



CASO PRÁCTICO

Evaluación del impacto de la superresolución sobre imágenes multiespectrales GEOSAT-2

César Fernández*¹, Carolina de Castro¹, Lucía García², Maria Elena Calleja³, Rubén Niño⁴,
Silvia Fraile¹, Rafael Sousa¹

¹ Innovation, GEOSAT Satélites SLU, Valladolid, España.

² Business Development, GEOSAT Satélites SLU, Valladolid, España.

³ Image Operations, GEOSAT Satélites SLU, Valladolid, España.

⁴ Satellite Operations, GEOSAT Satélites SLU, Valladolid, España.

Resumen: La creciente necesidad de observar la Tierra con mayor detalle supone la aparición de nuevas técnicas para la mejora del valor geométrico de las imágenes, conservando sus características radiométricas. El sector de seguridad y defensa es uno de los sectores estratégicos que requiere de estos avances, pero no los únicos, ya que, al ser capaces de conservar las características radiométricas del dato, la agricultura de precisión constituye un beneficiario clave de dichas mejoras. De esta manera se pueden proporcionar datos e información más detallada de las necesidades específicas de cada cultivo, lo que supone una mejora directa para el agricultor, las empresas agrícolas y el medio ambiente. En este trabajo se aplicaron los métodos *Random Forest* y *XGBoost* con el fin de mejorar la resolución de las imágenes GEOSAT-2 conservando sus valores radiométricos. Además, se evaluó la calidad de las imágenes mejoradas. Dicha valoración ha sido llevada a cabo por el equipo de control y evaluación de datos de Copernicus (CQC), permitiendo añadir un nuevo producto a la cartera de productos de GEOSAT, listo para ser integrado dentro de la oferta de datos del programa Copernicus.

Palabras clave: superresolución, GEOSAT-2, agricultura de precisión, inteligencia artificial

Evaluation of the impact of super-resolution on GEOSAT-2 multispectral images

Abstract: The growing need to observe the Earth in greater detail means the appearance of new techniques to improve the geometric value of images, preserving their radiometric characteristics. Security and Defence sectors are strategic users of these advances, but not the only ones. By being able to preserve the radiometric characteristics of the data, precision agriculture is a key beneficiary of these improvements. In this way, more detailed data and information can be provided on the specific needs of each crop, which means a direct implication for the farmer, the agricultural companies, and the environment. In this work, the Random Forest and XGBoost methods were applied in order to improve the resolution of the GEOSAT-2 images while preserving their radiometric values. In addition, the quality of the enhanced images was evaluated. Also, the satisfactory evaluation of the improved images is presented, both in terms of resolution and the final quality obtained. This evaluation has been conducted by the Copernicus Coordinated data Quality Control (CQC) team, allowing the addition of a new product to the GEOSAT portfolio, ready to be integrated into the Copernicus Programme data offer.

Key words: super-resolution, GEOSAT-2, precision agriculture, artificial intelligence.

To cite this article: Fernández, C., de Castro, C., García, L., Calleja, M.E., Niño, R., Fraile, S., Sousa, R. 2023. Evaluation of the impact of super-resolution on GEOSAT-2 multispectral images. *Revista de Teledetección*, 61, 83-96. <https://doi.org/10.4995/raet.2023.18470>

* Corresponding author: cesar.fernandez@geosat.space

1. Introducción

La necesidad de obtener imágenes satélites con mayor resolución geométrica se ha acrecentado durante las últimas décadas con el fin de atender las necesidades, cada vez más restrictivas, de los usuarios de datos de observación de la Tierra, especialmente en el ámbito de seguridad y defensa. Muchas de las grandes compañías del sector, incluida GEOSAT, han lanzado o están diseñando nuevas constelaciones de satélites capaces de cubrir esta demanda de acceso a datos submétricos de gran calidad combinada con el aumento de la anchura de barrido en un solo intento. Todo esto unido a los avances en computación que permiten el manejo de gran cantidad de datos en poco tiempo, han permitido el nacimiento de técnicas novedosas para la mejora de la calidad de los datos de las imágenes de los satélites de observación de la Tierra.

GEOSAT cuenta con dos satélites de observación de la Tierra diseñados para distintos alcances. GEOSAT-1, con 22 m de resolución fue lanzado en 2009 para cubrir la demanda de datos para agricultura de forma global y GEOSAT-2, con 0,75 m de resolución, fue lanzado en 2014 para proveer datos de muy alta resolución casi en tiempo real. Con gran capacidad de adquisición, más de 70 millones de kilómetros cuadrados hasta hoy, ha sido capaz de completar grandes coberturas globales para proyectos españoles, europeos e internacionales.

Con el paso de los años la combinación de instrumentos más precisos y órbitas más bajas han hecho posible la mejora en la resolución espacial de las imágenes adquiridas. No cabe duda de que este proceso de mejora de la resolución es largo y costoso desde el punto de vista económico, pero no es el único método de mejora, ya que esta también puede ser abordada mediante la utilización de métodos numéricos y el desarrollo de otras propiedades de las imágenes satélite, entre ellas, las técnicas de superresolución.

El principal objetivo de la superresolución es obtener una imagen de mayor resolución a partir de una imagen con una resolución menor. Así pues, después de una primera revisión del estado del arte, GEOSAT se basó únicamente en imágenes

RGB, al igual que la mayoría de los modelos encontrados, para desarrollar su primer algoritmo, como si de una representación fotográfica se tratase. Al centrarse exclusivamente en este tipo de imágenes RGB se observó la pérdida de datos físicos y la limitación de sus aplicaciones, por lo que se planteó el desarrollo de otro algoritmo que mejorase la calidad de las bandas multiespectrales de GEOSAT-2, y a su vez conservase sus características físicas. Para cerciorarse de que esas características físicas se mantienen una vez aplicado el algoritmo, se valora el impacto en la calidad geométrica y radiométrica de las mismas, enviando las imágenes al equipo de control y evaluación de datos de Copernicus (CQC) para su valoración. Este trabajo describe los algoritmos utilizados sobre imágenes multiespectrales GEOSAT-2 y detalla los resultados obtenidos de una serie de validaciones sobre los sets de imágenes de prueba.

2. Materiales y métodos

En las siguientes subsecciones se detallan los materiales utilizados, así como la descripción de los algoritmos para la generación de las imágenes multiespectrales GEOSAT-2 en superresolución.

2.1. Satélites e imágenes utilizadas

Para el entrenamiento y valoración del modelo de superresolución se han utilizado imágenes del satélite Kompsat-3A, mientras que para su validación se han utilizado imágenes de los satélites GEOSAT-2 y Sentinel 2, cuyas principales características se exponen a continuación:

2.1.1. Kompsat-3A

Kompsat-3A es un satélite surcoreano operado por SI Imaging Services. Al igual que GEOSAT-2, se trata de una plataforma ágil que opera entre -45° y 45° en movimiento transversal y posee una cámara *push-broom* de muy alta resolución con 5 canales espectrales (1 pancromático y 4 multiespectrales). Tiene una resolución espacial GSD (*Ground Sample Data*) de hasta 0,5 metros en su banda pancromática y 2 metros en las multiespectrales (Tabla 1), que es la resolución que se quiere alcanzar, e incorpora un sensor óptico AEISS-A (*Advanced Earth Imaging Sensor System*) que

Tabla 1. Komsat 3-A: Descripción de las bandas. Rangos espectrales sensor óptico AEISS-A.

Banda	Mínima longitud de onda (nm)	Máxima longitud de onda (nm)	GSD (m)
Pancromática	450	900	0,5
Azul	450	520	2
Verde	520	600	2
Roja	630	690	2
NIR (Infrarrojo cercano)	760	900	2

trabaja en los rangos espectrales que se muestran en la Tabla 1.

2.1.2. GEOSAT-2

GEOSAT-2 es un satélite óptico, de muy alta resolución y capaz de proporcionar imágenes multispectrales (MS) de 4 bandas y *pan-sharpened* (PAN), a 0,75 metros de resolución (GSD), Tabla 2.

Está diseñado como una plataforma ágil capaz de adquirir imágenes de gran precisión con hasta 45° fuera de nadir, principalmente para situaciones de emergencias. Lleva a bordo una cámara *push-broom* de muy alta resolución con 5 canales espectrales (1 pancromático y 4 multispectrales). Es operado en una órbita heliosíncrona con una altitud media de 620 km, con LTAN (*Local Time of Ascending Node*) de 10 h 30'. Tiene una revisita media de dos días en latitudes medias.

El sensor de tipo óptico (HIRAIS/EOS-D) trabaja dentro de los rangos espectrales del visible que se muestran en la Tabla 2.

La franja de adquisición es de 12 km y es capaz de adquirir aproximadamente 1400 km a lo largo de la dirección del movimiento por adquisición, con una capacidad máxima del sistema de unos 200 000 km² por día. La nomenclatura de los ficheros que define los productos es estándar y está preparada para que cualquier usuario pueda reconocer con qué producto y en qué nivel de

procesado están los datos con los que está trabajando. El convenio de nomenclatura adoptado es el siguiente:

```
<Mision>_<TipoProducto>_<NivelProducto>_
<Libre>_<FechaHoraComienzo>_
<FechaHoraFinal>_<Satelite>_<NoOrbita>_
<CRC>.
```

Se pone de ejemplo el producto de una de las imágenes utilizadas:

```
DE2_PM4_LID_000000_20210321T065823_20
210321T065825_DE2_36597_60DA.tif
```

“Geosat-2_Bundle_Orto con resolución mejorada_libre_21 de marzo de 2021 6:58:23_21 de marzo de 2021 6:58:25_Geosat-2_órbita 36597_alfamumérico aleatorio”

Estas imágenes se ofrecen normalmente en formato TIFF, junto con el fichero de metadatos de cada imagen DIMAP, versión 1.1 (.dim), que contiene datos necesarios para la posterior valoración de la calidad de las imágenes. Se muestran en archivos HTML (.html) como referencia. Toda la documentación de esta versión se puede consultar en “The DIMAP Format” (intelligence-airbusds.com).

Nos centramos en el producto *Bundle* (PM4), formado por una imagen pancromática, a 1 metro de resolución GSD, y otra imagen multispectral compuesta por cuatro bandas que cubren el espectro radiométrico en el rango visible de Azul (B), Verde (G), Rojo (R), y el

Tabla 2. GEOSAT-2: Descripción de las bandas. Rangos espectrales sensor óptico HIRAISS/EOS-D.

Banda	Mínima longitud de onda (nm)	Máxima longitud de onda (nm)	GSD (m)
Pancromática	560	900	0,75
Azul	466	525	4
Verde	532	599	4
Roja	640	697	4
NIR (Infrarrojo cercano)	770	892	4

Infrarrojo Cercano (NIR), con una resolución de 4 metros GSD.

Los niveles de procesamiento de los productos de GEOSAT-2 son:

- Nivel L1B: Producto calibrado y corregido radiométricamente. La información geométrica está contenida en un polinomio racional.
- Nivel L1C: Producto calibrado, corregido radiométricamente y ortorrectificado.
- Nivel L1S: Producto L1B con resolución mejorada.
- Nivel L1D: Producto L1C con resolución mejorada.

2.1.3. Sentinel 2

Los satélites Sentinel son una flota diseñada específicamente para proporcionar los datos e imágenes de los que se nutre el programa Copernicus, de la Comisión Europea.

Sentinel 2 llevan una cámara multispectral de alta resolución, con 13 bandas espectrales descritas en la Tabla 3, que aportan una nueva perspectiva de la superficie terrestre y la vegetación.

La combinación de la alta resolución y las nuevas capacidades espectrales, así como un campo de visión que abarca 290 kilómetros de anchura y sobrevuelos frecuentes, permite registrar una

cantidad de datos importantes para diversos estudios derivados de las adquisiciones.

La misión se basa en una constelación de dos satélites idénticos en la misma órbita, separados por 180 grados, para lograr una cobertura y una descarga de datos óptimos. Cada cinco días los satélites cubren todas las superficies terrestres, grandes islas y aguas costeras.

2.2. Algoritmos

El propósito principal de la superresolución es obtener una imagen de alta resolución (HR) partiendo de una imagen de menor resolución (LR), utilizando para ello, el cambio de resolución, el enfoque y la eliminación de ruido. Nos encontramos aquí ante lo que se conoce como un problema “mal planteado”, ya que las imágenes de baja resolución siempre contarán con información insuficiente para alcanzar una solución total. Actualmente, las últimas técnicas de aprendizaje automático nos proporcionan soluciones más que aceptables a este problema.

2.2.1. Planteamiento del problema

La mayoría de los modelos de inteligencia artificial para la superresolución están enfocados sobre imágenes en formato RGB. Estas ofrecen una representación fotográfica de la imagen captada por un satélite, dando una importancia relativa a la información radiométrica captada por los distintos sensores a bordo. Sin embargo, para el caso que nos ocupa, el objetivo

Tabla 3. Descripción de las bandas Sentinel-2. Las bandas visualizadas en negrita son las utilizadas para el análisis comparativa.

Número de banda (correspondencia con GEOSAT-2)	Mínima longitud de onda (nm)	Máxima longitud de onda (nm)	GSD (m)
B1	412	456	60
B2 (BLUE)	456	533	10
B3 (GREEN)	538	583	10
B4 (RED)	646	684	10
B5	695	714	20
B6	731	749	60
B7	769	797	20
B8 (NIR)	760	907	10
B8A	837	881	20
B9	932	958	60
B10	1337	1412	60
B11	1539	1682	20
B12	2078	2320	20

marcado es precisamente ser capaces de obtener un nuevo producto para las imágenes de la misión GEOSAT-2, que mantenga la radiometría original y mejore la geometría, aumentando la resolución final en un factor $\times 2$. Concretamente a partir del producto *Bundle PM4 LIC* (apartado 2.1.2).

Para el caso que nos ocupa, una imagen LR, y , puede definirse mediante la ecuación 1.

$$y = D(x; \delta) \quad (1)$$

donde D representa una función de degradación entre la imagen LR, y y la imagen HR, x , afectada por los parámetros propios del proceso de degradación δ (p.ej. el factor de escalado, el desenfoco o el ruido, entre otros). Generalmente, este proceso de degradación es desconocido pues solamente se proporcionan imágenes LR. La imagen HR puede definirse entonces como:

$$x = \mathcal{F}(y; \theta) \quad (2)$$

Donde \mathcal{F} es el modelo de superresolución y θ se refiere a los parámetros de \mathcal{F} . En la mayoría de los casos, \mathcal{F} únicamente construye una aproximación de la verdad terreno de la imagen HR.

2.2.2. Solución al problema de la superresolución

A primera vista, podríamos pensar en resolver la problemática anterior como una simple regresión lineal, por ejemplo, mediante interpolación bicúbica. Sin embargo, esta no resulta ser la estrategia más adecuada en este caso, ya que existe una relación no lineal entre las imágenes LR y HR. Hoy en día, las últimas técnicas de aprendizaje automático (ML) permiten soluciones que son más que aceptables para este problema (Raschka, 2016).

Podemos encontrar diferentes marcos que constituyen el actual estado del arte de la superresolución, como los modelos de aprendizaje profundo, tales como: *Enhanced Deep Super-Resolution Network* (Lim et al., 2017), *Residual Channel Attention Networks* (Zhang et al., 2018a), o *Residual Dense Network* (Zhang et al., 2018b), entre muchos otros. Para la consecución de nuestro objetivo hemos seguido el enfoque descrito por (Schulter et al., 2015) y (Huang et al., 2015) por su fácil implementación y sus óptimos resultados. El

marco de aprendizaje definido en este modelo está basado en la técnica de ML denominada *Random Forest*, o *árboles aleatorios*, a la que además hemos añadido la técnica de *XGBoost* (*Extreme Gradient Boosting*), por constituir una técnica que ofrece mejores resultados que otras técnicas computacionalmente más complejas, para conjuntos de datos heterogéneos (Gironés et al., 2017).

El modelo base para ambas técnicas, *Random Forest* y *XGBoost*, son los árboles de decisión. Estos son uno de los modelos más simples de clasificación que se conocen. Tienen una estructura jerárquica formada por ramas, nodos y hojas. Los nodos internos del árbol corresponden a las divisiones aplicadas para descomponer el dominio en regiones, y los nodos terminales asignan etiquetas de clase a las regiones que se consideran suficientemente pequeñas o uniformes. En cada nodo de un árbol de decisión se aplica una función de asignación para minimizar el error de clasificación. Los atributos se evalúan según la cantidad de información que aportan en la clasificación. Cuanta más entropía/información tiene un atributo, antes es evaluado. En comparación con los modelos de aprendizaje profundo los bosques aleatorios (*Random Forest*) tienen un tiempo de entrenamiento más corto con un resultado predictivo similar.

Los modelos de árboles aleatorios son un ejemplo exitoso de la técnica de combinación de modelos denominada *Bagging*, donde múltiples clasificadores del tipo de árboles de decisión o regresión son entrenados utilizando diferentes subconjuntos del conjunto de muestras de entrenamiento original (Harrell, 2001). La técnica de *Bagging* (acrónimo, en inglés, de *Bootstrap aggregating*) constituye una de las técnicas de combinación de modelos, junto con el *Boosting* y el *Stacking*, que pretenden mejorar el resultado final combinando los resultados de otros modelos más simples (Figura 1), con la esperanza de que este resultado final mitigue los errores de cada uno de estos modelos por separado, como, por ejemplo, el sobreajuste a los datos de entrenamiento inherente a los modelos de árboles de decisión simples.

Por otra parte, la idea detrás de la técnica de *Boosting*, utilizada en el algoritmo *XGBoost*, es generar múltiples modelos de predicción

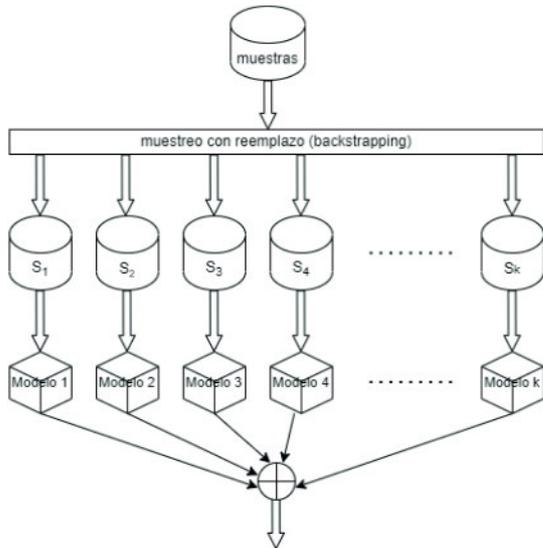


Figura 1. Diagrama de un clasificador combinado basado en Bagging.

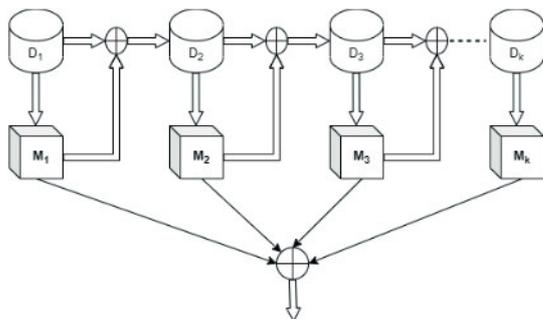


Figura 2. Diagrama de un clasificador combinado basado en Boosting.

“débiles” secuencialmente, y que cada uno de estos tome los resultados del modelo anterior, para generar un modelo más “fuerte”, con mejor

poder predictivo y mayor estabilidad en sus resultados, como se muestra en el diagrama de la figura 2.

2.3. Entrenamiento

2.3.1. Generación del conjunto de datos

Para la creación de los pares de imágenes se han utilizado imágenes satelitales de muy alta resolución. Concretamente, se han usado imágenes Kompsat-3A, tomadas en distintas zonas del mundo y en diferentes épocas del año, a 50 cm de resolución, con un nivel de procesado L1R, es decir corregidas las distorsiones radiométricas y del sensor, más sus RCPs (Coeficientes Polinómicos Racionales) asociados, con el fin de obtener un conjunto de muestras suficientemente representativo.

En nuestro caso, el modelo construido será entrenado inicialmente con pares de imágenes LR y HR (Ecuación 3).

$$P_i = (L_i, H_i) \quad (3)$$

donde $L_i \in \mathcal{R}$ es una imagen muestreada a partir de la imagen LR inicialmente remuestreada mediante interpolación bicúbica y desenfocada mediante un modelo gaussiano, y $H_i \in \mathcal{R}$ es la imagen correspondiente muestreada a partir de la imagen HR original. (Figura 3).

Siendo aquí el objetivo de la superresolución encontrar una función de mapeo capaz de minimizar el error cuadrático medio (MSE, del inglés *Mean Squared Error*) en los pares $L_i - H_i$:

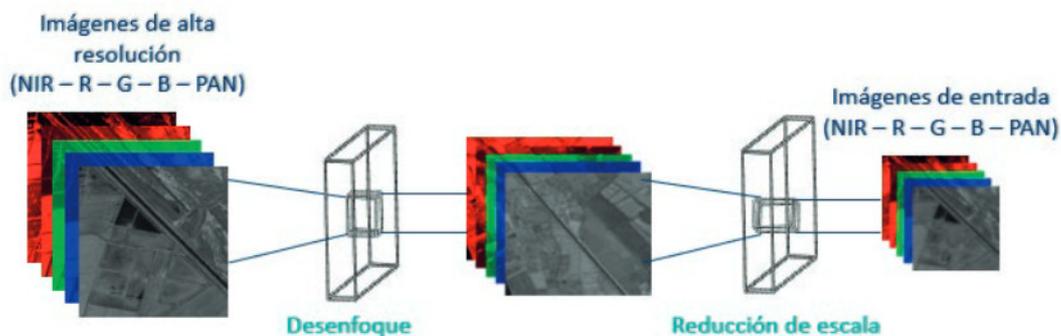


Figura 3. Construcción del conjunto de datos a partir de imágenes de muy alta resolución.

$$MSE = \frac{1}{N} \sum_{i=0}^{n-1} \|F(L_i) - H_i\|^2 \quad (4)$$

2.3.2. Entrenamiento del modelo

Para realizar el entrenamiento de los modelos *Random Forest* y de *XGBoost*, y conseguir la generalización del modelo final de superresolución a cualquier satélite, se han utilizado valores de radiancia en lo alto de la atmósfera (TOA), ya que no todos los satélites aplican una corrección atmosférica a sus imágenes. De esta forma, conseguimos una cierta armonización en los datos de muestra.

Una vez creados los pares de imágenes HR-LR, construimos un algoritmo que aplique inversamente los modelos anteriores para la inferencia de una imagen HR a partir de un producto LR siendo la variable dependiente cada uno de los píxeles de

las 5 bandas de las imágenes originales y la independiente cada uno de los píxeles de las 5 bandas de las imágenes degradadas.

Se entrenan los modelos específicos para cada una de las bandas del espectro consideradas, en nuestro caso: rojo, verde, azul e infrarrojo cercano, con el fin de conservar los valores radiométricos de las imágenes (Figura 4). Una vez entrenados los modelos se aplican sobre las imágenes de baja resolución para obtener las imágenes en alta resolución (Figura 5).

Al llevar a cabo este proceso nos encontramos con un ligero efecto de tablero de ajedrez en los resultados iniciales, que se soluciona considerando un solapamiento entre cada una de las porciones de la imagen de entrada utilizadas en cada iteración del algoritmo.

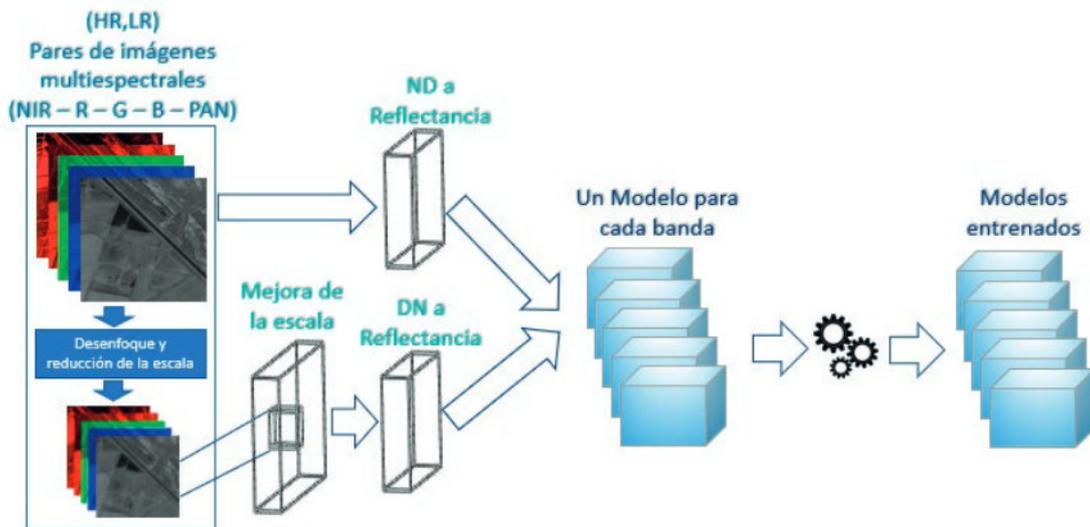


Figura 4. Entrenamiento de los modelos a partir de pares de imágenes HR-LR

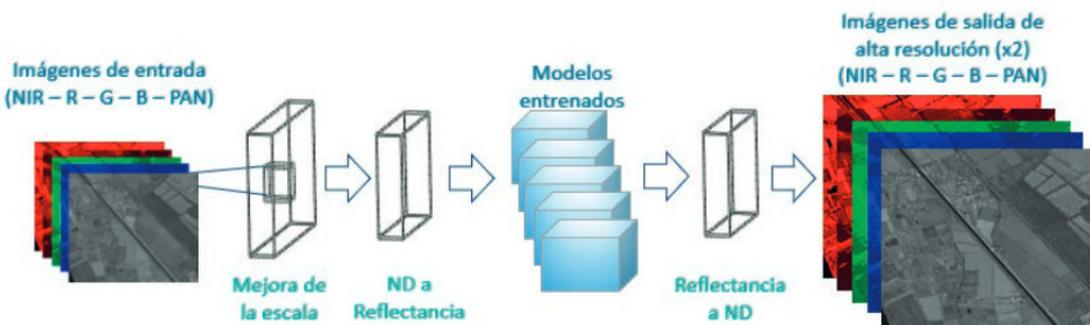


Figura 5. Aplicación de los modelos sobre imágenes en LR para obtener una versión HR.

2.4. Elección del modelo

Para la elección del modelo se han utilizado las métricas del *Peak Signal-Noise Ratio* (PSNR) y el índice de similitud estructural (SSIM). Estos índices permiten comparar distintos modelos y seleccionar aquel que presente mejores prestaciones en la reconstrucción de la imagen HR.

Mientras que el SSIM nos da un valor porcentual de la degradación de una imagen midiendo la similitud estructural entre dos imágenes, el PSNR obtiene un valor absoluto que mide la calidad en la reconstrucción de una imagen en procesos de comprensión.

3. Valoración de los productos de superresolución

El objetivo de este análisis es asegurar la calidad de los productos GEOSAT-2 mejorados con respecto a los productos originales derivados de la cadena de procesado. Para ello, se realiza una comparativa visual en diferentes zonas, urbana, rural, agrícola, desierto y masas de agua. Los aspectos que han sido considerados son:

- Confirmación de que no hay artefactos introducidos por el algoritmo de cálculo.
- Valoración de la definición de las imágenes de superresolución, con especial énfasis en la capacidad del algoritmo SR para mejorar el reconocimiento de detalles más pequeños.
- Cualquier otro problema de calidad detectable como problemas geométricos.
- Este análisis se hace por parejas. En la tabla 4 se muestran los productos de GEOSAT-2 utilizados para su valoración. Se detalla para cada producto su localización, nivel de procesado, ángulo de adquisición de la imagen en grados (Roll) y el tamaño del píxel en metros.

3.1. Valoración general de la calidad de las imágenes multispectrales

El objetivo de esta área es evaluar la calidad de la imagen general de los productos GEOSAT-2 *Bundle SR LID* descritos en la tabla 4, poniendo especial atención en la identificación de cualquier problema geométrico (bandas desalineadas), la presencia de artefactos radiométricos

(p. ej., bandas, rayas), la detección de problemas relevantes relacionados con la precisión de la geolocalización o la existencia de píxeles sin dato, detectables a través de una inspección visual. El nivel de procesado LID se corresponde con productos ortorrectificados a los que se les ha aplicado el algoritmo de superresolución.

3.2. Valoración radiométrica

La valoración radiométrica se realiza para valorar el rendimiento radiométrico de los datos GEOSAT-2 *Bundle SR LID*. El análisis tiene como objetivo analizar los datos, tanto en términos absolutos (teniendo en cuenta solo la radiometría del producto bajo valoración), como relativos (utilizando datos de referencia adicionales para realizar una comparación radiométrica). Para ello, se utilizan los datos de GEOSAT-2 adquiridos sobre el sitio cal/val de Libia4. El sitio cal/val está ubicado en el desierto del Sahara (<https://calval.cr.usgs.gov/apps/libya-4> - Centro: latitud 28,55°N, longitud 23,39°E; elevación media: 118 m).

Es importante señalar que, el sitio de Libia4, tiene un alto grado de uniformidad del paisaje y no está instrumentado, es decir, equipado con una estación de medición terrestre o atmosférica. Por lo tanto, durante el análisis, las influencias radiométricas, topográficas y atmosféricas se tratan como el componente de ruido.

En cuanto al procedimiento, se realizan dos comprobaciones principales durante la valoración radiométrica:

- Análisis de perfiles espectrales, para detectar cualquier anomalía radiométrica presente en dos perfiles espectrales (vertical y horizontal), obtenidos a partir de dos transectos proyectados sobre toda la imagen.
- Intercomparación con un sensor de referencia

3.2.1. Análisis de los perfiles espectrales

El objetivo de este análisis es detectar cualquier anomalía radiométrica presente en dos perfiles espectrales (vertical y horizontal), obtenidos a partir de dos transectos proyectados sobre toda la imagen.

Los perfiles espectrales se obtienen para todas las bandas del producto bajo análisis (RGB y NIR),

Tabla 4. Imágenes GEOSAT-2 utilizadas para la valoración general de la calidad de las imágenes multispectrales.

Nombre del producto	Localización	Nivel de Procesado	Roll (°)	Tamaño de Pixel (m)
DE2_PM4_L1D_000000_20210321T065823_20210321T065825_DE2_36597_60DA.zip	Dubái	L1D	3,5	PAN: 0,4
DE2_PM4_L1C_000000_20210321T065823_20210321T065825_DE2_36597_60DA.zip		L1C		MS: 1,6
DE2_PM4_L1D_000000_20161107T013821_20161107T013826_DE2_12927_DE02.zip	Japón	L1D	2,5	PAN: 1,0
DE2_PM4_L1C_000000_20161107T013821_20161107T013826_DE2_12927_DE02.zip		L1C		MS: 4,0
DE2_PM4_L1D_000000_20181019T022017_20181019T022019_DE2_23478_5ACA.zip	Corea	L1D	1,9	PAN: 0,4
DE2_PM4_L1C_000000_20181019T022017_20181019T022019_DE2_23478_5ACA.zip		L1C		MS: 1,6
DE2_PM4_L1D_000000_20210226T090433_20210226T090436_DE2_36257_0A92.zip	Libya_L1D_1	L1D	0,3	PAN: 1,0
DE2_PM4_L1S_000000_20210226T090433_20210226T090436_DE2_36257_0A92.zip	Libya_L1S_1	L1S	0,3	MS: 1,6
DE2_PM4_L1B_000000_20210226T090433_20210226T090436_DE2_36257_0A92.zip	Libya_L1B_1	L1B	0,3	PAN: 0,5
DE2_PM4_L1C_000000_20210226T090433_20210226T090436_DE2_36257_0A92.zip	Libya_L1C_1	L1C	0,3	MS: 2,0
DE2_PM4_L1D_000000_20210226T090435_20210226T090438_DE2_36257_54A4.zip	Libya_L1D_2	L1D	0,3	PAN: 1,0
DE2_PM4_L1S_000000_20210226T090435_20210226T090438_DE2_36257_54A4.zip	Libya_L1S_2	L1S	0,3	MS: 4,0
DE2_PM4_L1B_000000_20210226T090435_20210226T090438_DE2_36257_54A4.zip	Libya_L1B_2	L1B	0,3	PAN: 0,5
DE2_PM4_L1C_000000_20210226T090435_20210226T090438_DE2_36257_54A4.zip	Libya_L1C_2	L1C	0,3	MS: 2,0
DE2_PM4_L1D_000000_20211106T065020_20211106T065023_DE2_40010_1ECA.zip	Omán_1	L1D	3,6	PAN: 1,0
DE2_PM4_L1C_000000_20211106T065020_20211106T065023_DE2_40010_1ECA.zip		L1C		MS: 4,0
DE2_PM4_L1D_000000_20211106T065022_20211106T065025_DE2_40010_5D84.zip	Omán_2	L1D	3,6	PAN: 0,4
DE2_PM4_L1C_000000_20211106T065022_20211106T065025_DE2_40010_5D84.zip		L1C		MS: 1,6
DE2_PM4_L1D_000000_20211111T081224_20211111T081227_DE2_40085_F9B2.zip	Turquía	L1D	-1,7	PAN: 1,0
DE2_PM4_L1C_000000_20211111T081224_20211111T081227_DE2_40085_F9B2.zip		L1C		MS: 1,6

después de realizar la calibración radiométrica de la imagen desde Niveles Digitales (ND) hasta radiancia en lo alto de la atmósfera (TOA). La calibración se realiza utilizando la información proporcionada en los metadatos del producto.

3.2.2. Intercomparación con un sensor de referencia

El objetivo de este análisis es comparar la radiometría del producto bajo análisis, con la radiometría de un producto de referencia Sentinel 2, que se supone tiene una alta precisión radiométrica.

Para el análisis actual, se utilizó una imagen Sentinel 2 (S2) B Level-1C (L1C) como referencia para fines de intercomparación. Los datos S2 L1C son productos ortorrectificados (proyección UTM/WGS84) cuyos píxeles proporcionan medidas radiométricas en términos de reflectancia TOA, por lo que no están corregidos atmosféricamente. Estos productos se vuelven a muestrear con un tamaño de píxel constante de 10, 20 y 60 m según la resolución nativa (es decir, GSD) de las diferentes bandas espectrales. Estas características permiten realizar una comparación con los datos

Tabla 5. Fechas de adquisición, ángulos de elevación y acimut solar y cobertura de nubes de las imágenes de GEOSAT-2 e imagen de referencia Sentinel-2 utilizadas en la valoración radiométrica.

Producto	Fecha de adquisición	Elevación solar (grados)	Acimut solar (grados)	Cobertura nubes (%)
Libya_L1D_MS_1 Libya_L1D_PAN_1 Libya_L1B_MS_1	2021-02-26	46.3837	145.480258341	0
Libya_L1B_PAN_1 Libya_L1C_MS_1 Libya_L1C_PAN_1	09:04:33			
Libya_L1S_MS_1 Libya_L1S_PAN_1				
S2B_MSIL1C_20210226T085829_N0209_R007_T34RGS_20210226T100927	2021-02-26	47.604891	147.537353	0
	08:58:29			

de prueba GEOSAT-2 *Bundle SR L1D*, que tampoco están corregidos atmosféricamente.

Aunque las imágenes que se comparan de GEOSAT-2 y S2 se adquirieron el mismo día aproximadamente a la misma hora y todas las bandas MS de los productos GEOSAT-2 tienen sus correspondientes bandas MS de S2 adquiridas con un GSD de 10 m, existen factores que pueden causar ligeras diferencias entre las adquisiciones de los datos a valorar de GEOSAT-2 y el sensor de referencia (S2), como son el ángulo de adquisición o la condición atmosférica debido a las distintas fechas de captura. Las diferencias más importantes entre los productos utilizados se muestran en la tabla 5: el intervalo de longitud de onda, el tamaño de píxel/resolución espacial, el ángulo de elevación del sol y el ángulo de azimut del sol.

Se realiza la comparación de los productos en valores de reflectancias en lo alto de la atmósfera. Se calculan las estadísticas para todos los productos de GEOSAT-2, media, desviación estándar, percentil 5 y 95 que delimiten el intervalo de confianza. También para la imagen de Sentinel 2. Después se calcula el nivel de ruido de la señal, SNR (*Signal to Noise Ratio*), y se aplica el criterio de Rose para interpretar los resultados, es decir, que si SNR es mayor de 5, se considerará no significativo.

El sensor de referencia (S2) no contiene ninguna banda pancromática. Por lo tanto, la intercomparación entre los datos de GEOSAT-2 y S2 no se puede realizar para la banda PAN. Sin embargo, las estadísticas antes mencionadas también se calcularon para estas bandas para comparar los diferentes resultados obtenidos en los diferentes niveles de procesamiento

4. Resultados

4.1. Elección del método

En la Tabla 6 se comparan los resultados obtenidos para distintas parametrizaciones de los modelos entrenados anteriormente, tomando como referencia una interpolación bicúbica. En concreto, se han comparado los modelos obtenidos utilizando los algoritmos de *Random Forest* y de *XGBoost*, considerando distintos valores del número de estimadores: 50, 100 y 200 (Tabla 6).

Tabla 6. Media de los valores de PSNR y SSIM para cada parametrización del modelo comparado con interpolación bicúbica.

Modelo	Número estimadores	PSNR	SSIM
Interpolación bicúbica	-	41,73	0,9700
<i>Random Forest</i>	50	43,15	0,9789
	100	43,15	0,9790
	200	43,15	0,9790
<i>XGBoost</i>	50	43,31	0,9803
	100	43,31	0,9803
	200	43,29	0,9803

Se observa que los mejores resultados, resaltados en la tabla 6 en negrita, con un PSNR de 43,31 y un SSIM del 98,03%, se obtienen utilizando el algoritmo de *XGBoost* con 50 estimadores. Así pues, para la siguiente parte de este trabajo, se aplicará este modelo de SR, con esta misma configuración.

4.2. Valoración general de la calidad de las imágenes multispectrales

Con respecto a la evaluación general de la calidad de la imagen, todo el conjunto de datos de prueba GEOSAT-2 *Bundle SR L1D* se considera de buena calidad general y no se detectan problemas relevantes. El análisis comparativo entre los

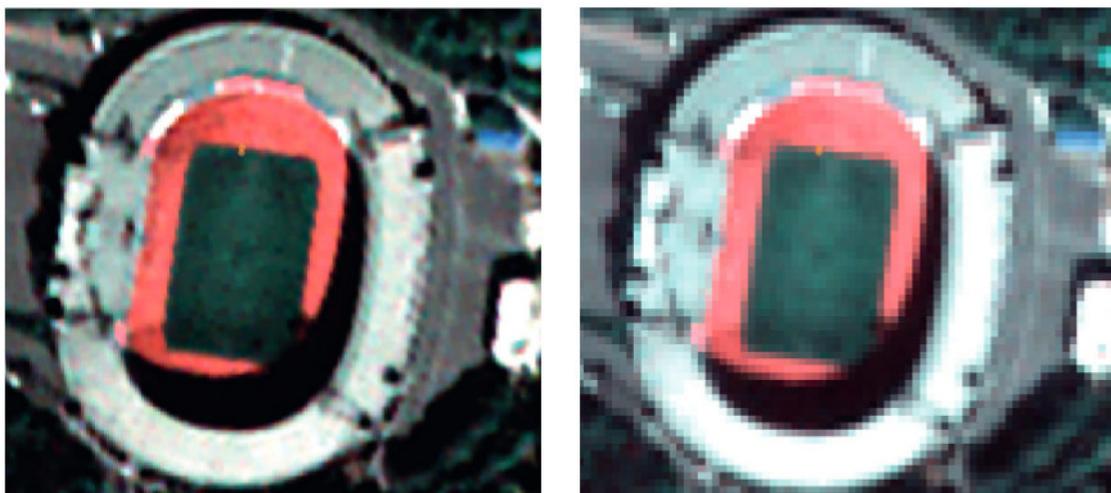


Figura 6. Análisis visual comparativo entre Corea_Bundle MS4-L1D (izquierda) y Corea_Bundle MS4-L1C (derecha). El desplazamiento espacial entre los dos productos es de 1,8 metros Escala: 1:2000.

productos *Bundle SR L1D* y los productos *Bundle LIC*, que se muestra en la figura 6 y figura 7, no muestra problemas radiométricos que pudieran estar conectados con el algoritmo SR. Desde un punto de vista geométrico, se encuentra un ligero desplazamiento espacial de unos pocos metros entre los dos productos. Este cambio es más evidente en las imágenes PAN que en las de MS, y en algunas escenas/áreas que en otras.

Los resultados relacionados con la valoración de la nitidez y la resolución espacial de la imagen real manifiestan que, aunque los productos *Bundle SR*

L1D pueden clasificarse como borrosos, esto no impide el reconocimiento de los detalles presentes en la escena. De hecho, en los productos *Bundle SR L1D* los objetivos se pueden resolver con un mayor nivel de detalle con respecto a los productos *Bundle LIC*.

4.3. Valoración radiométrica

Con respecto a la evaluación radiométrica, se encuentra que los datos del GEOSAT-2 que se analizaron en el sitio de prueba de Libia4 son de buena calidad.

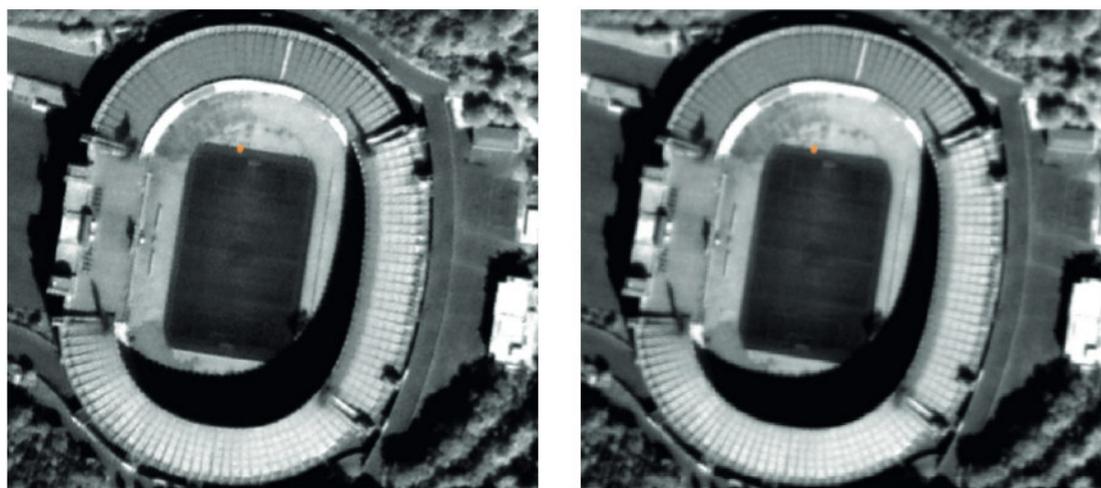


Figura 7. Análisis visual comparativo entre Corea_Bundle PAN-L1D (izquierda) y Corea_Bundle PAN_L1C (derecha). El desplazamiento espacial entre los dos productos es de 1,2 metros Escala: 1:2000.

4.3.1. Análisis de los perfiles espectrales

El análisis no presenta ninguna anomalía radiométrica presente en los perfiles espectrales vertical y horizontal. De hecho, no se han observado derivas radiométricas. Los picos se pueden asociar al patrón de suelo presente en las imágenes (por ejemplo, crestas de dunas). Los resultados se muestran en la figura 8 y la figura 9 (PRISM CQC Team, 2022).

4.3.2. Intercomparación con un sensor de referencia

Los resultados relacionados con la intercomparación entre las bandas MS del sensor de referencia (S2) y las bandas MS de los datos GEOSAT-2 *Bundle SR LID* y los resultados relacionados con la evaluación radiométrica realizada en las bandas MS de los productos *Bundle SR*

LIS, *Bundle LIC* y *Bundle LIB* se muestran en la tabla 7.

Como se puede observar, existe una fuerte concordancia tanto entre todos los productos GEOSAT-2, como entre los productos GEOSAT-2 y el sensor de referencia S2. De hecho, las diferencias entre los productos GEOSAT-2 son insignificantes (en las tablas, los resultados se aproximaron al cuarto dígito decimal para mostrar algunas diferencias irrelevantes). La comparación con los datos de S2 mostró diferencias muy moderadas, es decir, máximo de 1,5% en la banda verde, del orden de 1% en la banda azul, inferior al 1% en las bandas roja e infrarroja cercana.

Los resultados relacionados con la evaluación radiométrica realizada sobre la banda PAN de los datos *Bundle SR LID*, *Bundle SR LIS*, *Bundle LIC* y *Bundle LIB* se reportan en la tabla 8.

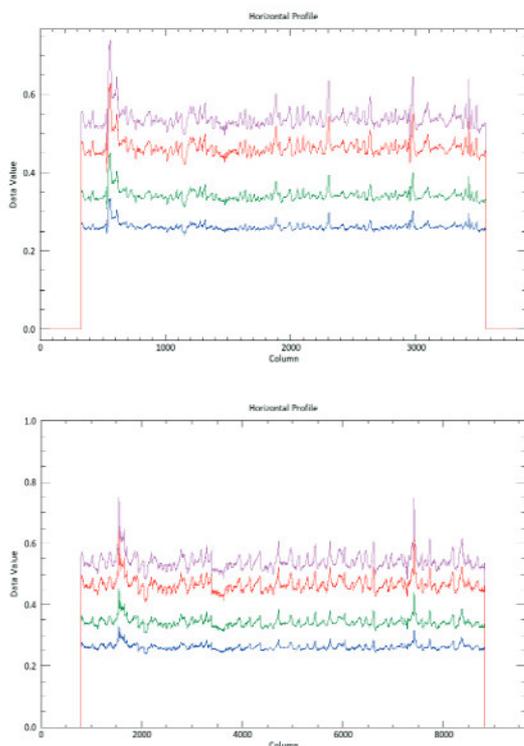


Figura 8. Perfiles horizontales de las bandas multispectrales de la imagen *Bundle* de GEOSAT-2. En la parte inferior *LID* (SR) y en la superior *LIC*. Leyenda: línea azul: banda azul; línea verde: banda verde; línea roja: banda roja; línea morada: banda NIR. Los datos se expresan en términos de valores [-] de reflectancia TOA.

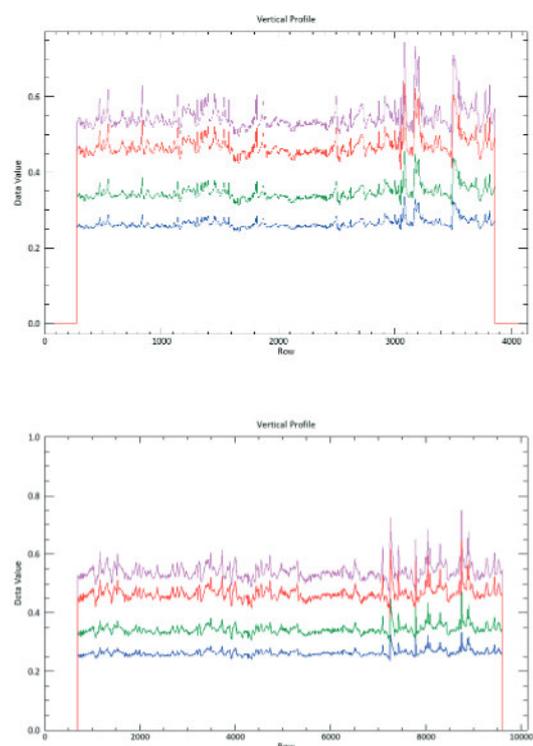


Figura 9. Perfiles verticales de las bandas multispectrales de la imagen *Bundle* de GEOSAT-2. En la parte inferior *LID* (SR) y en la superior *LIC*. Leyenda: línea azul: banda azul; línea verde: banda verde; línea roja: banda roja; línea morada: banda NIR. Los datos se expresan en términos de valores [-] de reflectancia TOA.

Tabla 7. Estadísticas de las bandas MS de los productos Sentinel 2 y GEOSAT-2 utilizados en la valoración radiométrica.

Producto	Banda	Media	Desviación standard	Percentil 5	Percentil 95	SNR
S2B MSIL1C	Azul	0.2524	0.0090	0.2413	0.2686	28
	Verde	0.3288	0.0138	0.3109	0.3527	24
	Roja	0.4643	0.0211	0.4364	0.4993	22
	Infrarroja	0.5349	0.0247	0.5043	0.5774	22
Bundle SR L1D	Azul	0.2630	0.0103	0.2500	0.2803	26
	Verde	0.3434	0.0158	0.3228	0.3685	22
	Roja	0.4658	0.0232	0.4358	0.5024	20
	Infrarroja	0.5404	0.0274	0.5071	0.5861	20
Bundle SR L1S	Azul	0.2630	0.0103	0.2499	0.2802	25
	Verde	0.3434	0.0158	0.3225	0.3683	22
	Roja	0.4658	0.0232	0.4359	0.5020	20
	Infrarroja	0.5104	0.0274	0.5063	0.5856	20
Bundle L1C	Azul	0.2630	0.0101	0.2506	0.2804	26
	Verde	0.3434	0.0155	0.3237	0.3695	22
	Roja	0.4657	0.0228	0.4361	0.5037	20
	Infrarroja	0.5404	0.0269	0.5077	0.5852	20
Bundle L1B	Azul	0.2630	0.0102	0.2505	0.2803	26
	Verde	0.3434	0.0156	0.3234	0.3696	22
	Roja	0.4657	0.0228	0.4353	0.5026	20
	Infrarroja	0.5404	0.0269	0.5080	0.5846	20

Tabla 8. Estadísticas de la banda PAN de los productos GEOSAT-2 utilizados en la valoración radiométrica.

Producto	Banda	Media	Desviación standard	Percentil 5	Percentil 95	SNR
Bundle SR L1D	PAN	0.3972	0.0196	0.3717	0.4274	20
Bundle SR L1S	PAN	0.3973	0.0196	0.3720	0.4286	20
Bundle L1C	PAN	0.3977	0.0193	0.3736	0.4290	21
Bundle L1B	PAN	0.3977	0.0194	0.3737	0.4289	21

También para las bandas PAN, las diferencias entre los diferentes niveles de procesamiento del GEOSAT-2 pueden considerarse insignificantes.

Aunque existen diferencias entre la resolución espacial/tamaño de píxel de los sensores utilizados en esta comparación, no se espera que dichas diferencias produzcan un impacto relevante al analizar los resultados porque estos últimos se expresan en términos de descriptores estadísticos calculados sobre la misma área.

5. Conclusiones

La solución propuesta arroja resultados más que satisfactorios en cuanto a la calidad final obtenida con una mayor resolución de las imágenes finales. Este modelo proporciona una importante mejora en la calidad de resolución de las imágenes *bundle* de GEOSAT-2, incrementando el valor de los datos su uso en el sector agrícola, en temas de agricultura de precisión. Esta mejora de la resolución resulta de gran importancia en la

detección de ciertas estructuras, así como, en el cálculo de índices de vegetación de mayor calidad espacial. Buscando seguir mejorando la capacidad de detección, manteniendo a su vez los valores radiométricos, queda pendiente el estudio de la distorsión de los valores radiométricos originales si se aplica un factor mayor ($\times 4$).

Entre esas actividades futuras se plantea principalmente la mejora del modelo en dos aspectos. En primer lugar, conseguir una mejora en los tiempos de inferencia del modelo para la entrada de imágenes de gran tamaño. Esto, en parte ya se ha conseguido con la utilización del algoritmo *XGBoost*, ya que este algoritmo de árboles aleatorios permite utilizar las posibilidades de paralelización que ofrecen las unidades de procesamiento gráfico (GPU) actuales.

Adicionalmente, se plantea considerar una nueva estructura del modelo que actúe sobre todas las bandas a la vez. Lo cual, junto con la utilización de un mayor número de datos de entrenamiento, nos llevará, previsiblemente, a una mayor

precisión del modelo al considerarse un mayor número de variables independientes. Además, se obtendrá una mayor velocidad de inferencia, pues solamente tendría que aplicarse un modelo global para el conjunto de las bandas radiométricas que componen la imagen de entrada.

En segundo lugar, se plantea la aplicación de nuevos modelos de aprendizaje profundo, mucho más complejos que los actualmente aplicados, y con más opciones de parametrización, que previsiblemente, podrían desembocar en una mejora de los índices de evaluación anteriormente mostrados. No obstante, se tendrá en cuenta que esto no siempre es así en este tipo de modelos, dependiendo enormemente de la configuración de la red neuronal intrínseca y de la correcta parametrización de esta.

Referencias

- Gironés, J., Casas, J., Minguillón, J., Caihuelas, R. 2017. *Minería de datos – modelos y algoritmos*. Barcelona: UOC.
- Harrell, F. 2001. *Regression Modeling Strategies*. Springer Series in Statistics. New York: Springer. <https://doi.org/10.1007/978-1-4757-3462-1>
- Huang, J., Siu, W. 2015. Practical application of random forests for super-resolution imaging. En: *IEEE International Symposium on Circuits and Systems*. Lisboa, Portugal, 24-27 Mayo. pp 2161–2164. <https://doi.org/10.1109/ISCAS.2015.7169108>
- Lim, B., Son, S., Kim, H., Nah, S., Lee, K.M. 2017. Enhanced Deep Residual Networks for Single Image Super-Resolution. En: *IEEE Conference on Computer Vision and Pattern Recognition Workshops*. Honolulu, HI, EE.UU., 21-26 Julio. pp 1132-1140. <https://doi.org/10.1109/CVPRW.2017.151>
- PRISM CQC Team. 2022. Copernicus Coordinated data Quality Control – GEOSAT-2 Test Data Set Analysis: Bundle Super Resolution. Copernicus Contributing Missions access support functions and platform. 8 Abril.
- Raschka, S. 2016. *Python Machine Learning*. Birmingham: Packt Publishing.
- Schulter, S., Leistner, C., Bischof, H. 2015. Fast and accurate image upscaling with super-resolution forests. En: *IEEE Conference on Computer Vision and Pattern Recognition*. Boston, MA, EE.UU., 7-12 Junio. pp 3791–3799. <https://doi.org/10.1109/CVPR.2015.7299003>
- Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B., Fu, Y.R., 2018a. Image Super-Resolution Using Very Deep Residual Channel Attention Networks. En: *European Conference on Computer Vision*. Munich, Alemania, 8-14 Septiembre. pp 294-310. https://doi.org/10.1007/978-3-030-01234-2_18
- Zhang, Y., Tian, Y., Kong, Y., Zhong, B., Fu, Y.R., 2018b. Residual Dense Network for Image Super-Resolution. En: *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, UT, EE.UU., 18-23 Junio. pp 2472-2481. <https://doi.org/10.1109/CVPR.2018.00262>