

MAPBIOMAS  
[AGUA]



## **Documento Metodológico de Superficie Glaciar**

Colección 4

Versión 1

Junio 2026

# Contenido

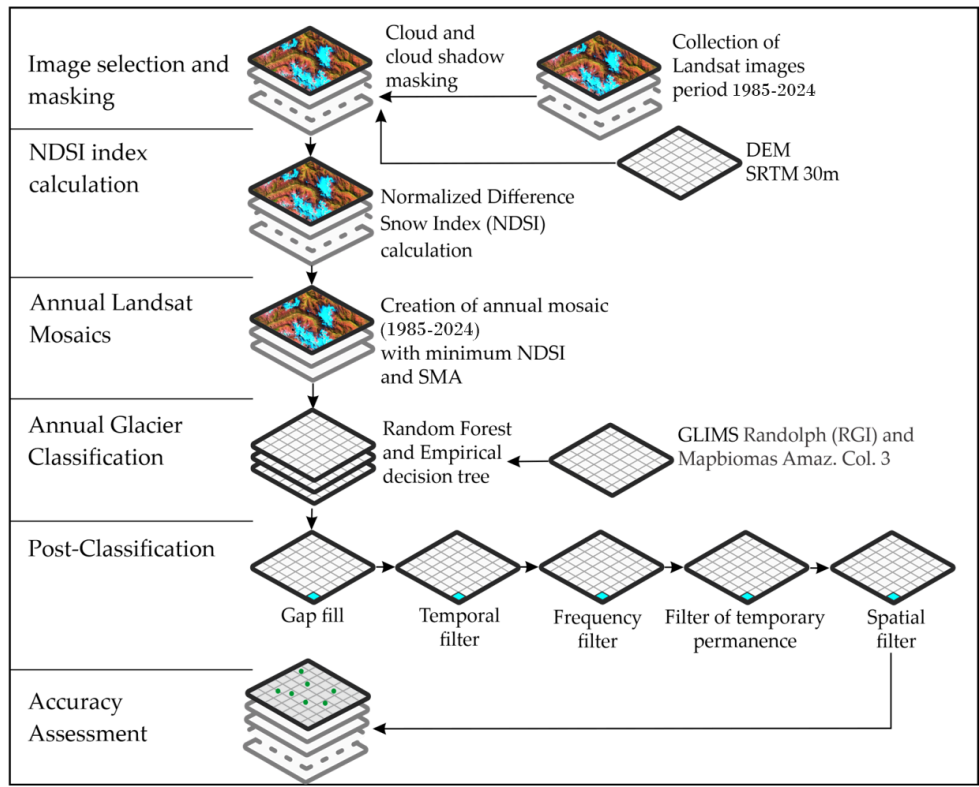
1.	Introducción	3
1.1.	Área de Estudio	4
2.	Mosaicos de imágenes	4
3.	Clasificación	5
3.1.	Variables de clasificación	6
3.2.	Mapas de referencia	7
4.	Post – clasificación	7
4.1.	Llenado de vacíos de información (Gap Fill)	8
4.2.	Filtro temporal	8
4.3.	Filtro de años base	10
4.4.	Filtro de frecuencia	12
4.5.	Enmascaramiento de lagunas	13
4.6.	Filtro de permanencia temporal	14
4.7.	Filtro espacial	14
4.8.	Integración con las otras clases MapBiomias Amazonía	15
5.	Consideraciones finales	15
6.	Referencias	16

## **1. Introducción**

La cartografía de los glaciares es difícil y peligrosa debido a la lejanía y la inaccesibilidad del terreno y los desafíos para realizar un extenso trabajo de campo (Racoviteanu et al., 2009). En este contexto, los datos obtenidos por satélites obtenidos por teledetección proporcionan información valiosa sobre los glaciares y los accidentes geográficos asociados. Es importante señalar que la selección juiciosa de bandas espectrales es fundamental en el mapeo de las características glaciales (Huang et al., 2021) . Los accidentes glaciares en la cuenca amazónica, en el bioma andes, se han delineado utilizando bandas seleccionadas de los datos del programa Landsat (Philip & Ravindran, 1998). La gran mayoría de las altas montañas con glaciares han experimentado una reducción acelerada de los glaciares en las últimas décadas (Bařka et al., 2020; Turpo Cayo et al., 2022)

Los glaciares de montaña, particularmente en los trópicos, actualmente están disminuyendo rápidamente su extensión superficial (Turpo Cayo et al., 2022) y se consideran buenos indicadores del cambio climático, debido a su tiempo de respuesta relativamente rápido a las perturbaciones en las variables climáticas como la precipitación, la temperatura del aire y la humedad atmosférica (Kaser & Osmaston, 2002). Muchos glaciares tropicales, como los de Perú y Bolivia, son amortiguadores críticos contra la reducción de las precipitaciones durante la estación seca, más del 99% de los glaciares tropicales se encuentran en los Andes de América del Sur, incluidos Venezuela, Colombia, Ecuador, Perú, Bolivia, Chile y Argentina. Gran parte de la investigación se ha realizado utilizando datos de detección remota, ya que el terreno difícil presenta desafíos para realizar un extenso trabajo de campo (Veettil & Kamp, 2019).

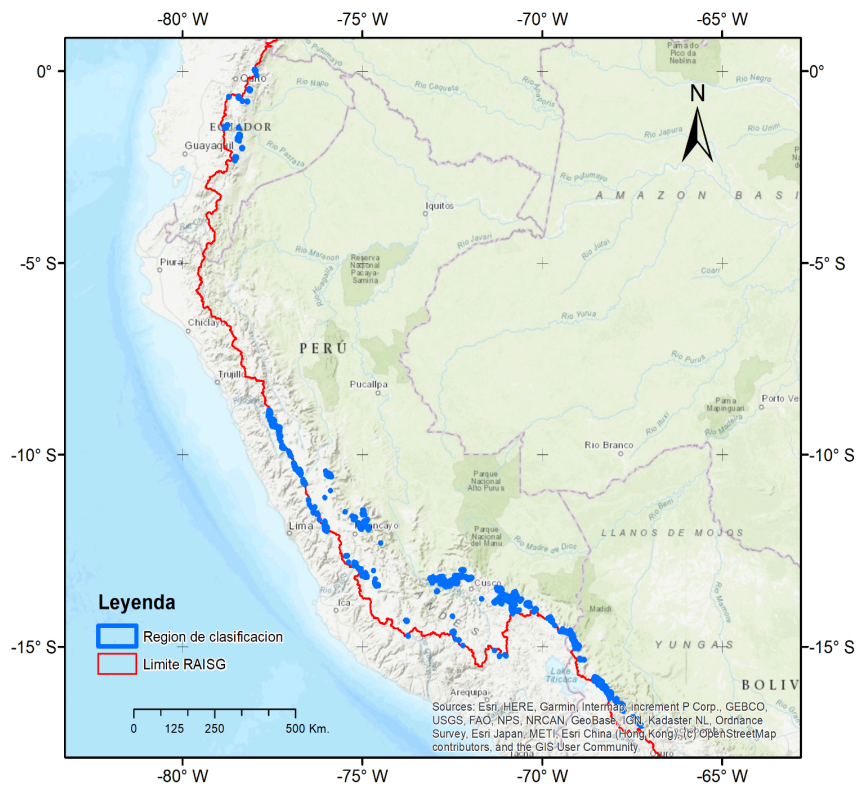
En este documento, presentamos una descripción de la metodología aplicada para el mapeo de los glaciares tropicales del Perú. El proceso completo se dividió en 6 etapas (Figura1).



**Figura 1** – Diagrama de flujo metodológico para la obtención de mapas de cobertura Glaciar

**1.1. Área de Estudio**

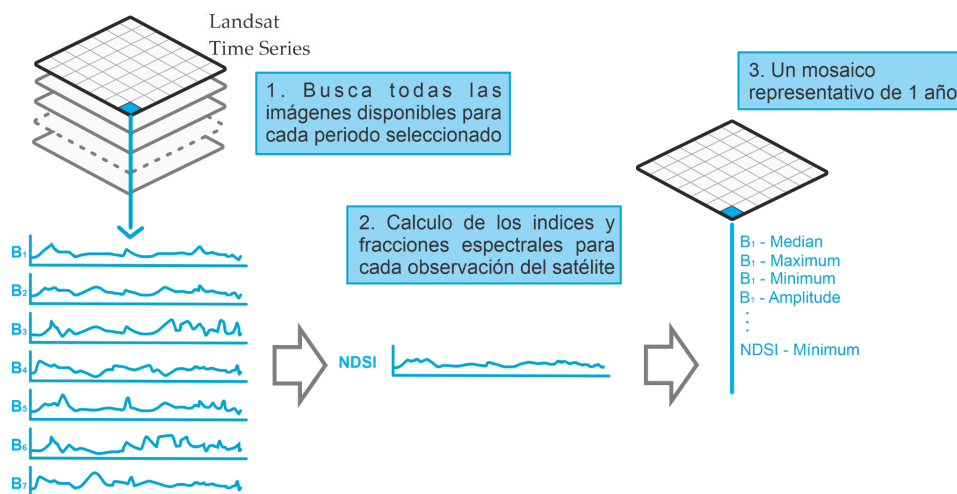
El área de estudio (Figura 2) se definió basado en el inventario de glaciares Randolph (RGI Consortium, 2017, p. 0), este ha sido cortado con el límite de Raisg. sobre la cual se ha aplicado un Buffer de 1.5 km para considerar área de clasificación.



**Figura 2** – Área de trabajo

## 2. Mosaicos de imágenes

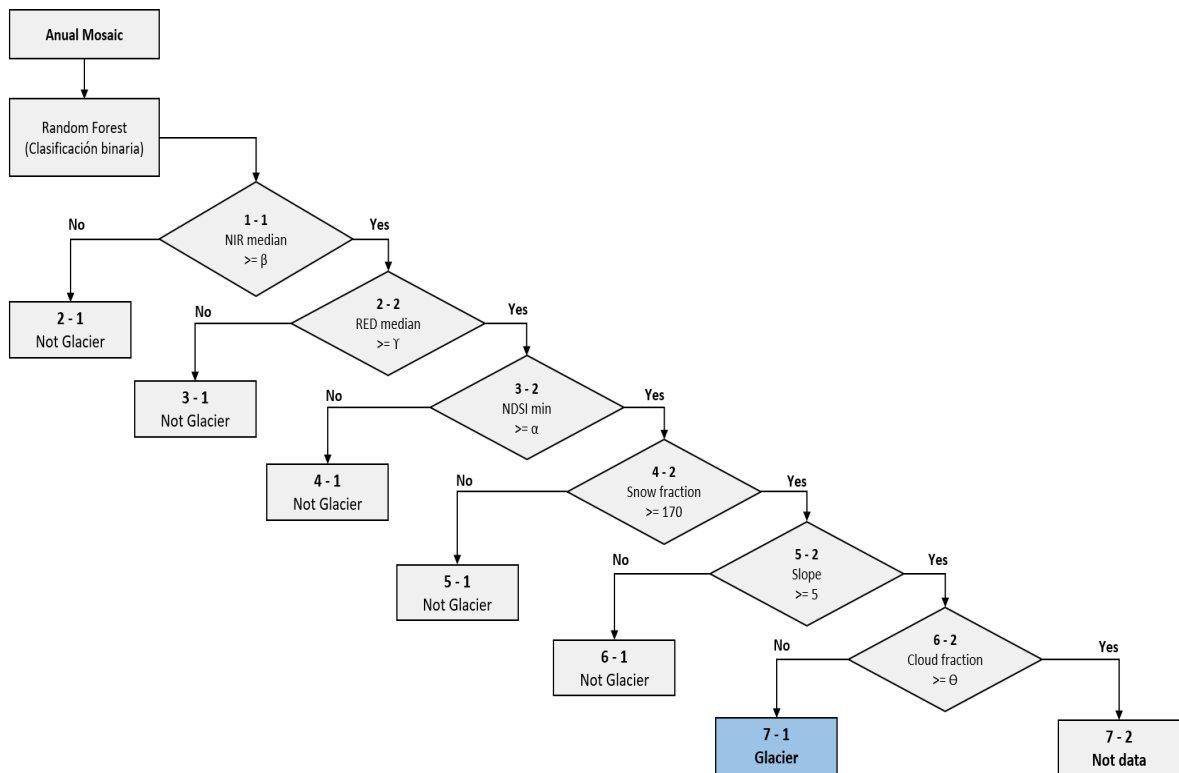
La clasificación del tema transversal “Glaciares” utilizó los mosaicos de imágenes Landsat generados específicamente para el mapeo de glaciares. Estos mosaicos contemplaban las imágenes con área glaciar mínimo anual, basado en el pixel de calidad de NDSI mínimo (Figura 3).



**Figura 3** – Creación de mosaicos anuales para el mapeo de Glaciares

## 3. Clasificación

La clasificación de los mosaicos Landsat se realizó íntegramente en la plataforma Google Earth Engine, basada en un árbol empírico (Figura 4).



**Figura 4** –Árbol empírico combinado con Random Forest para clasificación de Glaciares.

El sistema de clasificación de glaciares implementa un enfoque híbrido que combina aprendizaje automático con reglas de decisión específicas para diferentes sensores satelitales. El proceso de clasificación inicia con la generación de mosaicos anuales libres de nubes para cada año de estudio, utilizando imágenes Landsat de diferentes sensores (L5, L7, L8 y L9) según el periodo temporal.

La clasificación con Random Forest es refinada con un conjunto de reglas de decisión jerárquicas específicas para cada tipo de sensor. Para Landsat 5 y Landsat 7, se aplican umbrales de reflectancia NIR median (1-1) donde los valores son próximos a 0.2114, mientras que en Landsat 8 y Landsat 9 estos valores son próximos a 0.1730. En el caso de los umbrales para RED median (2-2), el valor estimado para Landsat 5 y Landsat 7 es de 0.2497, mientras que para Landsat 8 y 9 el valor estimado es de 0.2304.

La identificación final de glaciares se basa en una condición combinada que considera, NDSI mínimo (3-2), la fracción de nieve (4-2) y la pendiente (5-2). Esta clasificación dual nos permitirá capturar datos glaciares con alta reflectancia espectral en el infrarrojo cercano como aquellos en terrenos empinados con cobertura glaciar significativa. Finalmente, el proceso de clasificación aplica una condición en base a los valores de la fracción de nube (6-2), donde aquellos píxeles que superen el valor de 170 ( $\Theta$ ), son clasificados como píxeles “sin datos” y son descartados de la clasificación final, asegurando que solo píxeles con observaciones ideales sean incluidos en la clasificación final.

### 3.1. Variables de clasificación

El algoritmo de clasificación utiliza diferentes variables de clasificación, organizadas en cuatro categorías principales que capturan diferentes aspectos de la firma espectral y topográfica de las superficies glaciares.

La primera categoría comprende seis bandas espectrales utilizadas específicamente para la detección de glaciares, estos corresponden específicamente a valores medianos de época seca. Esta selección temporal es estratégica, ya que durante este período se minimiza la interferencia de nubes, también se minimiza la presencia de nieve y se maximiza la visibilidad de superficies glaciares, permitiendo una mejor discriminación espectral entre glaciares y otros tipos de cobertura.

La segunda categoría incluye el uso de índices espectrales, destacando las variaciones temporales del NDSI (Normalized Difference Snow Index) calculado para época seca, época húmeda y valor mínimo. El uso de este índice es fundamental para identificar superficies de nieve y hielo glaciar.

La tercera categoría incorpora la variable topográfica de pendiente derivada del modelo digital de elevación SRTM, la cual es crucial dado que los glaciares tropicales se encuentran típicamente en terrenos de alta montaña con topografía empinada, proporcionando un criterio geomorfológico adicional para la clasificación.

Finalmente, se incluyen las variables derivadas del análisis de mezcla espectral (Spectral Mixture Analysis - SMA). El SMA es una técnica de procesamiento que descompone la reflectancia de cada píxel en fracciones de diferentes materiales puros, proporcionando información cuantitativa sobre la composición sub-píxel de cada área. La fracción de nieve resulta particularmente relevante para distinguir superficies glaciares de otros tipos de cobertura en ambientes de alta montaña, mientras que las fracciones de nube y sombra contribuyen a identificar y filtrar píxeles con observaciones comprometidas.

**Tabla 1** – Bandas utilizadas para la clasificación

Tipo	Nombre	Fórmula	Descripción	Reductor <sup>1</sup>				
				Mediano	Mediano dry	Mediano wet	Mínimo	Máximo
Banda	blue	B1 (L5 y L7); B2 (L8)	Espectro visible azul		X			
	green	B2 (L5 y L7); B3 (L8)	Espectro visible verde		X			
	red	B3 (L5 y L7); B4 (L8)	Espectro visible rojo		X			
	nir	B4 (L5 y L7); B5 (L8)	Infrarrojo cercano		X			

	swir1	B5 (L5 y L7); B6 (L8)	Infrarrojo de onda corta 1		X			
	swir2	B7 (L5); B8 (L7); B7(L8)	Infrarrojo de onda corta 2		X			

**Tabla 2** – índices espectrales utilizadas para la clasificación

Tipo	Nombre	Fórmula	Descripción	Reductor <sup>1</sup>				
				Median	Median dry	Median Wet	Mín	Máx
Índices	NDSI	$\frac{green-swir1}{green+swir1}$	Índice Diferencial de Nieve Normalizado		X			

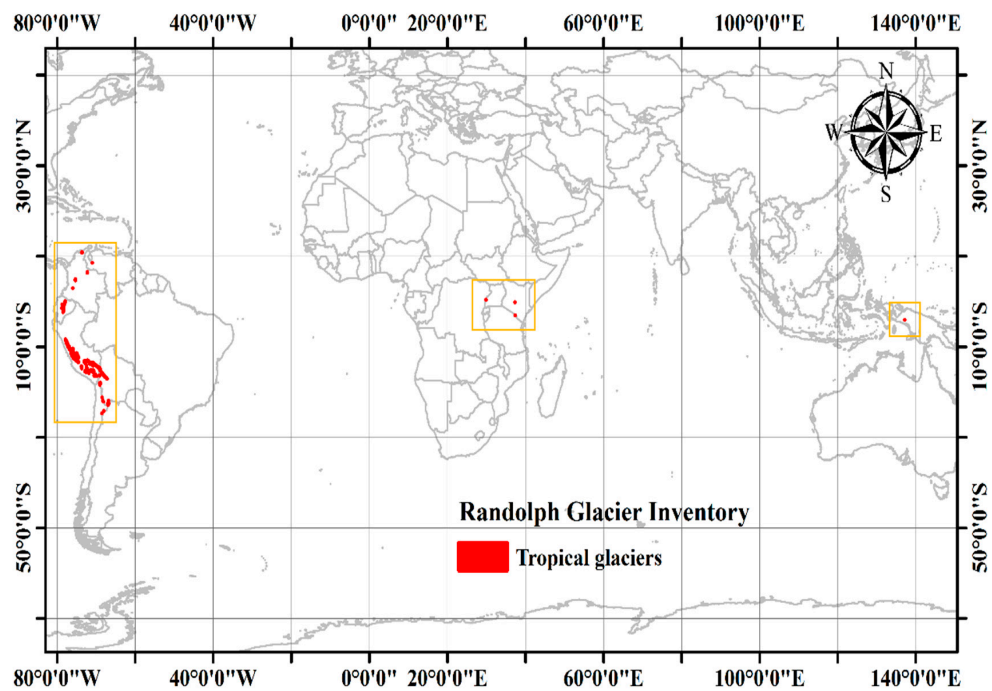
**Tabla 3** – SMA utilizadas para la clasificación

Tipo	Nombre	Fórmula	Descripción	Reductor <sup>1</sup>				
				Median	Median dry	Median Wet	Mín	Máx
Fracciones	Cloud fraction	SMA	Fracción de nube		X			
	Snow fraction	SMA	Fracción de nieve		X			

Nota: <sup>1</sup> El reductor está basado en el índice NDSI, con el uso de percentiles; percentil 75 y 25, para temporada húmeda y seca respectivamente.

### 3.2. Mapas de referencia

El área de estudio (Figura 5) se definió basado en el inventario de glaciares Randolph (RGI Consortium, 2017, p. 0), además fue inspeccionado y se agregaron algunos glaciares faltantes.



**Figura 5** – Distribución de glaciares tropicales; fuente: (RGI Consortium, 2017, p. 0; Veettil & Kamp, 2019)

#### 4. Post – clasificación

Dada la naturaleza pixel-based del modelo de clasificación y el procesamiento de una serie temporal extensa, se implementó una cadena de filtros post – clasificación. Este proceso incluyó la aplicación secuencial de filtros de relleno, temporales, espaciales, de frecuencia y sobreestimación.

##### 4.1.Llenado de vacíos de información (Gap Fill)

La secuencia de filtros comienza con el post-procesamiento llamado Gap Fill utilizado para el relleno de vacíos en los datos de clasificación de glaciares. El objetivo principal de este filtro es corregir píxeles faltantes o mal clasificados en una serie temporal. Este proceso es fundamental en el análisis de series temporales de glaciares, ya que aborda uno de los principales desafíos en teledetección como es la presencia de píxeles sin datos o mal clasificados debido a factores de cobertura nubosa, sombras topográficas o limitaciones en la captura satelital.

La función Gap Fill, implementa un enfoque bidireccional para el relleno de vacíos. Este algoritmo opera en dos fases complementarias que aseguran la completitud de la serie temporal analizada.

Durante la primera fase, el algoritmo recorre la serie temporal desde el año inicial de evaluación hasta el año final. Durante este recorrido hacia adelante, cuando el algoritmo encuentra un píxel sin datos en un año específico, le asigna el valor del año inmediatamente anterior.

La segunda fase implementa un recorrido inverso, desde el año final hacia el inicial. Los píxeles que permanecieron sin datos después de la primera fase, reciben valores del año posterior más cercano. Esta estrategia bidireccional garantiza que las brechas de datos solo persistan si un píxel carece de información válida en toda la serie temporal.



**Figura 6 – Filtro Gap Fill**

## 4.2. Filtro temporal

El segundo filtro implementa un proceso que constituye un proceso crítico en el refinamiento de las clasificaciones de glaciares después del proceso de Gap Fill. Este filtro se enfoca en corregir clasificaciones erróneas o inconsistentes que pueden ocurrir en píxeles individuales a lo largo de la serie temporal, aplicando una lógica de coherencia temporal basada en ventanas de análisis de múltiples años.

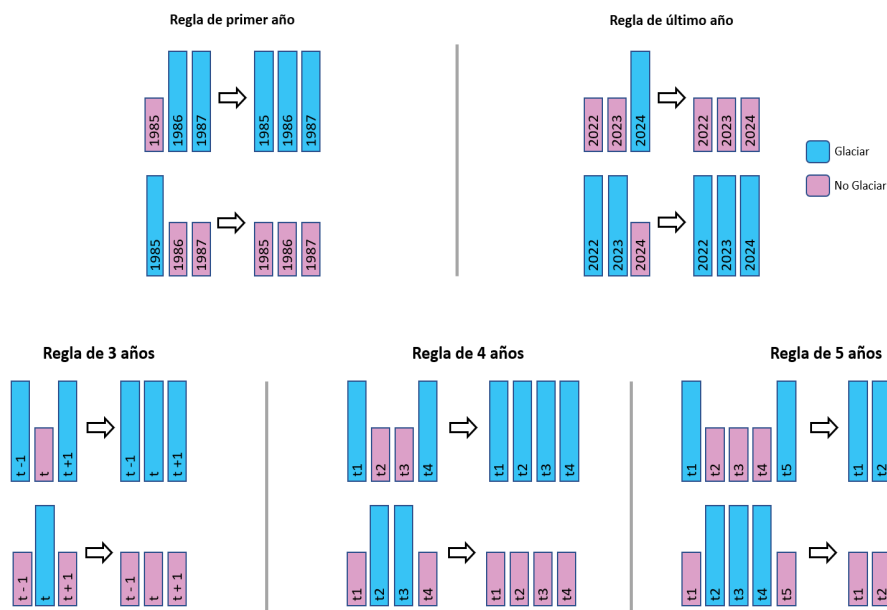
Este filtro es especialmente importante para eliminar el “ruido” en las clasificaciones, es decir, cambios abruptos e ilógicos en la cobertura glaciar que no corresponde a procesos naturales. Por ejemplo, un píxel clasificado como glaciar que súbitamente aparece como no-glaciar por un año y luego vuelve a ser glaciar, probablemente representa un error de clasificación más que un cambio real en la cobertura.

El filtro implementa tres tipos de ventanas de análisis temporal; ventanas de 3, 4 y 5 años. Cada ventana aplica una lógica específica para detectar y corregir inconsistencias en la clasificación.

La ventana de 3 años detecta situaciones donde un píxel tiene la misma clasificación en el año anterior y posterior, pero una clasificación diferente en el año central. Esta situación indica un error de clasificación, por lo que el algoritmo corrige el año central para mantener la coherencia temporal.

La ventana de 4 años extiende esta lógica para detectar gaps de dos años consecutivos. Si un pixel tiene la misma clasificación para el año  $t_1$  y  $t_4$ , pero clasificaciones diferentes en el  $t_2$  y  $t_3$ , el algoritmo corrige ambos años intermedios. Esto es útil para corregir errores de clasificación que persisten por dos años consecutivos.

La ventana de 5 años maneja casos complejos donde hay tres años consecutivos con clasificaciones erróneas entre dos años con la misma clasificación correcta. Esta ventana es particularmente útil para corregir períodos prolongados de cobertura nubosa o problemas sistemáticos en las imágenes satelitales.



**Figura 7** – Filtro Temporal

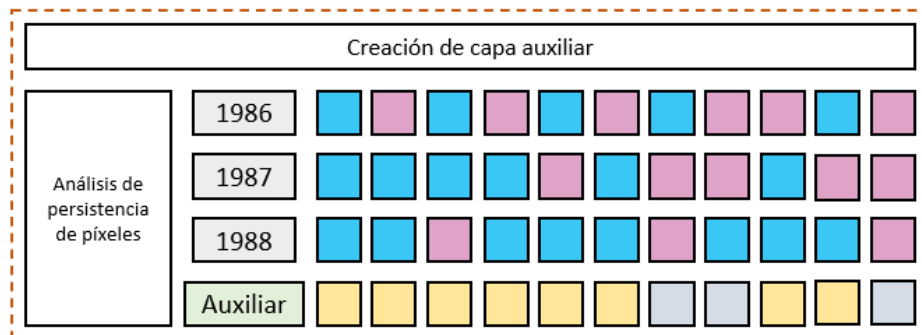
El filtro también implementa funciones específicas para manejar los años extremos de la serie temporal. Para el primer año, el filtro verifica si los dos años siguientes tienen la misma clasificación, de ser así, ajusta la clasificación del año inicial para mantener la coherencia. Este proceso se aplica de forma similar para el último año de la serie temporal, verificando su consistencia con los dos años anteriores a este.

Este tratamiento especial es necesario porque estos años carecen de contexto temporal completo, lo que requiere una lógica de filtrado adaptado. Esto asegura que toda la serie temporal mantenga coherencia desde el inicio hasta el final.

El orden de aplicación de estas reglas no es arbitrario, ya que el filtro temporal comienza con ventanas más pequeñas, procesando los años externos, permitiendo corregir los errores más simples y obvios, para luego procesar las ventanas más grandes, dejando los casos más complejos para aplicaciones posteriores, maximizando la efectividad del filtrado, mientras minimiza el riesgo de sobreestimación.

### 4.3. Filtro de años base

El tercer filtro tiene como objetivo corregir la sobreestimación y subestimación presentes en los años base de la serie temporal glaciár. Su aplicación se estructura en dos apartados: la corrección por capa auxiliar de persistencia y el análisis de secuencia temporal. El primer apartado consiste en construir una capa auxiliar de píxeles persistentes clasificados como glaciár. Para ello, se evalúan los tres años posteriores al año a corregir: si un píxel es detectado como glaciár en al menos dos de esos tres años, se incorpora a la capa auxiliar. Esta capa cumple la función de fuente de relleno para los vacíos de información presentes en el año evaluado, bajo la premisa de que, si un píxel es detectado consistentemente como glaciár en años posteriores, es altamente probable que también lo fuera en el año base anterior.




**Figura 8** – Creación de capa auxiliar

La corrección del año evaluado se aplica considerando tres casos posibles, derivados de la combinación entre la clasificación del año a corregir y el estado del píxel en la capa auxiliar:

- Si el píxel del año a corregir está clasificado como no glaciár y la capa auxiliar lo identifica como glaciár persistente, el píxel se reclasifica como glaciár. La lógica subyacente es que la detección consistente de glaciár en años posteriores respalda su presencia en el año base, por lo que el mapeo como no glaciár se atribuye a una subestimación derivada de la escasa disponibilidad de imágenes para los años base de nuestra evaluación.
- Si el píxel del año a corregir está clasificado como glaciár y la capa auxiliar también lo identifica como glaciár persistente, el píxel se conserva como glaciár sin modificación.
- Si el píxel del año a corregir está clasificado como glaciár pero la capa auxiliar lo identifica como no persistente, el píxel se conserva como glaciár. Esta decisión responde al criterio de respetar la cobertura clasificada para el año base ante la insuficiencia de mosaicos; su posible condición de sobreestimación no puede confirmarse únicamente con la capa

auxiliar y requiere un análisis adicional, que se aborda en el siguiente apartado.

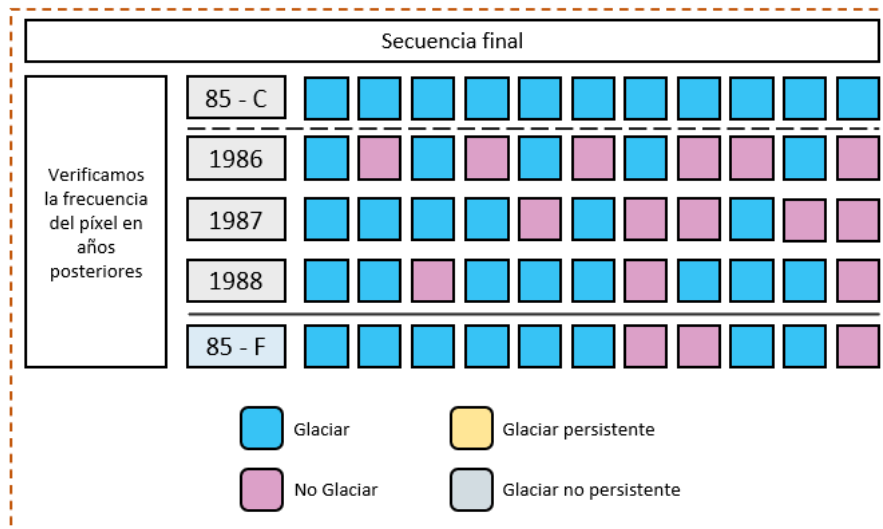


**Figura 9** – Corrección de año base con capa auxiliar

El resultado de este proceso es la capa denominada **85-C**, correspondiente a la clasificación corregida del año 1985.

El segundo apartado atiende específicamente el tercer caso del apartado anterior: píxeles clasificados como glaciar en el año base, pero identificados como no persistentes en la capa auxiliar. Para estos píxeles, se realiza un análisis de frecuencia de detección en los años posteriores al evaluado.

A partir de la capa 85-C, se evalúa si cada píxel en cuestión es detectado como glaciar en dos o más de los años posteriores considerados. Si cumple esta condición, el píxel se conserva como glaciar dentro de la serie temporal, confirmando su validez como cobertura glaciar. Si, por el contrario, la frecuencia de detección como glaciar es inferior a dos años, el píxel se reclasifica como no glaciar, dado que la ausencia de continuidad temporal respalda su condición de sobreestimación. Esta sobreestimación tiene origen en las limitaciones de los mosaicos de los años base: ante la escasa disponibilidad de imágenes satelitales en ese período, la composición de los mosaicos incorpora en ciertos casos píxeles pertenecientes a la temporada húmeda, los cuales pueden presentar cobertura nival estacional que es incorrectamente mapeada como glaciar permanente. Con el avance de la serie temporal, la disponibilidad de imágenes aumenta progresivamente, lo que permite una mejor composición del mosaico y una discriminación más precisa entre glaciar permanente y cobertura nival transitoria, reduciendo así este tipo de error en los años más recientes de la serie.



**Figura 10** – Análisis de secuencialidad de píxel


Estos resultados, son complementados con la aplicación de filtros posteriores.

#### 4.4. Filtro de frecuencia

El cuarto filtro en la cadena de procesamiento es el filtro de frecuencia. Este filtro opera bajo el principio de que las coberturas estables, como los glaciares, deben mantener una presencia consistente a lo largo del tiempo. A diferencia de filtros anteriores que trabajan con ventanas temporales específicas, el filtro de frecuencia analiza la serie temporal completa para identificar y consolidar las clasificaciones más persistentes.

El filtro es efectivo para distinguir cambios reales en la cobertura glaciar y errores de clasificación esporádicos. Al establecer umbrales de frecuencia mínima, el algoritmo puede determinar con alta confianza que píxeles representan verdaderamente glaciares permanentes versus aquellos que han sido mal clasificados.

El umbral establecido (70%), define el porcentaje mínimo de años en los que un píxel debe estar clasificado como glaciar o no glaciar para ser considerado como tal de manera definitiva, es decir si un píxel ha sido clasificado como glaciar en más del 70% de los años, este se consolida definitivamente como glaciar. El mismo principio se aplica para la clase no glaciar.



**Figura 11 – Filtro de Frecuencia**

#### 4.5. Enmascaramiento de lagunas

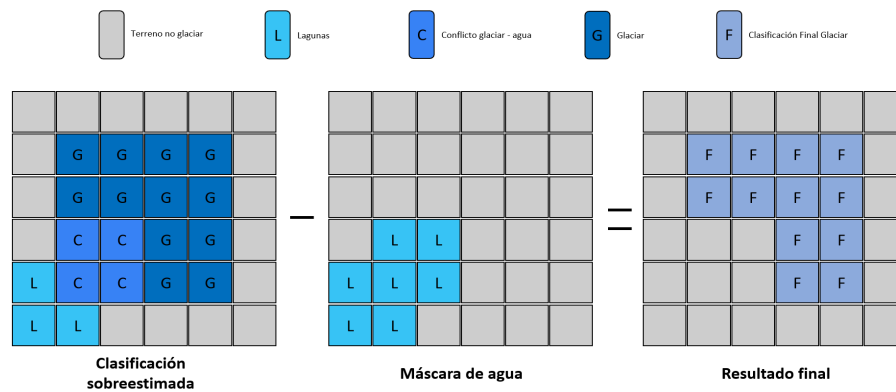
El proceso de enmascaramiento aborda un problema específico pero crítico en el mapeo de glaciares, la confusión espectral entre glaciares y cuerpos de agua. Este filtro de enmascaramiento utiliza datos de la colección de MapBiomasaAgua para identificar y eliminar áreas donde laguna glaciares han sido erróneamente clasificados como glaciares.

Esta confusión es común en ambientes de alta montaña porque tanto hielo glaciar como el agua pueden presentar respuestas espectrales similares en ciertas condiciones, especialmente cuando hay presencia de sedimentos glaciares o cuando los lagos están parcialmente congelados.

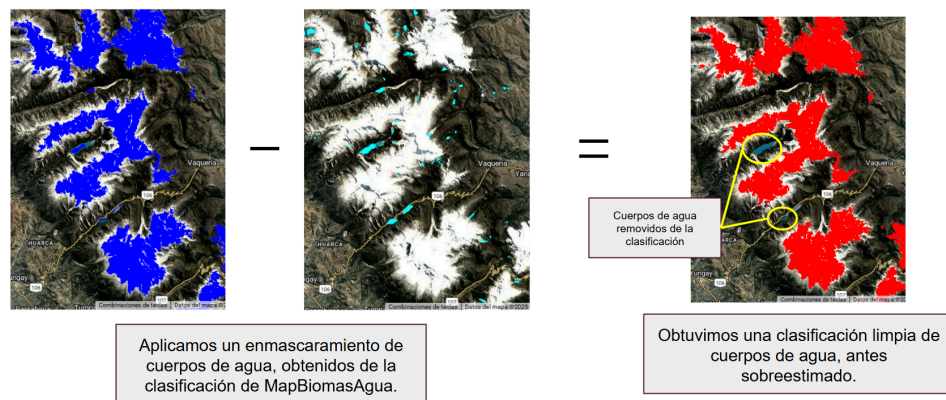
El filtro procesa cada año de manera independiente, integrando dos fuentes de datos complementarios, los datos son las clasificaciones de glaciares, resultado de todos los filtros anteriores aplicados y las

máscaras de agua, identificados específicamente por MapBiomasaAgua.

El filtro implementa una lógica de exclusión simple; si un píxel está clasificado como glaciar y agua, se reclasifica como agua, eliminando estos datos del mapa de glaciares; si un píxel está clasificado solo como glaciar, este se mantiene como glaciar en el resultado final; por último, si un píxel está clasificado solo como agua, este ya no se considera en el mapa final de glaciares. De esta forma reducimos la lectura de falsos positivos en el mapeo de glaciares, eliminando una fuente común de error en el mapeo de glaciares.



**Figura 12** – Secuencia de enmascaramiento de lagunas




**Figura 13** – Efecto del enmascaramiento de lagunas

#### 4.6. Filtro de permanencia temporal

El filtro de permanencia temporal, complementa al filtro de frecuencia. Mientras que el filtro de frecuencia evalúa la persistencia estadística de las clasificaciones a lo largo de toda la serie temporal, el filtro de permanencia temporal implementa una lógica de irreversibilidad en los cambios de cobertura glaciar.

Este filtro opera bajo el principio glaciológico de que una vez que un área pierde su cobertura glaciar, es extremadamente improbable que vuelva a formar glaciar en el corto plazo. Esta premisa se basa en la comprensión de que la formación de glaciares requiere condiciones

climáticas específicas sostenidas durante periodos prolongados, algo que no ocurre en escalas de tiempo de décadas (Marangunic, 2016).



**Figura 14** – Filtro de Permanencia Temporal

#### 4.7. Filtro espacial

El filtro espacial trabaja exclusivamente con la dimensión espacial de las imágenes, analizando la coherencia y conectividad de los píxeles clasificados en cada año de estudio individual.

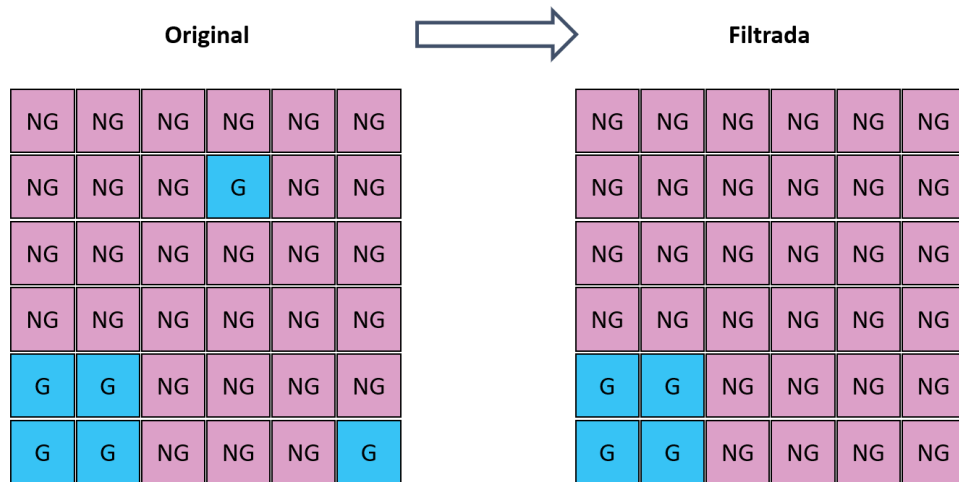
Este filtro aborda un problema común en la clasificación de imágenes satelitales, siendo la presencia de píxeles aislados o pequeños grupos de píxeles que son clasificados de manera diferente a su entorno inmediato. Estos píxeles aislados frecuentemente representan errores de clasificación más que características reales del terreno.

El proceso de filtro espacial se implementa en dos etapas principales, esto para cada año de la serie temporal.

Durante la primera etapa el filtro utiliza la función “connectedPixelCount” para calcular, cuantos píxeles glaciares están conectados entre sí. La segunda etapa del filtro consiste en agrupar píxeles, el filtro marca todos los grupos que tienen menos de 5 píxeles conectados. Estos grupos pequeños son candidatos a ser errores porque los glaciares reales raramente son tan pequeños.

Para el mapeo de glaciares en los Andes, donde los glaciares pueden tener formas complejas debido a la topografía montañosa, el filtro espacial es valioso, ya que ayuda a eliminar clasificaciones erróneas causadas por sombras topográficas, nubes pequeñas no detectadas, o

variaciones en la reflectancia de la nieve, mientras preserva la estructura real de los glaciares.




**Figura 15** – Efecto del filtro espacial

#### 4.8. Integración con las otras clases MapBiomias Amazonía

Luego de la aplicación de la secuencia de filtros en la etapa de Post clasificación, los temas transversales y los mapas generales de cada bioma son integrados. Esta integración depende de una serie de reglas jerárquicas específicas que asignan un orden de prevalencia a cada clase. Como resultado de esta etapa se obtienen los mapas anuales de cobertura y uso de la tierra para toda la Amazonía

#### 5. Consideraciones finales

Durante el desarrollo de la Colección 3, se identificó una pérdida glaciár desmedida y un aparente retroceso abrupto en los años base de la serie temporal. Inicialmente, una de las hipótesis consideradas para explicar esta anomalía fueron los errores de calibración radiométrica entre los sensores Landsat 5 TM, Landsat 7 ETM+ y Landsat 8 OLI.



**Figura 16** – Estadísticas C3 de glaciares


La hipótesis indicaba que; estos errores se manifiestan como una sobreestimación de los valores de radiancia y reflectancia, cuya magnitud varía según la banda espectral y se atenúa gradualmente hacia mediados


de los años noventa. Para superficies glaciares y nivales, las bandas más críticas (1, 2 y 3) presentan sobreestimaciones de 0.72%, 3.87% y 4.09% respectivamente, lo que amplifica artificialmente su alta reflectancia en el espectro visible e inflaría índices espectrales multibanda, derivando en una sobreestimación del área glaciar en los análisis temporales que incluyan dicho período (Micijevic et al., 2016).

No obstante, esta hipótesis fue descartada para esta colección 4 como causa principal de la anomalía observada en la Colección 3. Las imágenes procesadas en Google Earth Engine provienen de las colecciones de reflectancia de superficie de Landsat (Collection 2, Level-2), las cuales incorporan correcciones radiométricas y de calibración cruzada entre sensores, garantizando la consistencia y linealidad de los valores espectrales a lo largo de la serie temporal (USGS, 2021; Vermote et al., 2016; Dwyer et al., 2018). En consecuencia, los errores de calibración descritos por Micijevic et al. (2016) no constituyen una fuente de sesgo en el presente análisis.

La explicación de mayor peso para la sobreestimación detectada en los años base reside en la calidad de los mosaicos de composición. Para los años base de la serie temporal, la escasa disponibilidad de imágenes satelitales limita severamente la construcción de mosaicos óptimos. En ausencia de suficientes escenas de temporada, los algoritmos de composición incorporan píxeles pertenecientes a la temporada húmeda, caracterizada por alta precipitación y presencia de cobertura nival estacional. Estos píxeles de temporada húmeda introducen coberturas nivales transitorias que son incorrectamente clasificadas como glaciar permanente, generando una sobreestimación del área glaciar en los años base.


Este fenómeno es claramente observable en el análisis de la composición de los mosaicos. La **Figura 17** ilustra este problema en la zona del Coropuna, en la Cordillera Ampato: los píxeles marcados en rojo corresponden a imágenes de meses húmedos, para un mosaico compuesto de únicamente 20 imágenes. Los sectores identificados en verde y naranja corresponden en su mayoría a píxeles de temporada seca, evidenciando la heterogeneidad en la composición del mosaico y el impacto que tiene la incorporación de píxeles húmedos en la estimación de la cobertura glaciar.






**Figura 17** – Análisis de la procedencia de píxeles para la composición del mosaico de 1985 – Zona Coropuna

A medida que avanza la serie temporal, la disponibilidad de imágenes aumenta progresivamente, lo que permite construir mosaicos de mayor calidad, con mayor proporción de píxeles de temporada seca y una discriminación más precisa entre glaciar permanente y nieve estacional. La **Figura 18** muestra que ya en el mosaico del año 2000 predominan los píxeles de temporada seca, reflejando una cobertura glaciar más depurada y libre de la influencia de nieve húmeda. Esta mejora progresiva en la calidad de los mosaicos es la que genera la aparente caída brusca de cobertura glaciar entre los años base y los años posteriores observada en la Colección 3.



**Figura 18** – Análisis de la procedencia de píxeles para la composición del mosaico del 2000 – Zona Coropuna

Para la Colección 4, este problema fue abordado mediante la aplicación del filtro de corrección de años base, cuyo objetivo es estimar una cobertura glaciar más próxima a la real para los años base, asegurando trazabilidad y coherencia temporal con los años posteriores de la serie. Como resultado, las estadísticas de cobertura glaciar de la Colección 4 ya no presentan la caída abrupta detectada en la Colección 3, corrigiendo la sobreestimación asociada a la incorporación de píxeles de temporada húmeda en los mosaicos de los años base.



**Figura 19** – Estadísticas C4 de glaciares.

## 6. Referencias

- Batka, J., Vilímek, V., Štefanová, E., Cook, S. J., & Emmer, A. (2020). Glacial Lake Outburst Floods (GLOFs) in the Cordillera Huayhuash, Peru: Historic Events and Current Susceptibility. *Water*, 12(10), 2664. <https://doi.org/10.3390/w12102664>
- Dwyer, J. L., Roy, D. P., Sauer, B., Jenkerson, C. B., Zhang, H. K., & Lymburner, L. (2018). Analysis ready data: Enabling analysis of the Landsat archive. *Remote Sensing*, 10(9), 1363. <https://doi.org/10.3390/rs10091363>
- Huang, L., Li, Z., Zhou, J. M., & Zhang, P. (2021). An automatic method for clean glacier and nonseasonal snow area change estimation in High Mountain Asia from 1990 to 2018. *Remote Sensing of Environment*, 258, 112376. <https://doi.org/10.1016/j.rse.2021.112376>
- Kaser, G., & Osmaston, H. (2002). *Tropical glaciers*. Cambridge Univ. Press. <https://onggem.files.wordpress.com/2011/02/kaser-osmaston-2002-tropical-glaciers1.pdf>
- Marangunic, C. (2016). Glaciares y los ecosistemas de montaña: Las importantes tareas pendientes. *Revista de Glaciares y Ecosistemas de Montaña*, 1. <https://doi.org/10.36580/RGEM.11.11-19>
- Micijevic, E., Haque, Md. O., & Mishra, N. (2016). Radiometric calibration updates to the Landsat collection. *Earth Observing Systems XXI*, 9972, 99720D. <https://doi.org/10.1117/12.2239426>
- Philip, G., & Ravindran, K. (1998). Glacial mapping using landsat thematic mapper data: A case study in parts of gangotri glacier, NW himalaya. *Journal of the Indian Society of Remote Sensing*, 26(1-2), 29-34. <https://doi.org/10.1007/BF03007337>
- Racoviteanu, A. E., Paul, F., Raup, B., Khalsa, S. J. S., & Armstrong, R. (2009). Challenges and recommendations in mapping of glacier parameters from space: Results of the 2008 Global Land Ice Measurements from Space (GLIMS) workshop, Boulder, Colorado,

USA. *Annals of Glaciology*, 50(53), 53-69.

<https://doi.org/10.3189/172756410790595804>

RGI Consortium. (2017). Randolph Glacier Inventory – A Dataset of Global Glacier Outlines: Version 6.0. En *GLIMS Technical Report*.

[https://www.glims.org/RGI/00\\_rgi60\\_TechnicalNote.pdf](https://www.glims.org/RGI/00_rgi60_TechnicalNote.pdf)

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>

U.S. Geological Survey (USGS). (2021). *Landsat Collection 2 Level-2 Science Product Guide*. U.S. Department of the Interior.

<https://www.usgs.gov/landsat-missions/landsat-collection-2-level-2-science-products>

Veettil & Kamp. (2019). Global Disappearance of Tropical Mountain Glaciers: Observations, Causes, and Challenges. *Geosciences*, 9(5), 196.

<https://doi.org/10.3390/geosciences9050196>