

Cartografía de la innivación: más allá del NDSI

Pons Fernández, Xavier ¹ Navarro, Martí ¹ Pesquer, Lluís ¹ Cea, Cristina ¹ Gómez-Gener, Lluís ²

¹ Universitat Autònoma de Barcelona, España

² Institute of Environmental Assessment and Water Research (IDAEA-CSIC)

ORCID: Pons Fernández [0000-0002-6924-1641](https://orcid.org/0000-0002-6924-1641) Navarro [0009-0009-8174-0505](https://orcid.org/0009-0009-8174-0505) Pesquer [0000-0002-7396-2468](https://orcid.org/0000-0002-7396-2468) Cea [0000-0003-0776-6706](https://orcid.org/0000-0003-0776-6706) Gómez-Gener [0000-0003-3279-3589](https://orcid.org/0000-0003-3279-3589)

Correspondencia: xavier.pons@uab.cat Marti.NavarroP@autonoma.cat l.pesquer@creaf.uab.cat Cristina.Cea@uab.cat lgghse@cid.csic.es

RESUMEN

La cartografía de la cubierta de nieve y su dinámica han constituido aplicaciones típicas de las imágenes de teledetección. La automatización de estas aplicaciones ha sido un objetivo importante por el evidente interés que tiene el conocimiento del manto nival para la hidrología, el funcionamiento de los ecosistemas y el balance energético terrestre. La disponibilidad de sensores espaciales capaces de captar radiación reflejada en el infrarrojo de onda corta a la vez que en el verde fue especialmente importante para definir índices como el de innivación de diferencia normalizada (Normalized Difference Snow Index, NDSI), de cálculo rápido, una característica especialmente importante cuando se propuso. La utilización de umbrales simples y universales para separar superficies cubiertas de nieve de las no nevadas hacían todavía más atractivas estas aproximaciones. Sin embargo, las diferencias entre imágenes, las confusiones con otras cubiertas, etc., han ido llevando, primero, al uso de umbrales distintos y, más tarde a cuestionar si hoy en día está justificada una solución tan simple cuando disponemos de mucha más información espectral y de mucha más capacidad de cálculo. A estos interrogantes se une el hecho de que algunos productos de innivación proporcionados por las grandes agencias espaciales presentan frecuentes errores de omisión y comisión. Este trabajo plantea abandonar la incertidumbre asociada al NDSI y, en su lugar, utilizar aproximaciones más robustas, como las basadas en aprendizaje automático (k-NN) fuertemente multivariante con datos MSI de Sentinel-2. A continuación se explora la obtención de la innivación en días concretos en que se simula no disponer de imágenes MSI pero se modeliza la innivación en base a productos MODIS entrenados con los resultados de MSI y variables geográficas. Los resultados, muy prometedores, nos permiten vislumbrar una vía no solamente para mejorar la cartografía en fechas concretas, sino para generar series temporales coherentes.

Palabras clave: NDSI, mapas de cubiertas nivales, aprendizaje automático, k-NN, dinámica nival



Fecha de recepción: 23 febrero 2026 · Fecha de aceptación: 23 febrero 2026

Cartografía de la innivación: más allá del NDSI


Pons Fernández, Xavier ⁽¹⁾, Navarro, Martí ⁽¹⁾, Pesquer, Lluís ⁽¹⁾, Cea, Cristina ⁽¹⁾, Gómez-Gener, Lluís ⁽²⁾

⁽¹⁾ Universitat Autònoma de Barcelona, España.

 0000-0002-6924-1641, xavier.pons@uab.cat ;  0009-0009-8174-0505, Marti.NavarroP@autonoma.cat

 0000-0002-7396-2468, l.pesquer@creaf.uab.cat ;  0000-0003-0776-6706, Cristina.Cea@uab.cat

⁽²⁾ Institute of Environmental Assessment and Water Research (IDAEA-CSIC).

 0000-0003-3279-3589, lgghse@cid.csic.es

Resumen: La cartografía de la cubierta de nieve y su dinámica han constituido aplicaciones típicas de las imágenes de teledetección. La automatización de estas aplicaciones ha sido un objetivo importante por el evidente interés que tiene el conocimiento del manto nival para la hidrología, el funcionamiento de los ecosistemas y el balance energético terrestre. La disponibilidad de sensores espaciales capaces de captar radiación reflejada en el infrarrojo de onda corta a la vez que en el verde fue especialmente importante para definir índices como el de innivación de diferencia normalizada (*Normalized Difference Snow Index*, NDSI), de cálculo rápido, una característica especialmente importante cuando se propuso. La utilización de umbrales simples y universales para separar superficies cubiertas de nieve de las no nevadas hacían todavía más atractivas estas aproximaciones. Sin embargo, las diferencias entre imágenes, las confusiones con otras cubiertas, etc., han ido llevando, primero, al uso de umbrales distintos y, más tarde a cuestionar si hoy en día está justificada una solución tan simple cuando disponemos de mucha más información espectral y de mucha más capacidad de cálculo. A estos interrogantes se une el hecho de que algunos productos de innivación proporcionados por las grandes agencias espaciales presentan frecuentes errores de omisión y comisión. Este trabajo plantea abandonar la incertidumbre asociada al NDSI y, en su lugar, utilizar aproximaciones más robustas, como las basadas en aprendizaje automático (k-NN) fuertemente multivariante con datos MSI de Sentinel-2. A continuación se explora la obtención de la innivación en días concretos en que se simula no disponer de imágenes MSI pero se modeliza la innivación en base a productos MODIS entrenados con los resultados de MSI y variables geográficas. Los resultados, muy prometedores, nos permiten vislumbrar una vía no solamente para mejorar la cartografía en fechas concretas, sino para generar series temporales coherentes.

Palabras clave: NDSI, mapas de cubiertas nivales, aprendizaje automático, k-NN, dinámica nival.

Snow Cover Mapping: Beyond the NDSI

Abstract: *Snow cover mapping and the analysis of its dynamics have long been standard applications of remote sensing imagery. The automation of these applications has been a major objective due to the importance of snow cover information for hydrology, ecosystem functioning, and the Earth's energy balance. The availability of spaceborne sensors capable of acquiring reflected radiation in both the shortwave infrared and the green wavelengths was particularly relevant for defining indices such as the Normalized Difference Snow Index (NDSI), whose rapid calculation was a key advantage at the time it was proposed. The use of simple, universal thresholds to distinguish snow covered surfaces from snow free areas further increased the appeal of these approaches. However, differences among images, confusions with other land cover types, and additional sources of variability have progressively led first to the adoption of alternative thresholds and later to questioning whether such a simple solution remains justified today, given the much richer spectral information and far greater computational capacity now available. These concerns are compounded by the fact that several snow cover products distributed by major space agencies exhibit frequent omission and commission errors. This study proposes abandoning the uncertainty associated with the NDSI and, instead, adopting more robust approaches, such as strongly multivariate machine-learning methods (k-NN) using Sentinel-2 MSI data. The work then explores the retrieval of snow cover on specific days for which MSI imagery is assumed to be unavailable, modelling snow presence on the basis of MODIS products trained with MSI-derived results and geographic variables. The results, which are highly*

promising, point to a pathway not only for improving snow cover cartography on specific dates but also for generating coherent time series.

Keywords: NDSI, snow cover maps, machine learning, k-NN, snow dynamics.

1. INTRODUCCIÓN

El conocimiento del manto nival es fundamental para el estudio de la hidrología, el funcionamiento de los ecosistemas y el balance energético terrestre en zonas de alta montaña. Desde los inicios de la teledetección espacial se vieron las imágenes de satélite como prometedoras fuentes de datos para cartografiar la innivación así como para realizar un seguimiento de la misma. Con la llegada de sensores como el Thematic Mapper en el Landsat-4, capaces de captar la radiancia en la región espectral del infrarrojo de onda corta (IRoc, donde la nieve presenta una señal baja), además de en el verde (V, donde la nieve presenta una señal muy alta), se planteó la utilización de índices simples, como el de innivación de diferencia normalizada (*Normalized Difference Snow Index*), NDSI, formulado como se presenta en la Ecuación 1 (Cea *et al.*, 2007; Dozier, 1989):

$$NDSI = \frac{V - IRoc}{V + IRoc} \quad (1)$$

Como puede verse en la Ecuación 1, el cálculo del NDSI es rápido y, además, por su naturaleza de cociente, razonablemente tolerable sin correcciones radiométricas cuando los niveles digitales son proporcionales a radiancias y con factores de transformación parecidos. Si a estas características añadimos la utilización de umbrales simples y universales para discriminar las superficies nevadas de las no nevadas, es fácil entender el atractivo que supusieron dichas aproximaciones en tiempos con recursos de cálculo mucho más limitados que los actuales.

Sin embargo, a lo largo del tiempo ha ido haciéndose evidente que las diferentes características entre imágenes, las confusiones con otras cubiertas, etc. conllevaban problemas que se han intentado solucionar mediante el uso de umbrales cambiantes (Dozier, 1989, propuso un umbral 0.4, pero este criterio ha sido cuestionado por Härer *et al.*, 2018, y pueden encontrarse en la literatura valores entre 0.18 y 0.70, o autores, como Painter *et al.*, 2009, que proponen umbrales distintos según la cubierta existente bajo la zona nevada). La pérdida de generalización que implica esta “solución” plantea si hoy en día está justificado un procesado tan simple cuando disponemos de mucha más información espectral y de mucha más capacidad de cálculo. A estos interrogantes se une el hecho de que algunos productos de innivación proporcionados por las grandes agencias espaciales presentan frecuentes errores de omisión y comisión, y que con sensores con poca resolución radiométrica las zonas en sombra producen índices especialmente inestables.

Este trabajo plantea abandonar la incertidumbre asociada al NDSI que pretende discriminar la superficie

innivada mediante un umbral simple y, en su lugar, explorar aproximaciones más robustas, como las basadas en aprendizaje automático (k-NN) fuertemente multivariante, o basadas en regresiones logísticas también multivariantes. El objetivo inmediato es conseguir resultados más robustos en la cartografía del manto nival en fechas concretas y, en un horizonte cercano, generar series temporales coherentes.

2. MATERIAL Y MÉTODOS

2.1. Datos utilizados y área de estudio.

Para este trabajo se han utilizado imágenes del sensor MSI de los satélites Sentinel-2. Para obtener resultados más generalizables se ha optado por un nivel de procesado 2A, aunque para futuros trabajos se contemplará la posibilidad de aplicación de métodos propios para la obtención de reflectancias terreno de mayor calidad. Las imágenes utilizadas corresponden a la tesela 31TCH, ubicada en la zona pirenaica NO de Cataluña, y corresponden a los días 14, 19 y 24 de febrero de 2021. Para esas fechas se realizó un concienzudo trabajo de fotointerpretación de combinaciones RGB para generar áreas de entrenamiento y de test que proporcionen zonas nevadas y no nevadas.

Como covariables para la modelización en fechas supuestamente sin datos Sentinel-2 se han utilizado variables topográficas (altitud, pendiente), radiación solar calculada mediante el algoritmo [InsolMets](#) (Roca-Fernández *et al.* 2025) implementado en el *software* gratuito [MiraMon](#) (Pons, 2026) y con datos libremente disponibles en “[Mapas de radiación solar de la península ibérica](#)”, e imágenes de fracción de cubierta de innivación (FSC) de [MODIS](#).

2.2. Clasificación mediante aprendizaje automático (k-NN) multivariante

De entre los métodos de aprendizaje automático que permiten obtener clasificaciones robustas sin una inversión enorme en tiempo de cálculo (que en este método depende sobre todo del número de muestras de entrenamiento) y, a la vez, entender los resultados sin tratarlos como una total “caja negra”, el método k-NN ocupa un lugar destacado. k-NN es el acrónimo de k (que hace referencia a un número preestablecido de píxeles entre los píxeles usados para definir las clases deseadas en el mapa categórico que se desea obtener) y NN (siglas en inglés de *nearest neighbors*, vecinos más próximos). El método asume que es plausible que los píxeles próximos entre sí en el espacio estadístico pertenezcan a la misma clase informacional.

Para cada píxel de la imagen a clasificar, se calcula la distancia euclidiana (en el espacio estadístico de representación de las variables independientes) a cada píxel de las áreas de entrenamiento. Se eligen los k

píxeles más próximos de entre los de las áreas de entrenamiento y la clase predominante de este grupo de k píxeles será la clase que se le asigna al píxel a clasificar.

La implementación [k-NN](#) de MiraMon además de paralelización permite diversas sofisticaciones para un control óptimo de los resultados, como calcular la clase predominante mediante la moda o aplicando un peso en función del inverso de la distancia (es decir, que en el cálculo de la moda las muestras más cercanas en el espacio estadístico pesan más), etc.

2.3. Modelización mediante k-NN y mediante regresión logística para la obtención de la superficie innivada en fechas supuestamente sin datos MSI.

En una fecha en que no se disponga de datos MSI es posible abordar la cartografía a partir de una modelización entrenada con las variables geográficas y el producto MODIS citado en la sección anterior. Dicha modelización puede llevarse a cabo de nuevo con la implementación k-NN de MiraMon ya que ésta permite que las áreas de entrenamiento estén ubicadas en otra posición espacial y/o temporal a los datos a clasificar. En este caso los datos de entrenamiento corresponden a los resultados de la clasificación en la fecha en que se dispone de datos MSI, y se clasifica usando los datos de las covariables disponibles en la fecha problema. Los datos de test utilizados serán los resultados de las clasificaciones con imágenes Sentinel-2 si se demuestra que su calidad es cercana al 100 %.

Por otro lado, la naturaleza binaria del problema a resolver (nieve o no nieve) lo hace también especialmente adecuado para abordarlo mediante regresiones logísticas, tentativamente sofisticadas mediante modelos aditivos generalizados (GAM, por sus siglas en inglés). En este caso se ha utilizado la implementación del *software* gratuito [R](#) (R Core Team, 2026).

3. RESULTADOS Y DISCUSIÓN

El resultado de la clasificación en una fecha en que se dispone de datos MSI (14 de febrero de 2021) puede verse en la Figura 1. En el panel superior de dicha figura 1 se muestra una combinación RGB en la que puede apreciarse muy bien, en tonos fucsia, la extensión de la nieve en la zona cubierta por la imagen Sentinel-2. En el panel inferior puede apreciarse la clasificación prácticamente perfecta de color celeste (acierto muy cercano al 100 %). En los días 19 y 24 también se han obtenido clasificaciones prácticamente perfectas con los datos Sentinel-2, las cuales servirán de datos de test para las modelizaciones suponiendo que no se dispone de datos del sensor MSI.

Para cada una de las tres fechas de febrero de 2021 (días 14, 19 y 24) se han realizado modelizaciones basadas en los datos del día 14 para conocer con qué exactitud se pueden obtener los datos de innivación ya sin presentar los datos de las imágenes Sentinel-2, sino simplemente utilizando las covariables explicadas en el apartado anterior.

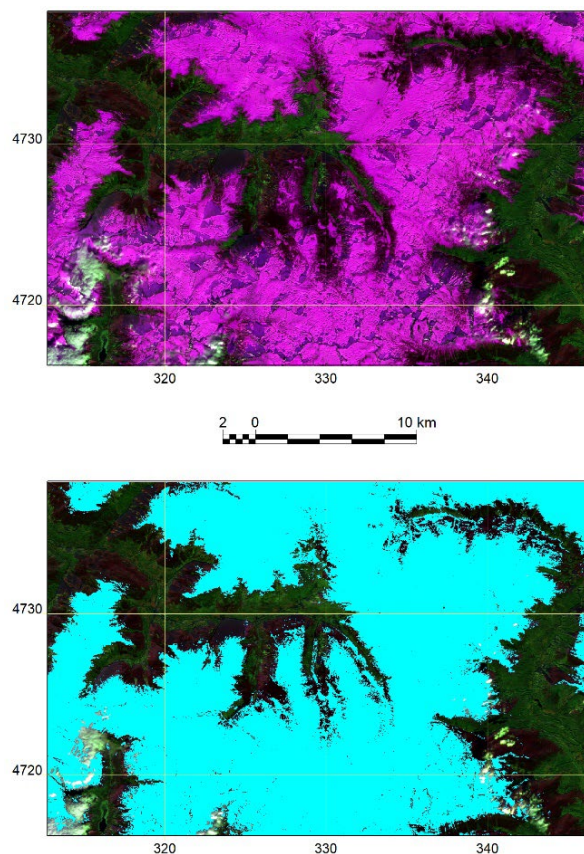


Figura 1. Detalle de composición RGB (bandas MSI 7,12,3) de la imagen del 14 de febrero de 2021 (panel superior) donde el color fucsia corresponde a píxeles innivados, y la clasificación obtenida mediante k-NN (panel inferior) donde el color celeste representa los píxeles clasificados como nieve. Sistema de referencia UTM-31-N WGS84. Coordenadas en km.

Como era esperable, en el día 14 la modelización con las variables geográficas y el producto MODIS permite obtener un mapa de innivación que presenta un 96 % de exactitud global con k-NN, y un 98 % con GAM. Cuando nos alejamos de la fecha de entrenamiento (día 14) y modelizamos en el día 19 obtenemos unos aciertos del 94 % con k-NN y del 97 % con GAM. Finalmente, alejándonos todavía más de la fecha de entrenamiento, el día 24 obtenemos unos aciertos del 95 % con k-NN y de un 96 % con GAM.

Cuando se modelizan los datos en los días 19 y 24 con los resultados de la clasificación MSI en dichas fechas el acierto es, como era de esperar, mayor (98 % en k-NN y entre 97 y 96 % con GAM).

Como ha podido verse, los niveles de acierto han sido muy altos con ambos métodos, oscilando alrededor de cifras parecidas, que no arrojan un resultado nítido sobre cuál de los métodos de modelización es mejor, pero que parecen indicar que cualquiera de los dos métodos da muy buenos resultados y que las pequeñas diferencias pueden deberse a fenómenos aleatorios o coyunturales.

4. CONCLUSIONES Y LÍNEAS DE INVESTIGACIÓN FUTURAS

La aplicación de k-NN a los datos MSI de Sentinel-2 permite una excelente cartografía de superficie innivada en las fechas en que se dispone de dichas imágenes, con resultados robustos que evitan la vacilación en los umbrales de los índices NDSI. Por otro lado, la modelización, tanto con k-NN como con GAM, en fechas sin imágenes MSI (en este experimento sí que se disponía de ellas pero se han utilizado para poder verificar la calidad de la modelización) ha proporcionado también muy buenos resultados de cartografía de innivación. Si en futuros experimentos se confirma una similar bondad de ambos métodos podría optarse por k-NN por su menor coste computacional y su mayor simplicidad conceptual, lo que permite un control mayor en caso de obtener resultados extraños. Finalmente, en futuros experimentos se comprobará el acierto obtenido ante la aparición de nuevas nevadas a la luz de las mismas variables geográficas y de FSC de MODIS.

5. AGRADECIMIENTOS

Este trabajo ha sido posible gracias a las subvenciones del SGR (Grupos de Investigación Consolidados y de Calidad de la Generalitat de Catalunya, SGR-2021-00554) y del proyecto DynaFun (PID2023-152719OB-C21-MCIU/AEI/ERDF,EU). Xavier Pons es beneficiario de una ayuda ICREA-Academia a la Excelencia en Investigación (2023-2027).

6. REFERENCIAS

- Cea, C., Cristóbal, J., & Pons, X. (2007). Determinación de la superficie nival del Pirineo catalán mediante imágenes Landsat y MODIS. XII Congreso Nacional de Tecnologías de la Información Geográfica. <https://www.researchgate.net/publication/23992680>
- Dozier, J. (1989). Spectral signature of alpine snow cover from the landsat thematic mapper. *Remote Sensing of Environment*, 28:9–22. [https://doi.org/10.1016/0034-4257\(89\)90101-6](https://doi.org/10.1016/0034-4257(89)90101-6)
- Härer, S., Bernhardt, M., Siebers, M., & Schulz, K. (2018). On the need for a time- and location-dependent estimation of the NDSI threshold value for reducing existing uncertainties in snow cover maps at different scales. *The Cryosphere*, 12(5):1629–1642. <https://doi.org/10.5194/tc-12-1629-2018>
- Painter, T. H., Rittger, K., McKenzie, C., Slaughter, P., Davis, R. E., & Dozier, J. (2009). Retrieval of subpixel snow covered area, grain size, and albedo from MODIS. *Remote Sensing of Environment*, 113(4):868–879. <https://doi.org/10.1016/j.rse.2009.01.001>
- Pons, X. (2026) MiraMon. Geographic Information System and Remote Sensing Software. Bellaterra: CREA. https://www.mirammon.cat/Index_spa.htm
- R Core Team (2024). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.r-project.org/>

Roca-Fernández, C., Pons, X., Ninyerola, M. (2025) A Comparison of Different Solar Radiation Models in the Iberian Peninsula. *Atmosphere* 16 (5): 590. <https://doi.org/10.3390/atmos16050590>.