

MAPBIOMAS
[AGUA]



Documento Metodológico

Superficie de Nieve

Colección 4

Versión 1

Junio 2026

Contenido

1.	Introducción	2
1.1.	Área de Estudio	3
2.	Mosaicos de imágenes	6
3.	Clasificación	7
3.1.	Variables de clasificación	8
4.	Post – clasificación	10
4.1.	Llenado de vacíos de información (Gap Fill)	10
4.2.	Enmascaramiento de lagunas	11
4.3.	Filtro espacial	12
4.4.	Filtro de persistencia	13
4.5.	Filtro Correctivo	13
5.	Referencias	15

1. Introducción

La nieve es un componente importante del ciclo hidrológico tanto a escala global como regional, y comprender las características de la evolución temporal y espacial de la capa de nieve es de gran importancia en los campos de la investigación climática y la gestión de los recursos hídricos (Luo et al., 2022).

La nieve constituye uno de los componentes más dinámicos e influyentes de la criósfera terrestre. Como forma de precipitación sólida, actúa como reservorio estacional de agua dulce, almacenando grandes volúmenes durante la estación fría y liberando gradualmente durante el deshielo, lo que regula el caudal de ríos y recarga acuíferos en regiones de montaña (Schaefli, 2015) Schaefli, B. (2015).

. En los andes tropicales del Perú, las cordilleras nevadas configuran el origen de sistemas fluviales vitales que abastecen a millones de personas, por lo que comprender la dinámica espacio-temporal de la cobertura nival resulta importante para la gestión integrada de los recursos hídricos (SENAMHI, 2018) SENAMHI. (2018).

Muy a parte de su rol hidrológico, la nieve ejerce una influencia determinante sobre los ecosistemas de alta montaña y el sistema climático global, ya que, su albedo reduce la absorción de radiación solar e incide directamente en las temperaturas regionales (Brown & Robinson, 2011) Brown, R. D., & Robinson, D. A. (2011).

Frente a esta realidad, el mapeo preciso y sistemático de superficie nival resulta una necesidad, sin embargo, la alta variabilidad espacio-temporal de la nieve, combinada con la inaccesibilidad a los ambientes de alta montaña, limita severamente los enfoques de medición tradicionales (Dietz et al., 2012).

En ese contexto, la teledetección satelital se ha consolidado como la herramienta más eficaz para el seguimiento continuo de la superficie nival a escala regional y global. Sensores como MODIS han permitido generar series temporales de varias décadas con cobertura casi diaria, mientras que plataformas de mayor resolución como Sentinel-2 y Landsat ofrecen capacidad de detección más refinada, indispensable para cartografiar la heterogeneidad del manto nival en zonas de alta montaña (Gascoin et al., 2019; Aalstad et al., 2020).

En este documento, presentamos una descripción de la metodología aplicada para el mapeo de la superficie nival en el Perú.

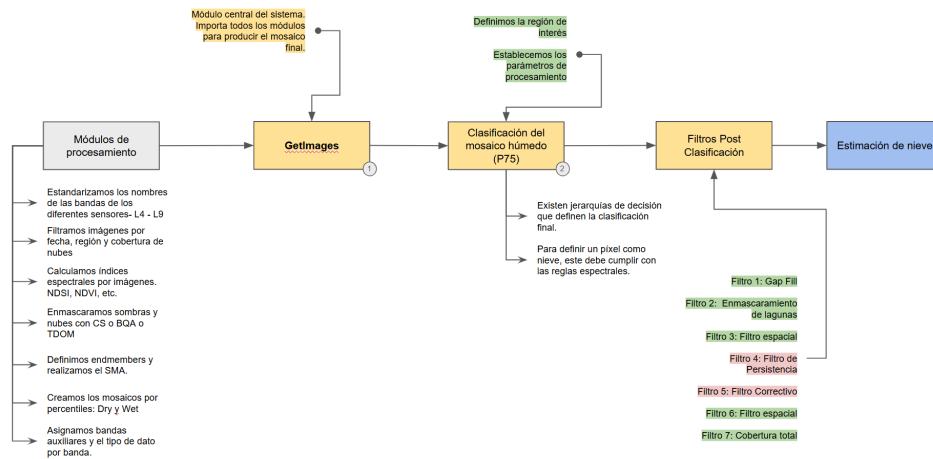


Figura 1 – Diagrama de flujo metodológico para la obtención de mapas de cobertura Nival

1.1. Área de Estudio

La región de estudio fue definida inicialmente a partir del inventario de glaciares del *Randolph Glacier Inventory* (RGI Consortium, 2017), cuyas delimitaciones resultan adecuadas para caracterizar la presencia glaciar. Sin embargo, dado que el objetivo del presente trabajo es mapear la cobertura nival, este marco de referencia inicial resultó insuficiente. (Figura 2).




Figura 2: Cobertura glaciar para el año 2000 en las regiones del RGI.

El procedimiento de mapeo emplea mosaicos contruidos a partir de los píxeles con mayor valor de NDSI dentro de la serie temporal, buscando capturar la máxima extensión nival posible para cada año. Al aplicar directamente las regiones del RGI sobre estos mosaicos, la cobertura de nieve quedaba truncada en sus bordes (Figura 3), lo que motivó la necesidad de ampliar las regiones de procesamiento.

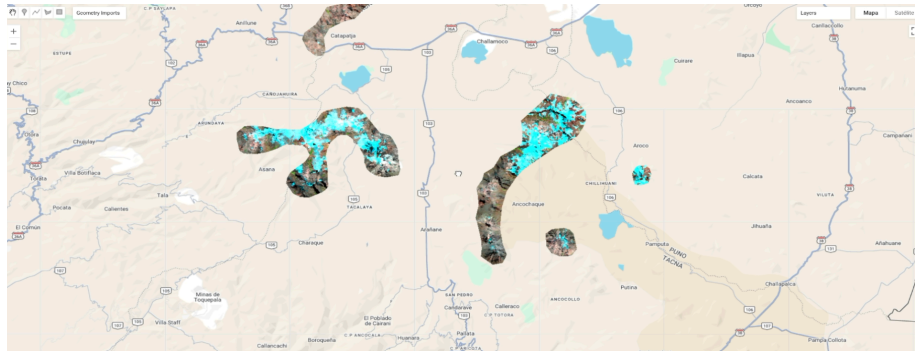


Figura 3: Cobertura nival para el año 2000 en las regiones del RGI.

Para ello es necesario expandir nuestras regiones de procesamiento y delimitar de forma acertada, hasta donde se extiende la nieve en los Andes, para diferentes años.




Figura 4: Extensión nival para en comparación con las regiones del RGI.

Con este fin, se aplicó un buffer de aproximadamente 50 km sobre las regiones originales del RGI (Figura 5), con el propósito de garantizar que los mosaicos cubrieran la totalidad de la extensión nival posible en diferentes años.

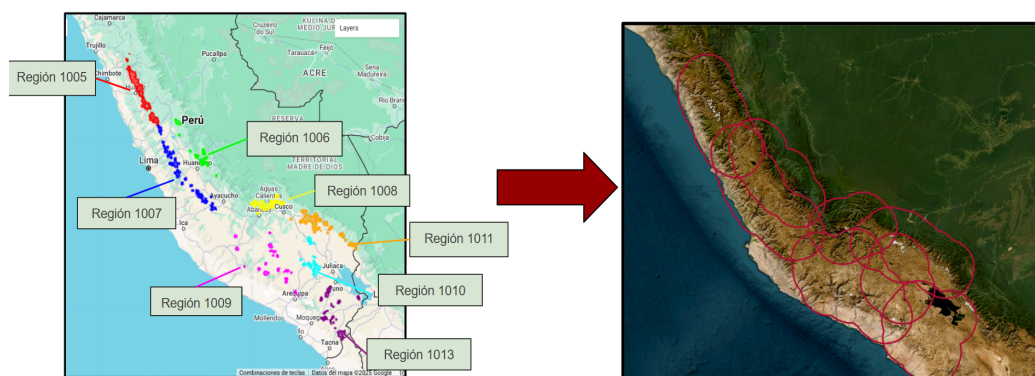


Figura 5: Ampliación de las áreas de procesamiento.

Adicionalmente, las regiones de procesamiento fueron ajustadas mediante la integración de dos capas complementarias: la capa de biomas de los Andes y la capa altitudinal de presencia nival del SENAMHI (Bomshoms Calvelo et al., 2018). Esta última, derivada del análisis de 35 estaciones meteorológicas distribuidas a nivel nacional, establece que las nevadas en el Perú se producen con mayor

frecuencia durante los meses de verano, aunque están presentes a lo largo de todo el año y a partir de los 3400 m s. n. m.

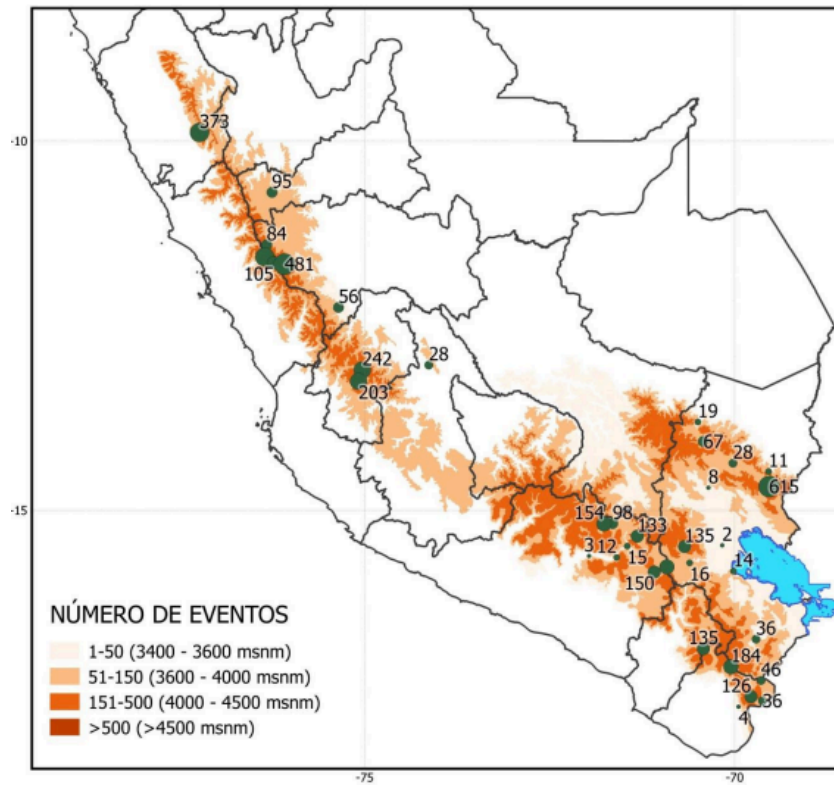


Figura 6: Número de eventos a nivel nacional según SENAMHI y la distribución altitudinal de estos, Bomshoms Calvelo et al. (2018).

La combinación de estas capas permitió delimitar de manera más precisa las zonas con potencial de nieve. La región de trabajo final corresponde a la delimitada por el bioma andino, recortada y complementada por la capa altitudinal de presencia nival, y fue subdividida en 45 subregiones de procesamiento para optimizar el rendimiento computacional en la nube.



Figura 7: Región de trabajo para el mapeo de nieve persistente en el Perú.

2. Mosaicos de imágenes

La clasificación de nieve utilizó los mosaicos de imágenes Landsat generados específicamente para el mapeo de nieve. Estos mosaicos fueron construidos a partir de los píxeles pertenecientes a los de temporada húmeda. Para constituir un mosaico, se usa la distribución por percentiles del análisis de píxeles de las diferentes imágenes filtradas para la región de análisis.




Figura 8: Análisis de los valores de píxeles del índice NDSI para la composición de los mosaicos de temporada húmeda.

Este análisis de píxeles responde a una distribución por percentiles, donde los píxeles pertenecientes al percentil 75, son tomados para la composición de los mosaicos de temporada húmeda.

El mosaico de temporada húmeda, captura las condiciones de un estimado máximo de cobertura nival del año y se construye seleccionando las imágenes donde el valor del NDSI es mayor o igual al percentil 75 de la distribución anual. Sobre estas imágenes filtradas se calcula la mediana píxel a píxel, generando las bandas “wet”, el percentil 75 se tomó como búsqueda de un balance entre la maximización de la cobertura nival capturada y la minimización del ruido introducido por nubes producto de la temporada.

El comportamiento del percentil en la selección de imágenes opera píxel a píxel sobre la distribución temporal de valores NDSI. Para que un píxel sea incluido en el mosaico de percentil 75 como cobertura nival, requiere haber sido clasificado como nieve en aproximadamente el 25% o más de las imágenes válidas del año, correspondiente a la posición estadística del percentil 75 en la distribución ordenada de valores.

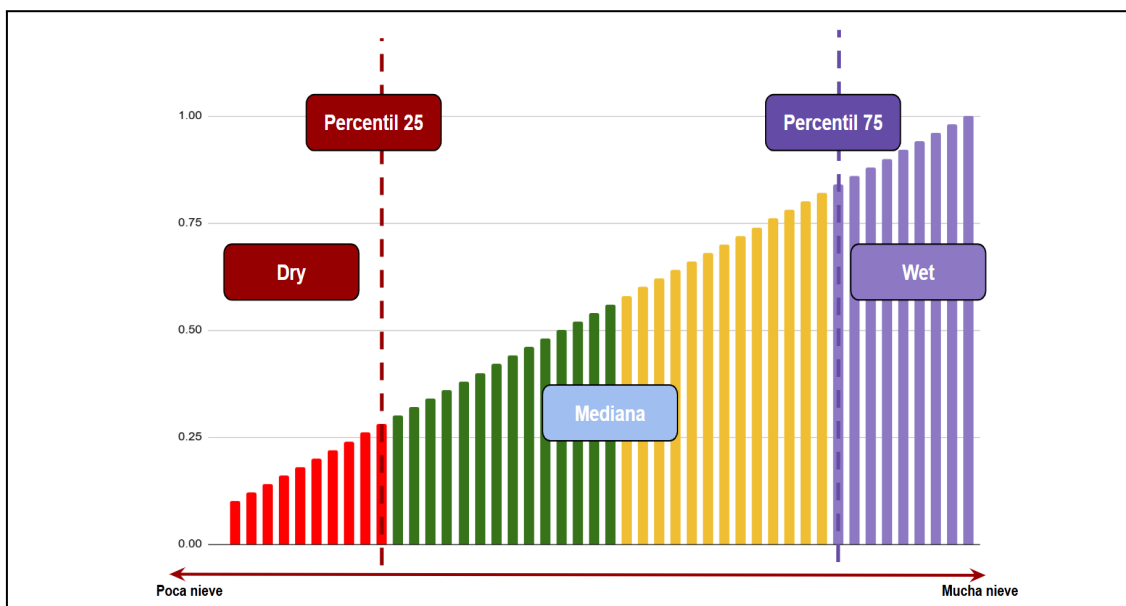


Figura 9: Construcción de los mosaicos de temporada húmeda, basada en la distribución de percentiles.

3. Clasificación

El proceso de clasificación de nieve opera sobre el mosaico de temporada húmeda (percentil 75 del NDSI de la serie anual), cuyo objetivo es capturar la máxima cobertura de nieve del año. La clasificación de los mosaicos Landsat se realizó íntegramente en la plataforma Google Earth Engine, basada en umbrales (Figura 10). La clasificación de la cobertura nival a partir del mosaico de temporada húmeda no emplea un clasificador supervisado como Random Forest. En su lugar, utiliza exclusivamente reglas de umbrales espectrales aplicadas directamente sobre las variables del mosaico mediante operaciones condicionales **where**. Este proceso de

clasificación en la metodología responde a la inestabilidad temporal de la nieve estacional, que impide construir un conjunto de píxeles de entrenamiento suficientemente estables para el período húmedo.

Sobre este mosaico se aplica un conjunto de condiciones secuenciales donde todos los píxeles parten de una asignación inicial “sin cobertura nival” y cada regla de umbrales puede sobrescribir el resultado de la anterior. La primera condición evalúa la reflectancia en la banda infrarroja cercana del mosaico de época húmeda (1-1), descartando como cobertura nival aquellos píxeles que no superan el umbral mínimo establecido según el sensor: valores próximos a 0.2114 para Landsat 5 y Landsat 7, y próximos a 0.1730 para Landsat 8 y Landsat 9. De forma análoga, la segunda condición evalúa la reflectancia en la banda roja del mosaico de época húmeda (2-2), aplicando umbrales de 0.2497 para Landsat 5 y Landsat 7, y de 0.2304 para Landsat 8 y Landsat 9, descartando igualmente los píxeles que no los alcanzan.

La identificación definitiva de cobertura nival se basa en una condición dual que debe cumplirse simultáneamente (3-2 y 4-2): el valor mínimo anual del NDSI, que representa la menor cobertura nival registrada para ese píxel en todo el año, debe ser mayor o igual a 100 en la escala reescalada (equivalente a NDSI real mayor o igual a 0.0), y la fracción de nieve derivada del Análisis de Mezcla Espectral debe ser mayor o igual al 20 por ciento. Los píxeles que satisfacen ambas condiciones son asignados a la de presencia nival.

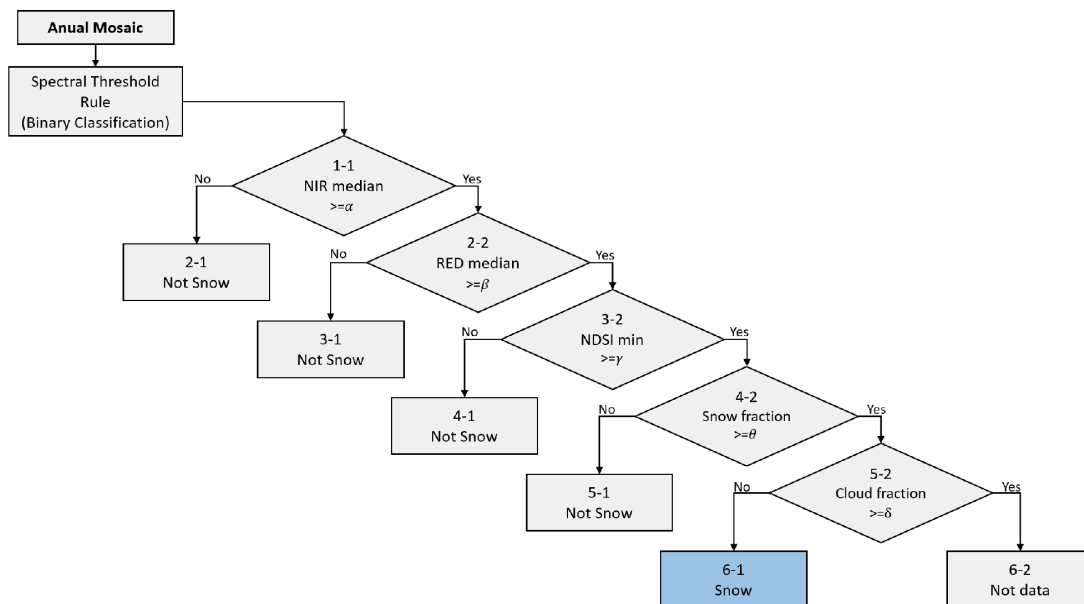


Figura 10 –Árbol empírico combinado con Random Forest para clasificación de nieve.

Finalmente, como paso de control de calidad, los píxeles con contaminación residual de nube son identificados mediante la fracción de nube derivada del SMA (6-2). Aquellos que superan el valor umbral de 170 en la escala de 0 a 200 son clasificados como “dato inválido” y descartados

de la clasificación final, asegurando que únicamente píxeles con observaciones espectralmente confiables sean incluidos en el producto de cobertura nival.

3.1. Variables de clasificación

El algoritmo de clasificación utiliza diferentes variables de clasificación, organizadas en tres categorías principales que capturan diferentes aspectos de la firma espectral de las superficies nivales.

La primera categoría comprende seis bandas espectrales en sus valores medianos de temporada húmeda (percentil 75 del NDSI).

La segunda categoría incluye el uso de índices espectrales, destacando las variaciones temporales del NDSI (Normalized Difference Snow Index) calculado tres momentos distintos.

- Ndsi_median_dry: NDSI mediano de época seca (percentil 25), que captura la condición espectral del glaciar permanente sin nieve estacional, o en su defecto, mínima presencia nival.
- Ndsi_median_wet: NDSI mediano de época húmeda (percentil 75), que refleja la máxima cobertura nival de periodo húmedo.
- Ndsi_min: Valor mínimo del NDSI en todo el año. Umbral restrictivo y relevante para la clasificación.

En la clasificación de cobertura nival, no utilizamos la pendiente topográfica como variables discriminantes directa, dado que la distribución espacial de la nieve estacional difiere del patrón morfológico del glaciar permanente. La nieve puede acumularse en superficies de baja pendiente, lo que haría que un umbral de pendiente excluyera zonas nevadas válidas. En su lugar, en los filtros post clasificación, empleamos el registro de presencia nival del SENAMHI, que documenta ocurrencia de eventos nivales a nivel nacional, desde los 3400 m.s.n.m. hacia niveles más elevados de altitud. Esta capa post-clasificación, actúa como una máscara altitudinal que filtra el ruido espectral proveniente de pisos altitudinales inferiores, principalmente en zonas de selva alta, donde píxeles de nubes densas presentan similitud espectral con la nieve y pueden ser clasificados erróneamente como nieve.

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 pixel en fracciones de diferentes materiales puros, proporcionando información cuantitativa sobre la composición sub-pixel de cada área. La fracción de nieve resulta particularmente relevante para distinguir superficies nivales 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				
				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 ¹				
				Median	Median dry	Median 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 temporada húmeda y seca respectivamente.

4. Post – clasificación

Dada la naturaleza del modelo de clasificación y el procesamiento de una serie temporal extensa, se implementó una cadena de filtros post – clasificación.

4.1.Llenado de vacíos de información (Gap Fill)

La secuencia de filtros de post-procesamiento se inicia con el Gap Fill, cuyo objetivo es corregir los vacíos de información presentes en la serie temporal de clasificación de cobertura nival. Este proceso resulta

fundamental en el análisis de series temporales de teledetección, ya que aborda uno de los desafíos más recurrentes en la disciplina: la existencia de píxeles sin dato o con clasificación comprometida como consecuencia de la cobertura nubosa, las sombras topográficas o las limitaciones propias de la captura satelital.




Figura 11 – Filtro Gap Fill

El algoritmo implementa un enfoque bidireccional que opera en dos fases complementarias para garantizar la completitud de la serie temporal. Durante la primera fase, el algoritmo recorre la serie desde el año inicial hasta el año final. Cada vez que encuentra un píxel sin dato en un año determinado, le asigna el valor clasificado del año inmediatamente anterior, propagando la información hacia adelante en el tiempo. La segunda fase ejecuta el recorrido inverso, desde el año final hacia el inicial, y rellena los píxeles que permanecieron sin dato tras la primera fase asignándoles el valor del año posterior más cercano con información válida. Esta estrategia bidireccional garantiza que los vacíos solo persistan en aquellos píxeles que carecen de observaciones válidas en la totalidad de la serie temporal, minimizando al máximo las brechas de información sin introducir valores artificiales.

4.2. Enmascaramiento de lagunas

Este filtro aborda un problema específico pero crítico en el mapeo de cobertura nival. Las lagunas son frecuentemente clasificadas de forma errónea como cobertura nival o glaciar debido a que la nieve como el agua pueden presentar respuestas espectrales similares bajo ciertas condiciones, como cuando las lagunas se encuentran parcialmente congeladas. Esta ambigüedad espectral es especialmente pronunciada en ambientes de alta montaña, donde ambas coberturas coexisten.

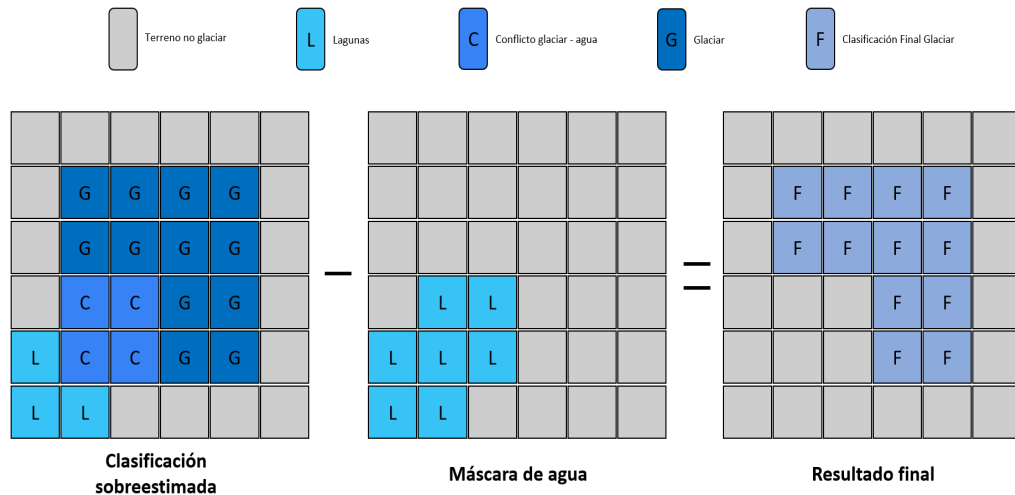


Figura 12 – Secuencia de enmascaramiento de lagunas

Para corregir este problema, el filtro procesa cada año de forma independiente integrando dos fuentes de datos complementarias: las clasificaciones de cobertura nivel obtenidas tras la aplicación de los filtros anteriores, y las máscaras anuales de cuerpos de agua derivadas de la colección MapBiomias Agua. La lógica de exclusión aplicada es directa: los píxeles clasificados como nieve siendo un cuerpo de agua son reclasificados como agua y excluidos del mapa de cobertura nivel, eliminando así los falsos positivos generados por la confusión espectral. Los píxeles clasificados como nieve y confirmados con el análisis de mosaicos son conservados sin modificación, y los píxeles identificados exclusivamente como agua quedan fuera del producto final de cobertura nivel. Esta estrategia reduce de forma sistemática una fuente recurrente de error en el mapeo superficies de alta montaña.

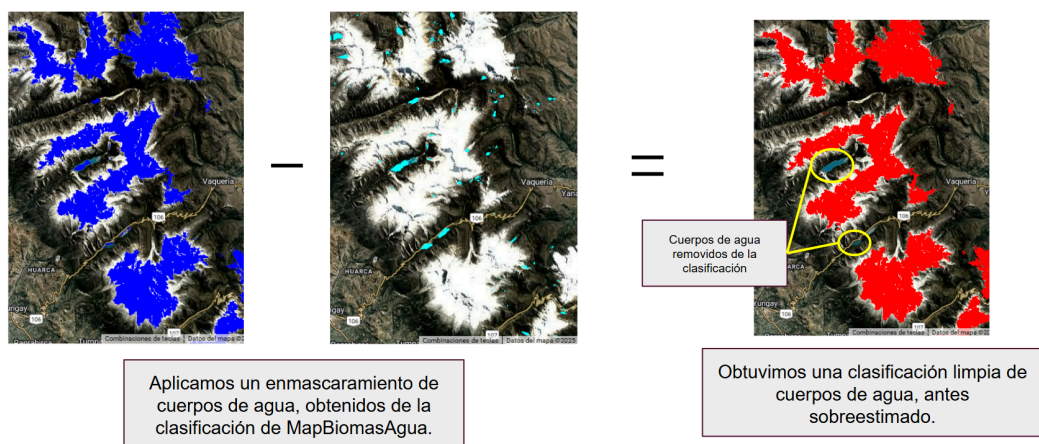


Figura 13 – Efecto del enmascaramiento de lagunas

4.3. 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.

Para el mapeo de nieve en los Andes, donde la superficie nival puede tener formas complejas debido a la topografía montañosa, el filtro espacial es valioso, ya que ayuda a eliminar clasificaciones erróneas causadas por sombras topográficas y nubes pequeñas no detectadas.

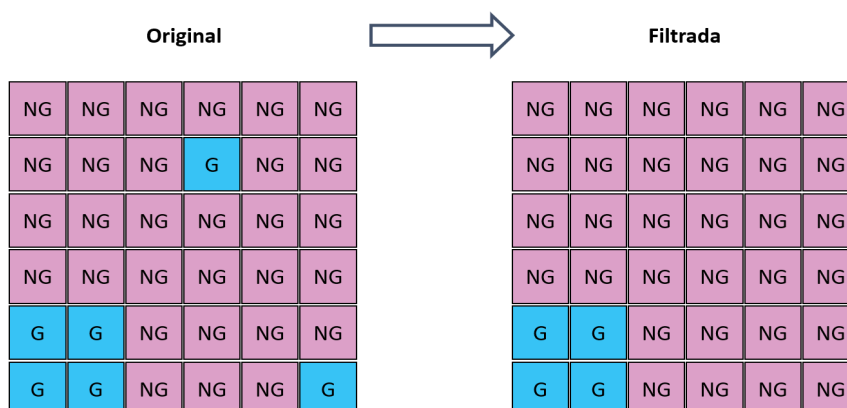


Figura 14 – Efecto del filtro espacial

4.4. Filtro de persistencia

El filtro de persistencia evalúa la frecuencia de presencia de cada píxel como cobertura nival en toda la serie temporal de 26 años, eliminando píxeles clasificados esporádicamente que corresponde a un ruido residual o a nieve estacional muy ocasional. Para cada píxel se contabilizan el número de años en que fue clasificado como cobertura nival y el número de total de años con dato válido. La frecuencia de persistencia se calcula como el cociente entre ambos valores, expresados en porcentaje, en este caso empleamos un umbral de persistencia al 35%. Este umbral es equivalente a una presencia mínima en aproximadamente 9 de los 26 años, la regla de decisión para la aplicación es la siguiente: Si la frecuencia es mayor al 35%

(presente en más de 9 años de los 26), el píxel se mantiene como cobertura nival en los años en que fue mapeado; y si la presencia del píxel es menor al 35% (menos de 9 años), el píxel es reclasificado a no nieve en todos los años de la serie. El filtro de persistencia no modifica los años en que el píxel no fue mapeado como nieve, únicamente eliminamos la presencia de cobertura nival en años donde no se supera el umbral.

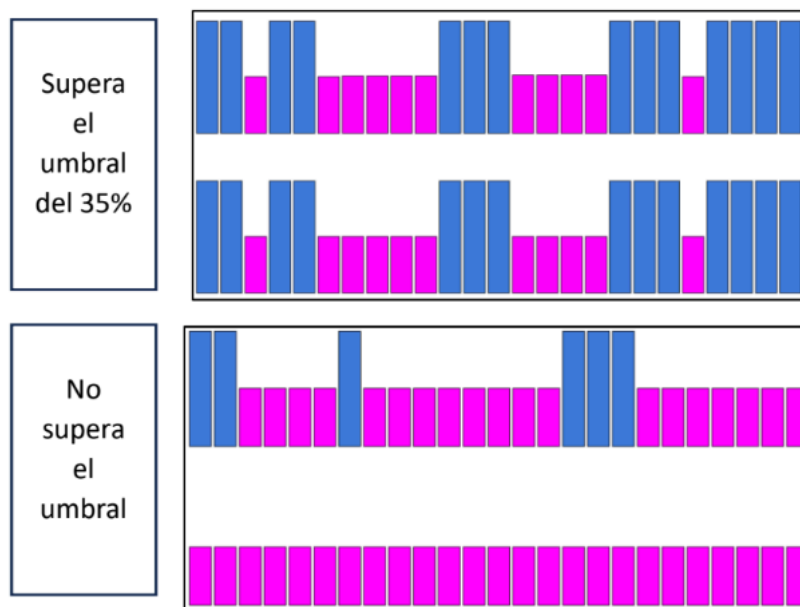


Figura 15 – Filtro de persistencia

4.5. Filtro Correctivo

La presencia de años con clasificación prácticamente vacía, producto de la ausencia de mosaicos válidos por alta nubosidad persistente durante toda la temporada húmeda. Estos años presentan muy pocos o ningún píxel clasificado como cobertura nival, incluso en zonas de glaciar permanente confirmado.

El filtro utiliza como referencia una capa auxiliar de píxeles persistentes al 90% de la serie temporal, que representa el núcleo de cobertura glaciar/nival con presencia en 23 de los 26 años analizados. Para cada año y región se evalúa la relación entre los píxeles de la capa de persistencia al 90% y los píxeles clasificados como cobertura nival en ese año dentro de la zona de persistencia. Si los píxeles de la capa de referencia al 90% superan en más del 30% a los píxeles clasificados en el año evaluado, dicho año es declarado como vacío.

Esta condición es válida porque los píxeles de la capa al 90% deberían estar contenidos dentro de la clasificación anual al 35% ($P_{90} \subseteq P_{35}$). Cuando esta relación de contención se invierte, es decir, cuando el núcleo permanente supera en cantidad a la clasificación anual, es indicativo de ausencia de mosaico válido o clasificación deficiente para ese año.

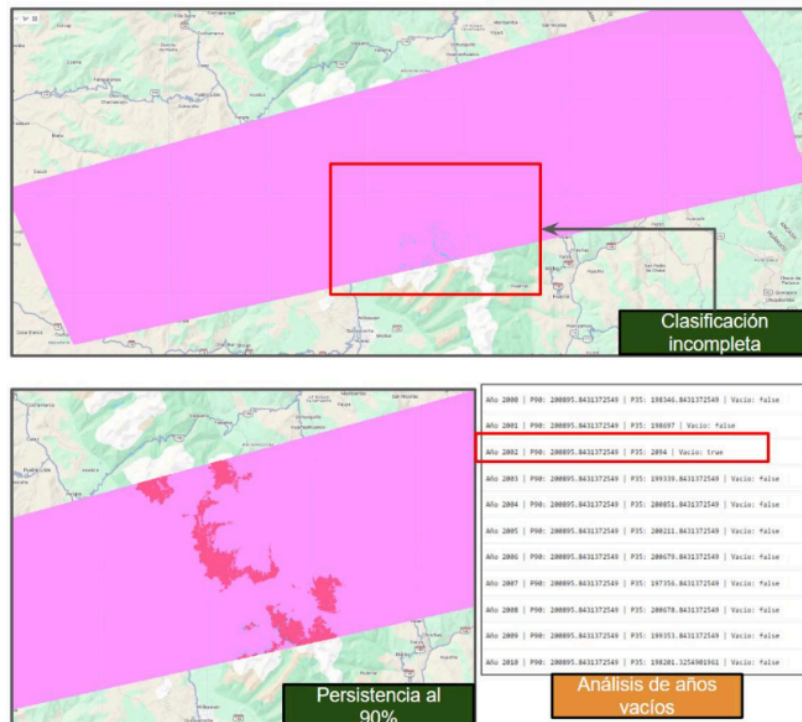


Figura 16 – Filtro correctivo

Para cada año declarado vacío, el algoritmo busca los años válidos más próximos anterior y posterior en la serie temporal. La corrección se aplica mediante la intersección (operación AND lógica) de las clasificaciones de ambos años vecinos válidos: únicamente los píxeles identificados como cobertura nival en ambos años son utilizados para rellenar el año vacío. Este criterio conservador garantiza que solo se rellene la mínima cobertura glaciar/nival verificada por continuidad temporal, evitando la sobreestimación.



Figura 17 – Acción del filtro correctivo

5. Referencias

Bomshoms Calvelo, M., Quispe Gutiérrez, N., & Quispe Vega, K. (2018).

Estudio de la frecuencia de nevadas en el Perú. Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI).

- Brown, R. D., & Robinson, D. A. (2011). Northern Hemisphere spring snow cover variability and change over 1922–2010 including an assessment of uncertainty. *The Cryosphere*, 5(1), 219–229.
- Dietz, A. J., Kuenzer, C., Gessner, U., & Dech, S. (2012). Remote sensing of snow – A review of available methods. *International Journal of Remote Sensing*, 33(13), 4094–4134.
- Gascoin, S., Grizonnet, M., Bouchet, M., Salgues, G., & Hagolle, O. (2019). Theia Snow collection: High-resolution operational snow cover maps from Sentinel-2 and Landsat-8 data. *Earth System Science Data*, 11(2), 493–514.
- Luo, Jianfeng, Dong, Chunyu, Lin, Kairong, Chen, Xiaohong, Zhao, Liqiang, & Menzel, Lucas. (2022). *Mapping forest snow cover using optical remote sensing, machine learning, and time-lapse photography. Remote Sensing of Environment.*
<https://doi.org/10.1016/j.rse.2022.113017>
- SENAMHI. (2018). *Estudio de la frecuencia de nevadas en el Perú.* Servicio Nacional de Meteorología e Hidrología del Perú.
- Schaefli, B. (2015). Projecting hydropower production under future climates: a guide for decision-makers and modelers based on a review of published studies. *WIREs Water*, 2(4), 311–340.