021.103538>

- Townshend, J. R., Masek, J. G., Huang, C., Vermote, E. F., Gao, F., Channan, S., Sexton, J. O., Feng, M., Narasimhan, R., Kim, D., Song, K., Song, D., Song, X.-P., Noojipady, P., Tan, B., Hansen, M. C., Li, M., & Wolfe, R. E. (2012). Global characterization and monitoring of forest cover using Landsat data: opportunities and challenges. *International Journal of Digital Earth*, 5(5), 373–397. <https://doi.org/10.1080/17538947.2012.713190>
- Turpo Cayo, E. Y. (2018). *Modelagem de mudancas espaco-temporais de ambientes glaciais dos andes do sul-PERU*.
- Turpo Cayo, E. Y., Borja, M. O., Espinoza-Villar, R., Moreno, N., Camargo, R., Almeida, C., Hopfgartner, K., Yarleque, C., & Souza, C. M. (2022). Mapping Three Decades of Changes in the Tropical Andean Glaciers Using Landsat Data Processed in the Earth Engine. *Remote Sensing*, 14(9), 1974. <https://doi.org/10.3390/rs14091974>
- Ubeda Palenque, J. (2011). *El impacto del cambio climático en los glaciares del complejo volcánico Nevado Coropuna,(Cordillera Occidental de los Andes Centrales)*.
- USGS. (2024, February 6). *Cronología de las misiones Landsat*. United States Geological Survey. <https://www.usgs.gov/media/images/landsat-missions-timeline>

- Valois, R., Schaffer, N., Figueroa, R., Maldonado, A., Yáñez, E., Hevia, A., Yáñez Carrizo, G., & MacDonell, S. (2020). Characterizing the Water Storage Capacity and Hydrological Role of Mountain Peatlands in the Arid Andes of North-Central Chile. *Water*, *12*(4), 1071. <https://doi.org/10.3390/w12041071>
- Vargas Huanca, D. E., Avendaño Condori, E., Alvarez Torres, E. M., & Aquino Santos, C. G. (2024). Destrucción de la Seguridad Hídrica y Minería en el Sur del Perú: ¿Un Atentado a las Generaciones Futuras? *Revista Seguridad y Poder Terrestre*, *3*(1). <https://doi.org/10.56221/spt.v3i1.48>
- Veetil, B. K., & Kamp, U. (2017). Remote sensing of glaciers in the tropical Andes: a review. *International Journal of Remote Sensing*, *38*(23), 7101–7137. <https://doi.org/10.1080/01431161.2017.1371868>
- Veetil, B. K., & Kamp, U. (2019). Global Disappearance of Tropical Mountain Glaciers: Observations, Causes, and Challenges. *Geosciences*, *9*(5), 196. <https://doi.org/10.3390/geosciences9050196>
- Velastegui-Montoya, A., Montalván-Burbano, N., Carrión-Mero, P., Rivera-Torres, H., Sadeck, L., & Adami, M. (2023). Google Earth Engine: A Global Analysis and Future Trends. *Remote Sensing*, *15*(14), 3675. <https://doi.org/10.3390/rs15143675>

- Veldkamp, A., & Lambin, E. F. (2001). Predicting land-use change. *Agriculture, Ecosystems & Environment*, 85(1–3), 1–6. [https://doi.org/10.1016/S0167-8809\(01\)00199-2](https://doi.org/10.1016/S0167-8809(01)00199-2)
- Verburg, P. H., Schot, P. P., Dijst, M. J., & Veldkamp, A. (2004). Land use change modelling: current practice and research priorities. *GeoJournal*, 61(4), 309–324. <https://doi.org/10.1007/s10708-004-4946-y>
- Verma, B., Porwal, M., Jha, A. K., Vyshnavi, R. G., Rajpoot, A., & Nagar, A. K. (2023). Enhancing Precision Agriculture and Environmental Monitoring Using Proximal Remote Sensing. *Journal of Experimental Agriculture International*, 45(8), 162–176. <https://doi.org/10.9734/jeai/2023/v45i82168>
- Vilcanqui-Alarcón, A., Pino-Vargas, E., & Vargas-Bernuy, J. (2022). Geomorphological alteration in relation to anthropic actions in the Caplina riverbed, Tacna, Peru. *Agroindustrial Science*, 12(1), 47–58. <https://doi.org/10.17268/agroind.sci.2022.01.06>
- Von Neumann, J., & Burks, A. W. (1966). Theory of self-reproducing automata. *IEEE Transactions on Neural Networks*, 5(1), 3–14.
- Vuille, M., Francou, B., Wagnon, P., Juen, I., Kaser, G., Mark, B. G., & Bradley, R. S. (2008). Climate change and tropical Andean glaciers: Past, present and future. *Earth-Science Reviews*, 89(3–4), 79–96. <https://doi.org/10.1016/j.earscirev.2008.04.002>

- Wang, H., Wang, B.-B., Cui, P., Ma, Y.-M., Wang, Y., Hao, J.-S., Wang, Y., Li, Y.-M., Sun, L.-J., Wang, J., Zhang, G.-T., Li, W.-M., Lei, Y., Zhao, W.-Q., Tang, J.-B., & Li, C.-Y. (2024). Disaster effects of climate change in High Mountain Asia: State of art and scientific challenges. *Advances in Climate Change Research*, 15(3), 367–389. <https://doi.org/10.1016/j.accre.2024.06.003>
- Warrens, M. J. (2015). Relative quantity and allocation disagreement measures for category-level accuracy assessment. *International Journal of Remote Sensing*, 36(23), 5959–5969. <https://doi.org/10.1080/01431161.2015.1110265>
- White, D. C., Lewis, M. M., Green, G., & Gotch, T. B. (2016). A generalizable NDVI-based wetland delineation indicator for remote monitoring of groundwater flows in the Australian Great Artesian Basin. *Ecological Indicators*, 60, 1309–1320. <https://doi.org/10.1016/j.ecolind.2015.01.032>
- Woodcock, C. E., Loveland, T. R., Herold, M., & Bauer, M. E. (2020). Transitioning from change detection to monitoring with remote sensing: A paradigm shift. *Remote Sensing of Environment*, 238, 111558. <https://doi.org/10.1016/j.rse.2019.111558>
- Wulder, M. A., White, J. C., Loveland, T. R., Woodcock, C. E., Belward, A. S., Cohen, W. B., Fosnight, E. A., Shaw, J., Masek, J. G., & Roy, D. P. (2016). The global Landsat archive: Status, consolidation, and direction. *Remote*

*Sensing of Environment*, 185, 271–283.  
<https://doi.org/10.1016/j.rse.2015.11.032>

Xie, F., Gu, W., Ha, S., Cui, W., Chen, W., Zhou, C., Huang, S., & Liu, Z. (2006). An experimental study on the spectral characteristics of one year-old sea ice in the Bohai Sea, China. *International Journal of Remote Sensing*, 27(14), 3057–3063. <https://doi.org/10.1080/01431160600589153>

Xu, C., Qu, J. J., Hao, X., & Wu, D. (2020). Monitoring Surface Soil Moisture Content over the Vegetated Area by Integrating Optical and SAR Satellite Observations in the Permafrost Region of Tibetan Plateau. *Remote Sensing*, 12(1), 183. <https://doi.org/10.3390/rs12010183>

Yager, K., Prieto, M., & Meneses, R. I. (2021). Reframing Pastoral Practices of Bofedal Management to Increase the Resilience of Andean Water Towers. *Mountain Research and Development*, 41(4). <https://doi.org/10.1659/MRD-JOURNAL-D-21-00011.1>

Yao, W., Donohue, S., & Dev, S. (2023). Optimizing Remote Sensing Image Classification with Spectral Indices and Convolutional Neural Networks. *2023 IEEE 7th Conference on Energy Internet and Energy System Integration (EI2)*, 3628–3633. <https://doi.org/10.1109/EI259745.2023.10513303>

Yao, X., Liu, S., Han, L., Sun, M., & Zhao, L. (2018). Definition and classification system of glacial lake for inventory and hazards study. *Journal of*

*Geographical Sciences*, 28(2), 193–205. <https://doi.org/10.1007/s11442-018-1467-z>

Zanter, K. (2016). Landsat 8 (L8) data users handbook. *Landsat Science Official Website*, 33.

Zhang, C., & Jiang, L. (2022). Fractional Snow Cover Mapping with High Spatiotemporal Resolution based on Landsat, Sentinel-2 And Modis Observation. *IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium*, 3935–3938. <https://doi.org/10.1109/IGARSS46834.2022.9884171>

Zhao, F., Gong, W., Bianchini, S., & Yang, Z. (2024). Linking glacier retreat with climate change on the Tibetan Plateau through satellite remote sensing. *The Cryosphere*, 18(12), 5595–5612. <https://doi.org/10.5194/tc-18-5595-2024>

Zhao, Q., Yu, L., Li, X., Peng, D., Zhang, Y., & Gong, P. (2021). Progress and Trends in the Application of Google Earth and Google Earth Engine. *Remote Sensing*, 13(18), 3778. <https://doi.org/10.3390/rs13183778>

Zhu, Z. (2017). Change detection using landsat time series: A review of frequencies, preprocessing, algorithms, and applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 370–384. <https://doi.org/10.1016/j.isprsjprs.2017.06.013>

Zhuang, L., Ke, C., Cai, Y., & Nourani, V. (2023). Measuring glacier changes in the Tianshan Mountains over the past 20 years using Google Earth Engine and machine learning. *Journal of Geographical Sciences*, 33(9), 1939–1964. <https://doi.org/10.1007/s11442-023-2160-4>

## **Anexos**

## ANEXO I. Matriz de Consistencia

Definición del Problema	Objetivos	Hipótesis	Variables	Indicadores	Metodología
<p><b>Problema general</b></p> <p>¿Cómo puede el uso de datos satelitales, mediante técnicas de teledetección, análisis multitemporales y modelos predictivos como los autómatas celulares, mejorar la precisión en la reconstrucción y proyección de la dinámica de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna?</p>	<p><b>Objetivo General:</b></p> <p>Realizar un análisis multitemporal de glaciares, bofedales y lagunas glaciares, y desarrollar un modelo predictivo basado en autómatas celulares para proyectar su evolución futura en la Cordillera del Barroso, Tacna.</p>	<p><b>Hipótesis General</b></p> <p>La integración de análisis multitemporales de datos satelitales, aplicando técnicas avanzadas de teledetección y modelado mediante autómatas celulares, permite proyectar de forma precisa y eficiente la evolución futura de los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.</p>	<p><b>Variable Dependiente</b></p> <p>Precisión en la reconstrucción y proyección de la dinámica de glaciares, bofedales y lagunas glaciares.</p>	<p><b>Indicador (VD)</b></p> <ul style="list-style-type: none"> <li>• Coeficiente Kappa de validación.</li> <li>• Error de omisión y comisión.</li> <li>• Matriz de confusión.</li> <li>• Mapas temáticos</li> </ul>	<p><b>Tipo de investigación</b></p> <ul style="list-style-type: none"> <li>• Aplicada</li> </ul> <p><b>Nivel:</b></p> <ul style="list-style-type: none"> <li>• Descriptivo</li> <li>• Predictiva</li> </ul> <p><b>Método:</b></p> <ul style="list-style-type: none"> <li>• Descriptivo</li> <li>• Explicativo</li> <li>• Predictivo</li> </ul> <p><b>Población:</b></p> <p>Glaciares, bofedales y lagunas glaciares de la Cordillera del Barroso, Tacna.</p> <p><b>Muestra:</b></p> <p>Coberturas derivadas de imágenes satelitales Landsat correspondientes a los años 1985 Y 2022.</p> <p><b>Técnicas:</b></p> <ul style="list-style-type: none"> <li>• Teledetección y análisis geoespacial (SIG).</li> <li>• Modelado predictivo basado en autómatas celulares.</li> </ul> <p><b>Instrumentos:</b></p> <ul style="list-style-type: none"> <li>• QGIS 3.28.15</li> <li>• Google Earth Engine</li> <li>• Python 3.14.0</li> </ul>
<p><b>Problemas específicos</b></p> <ul style="list-style-type: none"> <li>• ¿Cuál es la cobertura actual de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, y cómo puede ser clasificada con precisión mediante técnicas de teledetección y análisis SIG?</li> <li>• ¿Cómo ha cambiado la cobertura de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso a lo largo del tiempo, y qué patrones de transformación pueden identificarse mediante análisis multitemporales?</li> <li>• ¿Qué grado de precisión y confiabilidad presentan los modelos predictivos, basados en autómatas celulares, al proyectar escenarios futuros de pérdida o transformación de estos ecosistemas?</li> </ul>	<p><b>Objetivos específicos</b></p> <ul style="list-style-type: none"> <li>• Identificar y clasificar la cobertura de glaciares, bofedales y lagunas glaciares mediante imágenes satelitales y técnicas de teledetección en SIG, evaluando la precisión de la clasificación en la Cordillera del Barroso, Tacna.</li> <li>• Analizar la dinámica de cambio de cobertura en los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.</li> <li>• Desarrollar un modelo predictivo basado en Autómatas Celulares para proyectar la evolución futura de los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.</li> </ul>	<p><b>Hipótesis Específica</b></p> <ul style="list-style-type: none"> <li>• El procesamiento de imágenes satelitales mediante técnicas de teledetección y análisis geoespacial en sistemas de información geográfica (SIG) permite identificar y clasificar con precisión la cobertura de glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.</li> <li>• El análisis multitemporal de datos satelitales revela patrones significativos en la dinámica de cambio de cobertura de los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.</li> <li>• Un modelo predictivo basado en autómatas celulares es capaz de simular de manera efectiva la evolución futura de los glaciares, bofedales y lagunas glaciares en la Cordillera del Barroso, Tacna.</li> </ul>	<p><b>Variable Independiente</b></p> <ul style="list-style-type: none"> <li>• Análisis multitemporal de datos satelitales.</li> <li>• Técnicas de teledetección y SIG.</li> <li>• Modelos predictivos (Autómatas Celulares).</li> </ul>	<p><b>Indicador (VI)</b></p> <ul style="list-style-type: none"> <li>• Años históricos analizados (1985-2022).</li> <li>• Cambios de cobertura áreas en (km y %).</li> <li>• Método de clasificación basado en umbrales (NDVI, NDSI, NDII y NDWI).</li> <li>• Variables topográficas: Altitud (m), pendiente (%) aspecto (°), sombra de relieve y curvatura (horizontal y vertical).</li> <li>• Escenario de extensión futura (años 2032, 2042).</li> </ul>	

**ANEXO II.** *Tabla de resultados de superficie glaciar, bofedales y cuerpos de agua en (km<sup>2</sup>) en la Cordillera del Barroso*

Año	Glaciar	Variación	Bofedal	Variación	Lagunas	Variación
1984	38,149		3,650		1,667	
1985	34,467	-3,682	3,795	0,146	2,143	0,476
1986	44,642	10,175	5,700	1,904	3,013	0,870
1987	4,103	-40,539	6,849	1,149	2,317	-0,696
1988	4,011	-0,092	6,343	-0,506	2,979	0,662
1989	25,749	21,738	5,052	-1,291	2,592	-0,387
1990	17,817	-7,932	3,848	-1,205	2,109	-0,483
1991	8,725	-9,092	1,773	-2,074	1,727	-0,382
1992	0,472	-8,253	1,188	-0,585	1,269	-0,457
1993	11,938	11,467	3,972	2,784	2,340	1,070
1994	7,935	-4,003	6,777	2,805	2,808	0,468
1995	1,912	-6,023	6,548	-0,230	2,151	-0,657
1996	3,312	1,399	6,154	-0,393	2,510	0,359
1997	33,340	30,028	6,004	-0,150	4,180	1,670
1998	2,027	-31,312	7,751	1,748	3,681	-0,499
1999	30,536	28,508	8,974	1,223	2,997	-0,684
2000	22,592	-7,943	5,337	-3,638	3,646	0,649
2001	38,272	15,680	10,879	5,543	3,970	0,324
2002	31,558	-6,714	11,878	0,999	4,033	0,063
2003	18,504	-13,054	9,106	-2,772	3,468	-0,565
2004	5,613	-12,891	8,407	-0,699	3,232	-0,236
2005	5,119	-0,494	6,886	-1,521	3,572	0,340
2006	16,582	11,463	7,862	0,976	4,214	0,642
2007	5,368	-11,215	7,742	-0,120	3,710	-0,504
2008	2,255	-3,113	6,853	-0,889	3,487	-0,223
2009	6,125	3,870	6,173	-0,680	3,288	-0,199
2010	1,861	-4,264	12,771	6,599	2,625	-0,663
2011	15,552	13,691	6,901	-5,871	3,785	1,160
2012	32,631	17,080	8,759	1,859	4,301	0,516
2013	11,561	-21,070	14,609	5,849	4,315	0,014
2014	0,253	-11,308	10,974	-3,635	2,959	-1,356
2015	19,884	19,631	14,216	3,242	4,399	1,440
2016	1,515	-18,369	13,601	-0,616	3,629	-0,770
2017	12,576	11,061	11,962	-1,638	4,247	0,618
2018	22,482	9,905	12,309	0,346	4,267	0,020
2019	3,953	-18,529	13,538	1,229	4,263	-0,004
2020	14,114	10,161	16,157	2,619	4,756	0,493
2021	9,666	-4,448	14,019	-2,138	4,635	-0,121
2022	7,413	-2,253	12,067	-1,953	4,394	-0,241

**ANEXO III.** *Matriz de probabilidad de transición, período 2012-2022, para la predicción al 2042*

MOLUSCE

Datos de entrada | Evaluación de la correlación | Cambio de Territorios | Modelización del Potencial de Transición | Simulación de Autómatas Celulares | Validación | Mensajes

Estadísticas por clases cuadrados km

Color de la clase	2012	2022	Δ	2012 %	2022 %	Δ %
1	1404.52 cuadrados km	1426.23 cuadrados km	21.72 cuadrados km	96.85054030101954	98.34794243739931	1.497402136379776
2	8.81 cuadrados km	12.14 cuadrados km	3.33 cuadrados km	0.607761071019857	0.8373859012836649	0.22962483026380787
3	32.57 cuadrados km	7.42 cuadrados km	-25.15 cuadrados km	2.2461032045696583	0.5116910068986746	-1.7344121976709836
4	4.29 cuadrados km	4.39 cuadrados km	0.11 cuadrados km	0.2955954233909506	0.3029806544183541	0.007385231027403516

Matriz de transiciones

	1	2	3	4
1	0.9963193077427821	0.003402589812992126	7.497231791338583e-05	0.00020313012631233596
2	0.16440314510364545	0.8355968548963545	0.0	0.0
3	0.7739832007073386	0.0	0.22438660477453579	0.0016301945181255526
4	0.052487927776611376	0.0	0.0014696619777451185	0.9460424102456435

Actualizar tablas Crear un mapa de cambios

*Nota.* Elaborado en el software QGIS, plugin MOLUSCE

**ANEXO IV.** *Matriz de tabulación cruzada, tasa de cambios para las cuatro clases en los cinco períodos de análisis*

*observados*

1986	2001				Total 2001 (Km <sup>2</sup> )	Tasa de cambio	Pérdida (Li)	Cambio total (Ct)	Cambio neto (Cn)	Intercambio (Int)
	OT	BO	GL	CA						
Otros (OT)	1383,19	6,17	7,47	1,16	1398,00	0,00	1,06	2,13	0,01	2,12
Bofedales (BO)	0,82	4,98	0,00	0,01	5,81	4,45	14,24	120,53	92,04	28,49
Glaciar (GL)	13,94	0,00	30,99	0,01	44,95	-1,03	31,05	47,68	14,42	33,27
Cuerpo de agua (CA)	0,23	0,00	0,00	2,80	3,04	1,81	7,95	46,86	30,96	15,91
<b>Total 1986 (Km<sup>2</sup>)</b>	1398,19	11,15	38,47	3,99	<b>1451,79</b>					
Ganancia (G <sub>j</sub> ) %	<b>1,07</b>	<b>106,29</b>	<b>16,63</b>	<b>38,91</b>						

2001	2012				Total 2012 (Km <sup>2</sup> )	Tasa de cambio	Pérdida (Li)	Cambio total (Ct)	Cambio neto (Cn)	Intercambio (Int)
	OT	BO	GL	CA						
Otros (OT)	1393,47	1,314	2,963	0,40	1398,15	0,04	0,33	1,22	0,55	0,67
Bofedales (BO)	3,49	7,65	0,00	0,00	11,14	-1,44	31,32	43,12	19,52	23,60
Glaciar (GL)	8,78	0,00	29,80	0,04	38,62	-1,09	22,85	30,52	15,18	15,34
Cuerpo de agua (CA)	0,12	0,00	0,00	3,87	3,99	0,52	2,98	14,10	8,13	5,97
<b>Total 2001 (Km<sup>2</sup>)</b>	1405,86	8,96	32,76	4,31	<b>1451,89</b>					
Ganancia (G <sub>j</sub> ) %	<b>0,89</b>	<b>11,80</b>	<b>7,67</b>	<b>11,11</b>						

2012	2022				Total 2022 (Km <sup>2</sup> )	Tasa de cambio	Perdida (Li)	Cambio total (Ct)	Cambio neto (Cn)	Intercambio (Int)
	OT	BO	GL	CA						
Otros (OT)	1400,25	5,00	0,11	0,31	1405,67	0,10	0,39	2,31	1,54	0,77
Bofedales (BO)	1,50	7,43	0,00	0,00	8,93	2,23	16,80	72,76	39,15	33,61
Glaciar (GL)	25,32	0,00	7,35	0,05	32,72	-9,38	77,54	77,90	77,17	0,73
Cuerpo de agua (CA)	0,23	0,00	0,01	4,06	4,30	0,19	5,54	13,96	2,89	11,08
<b>Total 2012 (Km<sup>2</sup>)</b>	<b>1;427,30</b>	<b>12,43</b>	<b>7,47</b>	<b>4,42</b>	<b>1451,62</b>					
Ganancia (G <sub>j</sub> ) %	<b>1,92</b>	<b>55,96</b>	<b>0,37</b>	<b>8,42</b>						

1986	2022				Total 1990 (Km <sup>2</sup> )	Tasa de cambio	Perdida (Li)	Cambio total (Ct)	Cambio neto (Cn)	Intercambio (Int)
	OT	BO	GL	CA						
Otros (OT)	1388,45	7,85	0,10	1,49	1397,89	0,14	0,68	3,46	2,10	1,35
Bofedales (BO)	1,27	4,52	0,00	0,01	5,80	5,17	22,17	157,44	113,09	44,35
Glaciar (GL)	37,35	0,00	7,36	0,12	44,83	-11,26	83,58	83,82	83,33	0,49
Cuerpo de agua (CA)	0,23	0,00	0,01	2,80	3,04	2,53	7,84	61,23	45,55	15,68
<b>Total 1986 (Km<sup>2</sup>)</b>	<b>1427,31</b>	<b>12,37</b>	<b>7,47</b>	<b>4,42</b>	<b>1451,57</b>					
Ganancia (G <sub>j</sub> ) %	<b>2,78</b>	<b>135,27</b>	<b>0,25</b>	<b>53,39</b>						

**ANEXO V. Matriz de tabulación cruzada, tasa de cambios para las cuatro clases en los tres períodos de análisis  
predichos**

2022	2032				Total 2032 (Km <sup>2</sup> )	Tasa de cambio	Pérdida (Li)	Cambio total (Ct)	Cambio neto (Cn)	Intercambio (Int)
	OT	BO	GL	CA						
Otros (OT)	1421,95	5,31	0,12	0,33	1427,70	0,00	0,40	0,78	0,03	0,75
Bofedales (BO)	1,55	10,83	0,00	0,00	12,38	1,78	12,51	55,39	30,36	25,03
Glaciar (GL)	3,56	0,00	3,98	0,05	7,58	-4,01	47,51	49,14	45,87	3,27
Cuerpo de agua (CA)	0,23	0,00	0,01	4,19	4,42	0,21	5,29	13,70	3,12	10,58
<b>Total 2022 (Km<sup>2</sup>)</b>	1427,28	16,14	4,10	4,56	<b>1452,08</b>					
Ganancia (G <sub>j</sub> ) %	<b>0,37</b>	<b>42,87</b>	<b>1,64</b>	<b>8,41</b>						


2032	2042				Total 2042 (Km <sup>2</sup> )	Tasa de cambio	Pérdida (Li)	Cambio total (Ct)	Cambio neto (Cn)	Intercambio (Int)
	OT	BO	GL	CA						
Otros (OT)	1420,53	6,51	0,19	0,61	1427,84	-0,01	0,51	0,83	0,20	0,63
Bofedales (BO)	2,81	13,40	0,00	0,00	16,21	1,38	17,32	57,50	22,85	34,65
Glaciar (GL)	1,24	0,00	2,94	0,00	4,18	-1,89	29,64	34,40	24,89	9,51
Cuerpo de agua (CA)	0,47	0,00	0,01	4,10	4,58	0,19	10,48	23,83	2,86	20,97
<b>Total 2032 (Km<sup>2</sup>)</b>	1425,04	19,91	3,14	4,71	<b>1452,81</b>					
Ganancia (G <sub>j</sub> ) %	<b>0,32</b>	<b>40,18</b>	<b>4,76</b>	<b>13,35</b>						

1986	2042				Total 2042 (Km <sup>2</sup> )	Tasa de cambio	Perdida (L <sub>i</sub> )	Cambio total (C <sub>t</sub> )	Cambio neto (C <sub>n</sub> )	Intercambio (Int)
	OT	BO	GL	CA						
Otros (OT)	1380,75	16,00	0,11	1,92	1398,77	0,12	1,29	4,44	1,86	2,58
Bofedales (BO)	2,02	3,84	0,00	0,01	5,87	8,46	34,63	307,47	238,20	69,27
Glaciar (GL)	41,63	0,00	3,03	0,18	44,84	-16,24	93,24	93,49	93,00	0,49
Cuerpo de agua (CA)	0,44	0,00	0,01	2,60	3,05	2,96	14,57	83,95	54,81	29,14
<b>Total 1986 (Km<sup>2</sup>)</b>	1424,83	19,84	3,14	4,72	<b>1452,53</b>					
Ganancia (G <sub>j</sub> ) %	<b>3,15</b>	<b>272,83</b>	<b>0,25</b>	<b>69,38</b>						

## ANEXO VI. Evaluación de la precisión del LULC 1986-2022

AÑO	LULC	OT	BO	GL	CA	Total	Exactitud usuario	Error comisión	Coefficiente Kappa
1986	Otros (OT)	139	0	2	3	144	0,97	0,03	0,94
	Bofedales (BO)	6	93	0	1	100	0,93	0,07	
	Glaciar (GL)	1	0	97	2	100	0,97	0,03	
	Cuerpo de agua (CA)	2	0	0	38	40	0,95	0,05	
	Total	148	93	99	44	384			
	Exactitud productor	0,94	1,00	0,98	0,86				
	Error omisión	0,06	0,00	0,02	0,14				
Precisión global						<b>0,97</b>			
2001	Otros (OT)	159	19	17	2	197	0,81	0,19	0,83
	Bofedales (BO)	2	78	1	0	81	0,96	0,04	
	Glaciar (GL)	1	0	66	0	67	0,99	0,01	
	Cuerpo de agua (CA)	2	0	0	37	39	0,95	0,05	
	Total	164	97	84	39	384			
	Exactitud productor	0,97	0,80	0,79	0,95				
	Error omisión	0,03	0,20	0,21	0,05				
Precisión global						<b>0,89</b>			
2012	Otros (OT)	169	9	4	2	184	0,92	0,08	0,92
	Bofedales (BO)	4	56	0	0	60	0,93	0,07	
	Glaciar (GL)	1	0	79	0	80	0,99	0,01	
	Cuerpo de agua (CA)	1	0	0	59	60	0,98	0,02	
	Total	175	65	83	61	384			
	Exactitud productor	0,97	0,86	0,95	0,97				
	Error omisión	0,03	0,14	0,05	0,03				
Precisión global						<b>0,92</b>			
2022	Otros (OT)	133	20	1	0	154	0,86	0,14	0,90
	Bofedales (BO)	1	89	0	0	90	0,99	0,01	
	Glaciar (GL)	3	1	76	0	80	0,95	0,05	
	Cuerpo de agua (CA)	1	0	1	58	60	0,97	0,03	
	Total	138	110	78	58	384			
	Exactitud productor	0,96	0,81	0,97	1,00				
	Error omisión	0,04	0,19	0,03	0,00				
Precisión global						<b>0,87</b>			


**ANEXO VII. Mapa de ubicación del área de investigación**



 <p><b>UNIVERSIDAD NACIONAL JORGE BASADRE GROHMANN</b>  <b>FACULTAD DE INGENIERIA CIVIL, ARQUITECTURA Y GEOTECNIA</b>  <b>ESCUELA PROFESIONAL DE INGENIERIA GEOLOGIA - GEOTECNICA</b></p> 			
<p><b>TESIS:</b> ANÁLISIS MULTITEMPORAL DE GLACIARES, BOFEDALES Y LAGUNAS GLACIARES Y SU PREDICCIÓN BASADO EN AUTOMATAS CELULARES, CASO: CORDILLERA DEL BARROSO, TACNA, PERÚ</p>			
<p><b>PLANO:</b> MAPA DE UBICACION</p>			<p><b>CODIGO:</b> MU-01</p>
<p><b>SIG:</b> German Huayna Felipe</p>	<p><b>DATUM:</b> WGS 84, Zona 19 S</p>	<p><b>ESCALA:</b> 1 / 500,000</p>	<p><b>FECHA:</b> Marzo, 2025</p>
<p><b>DEPARTAMENTO:</b> TACNA</p>			

*Nota.* El mapa fue elaborado en el software ArcGIS, con datos proporcionados por GEE.

ANEXO VIII. Retroceso glaciar en la cordillera del Barroso



Nota. El mapa fue elaborado en el software ArcGIS, con datos proporcionados por GEE