

upna

Universidad Pública de Navarra
Nafarroako Unibertsitate Publikoa

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA AGRONÓMICA Y BIOCIENCIAS

NEKAZARITZAKO INGENIARITZAKO ETA BIOZIENTZIETAKO GOI MAILAKO ESKOLA TEKNIKOA

Monitorización de la extensión de nieve mediante imágenes Sentinel

presentado por

Naiara Gil Alonso

**MÁSTER UNIVERSITARIO EN SISTEMAS DE INFORMACIÓN GEOGRÁFICA Y TELEDETECCIÓN
UNIBERTSITATE MASTERRA INFORMAZIO GEOGRAFIKOKO SISTEMETAN ETA TELEDETEKZIOAN**



Septiembre, 2022

RESUMEN

La cobertura de nieve se considera una de las variables más relevantes para la evaluación y seguimiento de eventos meteorológicos extremos, estimación y previsión de recursos hidrológicos y, especialmente en montaña, centinela del cambio climático. Su seguimiento y evaluación a través de imágenes satelitales son de gran utilidad para conocer mejor estos procesos y optimizar la toma de decisiones. El objetivo de este trabajo es estudiar la aptitud de las imágenes Sentinel-2 para delinear la extensión de nieve en el Pirineo navarro-aragonés. Para ello se aplican diferentes técnicas de clasificación, basadas en umbrales de índices de nieve y técnicas de aprendizaje automático. Se analiza, además, el producto de Copernicus Snow and Ice en el mismo área de estudio. Los resultados obtenidos muestran que este último producto tiene margen de mejora en las zonas afectadas por sombras topográficas, en las que no identifica adecuadamente la nieve. Entre los clasificadores evaluados el clasificador de máxima verosimilitud y la herramienta Feature Analyst proporcionan los mejores resultados. Otros clasificadores más sencillos basados en umbrales de índices de nieve obtienen también buenos resultados y destacan por su sencillez. En un futuro sería interesante extender este trabajo a otras zonas montañosas en las que la estimación de la cobertura de nieve mediante teledetección resulta especialmente compleja.

Palabras clave: NDSI; S3 INDEX; Random Forest; Cobertura de nieve; S&I; Teledetección; Sentinel-2, Landsat-9, Pirineos.

ABSTRACT

Snow cover is considered one of the most relevant variables for the evaluation and monitoring of extreme weather events, estimation and forecasting of hydrological resources and, especially in mountains, as a sentinel of climate change. Its monitoring and evaluation through satellite images are especially useful to better understand these processes and to optimize decision making. The aim of this work is to study the suitability of Sentinel-2 images to delineate the snow extent in the Navarre-Aragon Pyrenees. For this purpose, different classification techniques based on snow index thresholds and machine learning techniques are applied. The Copernicus Snow and Ice product is also analyzed in the same study area. The results obtained show that the latter product has room for improvement in areas affected by topographic shadows, where it does not identify snow. Among the classifiers evaluated, the maximum likelihood classifier and the Feature Analyst tool provide the best results. Other simpler classifiers based on snow index thresholds also obtain satisfactory results and stand out for their simplicity. In the future it would be interesting to extend this work to other mountainous areas where the estimation of snow cover by remote sensing is particularly complex.

Keywords: NDSI; S3 INDEX; snow cover; Random Forest; S&I; remote sensing; Sentinel-2; Landsat-9; Pyrenees.

ÍNDICE

1.	Antecedentes.....	9
1.1.	Criosfera y cambio climático	9
1.2.	Marco teórico	10
1.2.1.	Caracterización física de la nieve.....	10
1.2.2.	Antecedentes en la temática.....	13
2.	Objetivos.....	13
2.1.	Objetivo general	13
2.2.	Objetivos específicos	14
3.	Materiales.....	14
3.1.	Área de estudio	14
3.2.	Plataformas de teledetección y productos adquiridos	17
3.2.1.	Sentinel-2.....	17
3.2.2.	Productos Snow and Ice del Copernicus Land Monitoring System.....	18
3.2.3.	Imágenes Landsat	21
3.3.	Áreas de entrenamiento.....	23
3.4.	Programas utilizados	26
4.	Metodología.....	26
4.1.	Creación y preparación de capas bajo análisis (Sentinel-2)	26
4.1.1.	Delineación de nieve basadas en clasificación de Sentinel-2.....	26
4.1.2.	Producto Copernicus Snow and Ice.....	34
4.2.	Creación de capa de referencia (Landsat)	35
4.2.1.	Pre-procesado de imágenes Landsat.....	35
4.2.2.	Delineación de nieve	38
4.2.3.	Post-procesado	39
4.3.	Validación/Comparación	39
5.	Resultados y discusión	41
6.	Conclusiones	49
7.	Bibliografía	50
8.	Anexos.....	54
8.2.	Anexo: Mapas de validación de las delineaciones	54
8.3.	Anexo: Matrices de confusión.....	63

ÍNDICE DE TABLAS

Tabla 1. Albedos de diferentes superficies (Fuente: Oke, 1998; Ahrens, 2001; Wikipedia).....	13
Tabla 2. Longitudes de onda y resolución para cada banda de Sentinel 2 (Fuente: ESA).....	17
Tabla 3. Tipos de producto de Sentinel-2. Fuente: Sentinel-2 Data Products. ESA).....	18
Tabla 4.Productos Sentinel de level 2A utilizados en el estudio.....	18
Tabla 5. Productos Proporcionados por el programa Copernicus Land Service y sus características.....	20
Tabla 6. Productos FSCOG utilizados para el estudio.....	21
Tabla 7. Diferencias entre bandas de Landsat 7 y Landsat 8 (Fuente: https://www.sigterritoires.fr).....	22
Tabla 8. Producto Landsat descargado de nivel 2.....	23
Tabla 9. Áreas de entrenamiento de la categoría de Nieve.....	24
Tabla 10. Áreas de entrenamiento de la categoría de No Nieve.....	24
Tabla 11. Áreas de entrenamiento en líneas de nieve (cordilleras y caminos).....	32
Tabla 12.Características de FSC On Ground (Fuente: Ref.: COSIMS-DT-060-MAG_PUM_SNOW).....	34
Tabla 13. Resultados de los valores para ponderar el nivel de detalle añadido a cada banda.....	38
Tabla 14. Matriz de confusión para clasificaciones binarias.....	39
Tabla 15. Matriz de confusión del producto de S&I contra la referencia (Landsat).....	41
Tabla 16. Resultados de las métricas estudiadas.....	41
Tabla 17. Tabla general con las diferentes validaciones obtenidas a través de las matrices de confusión....	43
Tabla 18. Estadístico F score de las delineaciones realizadas.....	49

ÍNDICE DE FIGURAS

Figura 1.Estructura molecular hexagonal de los cristales de hielo. Fuente: lugaresdenieve.com.....	10
Figura 2. Diagrama morfológico de los cristales de nieve en función de la temperatura y del grado de Humedad (Fuente: “SnowFlake Science,”)......	11
Figura 3. Curvas de reflectividad para distintos tipos de nieve y hielo (Fuente: Chuvieco, 2006).....	11
Figura 4. Curvas de reflectividad para la nieve con distintos tamaños de grano (Fuente: Dozier, 1989).....	12
Figura 5. Firmas espectrales de una nube densa y cobertura de nieve en distinto tamaño de grano (Fuente: Gareth Rees, 2006).....	12
Figura 6. Localización, límites y división administrativa (Fuente: Dialnet: El Medio Natural De Los Pirineos).	14
Figura 7. Área de estudio en la zona de los Pirineos.....	16
Figura 8. Cuadrícula/Tiles de Sentinel-2 sobre el EEA39 (Fuente: Ref.: COSIMS-DT-060-MAG_PUM_SNOW).	19
Figura 9. Diagrama de trabajo de HR-S&I. Fuente: Ref: COSIMS-DT-060-MAG_PUM_SNOW.....	19
Figura 10. Lista de archivos dentro del Producto FSC.....	20
Figura 11.El “Multispectral Scanner System (MSS) a bordo de Landsats 1-5 tenía 4 bandas. El “Thematic Mapper” (TM) a bordo de Landsats 4 y 5 tenía 7 bandas. El “Enhanced Thematic Mapper Plus” (ETM+) de landsat 7 tenía 8 bandas, y Landsats 8 y 9 tienen 11 bandas.....	22
Figura 12. Distribución espacial de las diferentes áreas de entrenamiento.....	25
Figura 13. Área de interés (AOI). Solapa de Landsat con el mosaico Sentinel 2.....	27
Figura 14. Figura 14. AOI de estudio. Solape Landsat - Sentinel-2.....	27
Figura 15. Patrón Manhattan 7x 7 píxeles.....	31
Figura 16. Limpieza píxeles “islas” MMU.....	33
Figura 17. Suavizado y Unión.....	33
Figura 18. Limpieza de huecos y resultado final de la máscara.....	33
Figura 19. Combinación de imágenes FSCOG.....	34
Figura 20. Clasificado nieve/no nieve.....	35

Figura 21. Diferencias de resolución entre las bandas a 30 m (composición RGB, Izda) y la pancromática a 15m (dcha).	36
Figura 22. Imagen pancromática(izda.), imagen multiespectral (composición en falso color, en el centro) .	36
Figura 23. Filtro Kernel utilizado para la transformada Walvelet à trous.	37
Figura 24. Imágenes del detalle (izda), la pancromática (centro y la pancromática con nivel 1 à trous.	37
Figura 25. Imagen multiespectral original (dcha.) e imagen multiespectral con el Pansharpening aplicado (izda.).	38
Figura 26. Delineación de referencia a través de la ftointerpretación de Landsat.	39
Figura 27. Delineaciones solapadas del producto S&I con la delineación de referencia (izda sup. Landsat composición RGB, dcha sup. Delineación Landsat, izda inf. Delineación S&I y dcha inf. Cruce delineaciones).....	42
Figura 28. Validación del producto S&I	43
Figura 29. Delineaciones con problemas para discernir la sombra de la nieve (izda sup. Landsat composición RGB, dcha sup. Delineación MDC, izda inf. Delineación Kmeans y dcha inf. Delineación S&I)	44
Figura 30. Mapa de validación de la delineación de S3.....	45
Figura 31. Validación de la delineación NDSI.	46
Figura 32. Delineaciones de clasificadores supervisados Random Forest y KNN (de arriba hacia abajo, Sentinel-2 en RGB, el clasificador de Random Forest y el clasificador KNN).....	47
Figura 33. Validación de la delineación obtenida por el clasificador supervisado de Feature Analyst.	48
Figura 34. Validación de la delineación obtenida por el clasificador de máxima verisimilitud.....	48
Figura 35. Mapas de clasificadores, de izda a dcha, imagen Sentinel-2 en RGB, MLC y el clasificador de FA	48

1. Antecedentes

La vigilancia de la extensión de la cobertura de nieve es fundamental para distintos aspectos como la monitorización del clima y sus procesos de cambio [1], el seguimiento de eventos meteorológicos extremos y potencialmente desastrosos [2] o la estimación y previsión de recursos hidrológicos [3]. En efecto, la cobertura de nieve se considera una de las variables de entrada relevantes para las previsiones en el campo de la meteorología, la hidrología y la gestión del agua, ya que tiene gran influencia en el ciclo del agua y en los flujos de energía de la superficie [4].

En el ámbito de la gestión de riesgos naturales, tanto la nieve como la cubierta de hielo son esenciales para evaluar los riesgos de desastres como las inundaciones, las avalanchas y gestionar los riesgos asociados a los periodos de estiaje [5]. También se le atribuyen intereses socioeconómicos como el turismo de invierno, la agricultura y la silvicultura, la generación de energía hidroeléctrica o el suministro de agua.

El manto de nieve y la cubierta de hielo de los lagos fueron especificados como una de las 50 variables climáticas esenciales (ECVs) que deben ser monitoreadas por teledetección satelital por el Sistema Global de Observación del Clima (GCOS). Las VCE están destinadas a apoyar el trabajo de la Convención Marco de las Naciones Unidas sobre el Cambio Climático y del Grupo Intergubernamental de Expertos sobre el Cambio Climático. El rápido desarrollo de las tecnologías y la creciente disponibilidad de datos de observación de la Tierra ofrecen un gran potencial para desarrollar metodologías y herramientas de vigilancia de la nieve y el hielo de alta resolución, que pueden incluso materializarse en servicios plenamente operativos [6].

El seguimiento y evaluación de la cobertura de nieve a través de imágenes satelitales, son de gran utilidad para la toma de decisiones en el pronóstico hidrológico a corto plazo, para la programación de un adecuado manejo de aguas que responda a las necesidades y restricciones de abastecimiento humanos e industriales, para el riego y drenaje, atenuación de crecidas, requerimientos ecológicos, así como el estudio y predicción de riesgos en asentamientos y construcciones, ya que un deshielo rápido puede traer graves problemas de estabilidad del terreno (inestabilidad de laderas y mayores riesgos de deslizamientos) [7].

La cobertura de nieve, especialmente en montaña, se considera un centinela del cambio climático, uno de sus indicadores más palpables. Alrededor del 78% de las zonas montañosas globales están experimentando una disminución de la nieve caracterizada por el acortamiento del periodo en el que se acumula nieve, que está relacionado tanto con el retraso en la aparición de las primeras nevadas como con el adelanto del deshielo. Estos cambios tienen un impacto profundo y en cascada sobre el medio ambiente de las montañas, su entorno y varios sectores socioeconómicos [1].

1.1. Criosfera y cambio climático

La criosfera comprende todas las regiones sobre y bajo la superficie de la Tierra y el océano donde el agua está en forma sólida, incluyendo el hielo del mar, el hielo de los lagos, el hielo de los ríos, la capa de nieve, los glaciares y las capas de hielo, así como el suelo congelado, incluyendo el permafrost [8]. Estas superficies pueden estar heladas de manera temporal o permanente. La criosfera, junto con el océano, sostienen hábitats únicos y se encuentran interconectados con otros componentes del sistema climático a través del intercambio global de agua, energía y carbono. La criosfera comprende cuatro tipos de estructuras; los glaciares, superficies con nieve, el hielo marino, y el suelo congelado (permafrost) y se estima que representan cerca de tres cuartos de las reservas de agua dulce del planeta.

Los glaciares son masas de hielo permanente que pueden medir desde unos pocos metros hasta cerca de dos mil metros de espesor, mientras que el hielo marino, o la superficie cubierta por hielo del mar, tienen un espesor de algunos metros que se extiende durante el invierno y se reduce en el verano. Ambos muestran una tendencia generalizada a retroceder como parte de un proceso natural, pero acelerado por los cambios provocados por la actividad humana [9]. El suelo congelado está compuesto por el agua que se congela en los espacios porosos del suelo. Puede mantenerse congelada solamente durante los meses fríos, pero en sitios muy fríos permanece perpetuamente en ese estado (permafrost). Por último, las superficies de nieve

temporal pueden darse tanto en la superficie terrestre como sobre el mar y son las que se cubren de nieve durante los meses fríos del año y pierden total o casi totalmente la nieve durante la temporada cálida [7].

Las zonas cubiertas de nieve son uno de los componentes más dinámicos de la criósfera, y por ello su cuantificación y medición son complejas. Sus parámetros están cambiando de manera acelerada en las últimas décadas con una disminución global afectando a los cambios hidrológicos asociados a ella (formación de nubes, la abundancia de precipitación, los mantos acuíferos, etc.) que impactan principalmente en las especies y ecosistemas polares y de alta montaña, que provocan alteraciones en las actividades estacionales y en la abundancia y distribución de especies importantes desde el punto de vista ecológico (pérdida de biodiversidad), cultural y económico [10]. En algunas partes del planeta ya se viven inundaciones o sequías en donde habitualmente no se presentaban [11].

Por otro lado, sin la criosfera, el albedo global se reduciría y por consiguiente las temperaturas globales serían aún más altas ya que la mayoría de la radiación sería absorbida por la Tierra. Por ello la cobertura de nieve se considera una variable importante, especialmente en el rol de controlar el albedo de la Tierra [12], ya que sus variaciones van estrechamente unidas al calentamiento global. El cambio climático, no solo altera el régimen de temperaturas, sino que también el de precipitaciones, lo que redundará en una menor y más irregular precipitación en forma de nieve.

Por su sensibilidad ante el aumento de la temperatura, la criosfera puede ofrecernos los mejores indicadores del cambio climático, su magnitud y dirección y por tanto es de gran urgencia estudiar y entender las implicaciones de los cambios que ocurren en profundidad.

1.2. Marco teórico

1.2.1. Caracterización física de la nieve

La nieve está conformada por cristales de hielo, agua líquida y aire. Normalmente tiene una estructura abierta y suave, excepto cuando es comprimida por la presión externa [14]. El hielo y la nieve se diferencian a nivel estructural, aunque ambos son agua en estado sólido. Dada su composición con 2 moléculas de Hidrógeno y 1 de oxígeno, el agua cristaliza siempre (bajo condiciones normales) en forma hexagonal (Figura 1), lo que se puede apreciar a simple vista al mirar un copo de nieve, y observar su típica forma [13].




Figura 1. Estructura molecular hexagonal de los cristales de hielo. Fuente: lugaresdenieve.com

Dependiendo de las condiciones en las que se conforman los copos de nieve (temperatura y humedad de las nubes) pueden tener otro tipo de apariencias, como se puede observar en el Diagrama de Nakaya (Figura 2). El máximo crecimiento se sitúa entre -12°C y -16°C , donde se formarán grandes copos si la humedad es muy elevada.




Figura 2. Diagrama morfológico de los cristales de nieve en función de la temperatura y del grado de Humedad (Fuente: "SnowFlake Science,").

Para que la precipitación llegue al suelo en forma de nieve es necesario que las condiciones de temperatura y humedad sean adecuadas para que los copos no se fundan en el camino. A partir del nivel en el que la temperatura alcanza los 0°C, los copos aún se mantendrán mientras que el aire no esté saturado de humedad, pues el mecanismo de evaporación de parte de la precipitación los seguirá enfriando [15].

La temperatura de la nieve es importante para determinar si la misma se encuentra seca o húmeda. La nieve seca es nieve a temperaturas inferiores a 0°C, no contiene agua líquida, mientras que la nieve húmeda se encuentra a 0°. Cuando la nieve está saturada, es un material sin aire, con agua que escurre sin la necesidad de comprimirla [16]

En cuanto a las propiedades electromagnéticas de la nieve en el espectro óptico e infrarrojo cercano, podemos decir que al ojo humano la nieve se observa blanca, ya que es altamente reflectiva en el rango de onda de 0,4 y 0,65 μm , con pequeñas variaciones, y va descendiendo a medida que aumenta la longitud de onda, reduciéndose en el infrarrojo cercano y más claramente en el medio (Figura 3).




Figura 3. Curvas de reflectividad para distintos tipos de nieve y hielo (Fuente: Chuvieco, 2006).

El grado de detección de la nieve parte de su respuesta espectral. Los factores que influyen en la reflectividad de la nieve son el tamaño del grano, la profundidad y densidad de la capa y la cantidad de impurezas que

contenga [17]. La densidad (ρ_s) de una cubierta de nieve se encuentra típicamente en un rango de 0,2 a 0,6 Mg m^{-3} [18]. La nieve fresca recién caída puede tener alrededor de 0,1 Mg m^{-3} y a medida que pasa el tiempo, su densidad aumenta como resultado de la compactación por el viento y gravedad, o a través de metamorfismo termal. Para la descripción de la estructura interna del paquete de nieve se utiliza el tamaño del grano o cristal, generalmente definido como el radio medio o radio equivalente de los cristales de hielo. Tamaños habituales de grano suelen estar entre 0,1 y 3 mm [12].

En la Figura 4 se observan las diferentes curvas de reflectividad para diferentes tamaños de grano. Cuanto menor es el tamaño del grano mayor es su reflectividad [19]. La nieve fresca tiene más reflectividad que la helada, mostrando los valores más bajos la nieve sucia [17].




Figura 4. Curvas de reflectividad para la nieve con distintos tamaños de grano (Fuente: Dozier, 1989).

En la figura 5 se observa la firma espectral de la nieve con distintos tamaños de grano, comparándola con la firma de una nube, para lo cual en el rango del visible ambas coberturas poseen una respuesta espectral similar, pero difieren a partir del infrarrojo cercano. Esta diferencia radica en que las gotas o cristales de hielo de las nubes son más pequeñas que los granos de nieve, por lo que absorben menos radiación en esta porción del espectro [17]

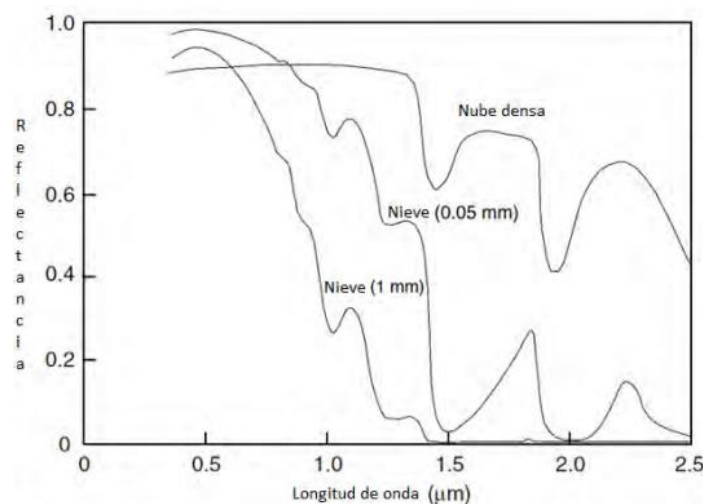


Figura 5. Firmas espectrales de una nube densa y cobertura de nieve en distinto tamaño de grano (Fuente: Gareth Rees, 2006)

Se denomina albedo al porcentaje de radiación que refleja una superficie en comparación con la que incide sobre ella. El albedo medio de nuestro planeta ronda el 38%. Las superficies de color claro poseen valores de albedo mayores que las oscuras, así como las brillantes superan a las mates [20]. Las superficies cubiertas de nieve y hielo tienen un albedo muy alto, que puede llegar el 95%. En contraste, el suelo sin vegetación tiene un albedo del 17%, los bosques entre el 8% y 20% y el océano apenas entre 5 y 10% [7] (Tabla 1).

Tabla 1. Albedos de diferentes superficies (Fuente: Oke, 1998; Ahrens, 2001; Wikipedia).

Superficie	Detalle	% Luz reflejada (Albedo)
Nieve	Reciente	70-95
	Vieja	40-70
Nubes	Densas	60-90
	Ligeras	30-50
Hielo	Oceáno	30-45
	Gracial	20-40
Agua		5-10
Suelos agrícolas		18-25
Bosques	Caducifolios	15-20
	Coníferas	8-15
Suelos	Oscuro y húmedo	5-20
	Brillante y seco	20-40
	Desnudo	17
Asfalto	Fresco	4
	Gastado	12
Ceniza Volcánica		7

1.2.2. Antecedentes en la temática

La teledetección es la observación remota de la superficie de la tierra [17]. El empleo de las técnicas de teledetección y el uso de Sistemas de Información Geográfica (SIG) para el análisis espacial y ambiental ha tenido un gran desarrollo en la ciencia contemporánea [18]. Los datos satelitales multitemporales y multiespectrales facilitan y ayudan con éxito en la supervisión de la extensión de la cubierta de nieve. La comunidad científica ha utilizado diferentes conjuntos de datos satelitales de resolución media, como Landsat (MSS, TM Y OLI), AWIFS, MODIS, etc., para cartografiar el área de la cubierta de nieve [1] [21] [22]. Los satélites gemelos de Sentinel-2 proporcionan la continuidad de los datos de imágenes de tipo SPOT y Landsat, que contribuyen a las observaciones multiespectrales en curso y benefician a los servicios y aplicaciones de Copernicus, como la gestión del territorio, la agricultura y la silvicultura, el control de catástrofes, las operaciones de ayuda humanitaria, la cartografía de riesgos y las cuestiones de seguridad [23].

La monitorización de la cubierta de nieve con un sensor de resolución media plantea ciertos retos, como es la precisión. Sentinel-2, adquiere imágenes multiespectrales, en un total de 13 bandas del espectro electromagnético con resoluciones espaciales de 10, 20 y 60 m (según la banda) [24], y un periodo de revisita combinado (Sentinel-2A y B) de 5 días. El poder extraer datos con una resolución de 10 m cubriendo una franja de 290km cada 5 días ha sido un avance sin precedentes que permite agilizar el seguimiento de las zonas a monitorizar de manera más eficaz [22]. Con todo, existen distintas metodologías disponibles que pueden ofrecer resultados en la detección de zonas cubiertas por nieve con distinto grado de acierto [25], [26]. Es por ello, por lo que este trabajo fin de máster se centra en la comparativa de distintas metodologías que permiten la identificación de la cobertura de nieve a partir de Sentinel-2.

2. Objetivos

2.1. Objetivo general

Este estudio se centra en analizar la aptitud de las imágenes Sentinel-2 para delinear la extensión de nieve en el Pirineo. Para ello se ha seleccionado un área y una fecha de estudio libre de nubes donde las fechas de toma de las imágenes Sentinel-2 coinciden con las de adquisición de una imagen Landsat, que se ha utilizado como fuente independiente de referencia o validación, previa fotointerpretación. Además, se analiza el comportamiento del producto de Snow and Ice (FSC On Ground) proporcionado por el pan-European High-Resolution Snow & Ice Monitoring service de Copernicus en la zona de estudio.

2.2. Objetivos específicos

- Generación de delineaciones de áreas cubiertas por nieve utilizando datos Sentinel-2, a través de algoritmos de clasificación y umbrales aplicados a los índices de nieve extraídos de referencias bibliográficas.
- Limpieza y depurado del producto de Snow and Ice, para su posterior análisis.
- Delineación de la cobertura de nieve a través de la fotointerpretación de una imagen Landsat, para posteriormente poder usarla como referencia.
- Depuración de las máscaras de nieve creadas a través de las clasificaciones.
- Comparar las delineaciones obtenidas con distintas metodologías a partir de imágenes Sentinel-2 con la capa de referencia mediante matrices de confusión y métricas de rendimiento derivadas de la misma.
- Comparar el producto Snow and Ice de Copernicus con la capa de referencia mediante matrices de confusión. Analizar la fiabilidad de este producto.

3. Materiales

3.1. Área de estudio

Los Pirineos son una cadena montañosa de relieve muy compacto de alrededor de 491 km de longitud que conforman la barrera natural entre la península Ibérica y el resto de Europa (Figura 6). Se dispone de este a oeste y es prácticamente rectilínea. Sus cordilleras se elevan de manera más o menos abrupta destacando sobre dos amplias zonas de tierras bajas, la zona de la depresión del Ebro y las llanuras de Aquitania y Languedoc-Rousillon abiertas al Atlántico y al Mediterráneo, respectivamente.



Figura 6. Localización, límites y división administrativa (Fuente: Dialnet: El Medio Natural De Los Pirineos).

En la vertiente norte están los Pirineos franceses, que incluyen los Pirineos orientales, los Altos Pirineos y los Pirineos Atlánticos; y en la vertiente sur los Pirineos españoles, que se extienden a Cataluña, Navarra, Aragón

y el País Vasco [27]. Su anchura no es regular. Se estrecha en sus extremos siendo el sector central el más ancho alcanzando los 150 km de extensión. Los picos más altos se concentran en la sección central, en tanto que en los Pirineos orientales la elevación media es más moderada hasta que en la parte más oriental las montañas pierden altura bruscamente.

Toda la cordillera alberga más de 50 picos que superan los 3.000 metros. El más grande es el pico Aneto, con 3.404 metros de altitud en el macizo de Maladeta. Dentro del área de estudio tenemos la Meseta de los Tres Reyes con 2.442 metros, y el Pico Moros/Balaitús con alrededor de 3.143 en Navarra y Huesca respectivamente [28].

Los Pirineos han influenciado en la cultura de las poblaciones circundantes, no solo en sus historias sino también en sus actividades. Es costumbre en los Pirineos rurales el pastoreo de trashumancia, en el que el ganado se mueve desde las granjas hasta las zonas más altas de las montañas durante el verano. Los Pirineos son destinos muy frecuentados para realizar actividades recreativas como el esquí y el montañismo [29].

La línea de nieve anual varía según la zona, pero puede alcanzar los 2.700-2.800 metros sobre el nivel del mar. Las montañas tampoco cuentan con lagos grandes ni son drenadas por ríos muy largos, aunque sí hay muchas cuevas y ríos subterráneos. En los Pirineos centrales el clima es seco y frío, y en los orientales los veranos tienden a ser considerablemente cálidos. La sección occidental es azotada por corrientes de aire húmedo que provienen del océano Atlántico [28].

De acuerdo con el Fondo Mundial para la Naturaleza (WWF), en los Pirineos coexisten alrededor de 3.500 especies de plantas, de las cuales unas 200 son endémicas. Como las precipitaciones son más abundantes en la parte occidental, debido a la influencia del Atlántico, la vegetación es más exuberante en esta sección.

En general, la flora de los Pirineos incluye bosques y prados alpinos en los que sobresalen el roble carrasqueño (*Quercus faginea*), el tilo de hoja ancha (*Tilia platyphyllos*), el orón (*Acer opalus*), el roble pubescente (*Quercus humilis*), el pino piñonero (*Pinus pinea*) y el enebro (*Juniperus thurifera*). Entre las especies endémicas están plantas del género *Xatardia*, *Arenaria montana* y *Colchicum bulbocodium*.

La fauna está representada principalmente por el desmán ibérico (*Galemys pyrenaicus*), osos, el íbice ibérico (*Capra pyrenaica*), el quebrantahuesos (*Gypaetus barbatus*) insectos del género *Anophthalmus*, el tritón pirenaico (*Calotriton asper*), la mariposa *Erebia rondoui* y el molusco *Helicella nubigena* [28].

En su conjunto los Pirineos están poco poblados, unos 22 habitantes / km², ya que el carácter abrupto del relieve con fuertes pendientes y desniveles, además de las temperaturas frías con frecuentes heladas, dificultando un desarrollo económico general, sobre todo en el contexto actual. En el sector occidental, donde se sitúa el área de estudio, las lluvias son más abundantes, de hasta 1.800 l/m².

La zona de estudio se encuentra ubicada en el sector occidental de los pirineos, en la zona navarra-aragonesa. Se ha escogido esta zona de los Pirineos por la familiaridad con ella, por su cercanía a Pamplona y la importancia que acarrea su ciclo de agua para el ecosistema medioambiental y la actividad económica, social y cultural de la zona y alrededores.

Los Pirineos experimentan un ciclo anual de acumulación y ablación de nieve que se extiende sobre amplias zonas y que, dependiendo de la altitud, dura desde el otoño hasta finales de la primavera. La acumulación de nieve sufre una fuerte variación interanual debido a la variabilidad de los fenómenos meteorológicos implicados, que en ocasiones pueden provocar dinámicas rápidas de aumento o reducción de la extensión del área cubierta por la nieve. El conocimiento de la dinámica espacio-temporal de la extensión es una información de interés tanto para la predicción meteorológica e hidrológica de la zona como para el seguimiento de los ecosistemas y el estudio de sus procesos de cambio.

El nivel de precipitaciones en los Pirineos se ha reducido un 25 % desde 1950 mientras la temperatura media subía más de 2 grados, lo que ha provocado una disminución de la nieve acumulada de hasta un 50 %, según el programa Evaluación de recursos hídricos procedentes de la innovación [30].

Aunque distintos organismos implicados cuenten con estaciones de medida de cantidad de precipitación de nieve, estas medidas son puntuales. Por ello, la posibilidad de obtener estimaciones de extensión de nieve a partir de sensores de teledetección resulta de gran ayuda.

La fecha escogida, 31 de diciembre de 2021, tras las primeras nevadas está sujeta al porcentaje de nubosidad alto característico de esta zona, ya que se busca el solape de una imagen Landsat con una Sentinel-2, sin nubosidad después de una gran nevada, lo cual deja con pocas fechas disponibles. En este estudio se consigue esta alineación de imágenes el 31 de diciembre de 2021, por lo que el área de interés es la intersección de la huella de la imagen Landsat con dos imágenes recogidas por Sentinel-2 en esa misma fecha (Figura 7). El área de interés resultante tiene una superficie de 7711.72 km² y su altitud oscila entre los 109 y los 3146 metros.




Figura 7. Área de estudio en la zona de los Pirineos.

3.2. Plataformas de teledetección y productos adquiridos

3.2.1. Sentinel-2

La misión Copernicus Sentinel-2 es una misión europea de imágenes multispectrales de alta resolución que está formada por una constelación de dos satélites de órbita polar situados en la misma órbita sincrónica al sol, desfasados 180° entre sí. Sentinel-2A se lanzó el 23 de junio de 2015 y Sentinel-2B le siguió el 7 de marzo de 2017.

Estos instrumentos ópticos multispectrales muestrean 13 bandas espectrales en la parte visible, infrarroja cercana e infrarroja de onda corta del espectro: cuatro bandas a 10 m, seis bandas a 20 m y tres bandas a 60 m de resolución espacial (Tabla 2). Estas últimas se utilizan a nivel interno para la corrección atmosférica y detección de nubes, mientras que las bandas a 10 y 20 m son las destinadas a los usuarios. Este tipo de imágenes permiten realizar una amplia gama de estudios y análisis terrestres, ya que Sentinel-2 proporciona adquisiciones sistemáticas a nivel mundial con una alta resolución espacial y una capacidad de revisita sin precedentes, 10 días en el ecuador con un satélite, y 5 días con 2 satélites.

Tabla 2. Longitudes de onda y resolución para cada banda de Sentinel 2 (Fuente: ESA).

	SENTINEL 2	
	Longitud de onda (μm)	Resolución (m)
Banda 1 - Aerosol	0,43 - 0,45	60
Banda 2 - Blue	0,45 - 0,52	10
Banda 3 - Green	0,54 - 0,57	10
Banda 4 - Red	0,65 - 0,68	10
Banda 5 - Red edge 1	0,69 - 0,71	20
Banda 6 - Red edge 2	0,73 - 0,74	20
Banda 7 - Red edge 3	0,77 - 0,79	20
Banda 8 - Near Infrared (NIR) 1	0,78 - 0,90	10
Banda 8A - Near Infrared (NIR) 2	0,85 - 0,87	20
Banda 9 - Water vapour	0,93 - 0,95	60
Banda 10 - Cirrus	1,36 - 1,39	60
Banda 11 - SWIR 1	1,56 - 1,65	20
Banda 12 - SWIR 2	2,10 - 2,28	20

Las imágenes Sentinel-2 dan continuidad a las imágenes multispectrales proporcionadas por la serie de satélites SPOT y el instrumento LANDSAT Thematic Mapper del USGS. Proporcionan a su vez datos de observación para la próxima generación de productos operativos, como los mapas de cobertura del suelo, los mapas de detección de cambios en el terreno y las variables geofísicas, que Copernicus tiene vocación de generar a modo de servicios.

Todos estos objetivos han sido determinados tras consultar a los usuarios, para así garantizar que Sentinel-2 contribuya de forma significativa a temas de relevancia global como el cambio climático, la contaminación, la vigilancia del territorio, la gestión de emergencias y la seguridad. Sentinel-2A es el resultado de una colaboración estrecha entre la ESA, la Comisión Europea, la industria, los proveedores de servicios y los usuarios de datos. Ha sido diseñado y construido por un consorcio de 60 compañías liderado por Airbus Defence and Space, con el apoyo de la agencia espacial francesa CNES para optimizar la calidad de las imágenes, y del Centro Aeroespacial Alemán DLR para mejorar la recuperación de datos mediante comunicaciones ópticas [31].

Los productos Sentinel-2 utilizados en este trabajo han sido descargados de "Copernicus Open Access Hub" [32], que proporciona actualmente un acceso completo, gratuito y abierto a los productos de Sentinel-1, Sentinel-2 y Sentinel-3. Los productos de Sentinel-2 disponibles se enumeran en la tabla 3[33]:



Tabla 3. Tipos de producto de Sentinel-2. Fuente: Sentinel-2 Data Products. ESA).

Name	High-Level Description	Production & Distribution	Data Volume
Level-1C	Top-Of-Atmosphere reflectances in cartographic geometry	Systematic generation and online distribution	~600MB (each 100km x 100km ₂)
Level-2A	Bottom-Of-Atmosphere reflectances in cartographic geometry	Systematic and on-user side (using Sentinel-2 Toolbox)	~800MB (each 100km x 100km ₂)

Las imágenes L1C están ortorrectificadas, y, por tanto, proyectadas a la proyección cartográfica UTM/WGS-84 y los valores de píxel representan reflectancias en el techo de la atmósfera (TOA). Por su parte, las imágenes L2A, utilizadas en este estudio, están corregidas atmosféricamente mediante el algoritmo Sen2Cor (incluyendo la corrección del efecto del relieve) y los valores de píxel representan reflectancias en superficie (BOA).

A continuación, se presentan los productos adquiridos desde el “Copernicus Open Access Hub” (Tabla 4).

Tabla 4. Productos Sentinel de nivel 2A utilizados en el estudio.

Identifier: S2A_MSIL2A_20211231T105441_N0301_R051_T30TXN_20211231T135006		Identifier: S2A_MSIL2A_20211231T105441_N0301_R051_T30TYN_20211231T135006	
			
Sensing Date:	2021-12-31T10:54:41.024Z	Sensing Date:	2021-12-31T10:54:41.024Z
Generation Date:	2021-12-31T13:50:06.000000Z	Generation Date:	2021-12-31T13:50:06.000000Z
Processing level:	Level-2A	Processing level:	Level-2A
Product type:	S2MSI2A	Product type:	S2MSI2A
Pass Direction:	DESCENDING	Pass Direction:	DESCENDING
Instrument:	MSI	Instrument:	MSI
Size:	703.94 MB	Size:	1.13 GB
Cloud cover percentage:	5,9742	Cloud cover percentage:	0.738149
Illumination Azimuth Angle:	163,0768	Illumination Azimuth Angle:	164,2486
Illumination Zenith Angle:	67,7495	Illumination Zenith Angle:	67,4739
Relative orbit (start):	51v	Relative orbit (start):	51

3.2.2. Productos Snow and Ice del Copernicus Land Monitoring System.

El producto Copernicus Pan-European High Resolution Snow & Ice (HR-S&I) Monitoring se lanzó en 2020 y desde entonces ha proporcionado información validada sobre la capa de nieve y hielo a los usuarios interesados. Proporcionan propiedades de cobertura de nieve en tierra y ocurrencias de hielo dentro de la

red hidrográfica. Se generan sobre todo el EEA39 (European Environment Agency) [6](32 países miembros del EEE, Reino Unido y 6 países cooperantes de los Balcanes Occidentales) a partir del 1 de septiembre de 2016 (Figura 8).




Figura 8. Cuadrícula/Tiles de Sentinel-2 sobre el EEA39 (Fuente: Ref.: COSIMS-DT-060-MAG_PUM_SNOW).

Los Parámetros Biofísicos del Servicio de Monitorización de Tierras de Copernicus se caracterizan por unos flujos de trabajo altamente escalables y totalmente automatizados casi en tiempo real y se basan en observaciones radar de Sentinel-1, y ópticas de Sentinel-2. Para satisfacer mejor las necesidades de los servicios de tiempo crítico, los productos se procesan y difunden dentro de las 6-12 horas posteriores a la detección de datos (NRT, Near Real Time) y una API permite la fácil integración en flujos de trabajo de usuario automatizados. Los productos HR-S&I ofrecen nuevas oportunidades para una amplia gama de aplicaciones en el sector de la gestión del agua, la energía, el turismo, el transporte, así como la gestión de riesgos naturales y el apoyo a la toma de decisiones locales [34].

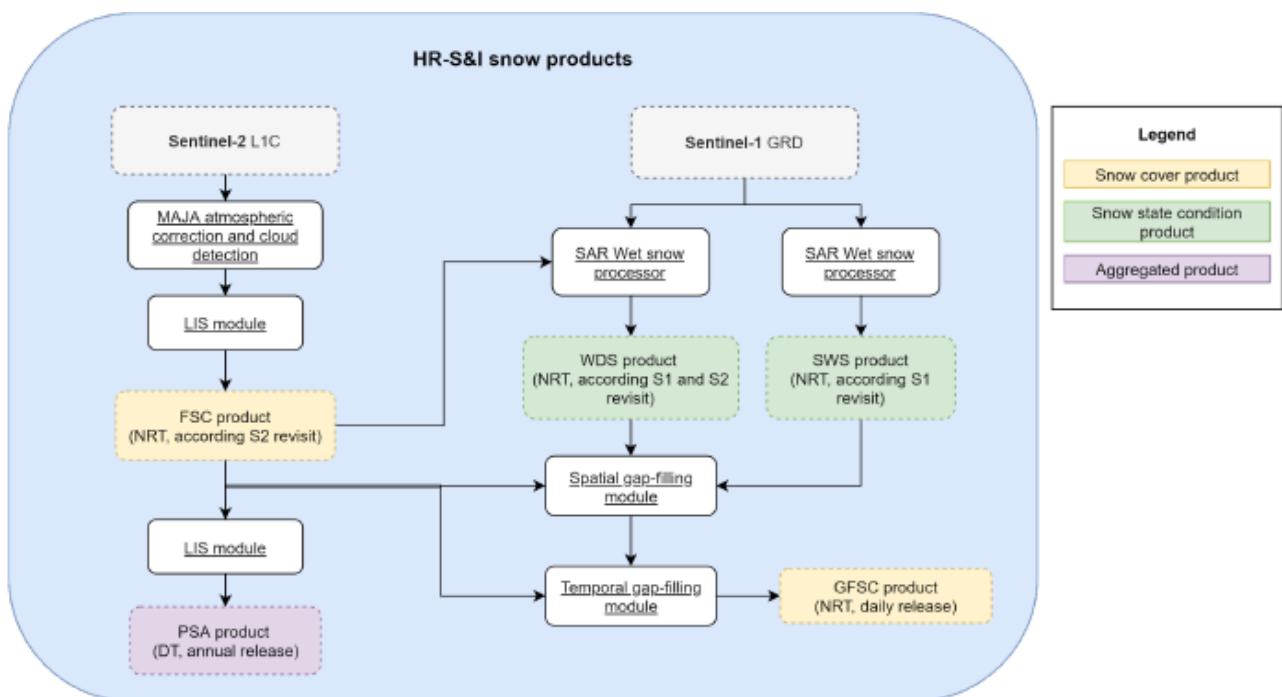


Figura 9. Diagrama de trabajo de HR-S&I. Fuente: Ref.: COSIMS-DT-060-MAG_PUM_SNOW.

En la figura 9 se puede observar el diagrama de producción de los productos de nieve HR-S&I. Se puede ver la dependencia entre los productos, así como los datos de satélite utilizados para obtenerlos y la resolución temporal en la que se generan. El único producto que no se genera en tiempo real es el PSA que se proporciona anualmente.

El producto L1C de Sentinel-2 se convierte en L2A mediante el procesador MAJA, que realiza la corrección atmosférica y proporciona una máscara de nubes precisa. El área de la cubierta de nieve se detecta a partir del producto L2A con el procesador LIS (Let It Snow), basado en un método de umbralización del Índice de Nieve de Diferencia Normalizada (NDSI) y un modelo de elevación digital. La cubierta de nieve fraccionada de los píxeles cubiertos de nieve se deriva entonces de una relación empírica con el NDSI que ha sido calibrada utilizando imágenes de satélite de mayor resolución [35].

De entre los productos proporcionados por el servicio de monitorización de tierras de Copernicus (tabla 5) nos interesa el FSC. El producto Fraccional Snow Cover (FSC) se genera en NRT basándose en datos de satélites ópticos de la constelación S2. Proporciona la fracción de la superficie cubierta de nieve (en caso de cubiertas vegetales en la parte superior del dosel) por píxel en forma de porcentaje (0% - 100%) con una resolución espacial de 20 m x 20 m. Este producto ha sido descargado del Data Access Land Monitoring Service- High resolution Snow and Ice monitoring [36]

Tabla 5. Productos Proporcionados por el programa Copernicus Land Service y sus características.

Productos de Nieve	Entradas/ Inputs	Resolución Temporal	Resolución Espacial	Descripción
FSC	Sentinel-2 MSI	NRT	20 m x 20 m	"Fractional Snow Cover" (0-100%)
GFSC	FSC, WDS y SWS	NRT	60 m x 60 m	"Gap-filled Fractional Snow Cover"
PSA	FSC, WDS y SWS	Anual	20 m x 20 m	"Persistent Snow Area"
WDS	Sentinel-1 SAR, FSC	NRT	60 m x 60 m	"Wet/Dry Snow"
SWS	Sentinel-1 SAR, FSC	NRT	60 m x 60 m	"SAR Wet Snow"

El producto FSC tiene dos capas de información de extensión de nieve fraccionada: el FSC Top Of Canopy (FSCTOC) y el FSC On Ground (FSCOG). El FSCOG deriva del FSCTOC utilizando el producto Copernicus Tree Cover Density [37].

El FSCOG (Figura 10) es el producto final y se usa por defecto para mapear la fracción de cobertura de nieve.

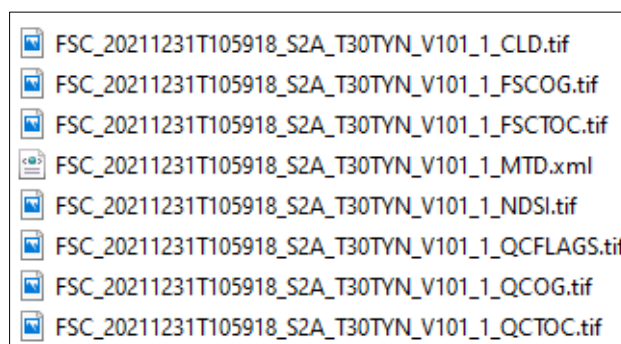
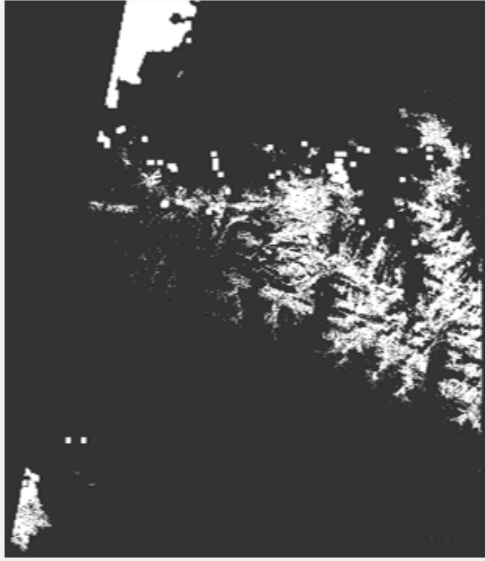
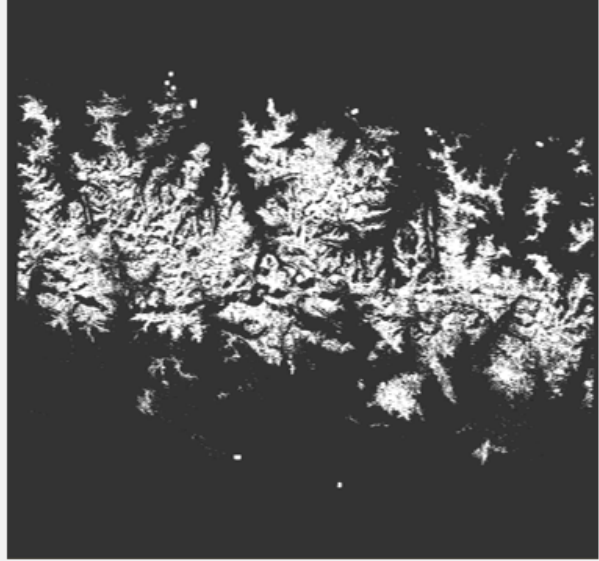


Figura 10. Lista de archivos dentro del Producto FSC.

A continuación, se presentan los productos FSCOG derivados de Sentinel-2 (Tabla 6).

Tabla 6. Productos FSCOG utilizados para el estudio

Identifier: FSC_20211231T105921_S2A_T30TXN_V101_1_FSCOG		Identifier: FSC_20211231T105918_S2A_T30TYN_V101_1_FSCOG	
			
Start Date:	2021-12-31T10:59:21.19507Z	Start Date:	2021-12-31T10:59:18.4765Z
Completion Date:	2021-12-31T15:11:15.981598Z	Completion Date:	2021-12-31T15:40:34.408593Z
Published:	2021-12-31T15:11:29.546503Z	Published:	2021-12-31T15:40:58.954615Z
Mission:	S2	Mission:	S2
Product Type:	FSC- On Ground (HRSI)	Product Type:	FSC - On Ground (HRSI)
Organization Name:	EEA	Organization Name:	EEA
Size:	10 MB	Size:	20 MB
Resolution:	20 x 20 m	Resolution:	20 x 20 m
Block Size:	5490 x 5490 px	Block Size:	5490 x 5490 px

3.2.3. Imágenes Landsat

Con el objeto de obtener una máscara de nieve que permita validar o comparar los resultados obtenidos mediante los datos de Sentinel 2, se procedió a delinear la extensión de nieve con una imagen del sensor Landsat de la misma fecha de la toma de la imagen multiespectral. Normalmente las imágenes de referencia para comparar datos suelen ser de mayor resolución, no siendo éste el caso ya que Landsat tiene menos resolución espacial que Sentinel-2. En este estudio se utilizó por ser un dato de acceso libre y gratuito y para tener una fuente de imagen alternativa con la que fotointerpretar visualmente (delineación manual) las áreas de nieve. La delineación manual se ha utilizado ampliamente para cartografiar las extensiones de hielo y nieve de los glaciares y, en particular, para estimar el retroceso y la deglaciación en diversas partes del mundo [38]–[42].

Landsat 9 es el último satélite de la serie Landsat, que continua con el importante trabajo de registro de la superficie terrestre de Landsat desde su lanzamiento en septiembre de 2021 replicando en gran medida a su predecesor Landsat 8 [43]. Landsat 9 lleva dos instrumentos: el Operational Land Imager 2 (OLI-2) y el Thermal Infrared Sensor 2 (TIRS-2). Ambos son una réplica de los instrumentos a bordo de Landsat 8, que se lanzó en febrero de 2013, y ambos tienen una vida útil de cinco años [44].

Actualmente, Landsat 8 y Landsat 9 cuentan con once bandas espectrales adquiridas por los instrumentos OLI/TIRS y OLI-2/TIRS-2, respectivamente (Figura 11).




Figura 11. El "Multispectral Scanner System (MSS) a bordo de Landsats 1-5 tenía 4 bandas. El "Thematic Mapper" (TM) a bordo de Landsats 4 y 5 tenía 7 bandas. El "Enhanced Thematic Mapper Plus" (ETM+) de Landsat 7 tenía 8 bandas, y Landsats 8 y 9 tienen 11 bandas.

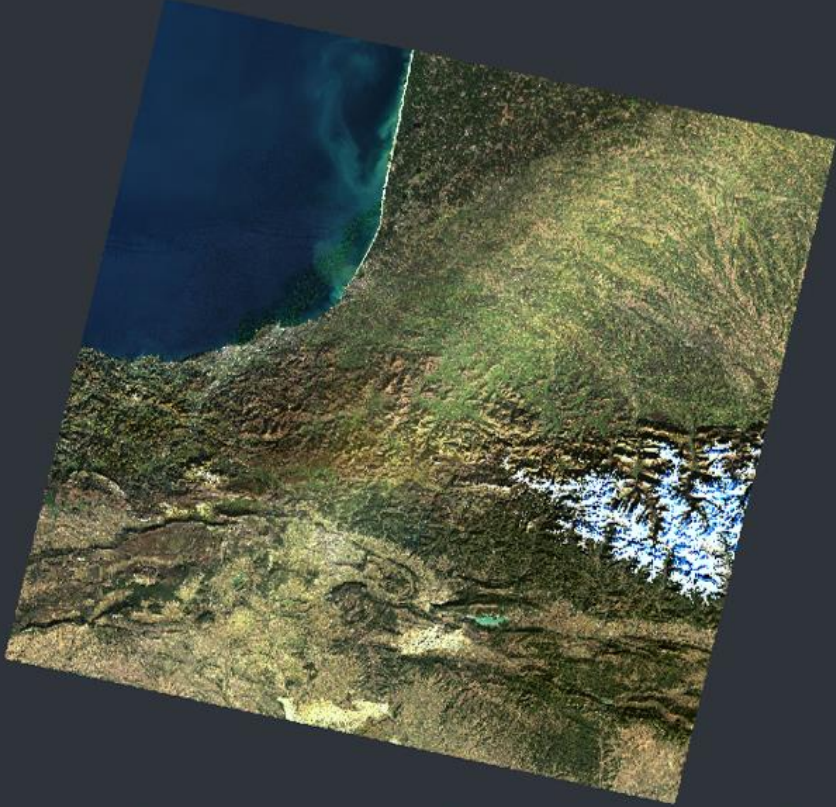
El diseño innovador de Landsat 8 y Landsat 9 los hace más sensibles y fiables que los anteriores satélites Landsat. El OLI recoge datos para dos nuevas bandas, una banda costera/aerosol (banda 1) y una banda de cirros (banda 9), así como las bandas multiespectrales del Landsat. Además, se ha mejorado el ancho de banda de seis de las bandas tradicionales. En la Tabla 7 se pueden ver las diferencias entre bandas entre diferentes sensores a bordo de Landsat 7 y 8-9.

Tabla 7. Diferencias entre bandas de Landsat 7 y Landsat 8 (Fuente: <https://www.sigterritoires.fr>).

Landsat-7 ETM+ Bands (μm)			Landsat-8 OLI and TIRS Bands (μm)		
			30 m Coastal/Aerosol	0.435 - 0.451	Band 1
Band 1	30 m Blue	0.441 - 0.514	30 m Blue	0.452 - 0.512	Band 2
Band 2	30 m Green	0.519 - 0.601	30 m Green	0.533 - 0.590	Band 3
Band 3	30 m Red	0.631 - 0.692	30 m Red	0.636 - 0.673	Band 4
Band 4	30 m NIR	0.772 - 0.898	30 m NIR	0.851 - 0.879	Band 5
Band 5	30 m SWIR-1	1.547 - 1.749	30 m SWIR-1	1.566 - 1.651	Band 6
Band 6	60 m TIR	10.31 - 12.36	100 m TIR-1	10.60 - 11.19	Band 10
			100 m TIR-2	11.50 - 12.51	Band 11
Band 7	30 m SWIR-2	2.064 - 2.345	30 m SWIR-2	2.107 - 2.294	Band 7
Band 8	15 m Pan	0.515 - 0.896	15 m Pan	0.503 - 0.676	Band 8
			30 m Cirrus	1.363 - 1.384	Band 9

Los productos adquiridos de Landsat 9 (Tabla 8) han sido descargados desde EarthExplorer ([usgs.gov](https://earthexplorer.usgs.gov)) [45]. El nivel de procesamiento del producto adquirido es de nivel 2 (L2SP). El L2SP incluye reflectancia de superficie (SR), temperatura de superficie (ST), bandas intermedias ST, un archivo de coeficientes de ángulo y bandas de evaluación de calidad (QA). Se crea corrigiendo un producto de nivel 1 de Terreno de Precisión (corregido) (L1TP) para efectos atmosféricos [46].

Tabla 8. Producto Landsat descargado de nivel 2.

Identifíer: LC09_L2SP_200030_20211231_20220123_02_T1			
			
Origin:	U.S. Geological Survey	Collection Number:	2
Sensing Date:	31/12/2021 10:48	Sensor:	OLI-TIRS
Generation Date:	23/01/2022 8:17	Size:	895 Mb
Product type:	LANDSAT_9_OLI_TIRS_L2SP	Cloud cover percentage:	4,36
Processing level:	L2SP	Illumination Azimuth Angle:	160,40
Collection Number:	2	Path:	200
Collection Category:	T1	Row:	30

3.3. Áreas de entrenamiento

Para llevar a cabo las clasificaciones supervisadas, se necesitan datos de entrenamiento. Estos datos permiten definir las diferentes clases para clasificar los datos de entrada. Habitualmente se utilizan contenedores vectoriales para desarrollar los datos de entrenamiento [24]. Para ello se construyen vectores de entrenamiento, es decir, polígonos en las áreas de la imagen a clasificar que representan las clases de interés, por ejemplo, agua, nieve, bosque etc.

Las áreas de entrenamiento utilizadas para las clasificaciones supervisadas se engloban en dos categorías:

Nieve: todos aquellos píxeles que correspondan a nieve. Se seleccionan áreas de entrenamiento para nieve blanca y para nieve azul o en sombra (tabla 9). En total conforman una selección de aproximadamente 7.939,22 ha.

No Nieve: Todos aquellos píxeles que estén en ausencia de nieve. Se seleccionarán áreas de entrenamiento para suelo urbano, bosque, cultivos, agua y terreno sin vegetación (tabla 10). En total conforman una selección de aproximadamente 11.410,27 ha.

Tabla 9. Áreas de entrenamiento de la categoría de Nieve



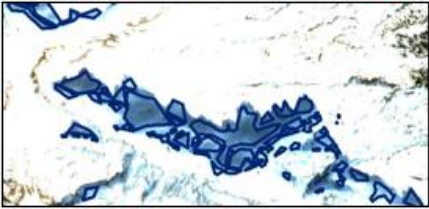
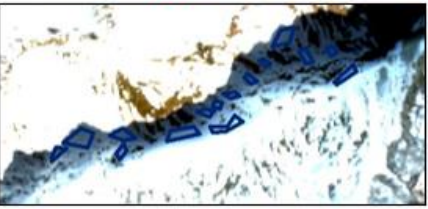










	Ejemplos de AE		Nº de muestras	Área (ha)
Nieve Blanca			600	6818,4
Nieve azul o en sombra			538	1120,82

Tabla 10. Áreas de entrenamiento de la categoría de No Nieve

	Ejemplos de AE		Nº de muestras	Área (ha)
Bosques			145	4531,55
Cultivos			247	4388,85
Agua			74	1483,40
Urbano			81	515,44
Suelo desnudo			239	491,03

En la figura 12, se puede observar la distribución espacial dentro del área de interés de estudio de las diferentes áreas de entrenamiento para cada clase.




Figura 12. Distribución espacial de las diferentes áreas de entrenamiento

3.4. Programas utilizados

SNAP

La plataforma de aplicaciones de Sentinel (SNAP) es una colección de herramientas ejecutables e interfaces de programación de aplicaciones que se han desarrollado para facilitar la utilización, la visualización y el procesamiento de diversos datos obtenidos por teledetección. El software ha sido desarrollado por Brockmann Consult, Skywatch, Sensor y C-S [47]. ESA/ESRIN [48] proporciona la herramienta de usuario SNAP de forma gratuita a la comunidad de observación de la Tierra.

El acceso a la funcionalidad de SNAP se realiza a través de la caja de herramientas “Sentinel Toolbox”. El propósito de la caja de herramientas de Sentinel no es duplicar los paquetes comerciales existentes, sino complementarlos con funciones dedicadas al manejo de los productos de datos de los satélites de observación de la Tierra [24].

En este trabajo se ha utilizado para visualizar y procesar las imágenes Sentinel-2 para lograr extraer las delineaciones de nieve/no nieve para su posterior análisis. Se utilizaron diferentes herramientas para poder clasificar la extensión de nieve a estudiar.

QGIS y ArcMap

Tanto ArcGis (siendo ArcMap una de sus aplicaciones) como QGIS son softwares que facilitan el geoprocésamiento de datos, su análisis, proyecciones, datos estadísticos, gestión de territorio, toma de decisiones, visualización y obtención de mapas, etc. [49].

QGIS es un Sistema de Información Geográfica (SIG) de Código Abierto licenciado bajo GNU (General Public License). Es un proyecto oficial de Open Source Geospatial Foundation (OSGeo). Corre sobre Linux, Unix, Mac OSX, Windows y Android y soporta numerosos formatos y funcionalidades de datos vector, datos ráster y bases de datos [50].

ArcMap es una de las aplicaciones principales que se usan en ArcGIS Desktop. Es donde se visualiza y explora los dataset SIG del área de estudio además de poder crear y editar datasets[51].

Con estos dos programas se han limpiado y depurado las diferentes delineaciones anteriormente extraídas de SNAP. También se han clasificado a nivel objeto las imágenes Sentinel-2 (con el módulo Feature Analyst de ArcGIS) y se ha delineado en ArcMap, mediante fotointerpretación de la imagen Landsat la cubierta de nieve utilizada como referencia.

Por último, mediante una herramienta automatizada diseñada para Tracasa se han extraído las estadísticas para las matrices de confusión de las comparaciones entre las delineaciones y la referencia.

4. Metodología

4.1. Creación y preparación de capas bajo análisis (Sentinel-2)

4.1.1. Delineación de nieve basadas en clasificación de Sentinel-2

Preprocesado de imágenes Sentinel-2

Las dos imágenes con las que se han trabajado están ya procesadas a nivel L2A por lo que no fue necesario ningún tipo de procesamiento adicional, salvo el mosaico de ambas imágenes como puede verse en la figura 13, y un remuestreo de las bandas para que tengan la misma resolución (10m) y poder operar con ellas.




Figura 13. Área de interés (AOI). Solapa de Landsat con el mosaico Sentinel 2.

El AOI es el área extraída del solapamiento entre la imagen Landsat y las imágenes Sentinel-2 (Figura 14).



Figura 14. Figura 14. AOI de estudio. Solape Landsat - Sentinel-2

Delineación de nieve

Para lograr separar la de nieve de lo que no es nieve, se utilizaron una serie de técnicas que ayuden a tener delineaciones cercanas a lo que realmente hay es ese momento sobre la superficie. Se utilizaron clasificadores automáticos e índices de nieve con diferentes umbrales de corte obtenidos de revisiones bibliográfica.

Índices de nieve

Para la extracción de las delineaciones de nieve, se utilizaron los índices NDSI y S3 (descritos a continuación), que se basan en la signatura espectral de la nieve. Estos índices se han utilizado para separar nieve vs. terreno mediante umbrales (valores de corte) que se han optimizado.

- **Índice de diferencia de nieve normalizado (NDSI)**

En comparación al resto de la cobertura terrestre, la nieve se distingue por dos propiedades: su elevada reflectividad en la parte visible del espectro y su baja reflectividad en el infrarrojo medio. Esto permite una buena discriminación entre otras coberturas. La combinación de estos dos rasgos espectrales se recoge en el conocido índice NDSI (Normalized Difference Snow Index) [52], que es un índice normalizado como el popular índice normalizado de vegetación (NDVI), pero con otra combinación de bandas que maximizan la diferenciación entre nieve y terreno.

El NDSI se ha utilizado ampliamente para cartografiar la cubierta de nieve desde satélite [53]. Tiene la capacidad de discriminar el hielo/nieve de las nubes. Sus valores son además independientes de las condiciones de iluminación, es decir, que se pueden identificar los píxeles de nieve/no nieve en diferentes pendientes y orientaciones, incluso en la región de sombra de la montaña [53].

A continuación, la fórmula para calcular el índice NDSI:

$$NDSI = \frac{(Green - SWIR)}{(Green + SWIR)}$$

Ecuación 1. Índice de diferencia de nieve normalizado

Como se ha comentado anteriormente, se basa en la alta y baja reflectancia de la nieve en la región visible (verde, B3) y en la región infrarroja de onda corta (SWIR, B11), respectivamente (Ecuación 1). Para discriminar los píxeles de nieve de los que no lo son, se ha utilizado un valor umbral de NDSI mayor a 0,4. Se estima que los píxeles con un contenido superior al 50% en cobertura de nieve, poseen valores de NDSI mayores o iguales a 0,4 [54], por encima de este valor se suelen encontrar superficies de nieve, hielo, nieve bajo sombras, pero también las masas de agua [21]. Para evitar etiquetar erróneamente los píxeles de agua se hicieron una serie de pruebas de clasificación en las cuales, se añadieron otros umbrales de corte sucesivos en otras dos bandas, en concreto en la banda 8 y en la banda 3, siguiendo la metodología de Nolin et al. [55], que propusieron aplicar unos umbrales de 0,11 y 0,10 en esas bandas espectrales (en realidad sus correspondientes bandas en MODIS) para evitar la confusión entre nieve y agua.

- **Índice S3**

Saito y Yamazaki fueron quienes propusieron el índice S3 como un índice mejorado de cartografía de la cubierta de nieve en 1999[56], de forma paralela al desarrollo del NDSI. El índice S3 fue diseñado originalmente para el sensor GLI (Global Imager) del ADEOS-II (Advanced Earth Observing Satellite II), que fue lanzado en diciembre del 2002. Cuando dejó de funcionar, varios investigadores utilizaron Landsat ETM+ en diferentes regiones del mundo y comprobaron que el S3 tenía la capacidad de cartografiar con precisión la cubierta de nieve bajo zonas boscosas densas sin ningún dato de referencia (NDVI) [26].

La reflectancia de la nieve es alta en la región visible, mientras que, en el caso de la vegetación, la reflectancia aumenta desde el borde rojo hasta la longitud de onda NIR (infrarrojo cercano). Sin embargo, en la zona donde la nieve se encuentra bajo la cubierta vegetal, la reflexión de la nieve y la vegetación se vuelve mixta. Por lo tanto, este índice evita el efecto de los píxeles mixtos (nieve y vegetación) en la cartografía de la cubierta de nieve, utilizando para ello las longitudes de onda del rojo, NIR y SWIR [25] [57]. A continuación, la fórmula para calcular el índice S3:

$$S3 = \frac{NIR (Red - SWIR)}{(NIR + Red) (NIR + SWIR)}$$

Ecuación 2. Índice S3

En 2006 [25] se evaluó la precisión del S3 con respecto al NDSI, específicamente en las zonas en las que la cubierta de nieve y las zonas boscosas se solapaban y se demostró su eficacia para condiciones de alta vegetación. Como la zona de estudio tiene una cantidad elevada de cobertura vegetal, se ha propuesto utilizar este índice, estableciendo un umbral de $S3 > 0,18$ para identificar la cubierta de nieve y valores entre 0,05 y 0,18 para zonas de mezcla vegetación-nieve, según [25].

Clasificadores no supervisados

Además de la realización de clasificaciones determinísticas a partir de umbrales de los dos índices mencionados, en este trabajo se realizarán clasificaciones no supervisadas y supervisadas basados en herramientas aprendizaje automático (*Machine Learning*). En el primer caso, el de los clasificadores no supervisados (también denominado análisis clúster), los datos se clasifican a partir de su estructura interna sin necesidad de aportar un conocimiento externo a modo de entrenamiento [58]. Se utiliza el siguiente algoritmo no supervisado:

- **Clasificación K Means (Cluster análisis a nivel píxel)**

Es un algoritmo de clasificación no supervisada (clusterización) de uso popular que está implementado en SNAP. Este algoritmo agrupa los píxeles en k clases basándose en sus características (datos en las diferentes bandas analizadas). El agrupamiento se realiza minimizando la suma de distancias entre cada píxel y el centroide de su clase o clúster. Para ello se suele usar la distancia cuadrática. Se utilizaron todas las bandas del producto Sentinel-2.

El algoritmo consta de tres pasos:

1. **Inicialización:** una vez escogido el número de clases, k , se establecen k centroides en el espacio de los datos, en este primer caso aleatoriamente (Random seed).
2. **Asignación de objetos a los centroides:** cada píxel de la imagen es asignado a su centroide más cercano, formando grupos de objetos o clústers. Para esto se calcula la distancia cuadrática entre los datos de cada píxel y el centroide en las distintas bandas utilizadas.
3. **Actualización de centroides:** Una vez asignados los píxeles a los centroides iniciales y formados los clústers, se recalcula el centroide como promedio de los datos de todos los píxeles asignados a cada clúster. A continuación, se repiten los pasos 2 y 3 a modo de iteración, hasta que se alcance la convergencia y los centroides se mantengan estables o se supera un número máximo de iteraciones especificado por el usuario, que en este estudio son 30.

Al principio es probable que haya un movimiento considerable entre los clústers, pero la convergencia se alcanza rápidamente en la mayoría de los casos. Por lo general, en las iteraciones sucesivas habrá menos casos que se muevan de un clúster a otro, lo que significa que los centros de los clústeres no cambian tanto y, por tanto, habrá menos movimiento en la siguiente iteración [59].

Las principales ventajas del método *k-means* son que es un método sencillo y rápido, por lo que es adecuado para clasificaciones en las que se trabaja con grandes volúmenes de datos. Como inconvenientes cabría

mencionar el hecho de que sea necesario establecer el valor de k (número de clases) y la posibilidad de que la convergencia se produzca en un mínimo local y no en uno global.

Clasificadores Supervisados

El objetivo de los clasificadores supervisados es clasificar los píxeles de una imagen en diferentes clases basándose en las características de éstos (datos de las diferentes bandas) y aprendiendo una serie de diferencias entre las clases a partir de un conjunto de datos de entrenamiento. La clasificación supervisada se realiza en dos etapas: (1) la etapa de entrenamiento y (2) la etapa de clasificación. En la etapa de entrenamiento, el usuario establece un conjunto de vectores llamado muestras (o áreas) de entrenamiento para cada clase, a través de las que se construye el clasificador. En la etapa de clasificación, el clasificador entrenado se utiliza para clasificar los píxeles con valores de características conocidos, pero de clase desconocida [60]. En este caso se consideran dos categorías con sus respectivas clases: nieve (nieve blanca y nieve azul/en sombra) y no nieve (cultivos, bosques, agua, urbano y suelo desnudo). En total 7 clases.

- **Clasificador Random Forests (a nivel de píxel en SNAP)**

El Random Forests [61] es un método no paramétrico que funciona según el principio de aprendizaje múltiple o de conjunto, lo que significa que genera múltiples clasificadores supervisados y asigna la clase mayoritaria predicha por estos. Es un clasificador popular, también en el ámbito de la teledetección [62], ya que ofrece resultados de alta precisión y con un bajo coste computacional. Como en otros clasificadores supervisados, su precisión será mayor cuanto mayor sea el número de datos de entrenamiento [24].

Random Forests se basa en árboles de decisión automáticos. El algoritmo muestrea aleatoria e iterativamente los datos y las variables para generar un número elevado de árboles de decisión, es decir, un bosque. El resultado es un modelo más robusto que el basado en un solo árbol de clasificación.

Tres propiedades útiles del Random Forest son las estimaciones de errores internos, la capacidad de estimar la importancia de las variables y la capacidad de manejar variables explicativas débiles. La naturaleza iterativa del Random Forest le proporciona una clara ventaja sobre otros, ya que al generar subconjuntos aleatorios de datos y variables de entrenamiento (bootstrap) genera árboles diversos y con una baja correlación, lo que permite que el modelo final sea más robusto y evita los problemas asociados a las variables correlacionadas y al sobreajuste [61].

Para este estudio se introdujeron como parámetros 30 árboles de decisión, todas las bandas espectrales de Sentinel 2 y el número de clases, que fueron 7.

- **KNN**

El algoritmo de k -vecinos próximos (k -NN) es un método de clasificación no paramétrico que clasifica los objetos basándose en los ejemplos de entrenamiento más cercanos en el espacio de características. Las ideas iniciales en torno a este modelo se atribuyen a Evelyn Fix y Joseph Hodges [63], mientras que Thomas Cover amplió y profundizó estos conceptos [64].

K -NN es un tipo de aprendizaje basado en instancias, o aprendizaje perezoso, en el que la función sólo se aproxima localmente y todo el cálculo se aplaza hasta la clasificación. Es uno de los algoritmos de clasificación más sencillos que existen: un píxel se clasifica por el voto mayoritario de sus vecinos, asignándose el píxel a la clase más común entre sus k vecinos más próximos, que forman parte del conjunto de entrenamiento (k es un número entero positivo, normalmente pequeño).

La fase de entrenamiento del algoritmo consiste únicamente en almacenar los datos de la imagen y las etiquetas de clase de las muestras de entrenamiento. En la fase de clasificación, un píxel no etiquetado se clasifica asignando la etiqueta más frecuente (mayoría) entre las k muestras de entrenamiento más cercanas al píxel. Las clases a clasificar son 7, y se utilizaron las áreas de entrenamiento correspondientes y en todas las bandas del producto Sentinel-2.

Un inconveniente de la clasificación básica de "votación por mayoría" [65] se produce cuando la distribución de clases está sesgada. Es decir, los ejemplos de una clase más frecuente tienden a dominar la predicción del

nuevo ejemplo, porque tienden a ser comunes entre los k vecinos más cercanos debido a su gran número. Para superar este problema, se introducen diferentes tipos de funciones de peso o ponderación, cuyo objetivo es hacer que los vecinos lejanos tengan menos efecto en el voto mayoritario que los vecinos más cercanos. Las funciones de ponderación más utilizadas son Fracción, Escala, Distancia inversa y Distancia cuadrada inversa [60].

Es un algoritmo fácil de implementar y tiene pocos hiperparámetros. Aunque es propenso al sobreajuste y no funciona bien con entradas de datos de alta dimensión.

- **MDC**

Con el clasificador de distancia mínima (MDC del inglés *minimum distance classifier*), cualquier píxel de la escena se clasifica utilizando la distancia entre los datos de la imagen del píxel y las medias de las clases derivadas de los conjuntos de entrenamiento. El píxel se asigna a la clase más cercana, calculando la distancia euclídea media (de todas las bandas) [60]. Aunque algunos autores señalan esto como una ventaja, realmente es un problema ya que es preferible dejar áreas sin clasificar que clasificarlas sin garantías[66]. Como parámetros se utilizaron las áreas de entrenamiento para 7 clases, utilizando todas las bandas del producto de Sentinel-2.

- **MLC**

A partir de los datos de entrenamiento se puede obtener la media y la desviación típica de cada una de las clases, y ajustar a sus datos una distribución de probabilidad. El clasificador de máxima verosimilitud (MLC del inglés *maximum likelihood classifier*) es un método de clasificación tradicional, en el que un píxel se asigna a la clase que maximiza su función de pertenencia o verosimilitud, que se define como la probabilidad posterior de que un píxel pertenezca a una clase determinada [60]. Este clasificador asume que los datos siguen una función de distribución normal lo que, en función del tipo de dato evaluado puede no ser adecuado. Se utilizaron los mismos parámetros que en el clasificador anterior.

- **Clasificación a nivel de objeto (Feature Analyst 5.2.0 para ArcMap.)**

Feature Analyst es un clasificador supervisado con un potente sistema de herramientas para extraer automáticamente características geográficas específicas de objetos (AFE, *automatic feature extraction*) que son la base de su posterior clasificación. Utilizando la información espectral y las características de los objetos como la asociación espacial, el tamaño, la forma, la textura, el patrón y la sombra en los ejemplos de entrenamiento identificados por el usuario, Feature Analyst aprende de estos datos y construye el correspondiente clasificador. En esta última fase el clasificador se perfecciona mediante la ayuda proporcionada por el usuario ajustando una serie de parámetros, como las bandas a utilizar para la información textural y el Feature Selector para tener en cuenta el contexto espacial (Manhattan 7x7 píxeles, figura 15). Manhattan utiliza un patrón que se recomienda para identificar las características de la cubierta terrestre, de gran tamaño como vegetación, masas de agua, lagos y zonas inundadas.




Figura 15. Patrón Manhattan 7x7 píxeles.

El proceso básico de extracción asistida por el usuario de Feature Analyst implica:

- Definir las características objetivo para el modelo mediante la digitalización de ejemplos (objetos) de entrenamiento.
- Establecer los parámetros de aprendizaje para permitir a Feature Analyst utilizar información espectral (bandas de entrada), espacial (representación de entrada) y matemática (algoritmos de aprendizaje) para modelar el proceso de extracción de características a partir de su conjunto de polígonos de entrenamiento.
- Reforzar el modelo de extracción para mejorar los resultados utilizando el Aprendizaje Jerárquico para seleccionar los ejemplos correctos e incorrectos de las características devueltas.
- Examinar los resultados finales y utilizar las herramientas del Vector de Análisis de Características para eliminar cualquier desorden devuelto con las características correctas.

Las áreas de entrenamiento, utilizadas en Arcmap con Feature Analyst, se harán con polígonos de tres tipos de áreas de nieve: blanca, azulada o en sombra (especificadas en la sección 3.3.) y el área en línea de nieve de cordilleras y caminos como área de entrenamiento puntual (tabla 10).

Tabla 11. Áreas de entrenamiento en líneas de nieve (cordilleras y caminos).

	Ejemplos de AE	Nº de muestras	Área (ha)
Nieve en Línea		25	9,3

Post procesado

Justificación

En los productos de las clasificaciones pueden quedar píxeles y polígonos aislados otorgando una apariencia granulosa al mapa resultado (de sal y pimienta) y dificultando su interpretación y comparación con otros productos que pueden estar a escalas diferentes. En este caso la capa de referencia está a una resolución inferior, por lo que resulta conveniente depurar este tipo de datos, valorando la unidad mínima cartografiada (UMC) de la capa de referencia, que es la unidad más pequeña de representación que puede ser delimitada en un mapa para su respectiva clasificación. De esta manera se logra coherencia en la representación espacial de las imágenes clasificadas y la de referencia [67], [68].

En este caso se fija la UMC en 64000 m², es decir 0.64 ha para Sentinel-2. De esta manera todos los polígonos que no lleguen a 0,64 ha, tanto islas como huecos, se limpiaron o rellenaron.

Limpieza por UMC y suavizado

Para hacer la limpieza y suavizado de las imágenes clasificadas se necesitaron dos productos: El área de interés (AOI) de la zona de estudio y la capa de delineación obtenida a través de las clasificaciones. A continuación, se realizaron los siguientes pasos en Arcmap:

1. Se eliminaron de la capa de delineación todos aquellos polígonos que no lleguen a 0,64 ha., seleccionando por atributo el área y eliminando todas aquellas áreas que no lo cumplan (Figura 16).
2. Se realizó un suavizado de dientes de sierra de los píxeles del delineado con la herramienta Feature Analyst y se combinarán ambas capas. Esta combinación se calculó mediante una unión geométrica de las entidades de entrada y sus atributos (Figura 17).
3. Se utilizó una herramienta que crea una clase de entidad que contiene entidades de parte simple generadas al separar entidades multiparte de entrada. De esta manera se pudo a continuación eliminar huecos que no alcanzasen 0,64 ha (Figura 18, izda). Se calculó en la tabla de atributos de tal manera que se seleccionaron los huecos de más de 0,64 ha para eliminarlos.

$$"AOI" = 1 \text{ and } "mascarnieve" = 0 \text{ and } "AREA" > 0.64$$

Ecuación 3. Fórmula en la selección por atributos.

4. Y por último los huecos que no llegaron a 0,64 ha se rellenaron como si fueran capa nieve con la herramienta Dissolve (Figura 18, dcha).




Figura 16. Limpieza píxeles "islas" MMU




Figura 17. Suavizado y Unión




Figura 18. Limpieza de huecos y resultado final de la máscara.

4.1.2. Producto Copernicus Snow and Ice

Preparación Snow and Ice

Mosaico de las imágenes

En la figura 19 se puede observar la combinación de las dos teselas en las que se divide la zona de estudio en el producto Snow and Ice (FSC On Ground).




Figura 19. Combinación de imágenes FSCOG.

Clasificado nieve/no nieve

Se estableció el umbral utilizando $FSCOG > 0$ y < 205 para obtener un mapa de cobertura de nieve "binario" (presencia o ausencia de nieve, figura 20), discriminando posibles nubes y otros elementos (Tabla 12).

Tabla 12. Características de FSC On Ground (Fuente: Ref.: COSIMS-DT-060-MAG_PUM_SNOW)

FSCOG	On-ground fractional snow cover (%) and associated information. Possible values are as follows: → 0-100: FSCOG (%) → 205: cloud or cloud shadow → 255: no data	GeoTIFF	uint8	30MB/~4.5MB
-------	---	---------	-------	-------------




Figura 20. Clasificado nieve/no nieve

Post- procesado

Se procedió al post-procesado del producto Snow and Ice tal y como se explica al final de la sección [4.1.1](#).

4.2. Creación de capa de referencia (Landsat)

4.2.1. Pre-procesado de imágenes Landsat

El producto Landsat descargado ya está calibrado y octorectificado ya que tiene un procesamiento a nivel L2SP (Tabla 10). Por lo que a esta imagen tan solo se le realizó un pansharpening.

Pansharpening

Los algoritmos de pansharpening tienen como objetivo mejorar la resolución espacial de las imágenes multiespectrales (su información de detalle, figura 21), utilizando para ello una imagen pancromática de mayor resolución espacial. Se realizó la información espacial de la imagen Landsat multiespectral LC09_L2SP_200030_20211231_20220123_02_T1 aplicando el algoritmo de Pansharpening *Wavelet á trous Aditivo* [69].

Se utilizaron las siguientes bandas:

- Imagen multiespectral de resolución de 30m con cinco bandas:
 - B2 (Blue: 0,452 – 0,512 μm)
 - B3 (Green: 0,533 – 0,590 μm)
 - B4 (Red: 0,636 – 0,673 μm)
 - B5 NIR (infrarrojo cercano: 0.851 – 0.879 μm)
 - B6 SWIR-1 (Infrarrojo de onda corta 1: 1.566-1.651)
- Imagen pancromática de resolución 15m (B8).




Figura 21. Diferencias de resolución entre las bandas a 30 m (composición RGB, Izda) y la pancromática a 15m (dcha).

El método o proceso seguido ha sido en primer lugar el remuestreo de la imagen multiespectral a la resolución de la imagen pancromática donde se equipararon los tamaños de píxel de las dos imágenes (figura 22). Para hacerlo se utilizaron las herramientas disponibles en SNAP y de cara a la aplicación de algoritmos de pansharpening, se remuestreó la imagen multiespectral por el método Bicúbico, con el fin de minimizar el efecto diente de sierra en la imagen fusionada resultante.




Figura 22. Imagen pancromática(izda.), imagen multiespectral (composición en falso color, en el centro) Mismo tamaño de píxel. Comparación con imagen multiespectral a 30m (dcha).

A continuación, se realizó la “Transformada Wavelet à trous” en la imagen pancromática. Se aplicó este algoritmo para extraer el detalle espacial de la imagen pancromática que le hace falta a la imagen multiespectral. De esta manera se obtuvo una imagen degradada para poder obtener la diferencia entre esta imagen pancromática degradada (resolución 30m) y la imagen pancromática original (resolución 15m). Para generar la imagen PAN degradada se filtró esta imagen, con el filtro *à trous* de primer nivel (derivado de una función Spline B3, (figura 23)).

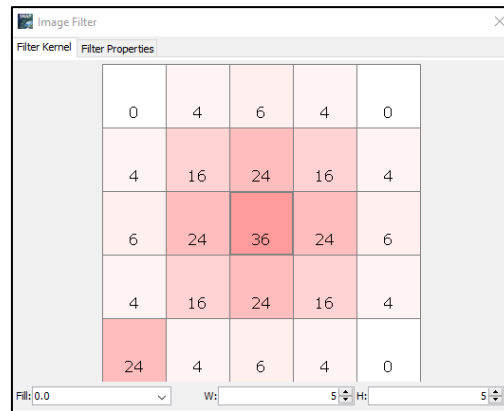


Figura 23. Filtro Kernel utilizado para la transformada *Walvelet à trous*.

Se extrajo el detalle espacial mediante la diferencia entre la imagen pancromática original y la obtenida en el paso anterior. Se operó con las imágenes, restando a la imagen original la imagen degradada final. El resultado de esta diferencia fue el detalle espacial que será añadido posteriormente a la imagen multiespectral. La imagen contiene únicamente información de bordes (figura 24).




Figura 24. Imágenes del detalle (izda), la pancromática (centro) y la pancromática con nivel 1 à trous.

Por último, se suma el detalle espacial a cada banda de la imagen multiespectral. Se sumó la imagen de detalle generada a cada una de las bandas de la imagen multiespectral con los tamaños de píxel remuestreados a 15m. Se reguló la cantidad de detalle que se añade a cada banda del multiespectral haciendo un balanceado ya que no todas las bandas tienen el mismo peso en la composición. Se llevó a cabo a partir del ratio entre los valores de desviación estándar (σ_{banda}) del histograma de cada banda y el valor de la desviación en la imagen pancromática original (σ_{PAN}) (tabla 13). Por último, se utilizó la ecuación 3 para conseguir la imagen final.

Tabla 13. Resultados de los valores para ponderar el nivel de detalle añadido a cada banda

Banda	σ_{Banda}	$\sigma_{Banda}/\sigma_{PAN}$
PAN	22,16	
B2	22,51	1,02
B3	22,09	1,00
B4	20,62	0,93
B5	16,79	0,76
B6	2,85	0,13

$$Imagen\ Final = Banda + Imagen\ Detalle \times \frac{\sigma_{Banda}}{\sigma_{PAN}}$$

Ecuación 3. Fórmula aplicada para conseguir las bandas de la imagen final.

En la figura 25 se puede observar la imagen original (dcha) y la imagen multispectral con el pansharpening aplicado (izda). Ambas imágenes se representan en una composición de RGB y con los valores de expansión de contraste de cada banda de la imagen generada ajustados a los de la imagen original.




Figura 25. Imagen multispectral original (dcha.) e imagen multispectral con el Pansharpening aplicado (izda.).

4.2.2. Delineación de nieve

En primer lugar, se hizo una clasificación supervisada automática con la herramienta Feature Analyst para poder tener un punto de partida con el que facilitar la fotointerpretación de la imagen. Las zonas de entrenamiento fueron las estipuladas en la sección 3.3 junto a las explicadas en la metodología del clasificador.

Posteriormente, teniendo como base esta clasificación que delinea aproximadamente la capa de nieve en la imagen, se fotointerpretó manualmente añadiendo y quitando polígonos allí donde se visualizaba que hay nieve o ausencia de ésta (corrección con supervisión humana de manera manual). De esta manera se extrajo una delineación de nieve bastante precisa a la que realmente hay en la toma de la imagen (figura 26).

Los valores de la matriz de confusión se han calculado con la ayuda de QC10B2, una herramienta comercial utilizada en Tracasa programada sobre ArcMap, que obtiene los valores de omisión, comisión y solape entre el producto del clasificador con el de la referencia. Estos valores ayudan a conseguir los TP, FP, FN y TN de la matriz de confusión. La herramienta pide como datos de partida el AOI (Área de interés), la capa de referencia y la del clasificador, todos en el mismo sistema de coordenadas (WGS 84/UTM zone 30N).

A partir de esta matriz se cuantificó la precisión de cada algoritmo de clasificación utilizado, valorando los verdaderos positivos, los falsos positivos, verdaderos negativos y falsos negativos, así como una serie de métricas de rendimiento como la exactitud (Accuracy), la precisión (users's accuracy), la sensibilidad (Recall, producer's accuracy), el error de comisión y omisión, la especificidad y el estadístico F score. Por otro lado, se han elaborado las estadísticas de la unión de las delineaciones de nieve, obteniendo de esta manera la exactitud, la comisión y omisión de la unión de nieve, que compara los solapes de ambas delineaciones sin contabilizar el área del resto del AOI (no se tiene en cuenta el fondo).

A continuación, se explican las diferentes métricas:

Exactitud: Porcentaje de píxeles correctamente clasificados (en las clases *i* y No *i*) respecto al total de píxeles verificados, es decir, el porcentaje de casos que el modelo acierta. Cantidad de predicciones positivas que fueron correctas.

$$\text{Exactitud} = \frac{TP + TN}{TP + FP + TN + FN}$$

Precisión: Porcentaje de píxeles clasificados como pertenecientes a la clase *i* que realmente corresponde a dicha clase en el terreno, es decir, se refiere a lo cerca que está el resultado de una predicción del valor verdadero.

$$\text{Precision} = \frac{TP}{TP + FP}$$

Sensibilidad: Tasa de verdaderos positivos. El porcentaje de píxeles de una determinada clase *i* que hay en el terreno y que se han clasificado como tal.

$$\text{Recall} = \frac{TP}{TP + FN}$$

Especificidad: Tasa de verdaderos negativos. Es la proporción entre los casos negativos bien clasificados por el modelo, respecto al total de negativos. Si tiene un valor alto significará que discrimina de forma aceptable los casos negativos. Es decir que es difícil obtener falsos positivos.

$$\text{Specificity} = \frac{TN}{TN + FP}$$

F score: Resume la precisión y sensibilidad en una sola métrica. Es de gran utilidad cuando la distribución de las clases es desigual, como es este el caso, que hay muchos más píxeles de no nieve que de nieve.

$$F \text{ score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Error de comisión y omisión: El error que se comete en la clasificación por encima y por debajo al comparar la clasificación con la referencia. El error de comisión se calcula restando a 1 la precisión y el error de omisión se calcula restando a 1 la sensibilidad.

Exactitud de la unión de nieve: Refleja de manera más intuitiva la exactitud entre la delineación de referencia y las del clasificador que la exactitud global de todo el producto, ya que las clases están desbalanceadas y puede que este sea una métrica muy fiable.

Comisión y omisión de la unión de nieve: Reflejan de manera más intuitiva el porcentaje de error de omisión y de comisión de la clase nieve por la misma explicación que el parámetro anterior.

5. Resultados y discusión

A continuación, se presentan los resultados obtenidos en las distintas clasificaciones. Uno de los objetivos es valorar si las delineaciones de nieve basadas en las clasificaciones de Sentinel 2 en este estudio pueden o no mejorar los resultados del producto Copernicus Snow and Ice, basado en la misma fuente de información (Sentinel-2). Para ello se comparan las delineaciones de nieve obtenidas y el producto Snow and Ice con respecto a la delineación de referencia obtenida por fotointerpretación. La comparativa se basa en las matrices de confusión y las métricas de rendimiento comentadas en la sección 4.3..

En la tabla 15, se puede observar la matriz de confusión del producto Copernicus Snow and Ice contra la referencia (Landsat). En la tabla 16 se resumen las métricas de rendimiento estudiadas.

Tabla 15. Matriz de confusión del producto de S&I contra la referencia (Landsat).

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
FSC On Ground	Nieve	65887,20	808,95	66696,15	98,79	1,21
	No Nieve	36706,50	667768,25	704474,75	94,79	5,21
	TOTAL	102593,70	668577,20	771.170,90		
	Fiab. productor %	64,22	99,88			
	Error omisión %	35,78	0,12			

Tabla 16. Resultados de las métricas estudiadas.

	FSCOG
Exactitud (Unión delineaciones de Nieve %)	63,72
Error de Comisión (Unión delineaciones de Nieve %)	0,78
Error de Omisión (Unión delineaciones de Nieve %)	35,50
Exactitud %	95,14
Precisión (Fiabilidad del usuario %)	98,79
Sensibilidad (Fiabilidad del productor %)	64,22
Especificidad (Fiabilidad del productor %, clase No Nieve)	99,88
Error de Comisión %	1,21
Error de Omisión %	35,78
F score	0,78

Se observa que hay un solape del 63,72% con la capa de referencia, mientras que se omite un 35,50% de la cubierta de nieve estimada en la zona. Es un porcentaje muy alto, por lo que a continuación se analizará la problemática subyacente en estos datos.

En las imágenes de la figura 27, se puede discernir como el producto Snow and Ice no detecta la nieve en la sombra que proyectan las montañas. La reflectividad de la nieve sobre las partes en sombra es menor por lo que la nieve se enmascara o se convierte en medidas erróneas. En estas imágenes podemos observar la delineación de la referencia contra la delineación del producto S&I, y apreciarse como pierde la parte de información de nieve en las sombras.




Figura 27. Delineaciones solapadas del producto S&I con la delineación de referencia (izda sup. Landsat composición RGB, dcha sup. Delineación Landsat, izda inf. Delineación S&I y dcha inf. Cruce delineaciones)

La referencia derivada de la imagen Landsat tiene bastante más precisión a la hora de definir la delineación del área de nieve por la fotointerpretación en que se basa. En la figura 28 podemos ver como la delineación del producto de S&I omite todas las zonas sombreadas. Sin embargo, delinea muy bien la zona exterior del área, puesto que apenas tiene comisión (0.78%). El problema es que se deja buena parte de la cobertura de nieve sin identificar (omisión en color naranja). Coincide con laderas norte o zonas de cast-shadows (sombras de montes cercanos).

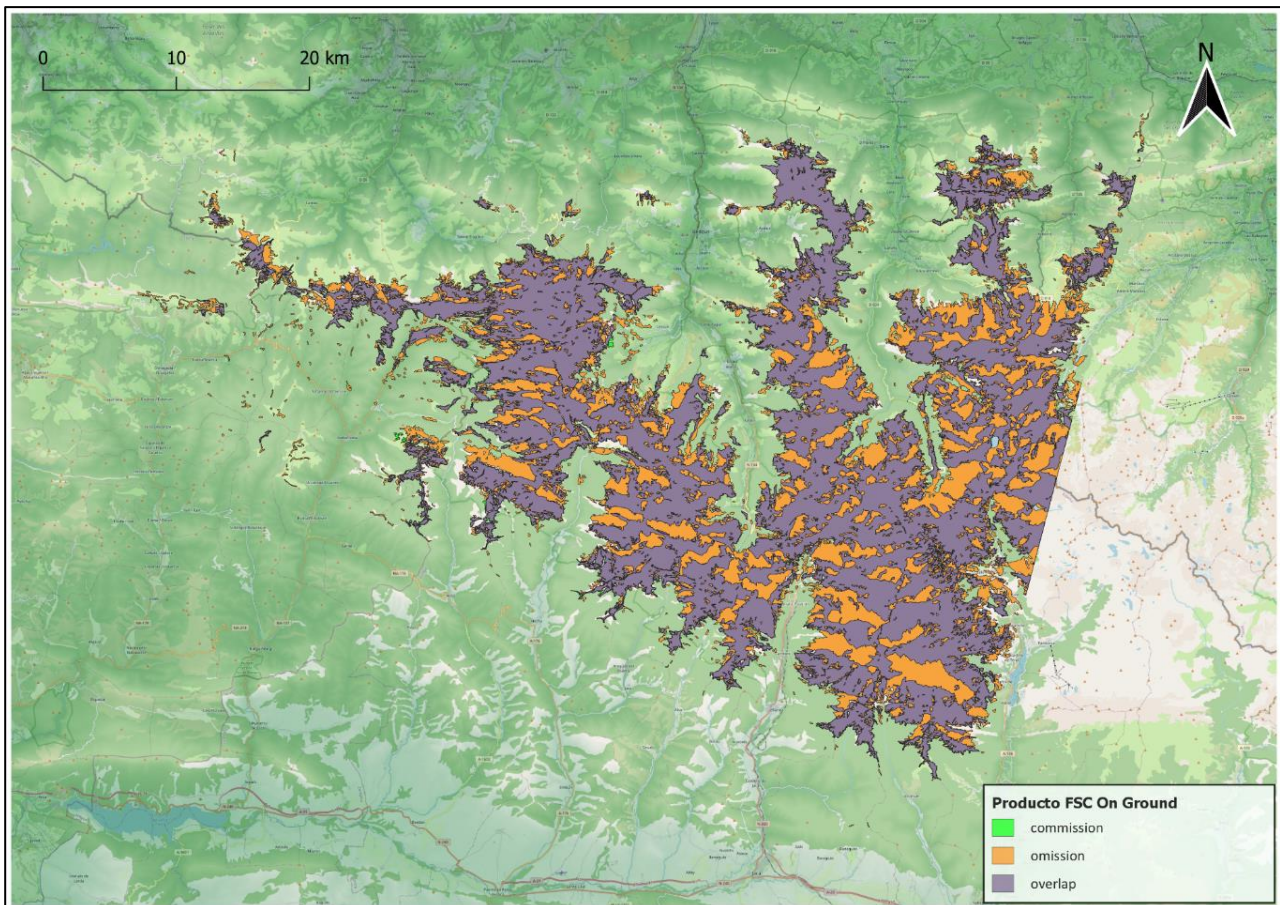


Figura 28. Validación del producto S&I

Para poder analizar la aptitud de las imágenes Sentinel-2 para delinear la extensión de nieve en el marco de estudio, se han realizado diferentes delineaciones a través de algoritmos de clasificación y umbrales aplicados a índices de nieve. En la tabla 17 se muestran los resultados obtenidos en la validación de las clasificaciones realizadas mediante las matrices de confusión y sus métricas de rendimiento. Se expone un resumen de los diferentes resultados extraídos de las matrices de confusión. Primero se leen las delineaciones a través de umbrales de índices con el índice NDSI y el S3. Después tenemos el K-Means que es el único clasificador no supervisado utilizado en el estudio y el Clasificador supervisado a nivel objeto realizado con la herramienta Feature Analyst (ArcMap). Por último, se exponen los clasificadores a nivel píxel realizados en SNAP de Mínima Distancia, Máxima Verisimilitud, KNN y Random Forest.

Tabla 17. Tabla general con las diferentes validaciones obtenidas a través de las matrices de confusión.

	NDSI	S3	K-Means	FA Sup.	MDC	MLC	KNN	RF
Exactitud (Unión delineaciones de Nieve %)	79,87	82,00	51,56	84,99	45,73	88,62	72,06	73,95
Error de Comisión (Unión delineaciones de Nieve %)	3,25	5,72	0,85	1,18	0,12	7,24	0,50	0,60
Error de Omisión (Unión delineaciones de Nieve %)	16,88	12,27	47,59	13,84	54,15	4,14	27,44	25,45
Exactitud %	97,23	97,46	93,50	97,98	92,77	98,37	96,26	96,51
Precisión (Fiabilidad del usuario %)	96,09	93,47	98,38	98,64	99,74	92,44	99,31	99,20
Sensibilidad (Fiabilidad del productor %)	82,55	86,98	52,00	86,00	45,78	95,54	72,42	74,39
Especificidad (Fiabilidad del productor %, clase No Nieve)	99,48	99,07	99,87	99,82	99,98	98,80	99,92	99,91
Error de Comisión %	3,91	6,52	1,62	1,36	0,26	7,56	0,69	0,80
Error de Omisión %	17,45	13,01	48,00	14,00	54,22	4,46	27,58	25,61
F score	0,89	0,90	0,68	0,92	0,63	0,94	0,84	0,85

De esta tabla se puede extraer que los clasificadores que peores resultados han obtenido son el K-means y el Clasificador de Mínima Distancia con un 51,56% y un 45,73% de exactitud respectivamente, puesto que no alcanzan a recoger los datos de nieve en sombra como se puede ver en su omisión con un 47,59% y un 54,15% respectivamente. La problemática en estos clasificadores se asemeja bastante a la que tiene el producto de Snow and Ice como podemos ver en la figura 29, donde se puede observar perfectamente como omiten las zonas donde la superficie está cubierta de nieve, pero se ve azulada u oscura. No obstante, el producto de S&I parece que falla menos en las sombras que los otros dos con un 35,50% de omisión, mientras que Kmeans tiene un 47% y el Clasificador de Mínima Distancia un 54,15%.




Figura 29. Delineaciones con problemas para discernir la sombra de la nieve (izda sup. Landsat composición RGB, dcha sup. Delineación MDC, izda inf. Delineación Kmeans y dcha inf. Delineación S&I)

En cuanto a los clasificadores a través de umbrales de índices, los mejores resultados los da el índice S3 con un 82% de exactitud con respecto a la delineación de referencia. Se considera uno de los más convenientes y precisos en zonas con bosques, ya que hace distinción de estos píxeles mixtos de nieve y vegetación, y extrae una mejor clasificación de píxeles. No obstante, podemos observar que gran parte de la comisión se debe a que clasifica como nieve los píxeles de agua del pantano de Yesa que se encuentra en la zona (Figura 30, en color verde). Se podría mejorar este clasificador, utilizando una máscara de agua de la zona para eliminar esta sobreestimación, con un Land Cover actualizado de agua en la zona.

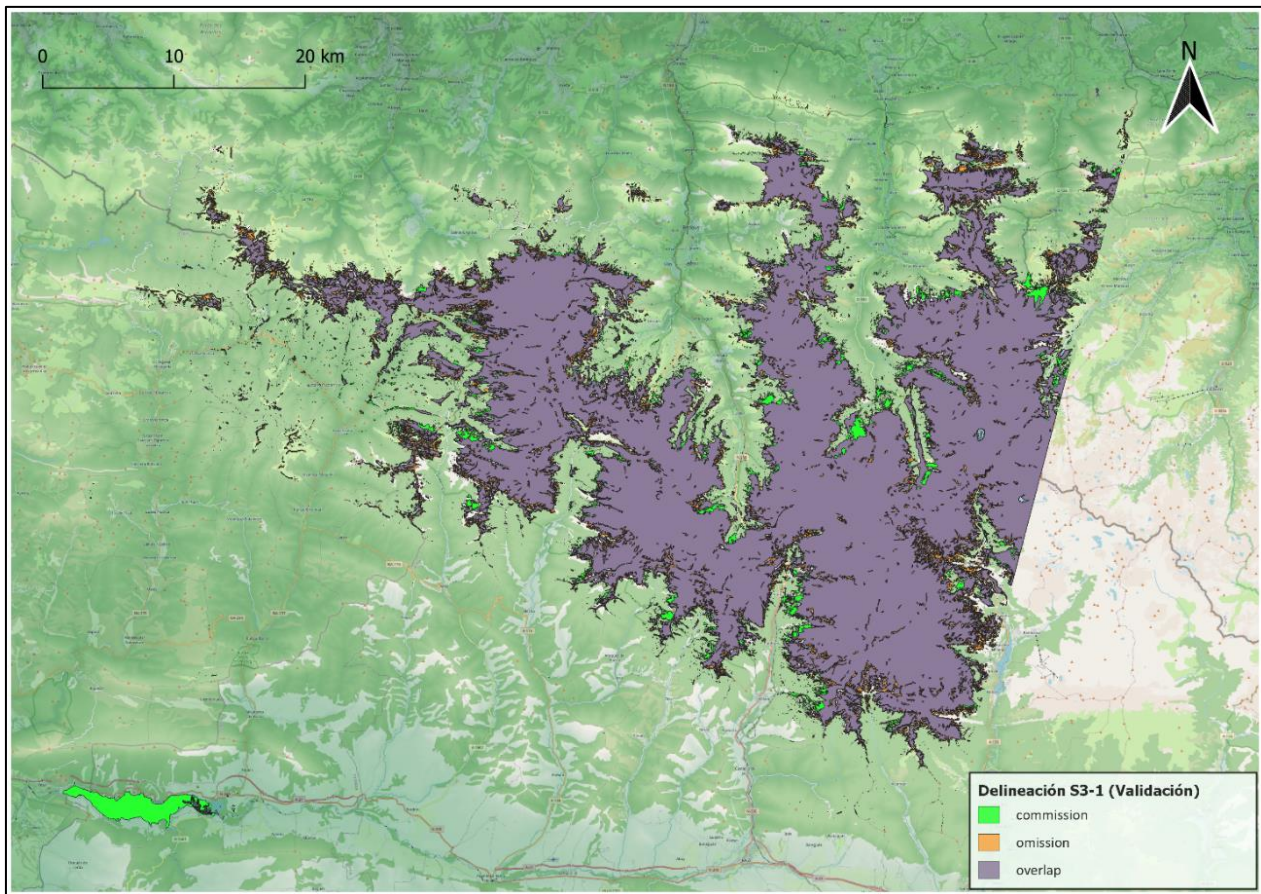


Figura 30. Mapa de validación de la delineación de S3.

El S3 mejora los resultados obtenidos en el NDSI porque distingue automáticamente las zonas cubiertas de nieve de las mezclas de nieve y vegetación.

A la clasificación basada en el NDSI además de introducirse un umbral del 0,4, se refinó añadiendo otros umbrales en las bandas 3 y 8. Tras efectuar distintas pruebas, se comprobó que la delineación NDSI (con el corte $B3 > 0.05$ y $B8 > 0.04$) mejora la clasificación previa que solo con el umbral del 0,4, obteniendo un mejor resultado, ya que no se equivoca clasificando los píxeles de agua como nieve (Figura 32). Los valores de corte recomendados en la bibliografía [70], de 0.11 y 0.10 respectivamente, se han modificado de forma sustancial.

Las delineaciones bajo los clasificadores a través de umbrales de índices tienen un grado moderado de omisión (entre el 14 y 17 %), pero son clasificaciones muy rápidas y sencillas de realizar, y no requieren de ningún software específico de pago.

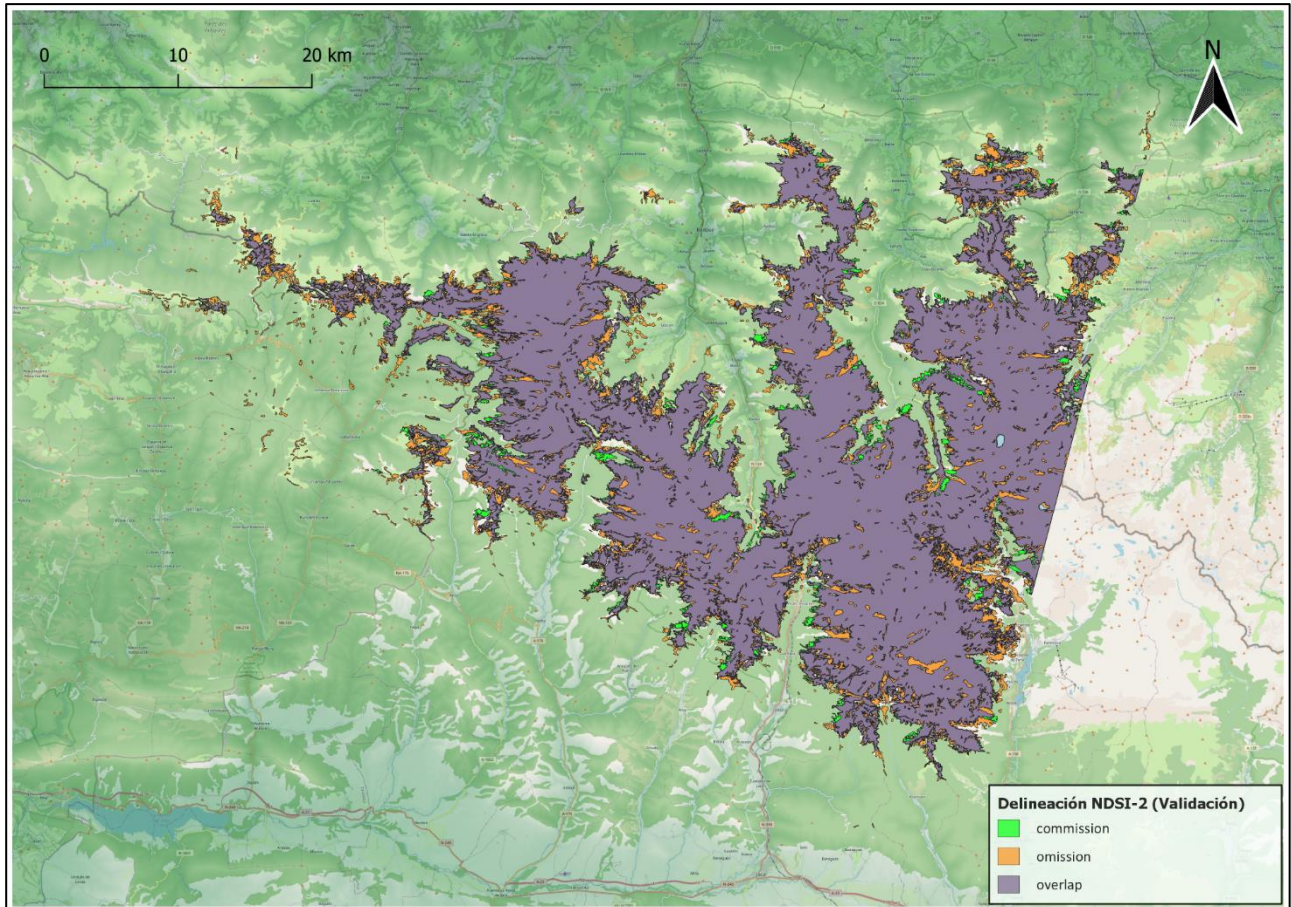


Figura 31. Validación de la delimitación NDSI.

El resto de las delimitaciones oscilan entre la exactitud del 72% con el Clasificador KNN y el 88,62% del clasificador de Máxima Verisimilitud, siendo este el que mejor delimitación de cobertura de nieve presenta en el marco de estudio, seguido del clasificador supervisado de la herramienta Feature Analyst con un 85% (Tabla 16).

El KNN y el Clasificador Random Forest, a pesar de tener menor porcentaje de solape con la delimitación de referencia, tienen un error bajísimo de comisión. No sobreestiman en ningún momento la nieve, sin embargo, incurren en errores importantes de omisión según la matriz de confusión (27,44 y 25,45 % respectivamente). Visualizando los mapas se puede ver algo de omisión en detalles y en algunas sombras, pero en general se ve una delimitación bastante buena. Estos errores de omisión pueden deberse en gran parte a la delimitación derivada de la fotointerpretación de Landsat, ya que no es tan precisa en los detalles, por lo que habría que ver como se comportarían estos estadísticos comparando la delimitación con una imagen de referencia más precisa. En la figura 32 se puede observar una buena aproximación a la delimitación de nieve, con más detalle.




Figura 32. Delineaciones de clasificadores supervisados Random Forest y KNN (de arriba hacia abajo, Sentinel-2 en RGB, el clasificador de Random Forest y el clasificador KNN).

La herramienta de clasificación a nivel de objeto de Feature Analyst consigue un 85% de solape con la delineación de referencia. Es el único clasificador a nivel objeto que se ha utilizado en este estudio. Este clasificador aprende a través de las formas que tienen las áreas de entrenamiento, de su tamaño y de su textura por lo que es probable que reconozca mejor que otros clasificadores las clases de nieve y la ausencia de ésta. Tiene muy poca comisión (1,18%) y una omisión del casi 14%. En la figura 33 se puede ver la validación y el gran solape que se obtiene con la delineación de referencia.

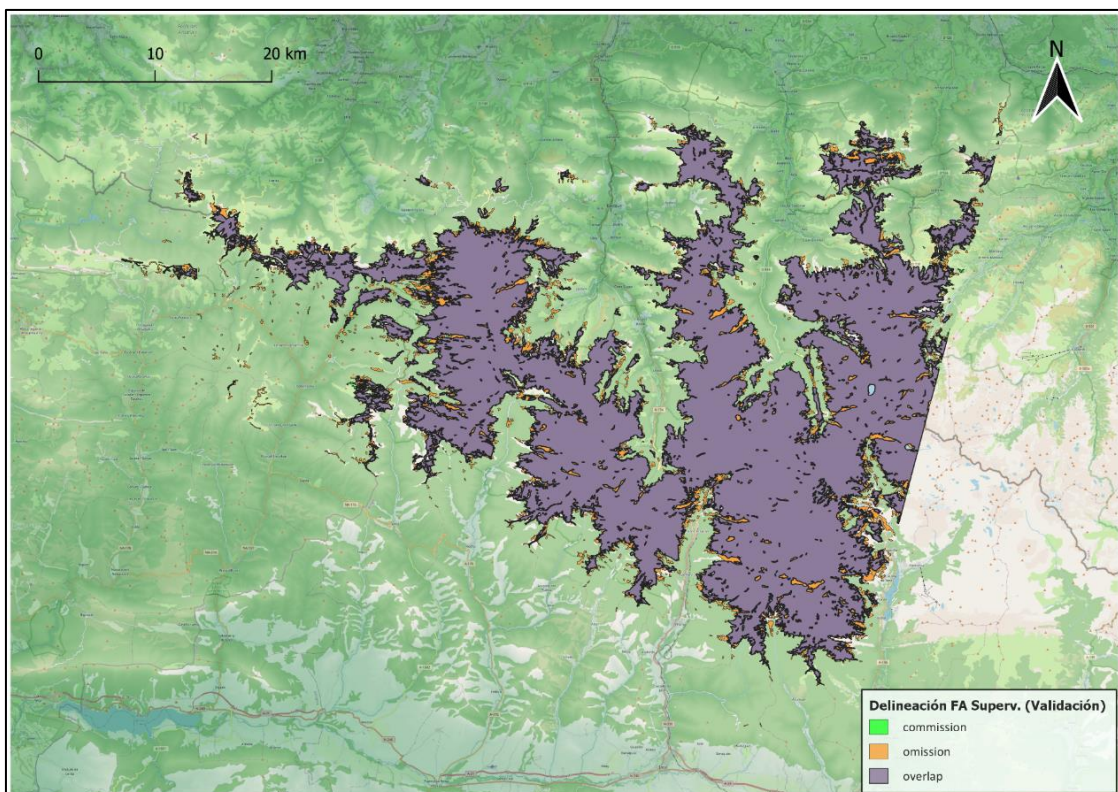


Figura 33. Validación de la delineación obtenida por el clasificador supervisado de Feature Analyst.

El clasificador que mejores resultados ha dado en este marco de estudio es el clasificador supervisado de Máxima Verisimilitud, con un 88,62 % de precisión. La comisión y la omisión están bastante balanceadas (7,24% y 4,14% respectivamente). Parece que este tipo de algoritmo, que clasifica cada píxel en la clase donde tenga la mayor probabilidad de pertenecer, da buenos resultados en este tipo de paisajes (Figura 34).

Random Forest ha desbancado actualmente a este clasificador, por lo que debería de dar mejores resultados que el clasificador de máxima verisimilitud, no resultando ser así en este estudio. Probablemente requiera de un estudio más minucioso y pruebas de diversas técnicas para la clasificación con árboles de decisión. Esta delineación, no obstante, se puede considerar una buena estimación de la delineación de nieve en la zona.

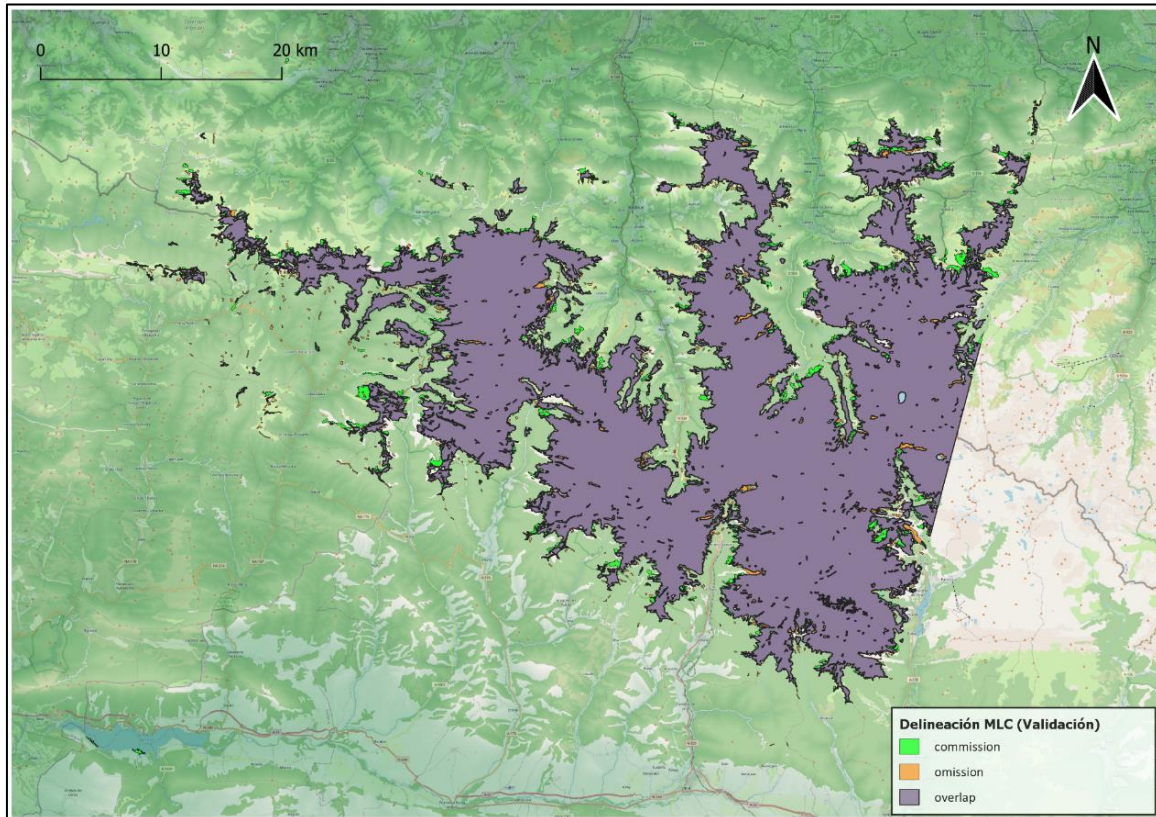


Figura 34. Validación de la delineación obtenida por el clasificador de máxima verisimilitud.

A continuación, se observan los clasificadores de Máxima Verisimilitud y de Feature Analyst:



Figura 35. Mapas de clasificadores, de izda a dcha, imagen Sentinel-2 en RGB, MLC y el clasificador de FA

Los resultados entre los tipos de clasificadores son muy diferentes. Dentro de los clasificadores supervisados se halla uno a nivel objeto (Clasificador de Feature Analyst) y otro a nivel píxel (Clasificador de máxima verisimilitud) con muy buenos resultados, mientras que el que peor exactitud ha obtenido es un clasificador supervisado (Clasificador de mínima distancia).

Los clasificadores basados en umbrales de índices de nieve obtienen resultados buenos sobrepasando el 79% de la exactitud en la delineación obtenida. Su rapidez y sencillez de utilización los hacen muy interesantes para hacer aproximaciones en este tipo de paisajes. Resultan ser bastante fiables.

En general el porcentaje de especificidad es alta en todas las clasificaciones por lo que discriminan de forma aceptable los casos negativos. Esto se debe al área de estudio que la extensión del área de interés sin nieve es bastante grande (el fondo).

Por último, es necesario mencionar el estadístico F score. Este estadístico compara el rendimiento combinado de la precisión y la exhaustividad entre las delineaciones comparadas dando una idea general de la calidad de éstas. En general los resultados han sido bastante buenos, rondando entre el 0,84 y el 0,94 exceptuando en Kmeans y el Clasificador de Mínima Distancia que han sido del 0,68 y 0,63 respectivamente. El producto S&I tiene un F score de un 0,78, alejándose un poco de la mayoría de los clasificadores (tabla 18), pero siendo de una calidad aceptable.

Tabla 18. Estadístico F score de las delineaciones realizadas.

	NDSI	S3	K-Means	FA Sup.	MDC	MLC	KNN	RF	FSCOG
F score	0,89	0,90	0,68	0,92	0,63	0,94	0,84	0,85	0,78

A la hora de realizar las clasificaciones es determinante las áreas de entrenamiento que se hayan escogido para definir la muestra de nieve y de no nieve. No solo se escogió áreas de nieve de color blanco, sino también las azuladas y en sombra. Si se hubieran elegido tan solo áreas blancas, probablemente las delineaciones se hubieran ajustado un poco más al producto Snow and Ice. Sin embargo, se puede decir que algunas de las delineaciones obtenidas son más precisas y detalladas que el producto de Copernicus.

6. Conclusiones

Se concluye que, dentro del marco de estudio, el producto FSC On Ground del pan-European High-Resolution Snow & Ice Monitoring service de Copernicus presenta resultados limitados al no detectar la nieve en las sombras que proyectan las montañas. Se observa que el producto S&I trabaja mejor en zonas donde el relieve no proyecta zonas de sombra, es decir, en áreas de cara al sol y de superficie plana. Sin restar mérito a este producto, se debería realizar alguna mejora para evitar estos problemas habituales en zonas montañosas, en las que la valoración precisa de la cobertura de nieve es de gran importancia.

En el marco concreto del área de estudio de este trabajo, las clasificaciones realizadas a partir de Sentinel-2 han mejorado las delineaciones de nieve del producto del programa Copernicus. El ajuste de algoritmos de clasificación a las condiciones locales de un área concreta permite mejorar la extracción del área de extensión de cobertura de nieve en alta montaña.

Las herramientas utilizadas a través de SNAP (plataforma gratuita), alcanzan en su mayoría unas métricas de rendimiento bastante exitosas. Cabe resaltar que el clasificador de máxima verisimilitud logra los mejores resultados entre todos los clasificadores investigados, al poderse implementar utilizando software gratuito este resultado es interesante, desde el punto de vista de facilitar su aplicabilidad.

Junto al clasificador de máxima verosimilitud, destaca el clasificador supervisado de la herramienta Feature Analyst (ArcMap). Ambos delinean de manera precisa la cobertura de nieve, sin omitir las zonas de nieve sombreadas de manera sistemática.

Respecto a los clasificadores determinísticos basados en umbrales de índices de nieve, los probados en este estudio han conseguido mejores resultados que el producto S&I. Si bien este resultado era esperable, dado que los refinamientos y pruebas realizados han permitido ajustar los umbrales al área local de estudio. Sería de interés evaluar si estos umbrales funcionan también mejor en otras zonas montañosas del planeta.

Los clasificadores de Mínima Distancia y Kmeans son los que obtienen una menor precisión, omitiendo en su clasificación muchas zonas de nieve.

La delimitación de Random Forest de este estudio, es un clasificador mejorable, requiriendo un estudio más minucioso. No obstante, es una buena estimación de delimitación de nieve ya que extrae bastante bien la nieve de las sombras. Con una delimitación de referencia más precisa se hubieran obtenido mejores resultados en cuanto a estadísticos, sin embargo como estimación de fiabilidad de la aptitud para delimitar nieve es buena.

Para la delimitación conseguida a través del índice S3, que no discrimina masas de agua de la nieve, se podría mejorar su precisión, utilizando capas de Land Cover actualizado de agua como máscaras, para poder eliminar este tipo de errores.

El S&I es un producto global que no requiere entrenamiento y está ya disponible. Se contemplaría para líneas futuras de investigación mejorar esas zonas de sombra a partir del FSC On Ground, que sabemos que capta bien la nieve iluminada. Para ello se debería de estudiar el comportamiento de las sombras y si se pueden umbralizar. Por ejemplo, el día que más sombra haya en invierno, elaborar una máscara con todas las áreas de sombra y estudiarlas por separado (con la ayuda de DEM actualizados) para ver si hay nieve junto a un análisis de sus estadísticas, y probar umbrales en diferentes índices para conseguir discriminar los píxeles de nieve y de no nieve.

Por último, sería interesante extender este trabajo en otras cordilleras y ver si el producto S&I requiere de mejoras para estas zonas de montaña en las que la estimación de la cobertura de nieve mediante teledetección resulta especialmente compleja.

7. Bibliografía

- [1] C. Notarnicola, "Hotspots of snow cover changes in global mountain regions over 2000–2018," *Remote Sens Environ*, vol. 243, p. 111781, Jun. 2020, doi: 10.1016/J.RSE.2020.111781.
- [2] F. J. Tapiador *et al.*, "A Satellite View of an Intense Snowfall in Madrid (Spain): The Storm 'Filomena' in January 2021," *Remote Sens (Basel)*, vol. 13, no. 14, p. 2702, Jul. 2021, doi: 10.3390/rs13142702.
- [3] J. M. García-Ruiz, I. I. López-Moreno, S. M. Vicente-Serrano, T. Lasanta-Martínez, and S. Beguería, "Mediterranean water resources in a global change scenario," *Earth Sci Rev*, vol. 105, no. 3–4, pp. 121–139, Apr. 2011, doi: 10.1016/J.EARSCIREV.2011.01.006.
- [4] T. Yao *et al.*, "Recent third pole's rapid warming accompanies cryospheric melt and water cycle intensification and interactions between monsoon and environment: Multidisciplinary approach with observations, modeling, and analysis," *Bull Am Meteorol Soc*, vol. 100, no. 3, pp. 423–444, Mar. 2019, doi: 10.1175/BAMS-D-17-0057.1.
- [5] P. K. Champati Ray, S. L. Chatteraj, M. P. S. Bisht, S. Kannaujiya, K. Pandey, and A. Goswami, "Kedarnath disaster 2013: causes and consequences using remote sensing inputs," *Natural Hazards*, vol. 81, no. 1, pp. 227–243, 2016, doi: 10.1007/s11069-015-2076-0.
- [6] "Land Monitoring Service. High Resolution Snow and Ice Monitoring," *Copernicus Programme*. <https://land.copernicus.eu/pan-european/biophysical-parameters/high-resolution-snow-and-ice-monitoring> (accessed Sep. 21, 2022).
- [7] V. Guerrero Mothelet, "La Criósfera: la parte helada de la tierra," *Universidad Nacional Autónoma de México - Dirección General de Divulgación de la Ciencia*, México, Nov. 30, 2020. Accessed: Sep.

- 03, 2022. [Online]. Available: <https://ciencia.unam.mx/leer/1064/la-criosfera-la-parte-helada-de-la-tierra>
- [8] S. Planton *et al.*, *IPCC: Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, vol. Annex III: Glossary. Cambridge and New York: Cambridge University Press, 2013. Accessed: Sep. 06, 2022. [Online]. Available: https://www.ipcc.ch/site/assets/uploads/2018/02/WG1AR5_AnnexIII_FINAL.pdf
- [9] E. Cassani, “El futuro de los glaciares.” *Universidad Nacional Autónoma de México - Dirección General de Divulgación de la Ciencia*, México, Apr. 18, 2018. Accessed: Sep. 05, 2022. [Online]. Available: <https://ciencia.unam.mx/leer/733/el-futuro-de-los-glaciares-entrevista-con-hugo-delgado>
- [10] E. Calvo Buendia *et al.*, “2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories,” 2019. https://www.ipcc.ch/site/assets/uploads/2019/12/19R_V0_01_Overview.pdf (accessed Sep. 21, 2022).
- [11] A. Ivette, “Criósfera,” *Economipedia*, Jun. 03, 2021. Accessed: Sep. 21, 2022. [Online]. Available: <https://economipedia.com/definiciones/criosfera.html>
- [12] W. Gareth Rees, *Remote Sensing of Snow And ice*. CRC Press, 2006.
- [13] Iberbeu, “La nieve: ese mágico elemento,” *Lugares de nieve*, Jul. 20, 2014. Accessed: Sep. 21, 2022. [Online]. Available: <https://www.lugaresdenieve.com/?q=es/reportaje/la-nieve-ese-m-gico-elemento>
- [14] K. G. Libbrecht, “SnowFlake Science,” *Snow Crystals*. Accessed: Sep. 21, 2022. [Online]. Available: <http://www.snowcrystals.com/science/science.html>
- [15] AEMET, “Breve Guía Descriptiva de los Fenómenos Meteorológicos recogidos en el Sistema de Notificación de Observaciones Atmosféricas Singulares SINOBAS.” Accessed: Sep. 21, 2022. [Online]. Available: https://sinobas.aemet.es/objetos/Guia_fenomenos_sinobas.pdf
- [16] Geoestudios LTDA., *Manual de Nieve y Nivometría*, vol. 1. Santiago de Chile: Ministerio de Obras Públicas- Dirección General de Aguas, 2008. Accessed: Sep. 21, 2022. [Online]. Available: <https://snia.mop.gob.cl/sad/GLA5146v1.pdf>
- [17] E. Chuvieco, *Teledetección ambiental: La observación de la tierra desde el espacio*. Ariel Ciencia, 2006.
- [18] A. P. Salcedo, “Estimación de área cubierta de nieve en cuencas con elevado aporte de fusión utilizando datos ERS-2,” *CONAE*, Jan. 2011, Accessed: Sep. 21, 2022. [Online]. Available: https://rdu.unc.edu.ar/bitstream/handle/11086/6925/2009_Salcedo-Ana.pdf?sequence=1&isAllowed=y
- [19] J. Dozier, “Spectral signature of Alpine snow cover from the LANDSAT Thematic Mapper,” *Remote Sens Environ*, vol. 28, no. C, pp. 9–22, Apr. 1989, doi: 10.1016/0034-4257(89)90101-6.
- [20] Edu.Lat, “Definición de criosfera.” <https://definicion.edu.lat/definicion/criosfera.html> (accessed Sep. 21, 2022).
- [21] H. S. Negi, A. V. Kulkarni, and B. S. Semwal, “Estimation of snow cover distribution in Beas Basin, Indian Himalaya using Satellite data and Ground measurements,” *Journal of Earth System Science*, vol. 118, no. 5, pp. 525–538, Oct. 2009, doi: 10.1007/s12040-009-0039-0.
- [22] M. Geetha Priya and P. Sharma, “Snow Cover Estimation of Western Himalayas using Sentinel-2 High Spatial Resolution Data,” *Indian Journal of Ecology*, vol. 46, no. 1, pp. 88–93, Mar. 2019, [Online]. Available: <https://www.researchgate.net/publication/331588727>
- [23] ESA. The European Space Agency, “ESA. Sentinel-2. Overview.” <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/overview>
- [24] “Random Forest Supervised Classification Using Sentinel-2 Data.” MediaWiki, 2022. Accessed: Sep. 22, 2022. [Online]. Available: https://dges.carleton.ca/CUOSGwiki/index.php/Random_Forest_Supervised_Classification_Using_Sentinel-2_Data
- [25] Y. Shimamura, T. Izumi, and H. Matsuyama, “Evaluation of a useful method to identify snow-covered areas under vegetation—comparisons among a newly proposed snow index, normalized

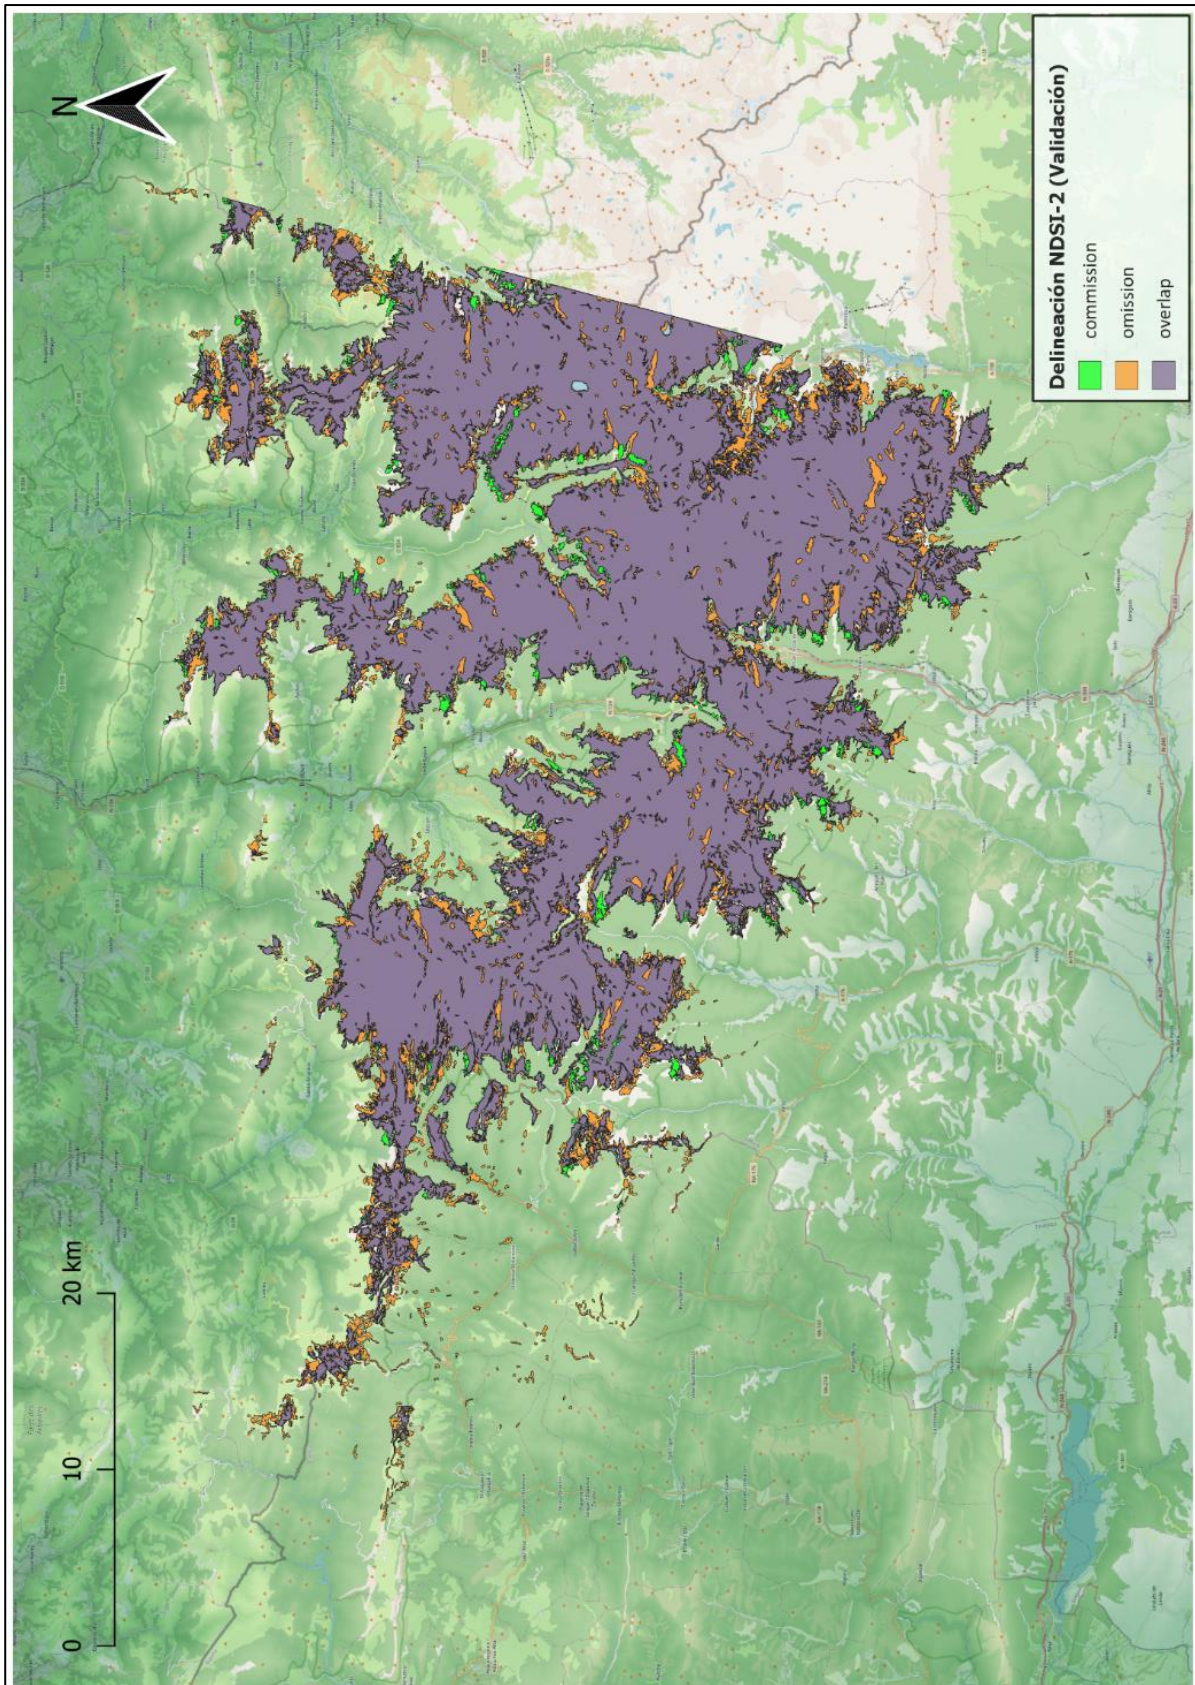
- difference snow index and visible reflectance," *Int J Remote Sens*, vol. 27, pp. 4867–4884, Nov. 2006, doi: 10.1080/01431160600639693.
- [26] A. Dixit, A. Goswami, and S. Jain, "Development and Evaluation of a New 'Snow Water Index (SWI)' for Accurate Snow Cover Delineation," *Remote Sens (Basel)*, vol. 11, Nov. 2019, doi: 10.3390/rs11232774.
- [27] C. Dendaletche, *Guía de los Pirineos. Geología, Ecología y Biología*. Ediciones Omega, 1991.
- [28] "GeoEnciclopedia: Pirineos", Accessed: Sep. 21, 2022. [Online]. Available: <https://www.geoenciclopedia.com/pirineos/>
- [29] W. Gibbons and T. Moreno, *The Geology of Spain. The Geological Society*. Geological Society, 2002.
- [30] Ministerio para la Transición Ecológica y el Reto Demográfico, "Evaluación de los Recursos Hídricos Procedentes de la Innivación (ERHIN)." <https://www.miteco.gob.es/es/agua/temas/evaluacion-de-los-recursos-hidricos/ERHIN/> (accessed Sep. 22, 2022).
- [31] "ESA. The European Space Agency," *Sentinel-2*, Jun. 17, 2015. https://www.esa.int/Space_in_Member_States/Spain/SENTINEL_2 (accessed Sep. 22, 2022).
- [32] "Copernicus," *Copernicus Open Access Hub*. <https://scihub.copernicus.eu/> (accessed Sep. 22, 2022).
- [33] "ESA. Sentinel Online," *Sentinel-2. Data Products*. <https://sentinel.esa.int/web/sentinel/missions/sentinel-2/data-products> (accessed Sep. 22, 2022).
- [34] High Resolution Snow and Ice Monitoring Facts Sheet, "Copernicus Land Monitoring Service," 2022. [Online]. Available: <https://www.wekeo.eu/>
- [35] "HR-S&I Pan-European High-Resolution Snow & Ice Monitoring Of The Copernicus Land Monitoring Service-Production Of Basic Products Algorithm Theoretical Basis Document For Snow Products Based On Sentinel-2. ATBD for snow products based on S2," Oct. 2021.
- [36] "Copernicus. Land Monitoring Service," *High Resolution Snow & Ice Monitoring. Product Finder plataform*. <https://cryo.land.copernicus.eu/finder/>
- [37] Copernicus and European Environment Agency, "GMES Initial Operations / Copernicus Land monitoring services-Validation of products COMPARATIVE VALIDATION OF HRL-TCD AND UNIVERSITY OF MARYLAND GLOBAL FOREST CHANGE PRODUCTS," 2017.
- [38] D. K. Hall, G. A. Riggs, and V. V. Salomonson, "Development of Methods for Mapping Global Snow Cover Using Moderate Resolution Imaging Spectroradiometer Data," *Remote Sens Environ*, vol. 54, pp. 127–140, 1995.
- [39] R. Williams, D. Hall, O. Sigurðsson, and J. Chien, "Comparison of satellite-derived with ground-based measurements of the fluctuations of the margins of Vatnajökull, Iceland," *Annals of Glaciology. Cambridge University Press*, vol. 24, pp. 72–80, Jan. 1997, doi: 10.3189/S0260305500011964.
- [40] R. S. Williams and D. K. Hall, "Atlas of satellite observations related to global change ," *Cambridge University Press*, pp. 401–421, 1993.
- [41] T. E. Khromova, G. B. Osipova, D. G. Tsvetkov, M. B. Dyurgerov, and R. G. Barry, "Changes in glacier extent in the eastern Pamir, Central Asia, determined from historical data and ASTER imagery," *Remote Sens Environ*, vol. 102, no. 1–2, pp. 24–32, May 2006, doi: 10.1016/J.RSE.2006.01.019.
- [42] A. v Kulkarni *et al.*, "Glacial retreat in Himalaya using Indian Remote Sensing satellite data," *Curr Sci*, vol. 92, no. 1, pp. 69–74, 2007.
- [43] "NASA. Landsat Science," *Satellites. Landsat 9*. <https://landsat.gsfc.nasa.gov/satellites/landsat-9/>
- [44] N. Grumman, "Mission Management and Operations: Spacecraft Provider and Observatory Integration."
- [45] The United States Geological Survey, "USGS. Science for a changing world," *EarthExplorer*. <https://earthexplorer.usgs.gov/>
- [46] USGS, "Landsat 8-9 Operational Land Imager (OLI)-Thermal Infrared Sensor (TIRS) Collection 2 Level 2 (L2) Data Format Control Book (DFCB)," 2020.
- [47] "ESA. Earth Online," *SNAP Description*. <https://earth.esa.int/eogateway/tools/snap>
- [48] ESA, "The European Space Agency." <https://www.esa.int/>
- [49] "Ingeniería Ambiental," *QGIS vs ArcGIS: ventajas y desventajas, diferencias*, Feb. 01, 2022. <https://ingenieriaambiental.net/qgis-vs-arcgis/>

- [50] “QGIS. SIG Libre de Código Abierto para Escritorio,” *Acerca de QGIS*.
<https://www.qgis.org/es/site/about/index.html> (accessed Sep. 22, 2022).
- [51] ESRI, “ArcGIS Desktop: Arcmap,” *Qué es ArcMap*.
<https://desktop.arcgis.com/es/arcmap/latest/map/main/what-is-arcmap-.htm>
- [52] J. Dozier, *Spectral Signature of Alpine Snow Cover from the Landsat Thematic Mapper*. *Remote Sensing of Environment*. 1989.
- [53] Kulkarni AV, *Effect of global warming on snow ablation pattern in the Himalaya*. 2002.
- [54] D. K. Hall, A. T. C. Chang, J. L. Foster, and J. Y. L. Chien, “Technical Report Series on the Boreal Ecosystem-Atmosphere Study (BOREAS): BOREAS RSS-8 Snow Maps Derived from Landsat TM Imagery,” *NASA/TM*, vol. 56, Aug. 2000.
- [55] A. W. Nolin, “Recent advances in remote sensing of seasonal snow,” *Journal of Glaciology*, vol. 56, no. 200, pp. 1141–1150, 2010, doi: 10.3189/002214311796406077.
- [56] A. Saito and T. Yamazaki, “Characteristics of spectral reflectance for vegetation ground surfaces with snowcover: Vegetation indices and snow indices,” *Journal of Japan Society of Hydrology and Water Resources*, vol. 12, pp. 28–38, 1999.
- [57] H. S. Negi, A. V. Kulkarni, and B. S. Semwal, “Study of contaminated and mixed objects snow reflectance in Indian Himalaya using spectroradiometer,” *International Journal of Remote Sensing*, vol. 30, no. 2, pp. 315–325, Jan. 2009, doi: 10.1080/01431160802261197.
- [58] Universidad de Oviedo, “El algoritmo k-means aplicado a clasificación y procesamiento de imágenes. Computación numérica.” Oviedo. [Online]. Available:
https://www.uniovi.es/compun/laboratorios_py/kmeans/kmeans.html#:~:text=K%2Dmeans%20es%20un%20algoritmo,de%20su%20grupo%20o%20cluster
- [59] “Introduction to cluster analysis,” *Snap Surveys*. [Online]. Available:
<https://www.snapsurveys.com/support-snapxmp/snapxmp/introduction-cluster-analysis/?print=print>
- [60] ESA. Sentinel Applications Platform, “SNAP: Sentinel Toolbox Help.”
- [61] L. Breiman, “Random forests,” *Mach Learn*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [62] M. Belgiu and L. Drăgu, “Random forest in remote sensing: A review of applications and future directions,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 114. Elsevier B.V., pp. 24–31, Apr. 01, 2016. doi: 10.1016/j.isprsjprs.2016.01.011.
- [63] E. Fix and J. L. Hodges, “Discriminatory Analysis. Nonparametric Discrimination Consistency Properties,” Berkeley, Feb. 1951.
- [64] T. M. Cover and P. E. Hart, “Nearest Neighbor Pattern Classification. Approximate formulas for the information transmitted by a discrete communication channel,” Jan. 1952.
- [65] S. Raschka, “STAT 479: Machine Learning Lecture Notes,” 2018. [Online]. Available:
<http://stat.wisc.edu/~sraschka/teaching/stat479-fs2018/>
- [66] SIG y Teledetección en la Universidad de Murcia., “Universidad de Murcia.”
<https://www.um.es/geograf/sig/teledet/clasific1.html>
- [67] W. Tobler, “Measuring spatial resolution Spatially Coherent Migration.pptx View project Solstice: An Electronic Journal of Geography and Mathematics View project,” 2017. [Online]. Available:
<https://www.researchgate.net/publication/291877360>
- [68] Á. Priego, G. Bocco, M. Mendoza, and A. Garrido, *Propuesta para la deneración semiautomatizada de unidades de paisaje: Planeación Territorial*. SEMARNAT, INE, CIGA, UNAM, Mexico, 2010. Accessed: Sep. 03, 2022. [Online]. Available:
https://www.ciga.unam.mx/publicaciones/images/abook_file/propuestaSemi.pdf
- [69] M. L. Saavedra, C. G. Martin, F. Zambrano, and F. J. Merino, “Clasificación de Imágenes Fusionadas, un problema de explosión de información.”
- [70] Anne W.Nolin, “Recent advances in remote sensing of seasonal snow,” 2010.


8. Anexos

8.2. Anexo: Mapas de validación de las delineaciones

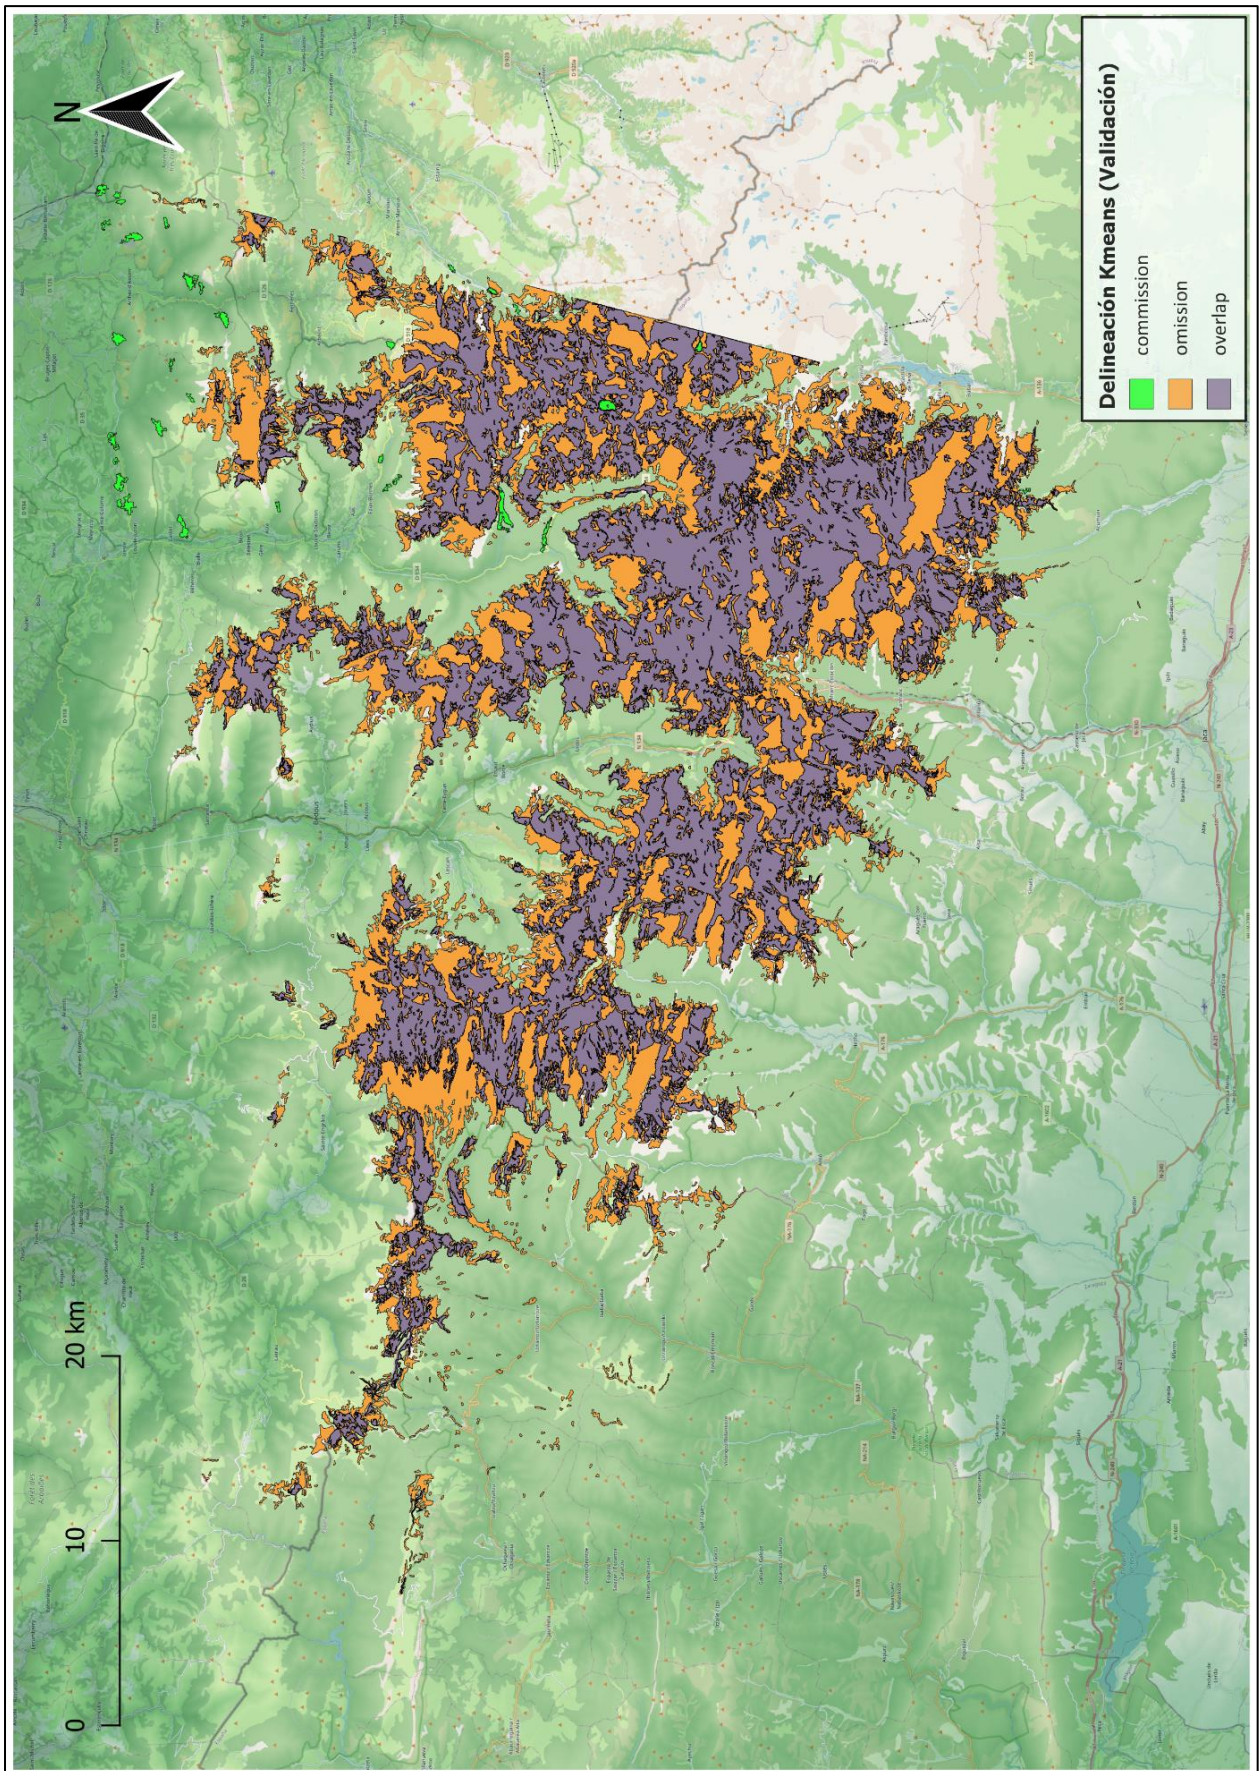
NDSI




S3



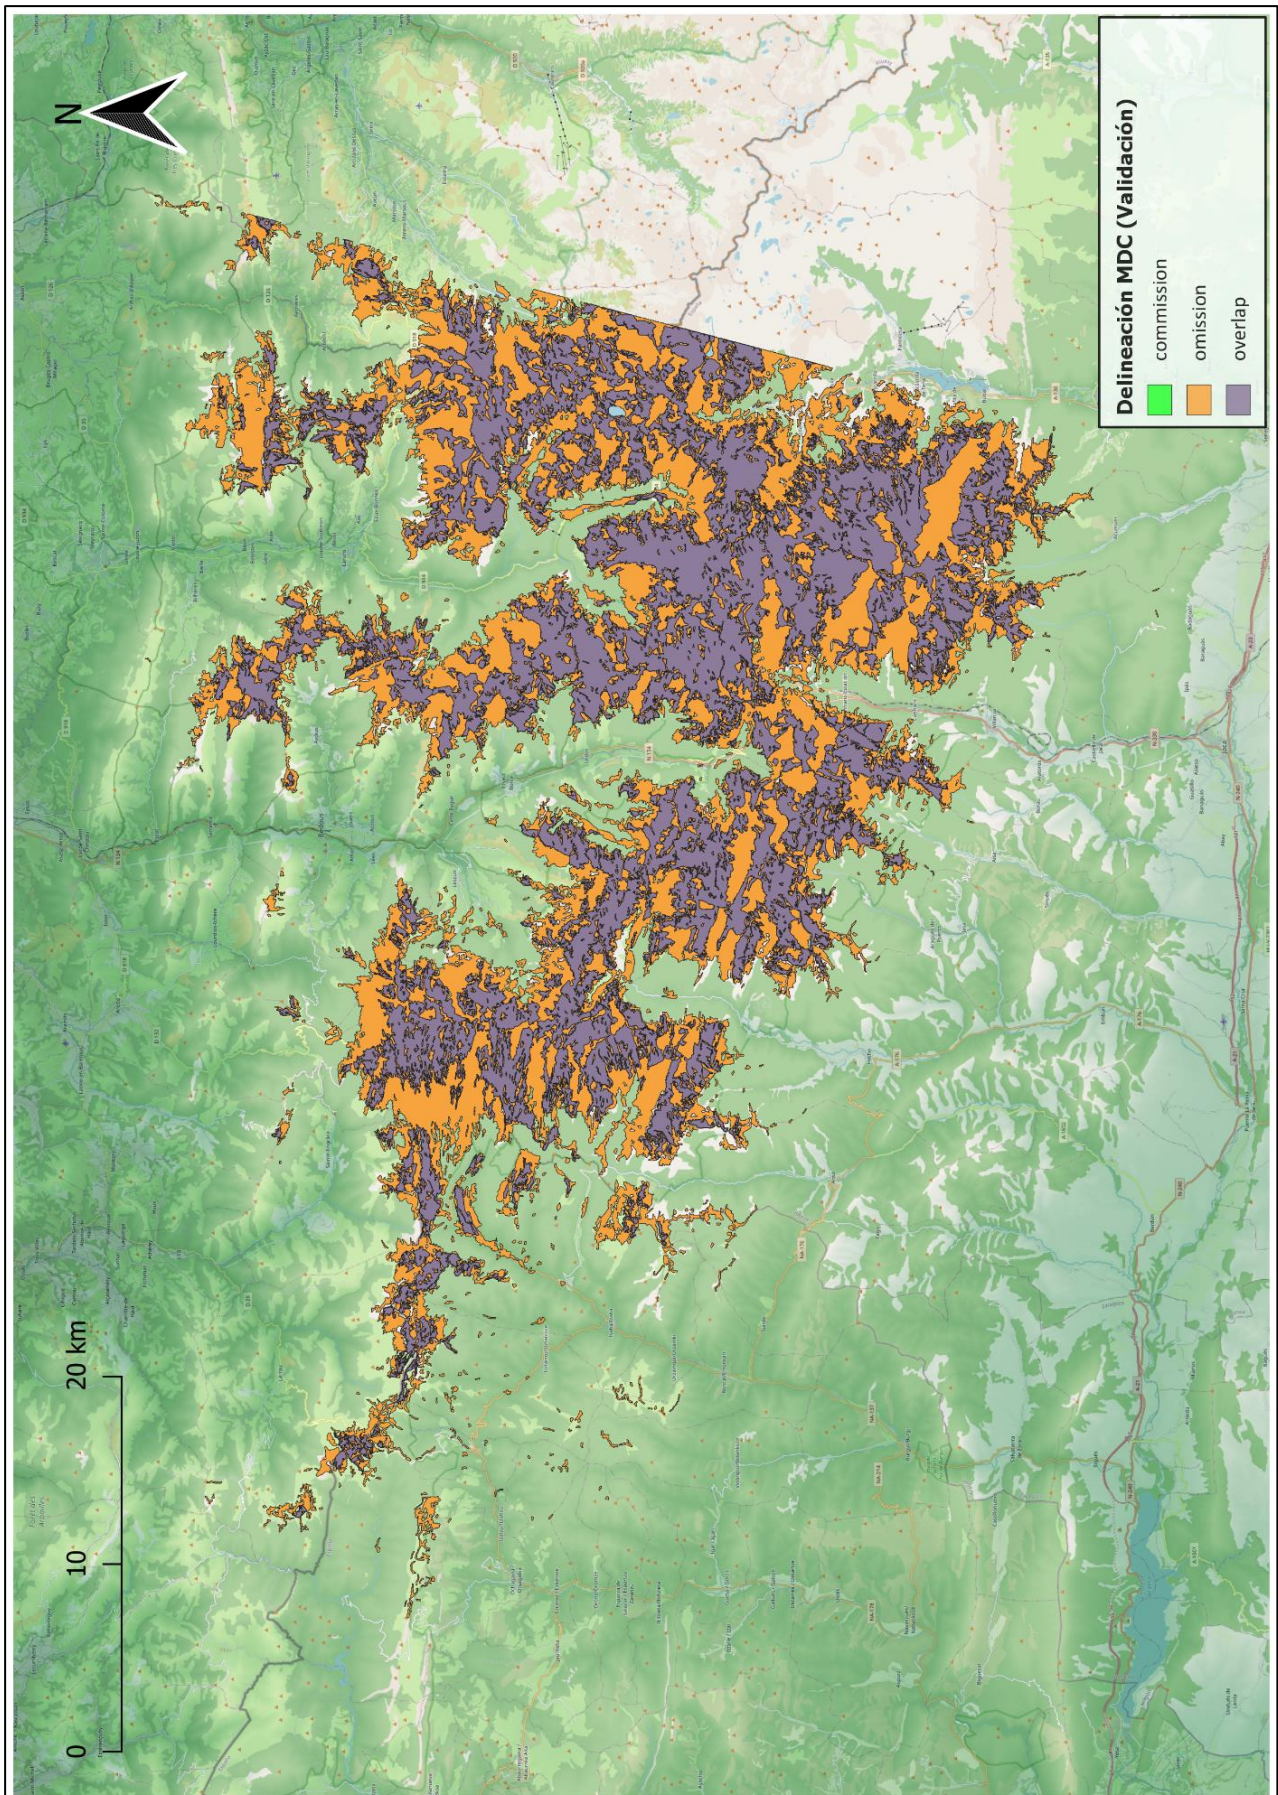
K Means

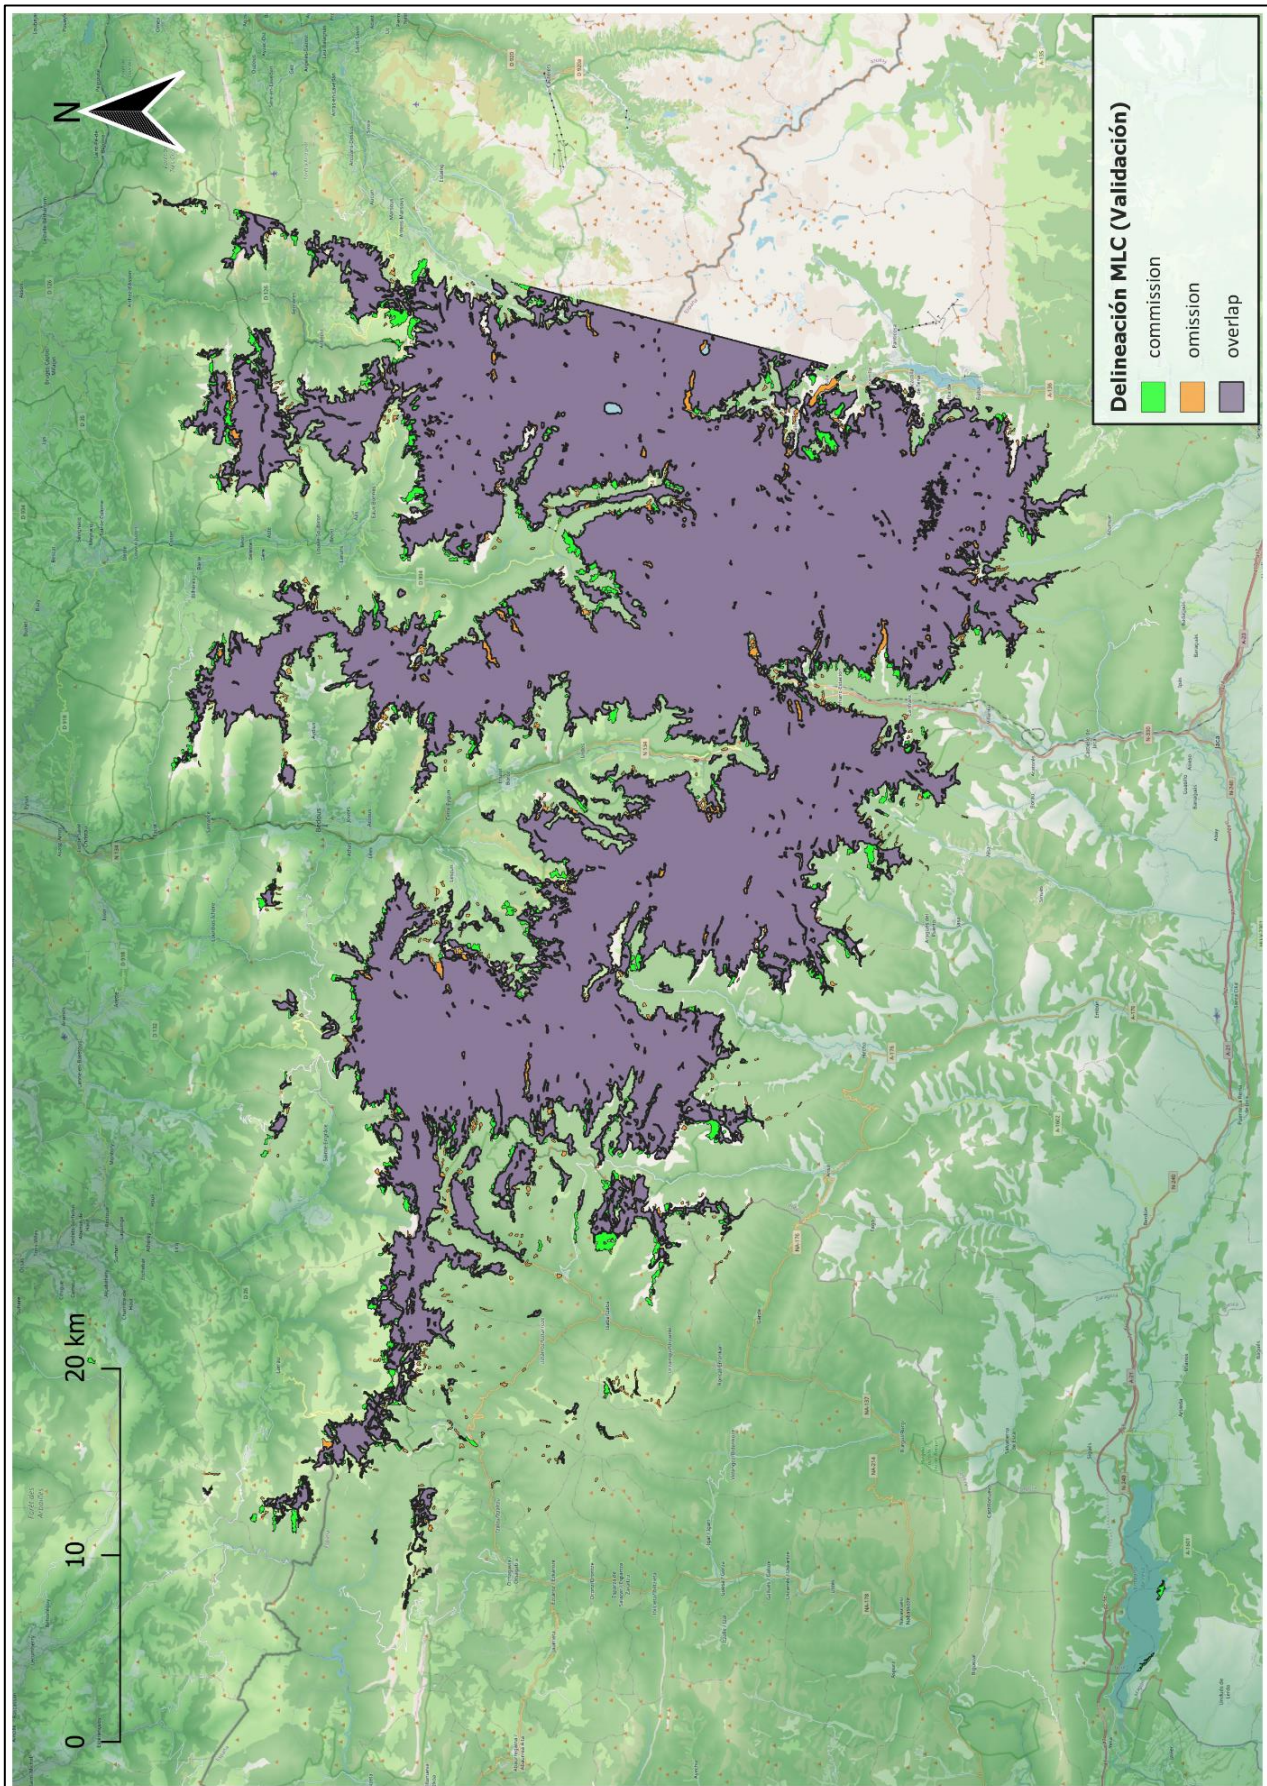


Feature Analyst Supervisado

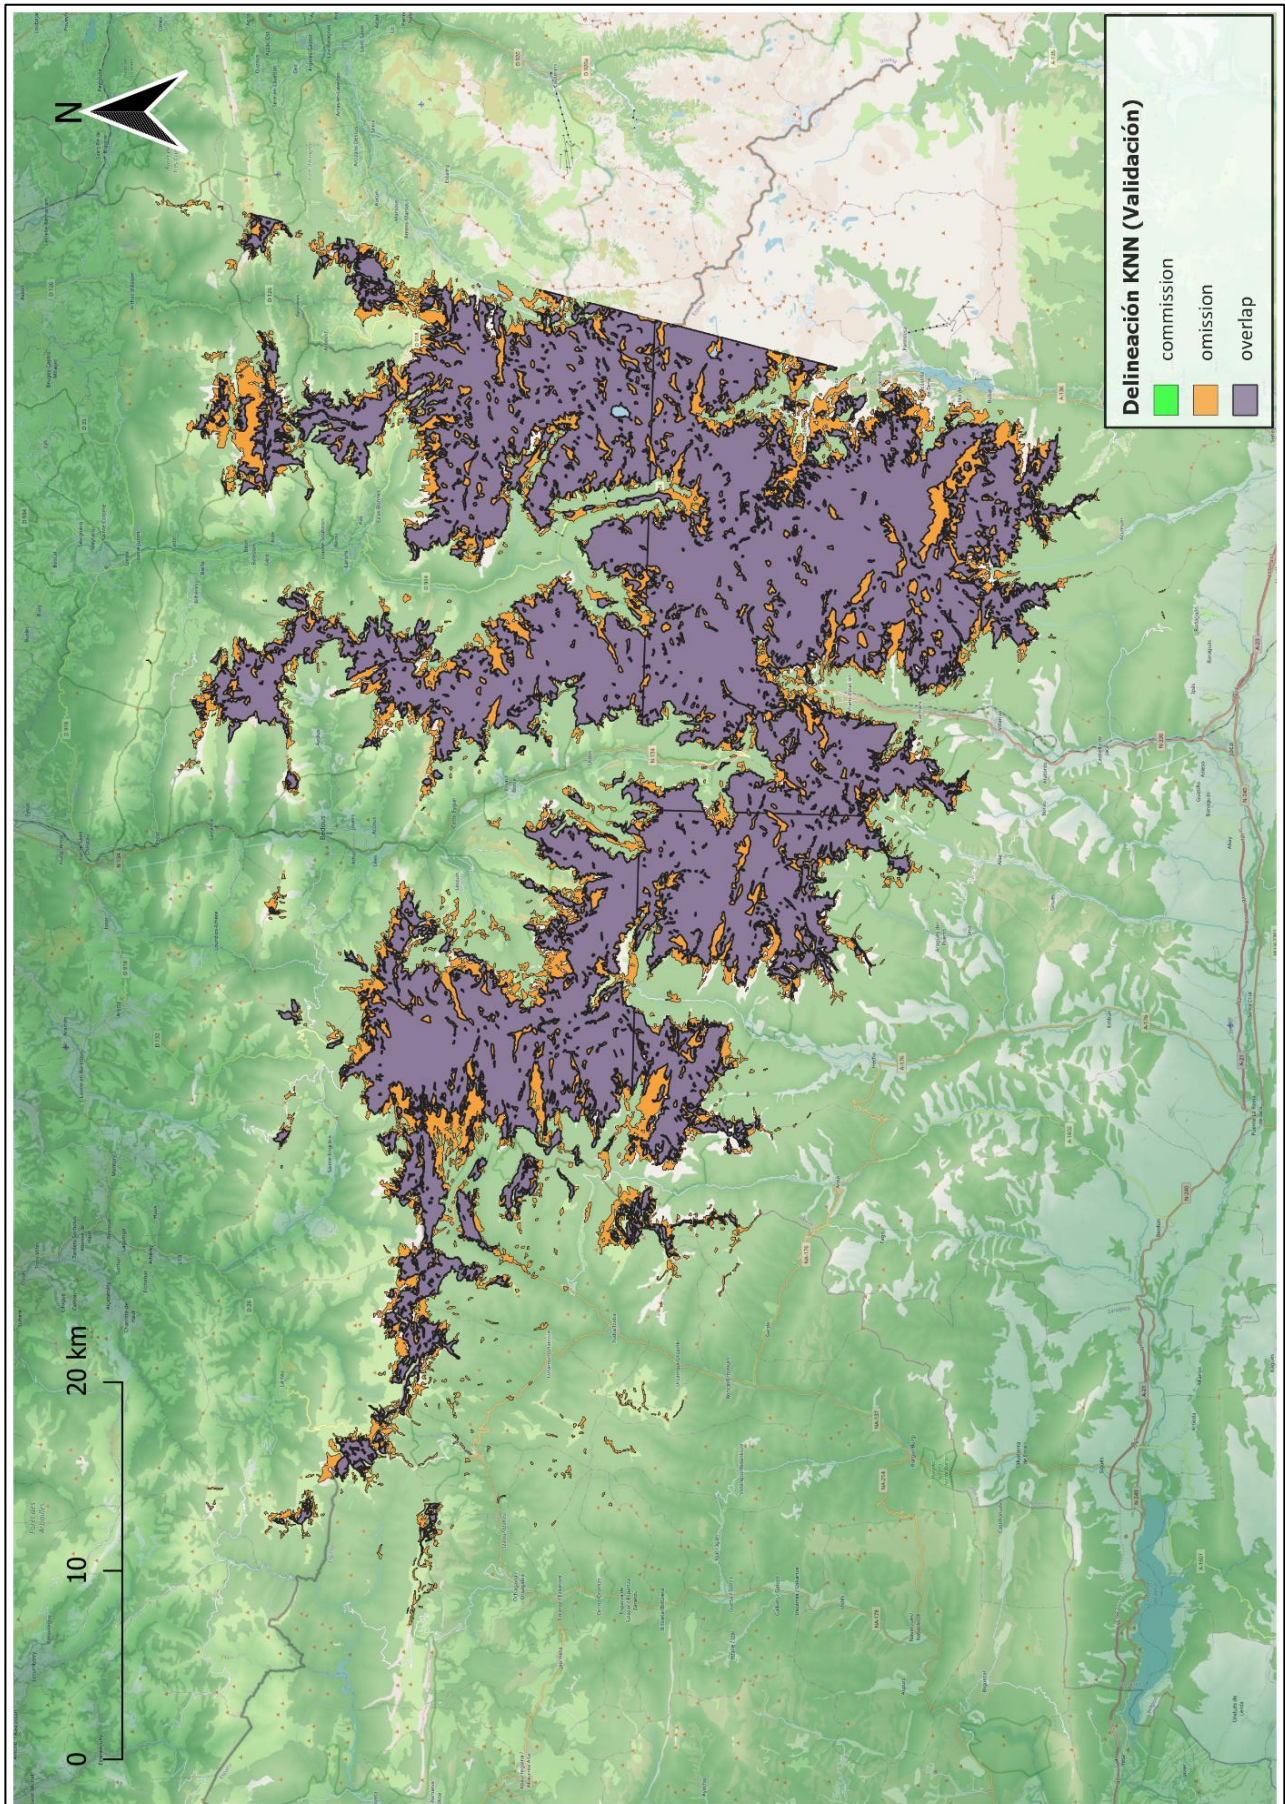


Minimun Distance Classifier (Clasificador de Mínima Distancia)

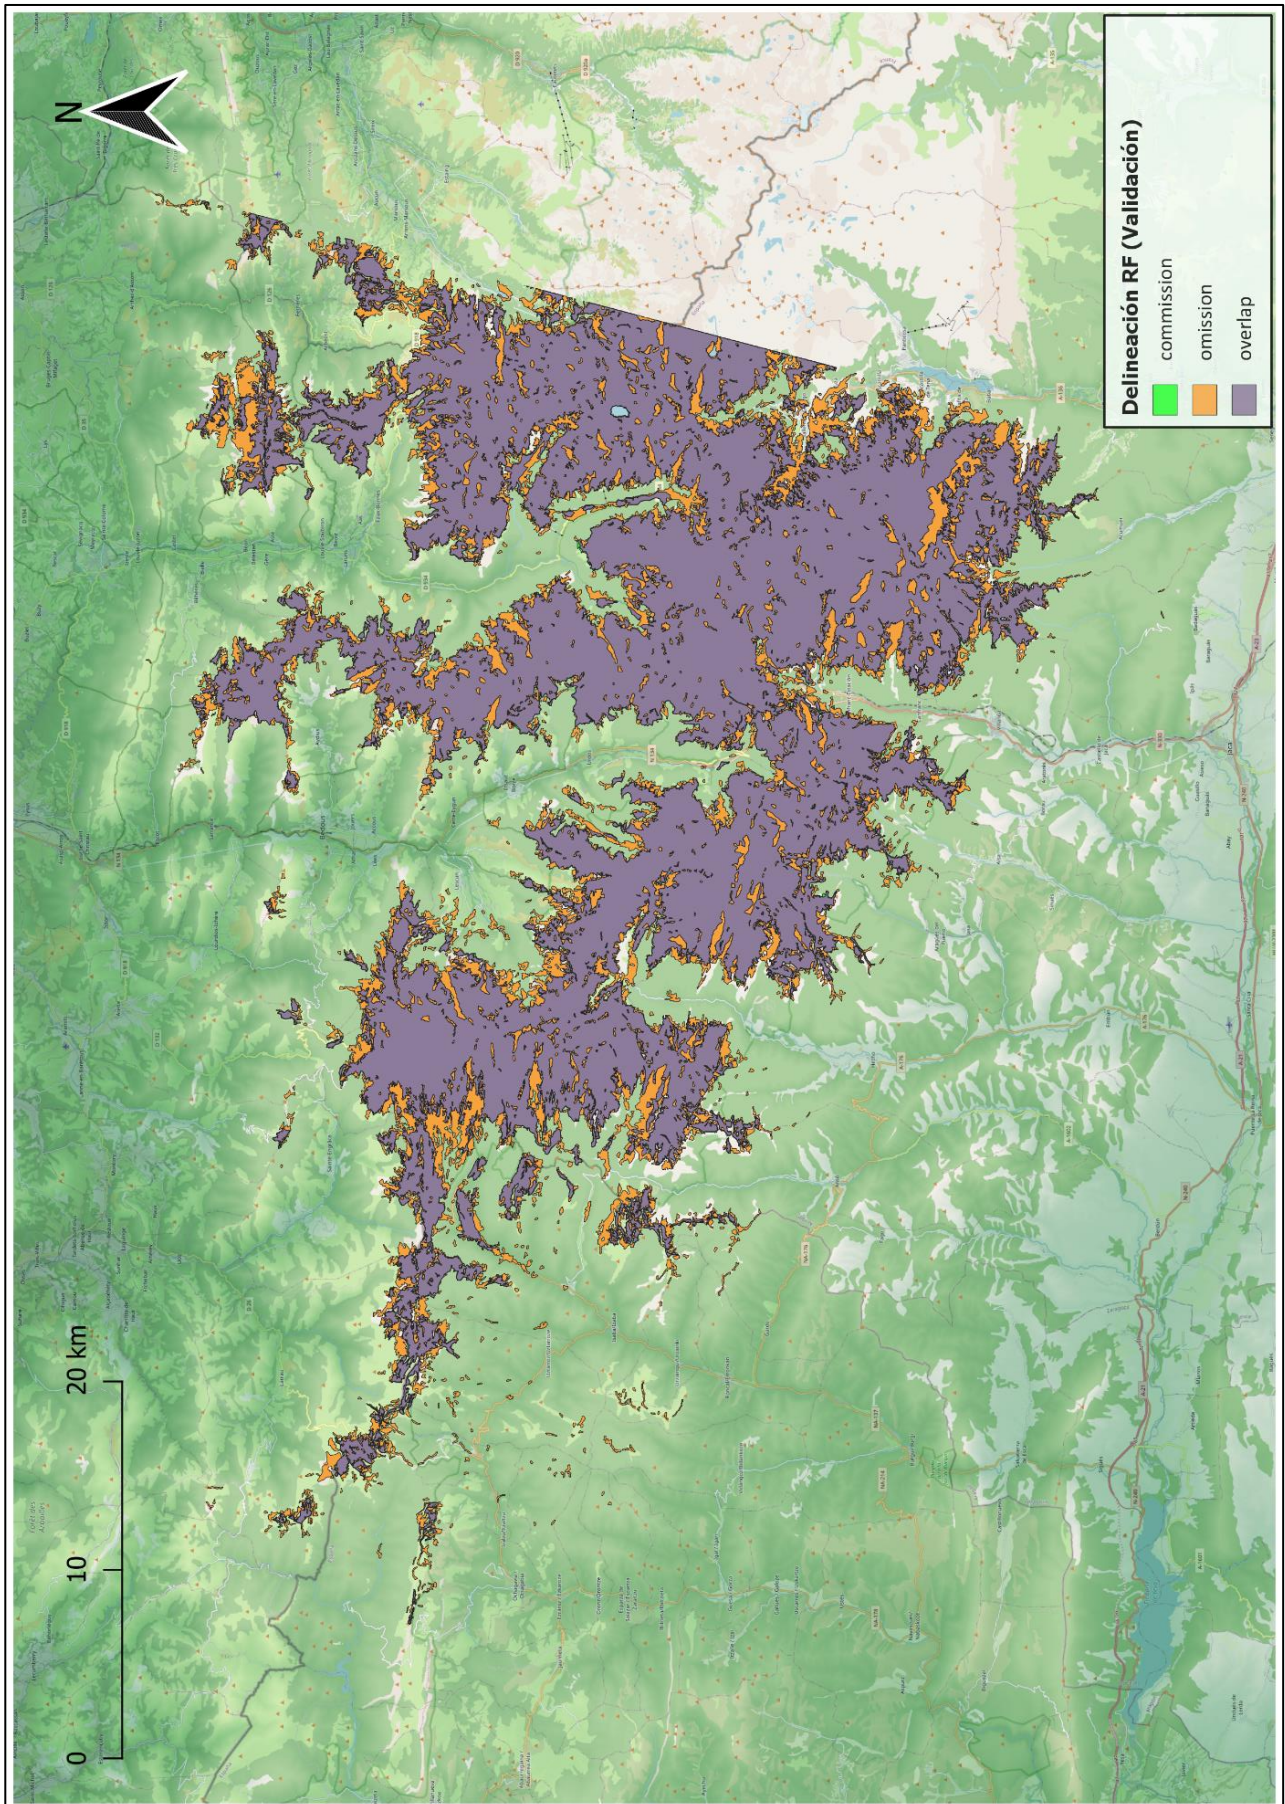


Maximun Likelihood Classifier (Clasificador de máxima verisimilitud)

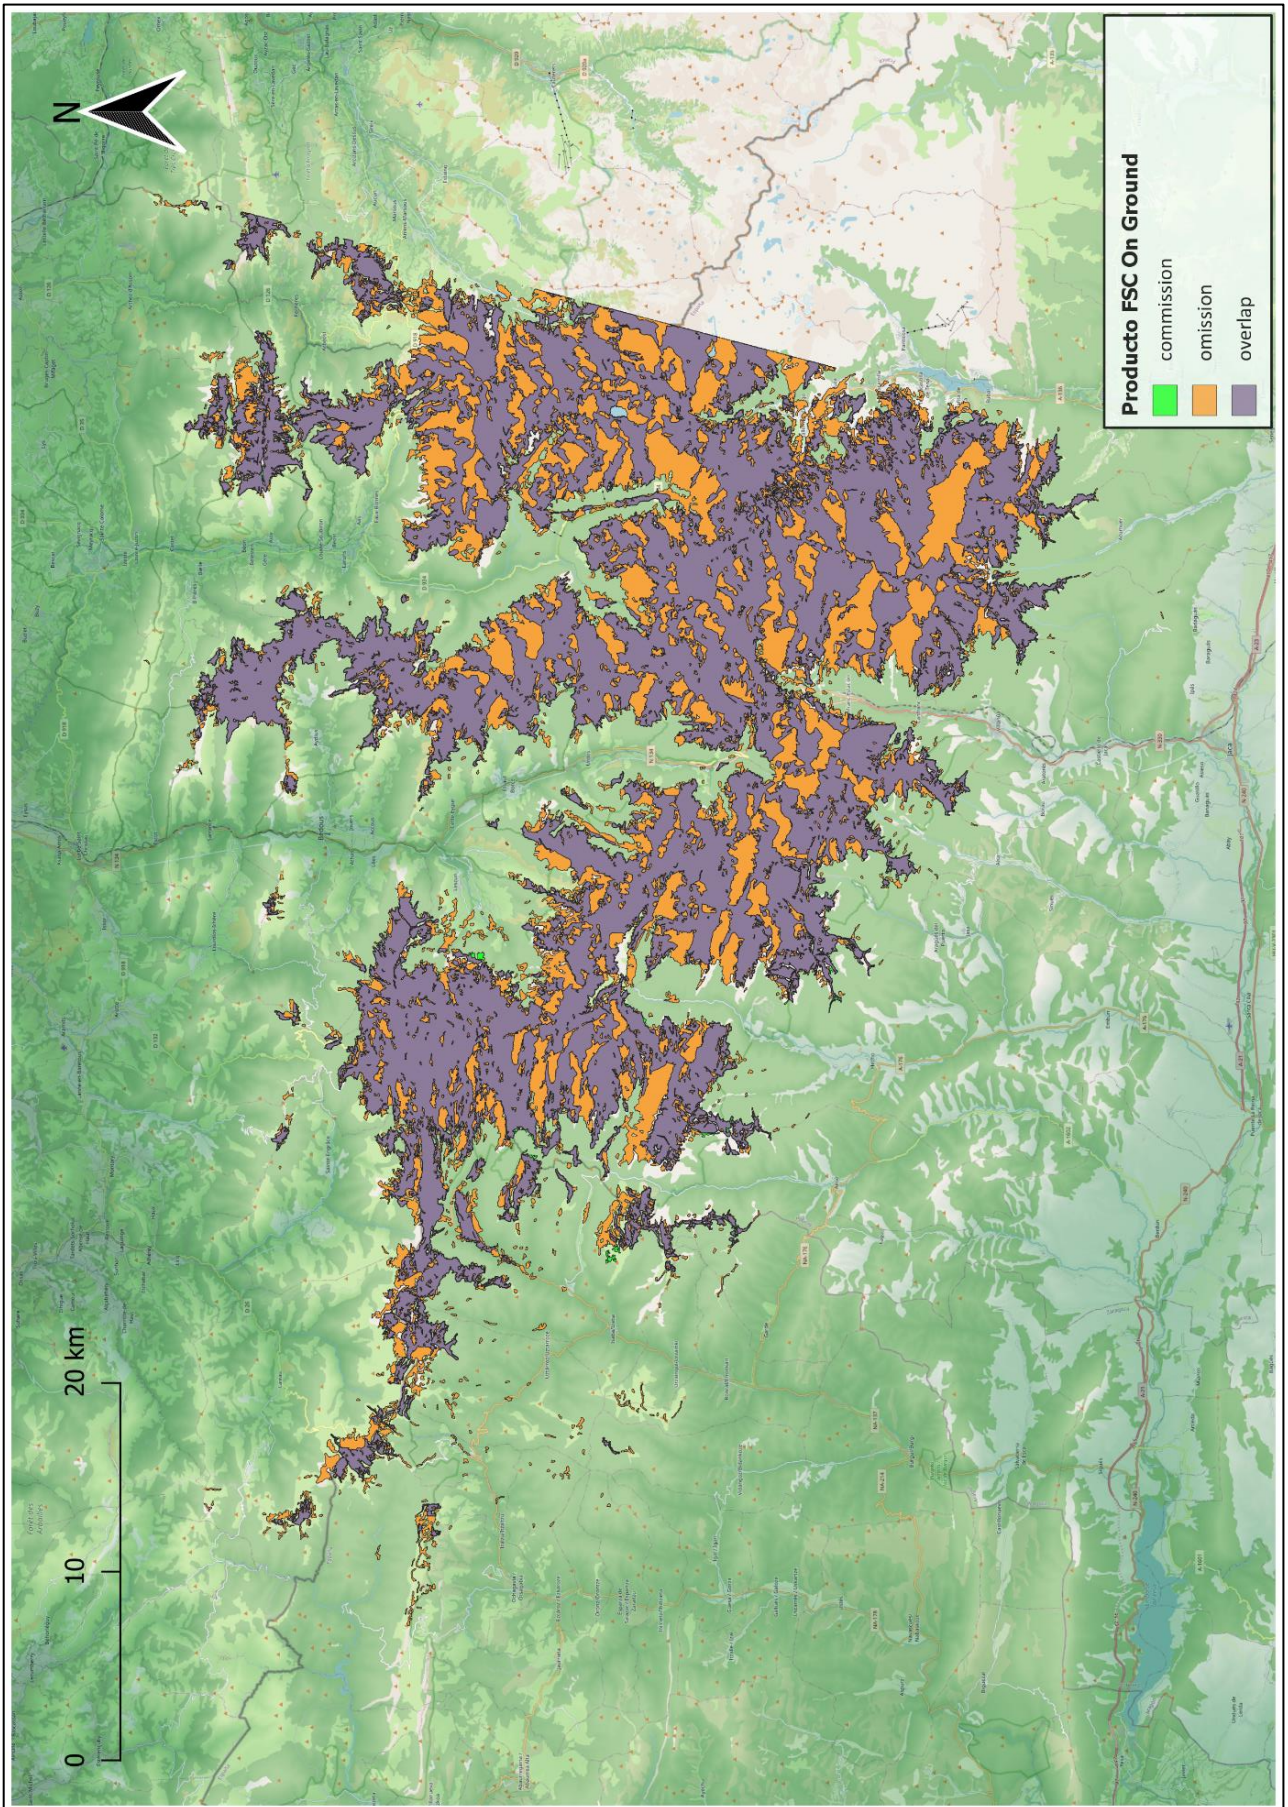
KNN



Random Forest



FSC On Ground Product (Delineación del producto de S&I)



8.3. Anexo: Matrices de confusión

NDSI

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
NDSI	Nieve	84507,65	3250,79	87758,44	96,30	3,70
	No Nieve	18086,06	665326,40	683412,46	97,35	2,65
	TOTAL	102593,71	668577,19	771.170,90		
	Fiab. productor %	82,37	99,51			
	Error omisión %	17,63	0,49			

	NDSI
Exactitud (<i>Unión delimitaciones de Nieve %</i>)	79,87
Error de Comisión (<i>Unión delimitaciones de Nieve %</i>)	3,25
Error de Omisión (<i>Unión delimitaciones de Nieve %</i>)	16,88
Exactitud %	97,23
Precision (<i>Fiabilidad del usuario %</i>)	96,09
Sensibilidad (<i>Fiabilidad del productor %</i>)	82,55
Especificidad (<i>Fiabilidad del productor %, clase No Nieve</i>)	99,48
Error de Comisión %	3,91
Error de Omisión %	17,45
F score	0,89

S3

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
S3	Nieve	89240,25	6229,41	95469,66	93,47	6,53
	No Nieve	13353,46	662347,78	675701,24	98,02	1,98
	TOTAL	102593,71	668577,19	771.170,90		
	Fiab. productor %	86,98	99,07			
	Error omisión %	13,02	0,93			

	S3
Exactitud (<i>Unión delimitaciones de Nieve %</i>)	82,00
Error de Comisión (<i>Unión delimitaciones de Nieve %</i>)	5,72
Error de Omisión (<i>Unión delimitaciones de Nieve %</i>)	12,27
Exactitud %	97,46
Precision (<i>Fiabilidad del usuario %</i>)	93,47
Sensibilidad (<i>Fiabilidad del productor %</i>)	86,98
Especificidad (<i>Fiabilidad del productor %, clase No Nieve</i>)	99,07
Error de Comisión %	6,52
Error de Omisión %	13,01
F score	0,90

K-Means

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
K Means	Nieve	53346,43	880,24	54226,67	98,38	1,62
	No Nieve	49247,28	667696,95	716944,23	93,13	6,87
	TOTAL	102593,71	668577,19	771.170,90		
	Fiab. productor %	52,00	99,87			
	Error omisión %	48,00	0,13			

	K-Means
Exactitud (Unión delineaciones de Nieve %)	51,56
Error de Comisión (Unión delineaciones de Nieve %)	0,85
Error de Omisión (Unión delineaciones de Nieve %)	47,59
Exactitud %	93,50
Precisión (Fiabilidad del usuario %)	98,38
Sensibilidad (Fiabilidad del productor %)	52,00
Especificidad (Fiabilidad del productor %, clase No Nieve)	99,87
Error de Comisión %	1,62
Error de Omisión %	48,00
F score	0,68

Feature Analyst Supervised Class.

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
FA Sup.	Nieve	88226,31	1220,16	89446,47	98,64	1,36
	No Nieve	14367,40	667357,03	681724,43	97,89	2,11
	TOTAL	102593,71	668577,19	771.170,90		
	Fiab. productor %	86,00	99,82			
	Error omisión %	14,00	0,18			

	FA Sup.
Exactitud (Unión delineaciones de Nieve %)	84,99
Error de Comisión (Unión delineaciones de Nieve %)	1,18
Error de Omisión (Unión delineaciones de Nieve %)	13,84
Exactitud %	97,98
Precisión (Fiabilidad del usuario %)	98,64
Sensibilidad (Fiabilidad del productor %)	86,00
Especificidad (Fiabilidad del productor %, clase No Nieve)	99,82
Error de Comisión %	1,36
Error de Omisión %	14,00
F score	0,92

Minimum Distance Classifier

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
Minimum Distance Classifier	Nieve	46972,01	120,76	47092,77	99,74	0,26
	No Nieve	55621,69	668456,44	724078,13	92,32	7,68
TOTAL		102593,70	668577,20	771.170,90		
Fiab. productor %		45,78	99,98			
Error omisión %		54,22	0,02			

	MDC
Exactitud (Unión delimitaciones de Nieve %)	45,73
Error de Comisión (Unión delimitaciones de Nieve %)	0,12
Error de Omisión (Unión delimitaciones de Nieve %)	54,15
Exactitud %	92,77
Precisión (Fiabilidad del usuario %)	99,74
Sensibilidad (Fiabilidad del productor %)	45,78
Especificidad (Fiabilidad del productor %, clase No Nieve)	99,98
Error de Comisión %	0,26
Error de Omisión %	54,22
F score	0,63

Maximum likelihood Classifier

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
Maximum Likelihood Classifier	Nieve	98015,41	8013,06	106028,47	92,44	7,56
	No Nieve	4578,30	660564,13	665142,43	99,31	0,69
TOTAL		102593,71	668577,19	771.170,90		
Fiab. productor %		95,54	98,80			
Error omisión %		4,46	1,20			

	MLC
Exactitud (<i>Unión delimitaciones de Nieve %</i>)	88,62
Error de Comisión (<i>Unión delimitaciones de Nieve %</i>)	7,24
Error de Omisión (<i>Unión delimitaciones de Nieve %</i>)	4,14
Exactitud %	98,37
Precisión (<i>Fiabilidad del usuario %</i>)	92,44
Sensibilidad (<i>Fiabilidad del productor %</i>)	95,54
Especificidad (<i>Fiabilidad del productor %, clase No Nieve</i>)	98,80
Error de Comisión %	7,56
Error de Omisión %	4,46
F score	0,94

KNN

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
KNN	Nieve	74300,65	516,54	74817,19	99,31	0,69
	No Nieve	28293,06	668060,65	696353,71	95,94	4,06
	TOTAL	102593,71	668577,19	771.170,90		
	Fiab. productor %	72,42	99,92			
	Error omisión %	27,58	0,08			

	KNN
Exactitud (<i>Unión delimitaciones de Nieve %</i>)	72,06
Error de Comisión (<i>Unión delimitaciones de Nieve %</i>)	0,50
Error de Omisión (<i>Unión delimitaciones de Nieve %</i>)	27,44
Exactitud %	96,26
Precisión (<i>Fiabilidad del usuario %</i>)	99,31
Sensibilidad (<i>Fiabilidad del productor %</i>)	72,42
Especificidad (<i>Fiabilidad del productor %, clase No Nieve</i>)	99,92
Error de Comisión %	0,69
Error de Omisión %	27,58
F score	0,84

Random Forest

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
Random Forest	Nieve	76321,54	619,28	76940,82	99,20	0,80
	No Nieve	26272,17	667957,91	694230,08	96,22	3,78
	TOTAL	102593,71	668577,19	771.170,90		
	Fiab. productor %	74,39	99,91			
	Error omisión %	25,61	0,09			

	RF
Exactitud (Unión delimitaciones de Nieve %)	73,95
Error de Comisión (Unión delimitaciones de Nieve %)	0,60
Error de Omisión (Unión delimitaciones de Nieve %)	25,45
Exactitud %	96,51
Precisión (Fiabilidad del usuario %)	99,20
Sensibilidad (Fiabilidad del productor %)	74,39
Especificidad (Fiabilidad del productor %, clase No Nieve)	99,91
Error de Comisión %	0,80
Error de Omisión %	25,61
F score	0,85

FSCOG

		Referencia (Landsat)		TOTAL	Fiab. usuario %	Error Comisión %
		Nieve	No Nieve			
FSC On Ground	Nieve	65887,20	808,95	66696,15	98,79	1,21
	No Nieve	36706,50	667768,25	704474,75	94,79	5,21
	TOTAL	102593,70	668577,20	771.170,90		
	Fiab. productor %	64,22	99,88			
	Error omisión %	35,78	0,12			

	FSCOG
Exactitud (Unión delimitaciones de Nieve %)	63,72
Error de Comisión (Unión delimitaciones de Nieve %)	0,78
Error de Omisión (Unión delimitaciones de Nieve %)	35,50
Exactitud %	95,14
Precisión (Fiabilidad del usuario %)	98,79
Sensibilidad (Fiabilidad del productor %)	64,22
Especificidad (Fiabilidad del productor %, clase No Nieve)	99,88
Error de Comisión %	1,21
Error de Omisión %	35,78
F score	0,78