

MapBiomias Agua - PERÚ

Manual General
GLACIARES

Documento de base teórica sobre algoritmos (ATBD)

Colección 3, Versión 1

Equipo Perú:

Sandra Ríos, Nicole Moreno, Joaquin Romualdo, Cristhian Vega, Ricardo Valverde

Julio 2025



MAPBIOMAS
[AGUA]



MAPBIOMAS
PERU

RAISG

RED AMAZÓNICA DE INFORMACIÓN
SOCIOAMBIENTAL GEORREFERENCIADA



INSTITUTO DEL
BIEN COMÚN

Tabla de contenido

1. Introducción	3
1.1. Área de Estudio	4
2. Mosaicos de imágenes	4
3. Clasificación	4
3.1. Variables de clasificación	5
3.2. Mapas de referencia	7
4. Post – clasificación	7
4.1. Llenado de vacíos de información (Gap Fill)	7
4.2. Filtro temporal	8
4.3. Filtro de frecuencia	10
4.4. Filtro de permanencia temporal	11
4.5. Filtro espacial	12
4.6. Enmascaramiento de lagunas	13
4.7. Integración con las otras clases MapBiomias Amazonía	14
5. Consideraciones finales	14
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 anterior 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 en los tropicales que pertenecen a la cuenca Amazónica, en la colección 6 de MapBiomass Amazonía usamos como base la metodología de la colección 3, 4 y 5 y otras referencias (Turpo Cayo et al., 2022), que consistió en agregar el año 2023. El proceso completo se dividió en 6 etapas (Figura 1).




Figura 1 – Diagrama de flujo metodológico para la obtención de mapas de coberturas Glaciares

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 glaciaria mínima anual, basado en el pixel de calidad de NDSI mínimo (Figura 3).




Figura 3 – Creación de mosaicos anuales para 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 glaciaria 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 (Θ), 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 periodo se minimiza la interferencia de nubes 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 glaciario.

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 ¹				
				Mediano	Median dry	Median wet	Mín	Máx
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 ¹				
				Mediano	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 ¹				
				Mediana	Mediana dry	Mediana Wet	Mín	Máx
Fracciones	Cloud fraction	SMA	Fracción de nube		X			
	Snow fraction	SMA	Fracción de nieve		X			

Nota: ¹ El reductor está basado en el índice NDSI, con el uso de percentiles; percentil 75 y 25, para Wet y Dry de NDSI 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 agregado 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 ventas 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 píxel 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 frecuencia

El tercer 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 8 – Filtro de Frecuencia

4.4. 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 9 – Filtro de Permanencia Temporal

4.5. 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 10 – Efecto del filtro espacial

4.6. 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 11 – Secuencia de enmascaramiento de lagunas




Figura 12 – Efecto del enmascaramiento de lagunas

4.7. Integración con las otras clases MapBiomos 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

Las actualizaciones de calibración radiométrica implementadas en la colección 1 de Landsat revelaron errores significativos en los datos históricos de Landsat 4 y Landsat 5 TM, particularmente para el período 1985 - 1990 (Micijevic et al., 2016).

Estos errores de calibración se manifiestan como una sobreestimación de los valores de radiancia y reflectancia durante el periodo de 1984 - 1995 aproximadamente, con magnitudes variables según la banda espectral. El análisis de los modelos de ganancia de vida útil revela que el error es más pronunciado en

los primeros años de operación (1984 - 1990) y se atenúa gradualmente hacia mediados de los años 90 (Micijevic et al., 2016).

La calibración cruzada con Landsat 7 ETM+ corrigió errores de hasta el 2% de radiancia, mientras que la integración con la calibración de reflectancia de Landsat 8 OLI reveló discrepancias aún mayores (Micijevic et al., 2016).

La sobreestimación radiométrica durante el periodo 1984 - 1995, con máxima intensidad entre 1984 - 1990, tiene consecuencias específicas y diferenciadas según el tipo de superficie mapeada. Para superficies glaciares y nivales, las bandas más críticas (1, 2 y 3) muestran sobreestimación del 0.72%, 3.87% y 4.09% respectivamente, lo que amplifica artificialmente su característica reflectancia alta en el espectro visible (Micijevic et al., 2016).

Para superficies glaciares, caracterizadas por su alta reflectancia en el espectro visible, estos errores implicarían la sobrestimación artificial del área glaciar en clasificaciones automáticas y se manifestaría una inflación de índices espectrales multibanda. Consecuentemente, los análisis temporales de retroceso glaciar que incluyan el periodo 1984 - 1995 presentan una sobreestimación inicial del área glaciar cuando se comparan con mediciones de periodos posteriores correctamente calibrados.




Figura 13 – Cobertura glaciar evaluada de 1985 a 2024

La Figura 13, ilustra este fenómeno, ya que se observa una caída brusca en el área glaciar registrada entre 1985 y 1990, que corresponde precisamente al período de máxima intensidad del error de calibración. Esta “caída brusca” no muestra necesariamente un periodo de derretimiento acelerado real, sino que constituye en gran medida un error instrumental resultante de la transición entre datos sobreestimados (1985) datos más precisos (hacia 1990).

Es fundamental que los estudios de evolución glaciar que utilicen datos Landsat del período 1984 a 1990 interpreten con cautela las tendencias aparentes durante este período. La comprensión de este sesgo es esencial para distinguir entre cambios reales y errores instrumentales.

6. Referencias

Bařka, J., Vilímek, V., řtefanová, 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>

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.I1.11-19>

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

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>

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

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