



Fusión de imágenes satelitales para una alta resolución espacial y temporal del Lago Güija

Merging Satellite Images for High Spatial and Temporal Resolution of Lake Güija

DOI: <https://doi.org/10.51378/ilia.vi2.9654>

B. Carpio¹  E. Domínguez²  C. Vásquez³ 

^{1,2,3}Departamento de Electrónica e Informática, Universidad Centroamericana José Simeón Cañas, El Salvador.

E-mail: 00205619@uca.edu.sv, 00136319@uca.edu.sv y 00062619@uca.edu.sv

Fecha de recepción: 14 de mayo 2025

Fecha de aprobación: 25 de agosto de 2025

Resumen

El presente estudio tiene como objetivo evaluar y comparar técnicas de fusión de imágenes satelitales para mejorar la resolución espacial y temporal de datos destinados a estudios locales de alta precisión [1] [2]. La disponibilidad de información detallada a pequeña escala es esencial para el monitoreo y gestión de recursos naturales, especialmente en zonas con actividades productivas o impactos ambientales potenciales, como el Lago Güija. Este lago, ubicado en la frontera entre Guatemala y El Salvador, desemboca en el río Lempa, fuente principal para el abastecimiento de agua potable y la agricultura en la región [3].

Para este propósito, se utilizaron imágenes de los satélites Landsat y MODIS, seleccionados por sus capacidades complementarias de observación en diferentes resoluciones espaciales y temporales [4]. Se aplicaron dos enfoques de fusión: el método espacial Pansharpening, que combina datos pancromáticos de alta resolución con imágenes multiespectrales para optimizar el detalle espacial, y el modelo espacio-temporal STARFM (Spatio-Temporal Adaptive Reflectance Fusion Model), que integra información de Landsat y MODIS para obtener series de datos con mejor resolución tanto espacial como temporal [5] [6] [7].

Los resultados evidencian que ambas técnicas son viables para la generación de información útil en estudios de carácter local, siendo la metodología basada en Pansharpening con entrada MODIS la más adecuada por su balance entre calidad y viabilidad de implementación. El Lago Güija se presenta como un caso de estudio que ilustra el potencial de estas metodologías para el monitoreo continuo y preciso de eco-

sistemas acuáticos, contribuyendo así a la disponibilidad de datos confiables para la toma de decisiones.

Palabras clave – Fusión de imágenes, Pansharpening, STARFM, Landsat, MODIS.

Abstract

This study aims to evaluate and compare satellite image fusion techniques to improve the spatial and temporal resolution of data for high-precision local studies [1][2]. The availability of detailed, small-scale information is essential for the monitoring and management of natural resources, especially in areas with productive activities or potential environmental impacts, such as Lake Güija. This lake, located on the border between Guatemala and El Salvador, flows into the Lempa River, the main source of drinking water and agriculture in the region [3].

For this purpose, images from the Landsat and MODIS satellites were used, selected for their complementary observation capabilities at different spatial and temporal resolutions [4]. Two fusion approaches were applied: the spatial Pansharpening method, which combines high-resolution panchromatic data with multispectral imagery to optimize spatial detail, and the spatio-temporal STARFM (Spatio-Temporal Adaptive Reflectance Fusion Model), which integrates Landsat and MODIS datasets to obtain data sets with improved spatial and temporal resolution [5] [6] [7].

The results show that both techniques are viable for generating useful information in local studies, with the Pansharpening-based methodology with MODIS input being the most appropriate due to its balance between quality and implementation feasibility. Lake Güija is presented as a case study that illustrates the potential of these methodologies for

the continuous and accurate monitoring of aquatic ecosystems, thus contributing to the availability of reliable data for decision-making.

Keyword – Image fusion, Pansharpening, STARFM, Landsat, MODIS

I. INTRODUCCIÓN

En muchas sociedades, la explotación desmedida de los sistemas naturales se ha convertido en un fin en sí mismo, impulsado por multinacionales que anteponen el lucro a cualquier consideración ambiental. Este es el caso que comparten comunidades de Guatemala, Honduras y El Salvador, donde una multinacional de Canadá específicamente la empresa llamada Bluestone Resources con sede en Vancouver, propone una mina a cielo abierto en Cerro Blanco, Guatemala, donde afecta directamente ríos cercanos y al lago Güija que desemboca en el río Lempa [2].

Por medio de un monitoreo constante con satélites disponibles es posible documentar el estado y la situación en la que se encuentra el Lago Güija a través de un algoritmo que permita identificar los metales pesados por medio de imágenes satelitales. Sin embargo, en la actualidad no es posible disponer de un producto de alta resolución y al mismo tiempo diario, que es lo que se requiere para un sistema de alerta temprana. Por lo anterior, el problema a resolver en esta investigación consiste en generar mediante algoritmos fusiones de imágenes con diferente resolución y temporalidad [9]. Para lograr esto las imágenes deben ser compatibles entre sí para poderlas procesar y eliminar posibles fallas que ocasionen que no se tengan lecturas precisas del lugar y generar una fusión de imágenes adecuada que muestre el impacto que la mina Cerro Blanco está ocasionando en el Lago Güija y cómo se contamina el río más importante de El Salvador [10][14].

II. METODOLOGÍA

Para analizar el área de estudio definida se requiere de características específicas y necesarias en los formatos de recolección de datos para obtener información de calidad y procesarla. En esta etapa es necesario el uso de imágenes satelitales.

Landsat y MODIS son de los satélites de observación de la tierra más utilizados para el estudio del medio ambiente, ambos ofrecen amplia gama de beneficios valiosos para la investigación como la resolución espacial de Landsat, la temporalidad que proporciona MODIS, características adecuadas para

generar fusión de imágenes; son herramientas complementarias que ofrecen acceso a cualquier usuario sin ningún costo y con la mayor calidad en los datos, además de presentar una calibración con precisión y cuentan con un largo historial de imágenes, lo que permite analizar más información [13].

Se describen los satélites que se utilizaron para capturar las imágenes del lago Güija. A continuación, se presenta un cuadro comparativo de las principales características que cada satélite ofrece a sus usuarios [9].

Tabla 1. Cuadro comparativo de las características del satélite Landsat y el sensor MODIS

Características	Landsat	Modis (terra y aqua)
Tipo de sensor	Espectrorradiómetro multiespectral.	Espectrorradiómetro de imágenes de resolución moderada.
Resolución espacial.	30 metros (pan-cromático), 120 metros (multiespectral).	250 metros (bandas 1-7), 500 metros (banda 8), 1000 metros (bandas 9-36).
Número de bandas	11	36
Cobertura terrestre	100 km x 185 km	2330 km x 2330 km
Resolución temporal	16 días	1-2 días
Lanzamiento	Landsat 1: 1972 Landsat 9: 2021 (actual)	Terra: 1999, Aqua: 2002

El satélite Landsat presenta una resolución espacial mayor a la del satélite MODIS por lo que la calidad de las imágenes es superior indiscutiblemente [2] [3]. Por su parte, MODIS cuenta con una resolución temporal más favorable para el monitoreo del área de estudio, además de tener una cobertura terrestre mayor que Landsat [8].

Al fusionar las imágenes satelitales se puede obtener una de mayor calidad en la que estén presentes las características más destacadas de cada satélite y así obtener una imagen fácil de comprender visualmente y favorecer el análisis de los investigadores.

Los datos necesitan un preprocesamiento, es decir, el tratamiento donde se toman los datos sin ningún tipo de alteración y se modifican a tal punto que se consideren aptos para que un modelo o algoritmo o método pueda utilizarlos como entrada inicial. Al comenzar una metodología basada en el aprendizaje automático como el Modelo de fusión de reflectancia

adaptativa espacial y temporal (STARFM), método seleccionado para fusionar imágenes; no siempre se disponen de datos limpios y formateados, por lo que es indispensable realizar algunas operaciones que ayuden a reducir o eliminar algún desperfecto en los datos que se utilizarán en la fusión [19].

Con el avance en la tecnología, también se han incrementado los procesos que mejoran y limpian la información cuando se trabaja con datos satelitales, mismos que se encargan de reconstruir la información con base en las imágenes satelitales obtenidas y presentarla lista para ejecutar el siguiente paso en el proceso.

En la etapa de preprocesamiento, es importante destacar los procesos de remuestreo y calibración radiométrica. Estos procedimientos son fundamentales para mejorar la calidad de los datos satelitales, ya que eliminan el ruido y corrigen otros problemas potenciales que puedan afectar la precisión de la información [9].

La colección de imágenes utilizada es específicamente la de LANDSAT/LC08/C02/T1_RT que pertenece al satélite Landsat para obtener la información sobre la contaminación en la cuenca del Lago Güija. Se inicia con el desglose del ID de la colección de imágenes que se está importando obtenemos información como: "LANDSAT" indica que la colección pertenece al satélite Landsat; con "LC08", se hace referencia que pertenece específicamente al Landsat 8; "C02" indica la versión de la colección; y finalmente con "T1_RT" hace referencia que son imágenes de alta calidad georeferenciadas y que son procesadas y públicas casi en tiempo real después de su adquisición; de la misma forma se ejecuta para el satélite MODIS teniendo una colección de imágenes MODIS/061/MYD09GQ contiene imágenes de productos globales MODIS de 9 kilómetros de resolución espacial [10][11]. Estas imágenes se producen diariamente y contienen datos sobre una variedad de variables ambientales, como la temperatura de la superficie terrestre, la vegetación entre otros datos.

El Pansharpening es un proceso de fusión de imágenes en el cual se combina una imagen pancromática (PAN) de alta resolución espacial con una imagen multiespectral (MS) de menor resolución espacial [7].

El método PCA es un modelo estadístico que transforma los datos originales en un nuevo conjunto de variables no correlacionadas llamadas compo-

nentes principales, que retiene la mayor parte de la variabilidad de los datos originales, además es un método versátil, debido a que se puede aplicar a diversas combinaciones de imágenes pancromáticas y multi-espectrales de diferentes satélites [12].

III. RESULTADOS

A continuación, se presentan ejemplos de las imágenes recolectadas del satélite AQUA-MODIS y el satélite Landsat; con las cuales se realizó la fusión con el algoritmo Pansharpening [15].

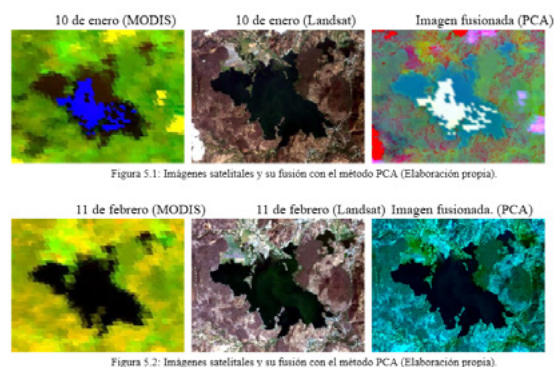


Fig. 1. Imágenes satelitales y su fusión con el método PCA. Elaboración propia.

El resultado de la fusión de las imágenes satelitales incluye los detalles completos de las fechas, lo que permite revisar y comprender los resultados obtenidos.

Tanto el Pansharpening PCA como el STARFM son métodos efectivos para la fusión de imágenes satelitales, cada uno con sus propios beneficios específicos [16]. El Pansharpening PCA es ideal para mejorar la resolución espacial mientras se mantiene la fidelidad espectral, un elemento crucial para aplicaciones que requieren alta precisión espacial y espectral [17]. Por el otro lado, STARFM, es excelente para producir series temporales de imágenes de alta resolución espacial, esenciales para el monitoreo continuo y la detección de cambios en el tiempo [20] [21][22].

El modelo STARFM se utilizó para fusionar imágenes de satélites de diferentes resoluciones espaciales y frecuencia temporal; el modelo combina la alta resolución espacial de Landsat con la alta frecuencia temporal de MODIS para generar imágenes fusionadas que son útiles en el monitoreo.

Se presentan las fechas usadas para la predicción donde L hace referencia a Landsat y M hace referencia a MODIS, si la combinación es “LM” hace referencia que la imagen Landsat y MODIS pertenecen a la misma fecha. Para tener una mejor referencia de la imagen fusionada a cada tabla se le agregara la columna system:index para mejor comprensión de los valores obtenidos [18].

Tabla 2. Métrica del sesgo del modelo STARFM sin Pansharpening

system: index	bias
L01-26M01-27-M02-09	0.03453180139
L05-17-M05-18-M05-26	0.5486080144
LM01-10-M01-25	0.0372489476
LM02-11-M02-25	0.01528838923
LM02-27-M03-13	0.1094473661
LM03-14-M-03-29	0.184919885
LM03-30-M-04-14	0.0807609736
LM04-15-M-04-30	0.1947060305
LM05-01-M05-16	0.1890867141

Elaboración propia.

La figura 2 muestra la ejecución de métricas del algoritmo STARFM. En esta figura se presentan los resultados obtenidos tras aplicar el algoritmo, destacando aspectos como la precisión espectral y la resolución espacial. Los datos fueron elaborados y analizados en el contexto de la presente investigación, proporcionando una evaluación visual y cuantitativa del rendimiento del algoritmo y su eficacia en la mejora de la calidad de las imágenes satelitales fusionadas [21].

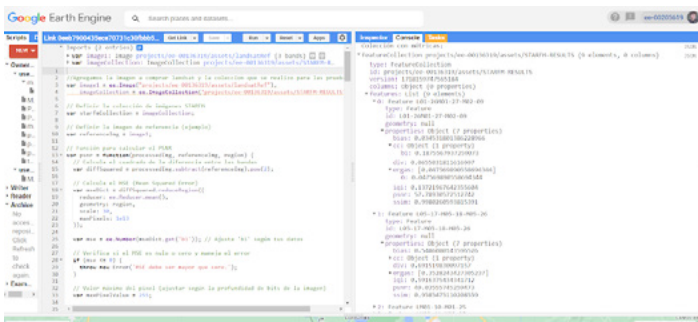


Fig. 2. Imágenes satelitales y su fusión con el método PCA.

Elaboración propia.

A. Métricas implementadas

RMSE: es la raíz cuadrada del MSE y proporciona una medida de la diferencia promedio entre los valores de los píxeles correspondientes de las dos imágenes.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (1)$$

CMC: medida de la diferencia en el contraste medio entre dos imágenes, diferencia en luminancia o color.

$$CMC = \frac{2std_ref \cdot std_eval}{var_ref + var_eval} \quad (2)$$

CML: medida de la diferencia en la luminancia media entre dos imágenes.

$$\text{CML} = \frac{2 \cdot \bar{x} \cdot \bar{y}}{\bar{x}^2 + \bar{y}^2} \quad (3)$$

Esta fórmula calcula un coeficiente que representa cómo cambia la luminosidad media entre dos imágenes. Se multiplica el valor medio de los píxeles de ambas imágenes, se multiplica por 2 y se divide entre la suma de los cuadrados de los valores medios de las dos imágenes.

RASE: evalúa la precisión espectral relativa promedio de una imagen en comparación con una imagen de referencia.

$$\text{RASE} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{y_i - \hat{y}_i}{\max(y_i, \hat{y}_i)} \right)^2} \quad (4)$$

B. Resultados de las fusiones de las imágenes satelitales

Resultados de las fusiones de las imágenes satelitales implementando el algoritmo STARFM sin Pansharpening.




Fig. 3.Fusión de imágenes. Elaboración propia.

Resultados de las fusiones de las imágenes satelitales implementando el algoritmo STARFM aplicando Pansharpening a las entradas Landsat y MODIS.

ResultadoPAN_L02-11_M02-11_M02-25




Fig. 4. Fusión de imágenes. Elaboración propia

Resultados de las fusiones de las imágenes satelitales implementando el algoritmo STARFM con entradas Landsat normales y aplicando Pansharpening solo a las entradas MODIS.

Resultado_L02-11_PM02-11_PM02-25




Fig. 5. Fusión de imágenes. Elaboración propia

Resultados de las fusiones de las imágenes satelitales implementando el algoritmo PCA-PANSARPENING.

Landsat y MODIS 11 de febrero




Fig. 6. Fusión de imágenes. Elaboración propia

IV. DISCUSIÓN

Pansharpening PCA como el STARFM son métodos efectivos para la fusión de imágenes satelitales, cada uno con sus propios beneficios específicos. El Pansharpening PCA es ideal para mejorar la resolución espacial mientras se mantiene la fidelidad espectral, lo que es crucial para aplicaciones que requieren alta precisión espacial y espectral. Por el otro lado, STARFM, es excelente para producir series temporales de imágenes de alta resolución espacial, esenciales para el monitoreo continuo y la detección de cambios en el tiempo.

El modelo STARFM se utilizó para fusionar imágenes de satélites de diferentes resoluciones espaciales y frecuencia temporal; el modelo combina la alta resolución espacial de Landsat con la alta frecuencia temporal de MODIS para generar imágenes fusionadas que son útiles en el monitoreo.

El resultado de las métricas de fusiones por algoritmo STARFM con entradas de Landsat y MODIS aplicando pansharpening a ambas, reveló que los datos no fueron tan favorables en comparación con aquellos obtenidos al aplicar únicamente la técnica de pansharpening a la entrada MODIS. Precisamente, los resultados obtenidos con la primera técnica, aunque inferiores, constituyen evidencia clave para sustentar la elección del segundo método. Presentar y analizar esta diferencia permite respaldar de manera científica la superioridad del enfoque propuesto, evitando sesgos y proporcionando una base objetiva para la comparación. Por ello, es fundamental incluir los resultados de ambas técnicas, destacando sus limitaciones y ventajas relativas.

Los resultados obtenidos en el análisis comparativo entre métricas por algoritmo STARFM con entradas de Landsat y MODIS sin Pansharpening con métricas de fusiones por algoritmo STARFM con entradas de Landsat y entrada aplicando Pansharpening a MODIS, se puede inferir que el segundo conjunto es ligeramente mejor que el primero en términos de consistencia y estabilidad de los valores, a pesar de que la media del primer conjunto es marginalmente más alta. Es decir, que aplicar Pansharpening a MODIS presenta ligeras mejoras.

Para el análisis de métricas comparativas entre algoritmos STARFM sin Pansharpening y STARFM con Pansharpening, se determina que el algoritmo STARFM conserva la resolución espacial de Landsat que es la mejor de los 2 satélites seleccionados, pero

en el caso de Pansharpening PCA la imagen es sometida a un proceso que incrementa su calidad. Además, la eficiencia computacional es crucial en el preprocesamiento debido al gran volumen de datos que se procesan. Un parámetro que sirve como medida es el tiempo de descarga de las imágenes preprocesadas, cabe señalar que este dato dependerá de la capacidad y potencia de la computadora donde se esté realizando este proceso.

Por el lado de utilizar Pansharpening -PCA se cuenta con la ventaja de que todo el proceso se realiza en los servidores de GEE (Google Earth Engine) por lo que no es un factor de preocupación la cantidad de memoria utilizada, permitiendo realizar procedimientos más intensivos y acceso a grandes volúmenes de datos. Para STARFM al ejecutarse en un entorno local, brinda un control total sobre los recursos, permitiendo optimizar específicamente a los criterios o necesidades, pero está limitado por el hardware disponible.

V. CONCLUSIONES

El método de Pansharpening basado en el Análisis de Componentes Principales (PCA) ha demostrado ser una herramienta eficaz para mejorar la resolución espacial de las imágenes multispectrales mientras se conserva la información espectral. Con este método se aprovecha la alta resolución espacial de la imagen pancromática, que actúa como base, para fusionarla con las bandas espectrales transformadas en componentes principales, logrando así una imagen fusionada con detalles finos y precisos.

STARFM ha demostrado ser una herramienta valiosa para generar predicciones temporales de imágenes de alta resolución espacial, combinando la alta frecuencia temporal de MODIS con la alta resolución espacial de Landsat. STARFM utiliza la información temporalmente rica pero espacialmente menos detallada de MODIS y la combina con la información espacial detallada pero menos frecuente de Landsat. Este enfoque permite generar series temporales de imágenes con la resolución espacial de Landsat y la frecuencia temporal de MODIS, ofreciendo una solución robusta para monitorear cambios en la superficie terrestre con alta resolución tanto temporal como espacial.

El Índice de Calidad de Imagen (IQI), la Relación Señal a Ruido Pico (PSNR), y el Índice de Similitud Estructural (SSIM) demuestran que la mayoría de las imágenes fusionadas por medio de los algoritmos

STARFM sin Pansharpening y STARFM con Pansharpening tienen una alta calidad, aunque hay excepciones que requieren atención. Estas excepciones suelen deberse a la calidad de la imagen base, debido a que las imágenes satelitales pueden verse afectadas por condiciones climáticas adversas en la fecha de captura.

El análisis de las métricas para el Pansharpening PCA revela una relación variada entre las bandas B2 y B3, con correlaciones tanto negativas y positivas que indican la complejidad de las relaciones espectrales en las imágenes fusionadas. Esta variabilidad sugiere que, aunque el PCA es eficaz para mejorar la resolución espacial y preservar la información espectral, puede requerir ajustes específicos dependiendo de las bandas utilizadas para optimizar los resultados.

El análisis comparativo entre métricas por algoritmo STARFM con entradas de Landsat y MODIS sin Pansharpening con métricas de fusiones por algoritmo STARFM con entradas de Landsat y entrada aplicando Pansharpening a MODIS, revela que ambos métodos muestran capacidades similares para ser implementadas en un monitoreo constante, tal como lo respaldan las métricas bias y cc, confirmando que ambos pueden capturar efectivamente las características de la imagen de referencia.

REFERENCIAS

- [1] M. Abid, A. Khabou, Y. Ouakrim, H. Watel, S. Chemkhi, A. Mitiche, A. Benazza-Benyahia y N. Mezghani, Physical Activity Recognition Based on a Parallel Approach for an Ensemble of Machine Learning and Deep Learning Classifiers". ArXiv.org, 2021, <https://arxiv.org/abs/2103.01859>.
- [2] J. Acafremin, "Mina Cerro Blanco: amenaza latente para el agua de El Salvador". 2021. <https://acafremin.org/es/blog/829-mina-Cerroblanco-amenaza-latente-para-el-agua-de-el-salvador>.
- [3] K. Arévalo, El caso de la mina Cerro Blanco: ¿amenaza para los ríos de Guatemala y El Salvador? Voz de América, 2022, [Online]. Available: <https://www.vozdeamerica.com/a/guatemala-elsalvador-mina-Cerro-blanco-amenaza-rios-/6812463.html>.
- [4] A. Ariza, Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission), 2013. [Online]. Available: <http://www>.

- un-spider.org/sites/default/files/LDCM-L8.R1.pdf.
- [5] D. Borini Alves, R. Montorio Llovería, F. Pérez-Cabello y L. Vlassova, "Fusionado de imágenes Terra-MODIS y Landsat-TM/OLI en el contexto del análisis del incendio forestal de Las Hurdes (Cáceres) GeoFocus", 2016, (Artículos), n° 18, p. 65-81. ISSN: 1578-5157.
- [6] Confronting tech power 2023 Landscape. (n.d.). [Online]. Available: <https://ainowinstitute.org/wp-content/uploads/2023/04/AI-Now-2023-Landscape-Report-FINAL.pdf>.
- [7] L. De Computación y A. Ignacio, M. Mendoza, Centro de Investigación Científica y de Educación Superior de Senada, Baja California, Programa de Posgrado en Ciencias "Algoritmos para la corrección radiométrica de imágenes de satélite", 2014, [Online]. Available: <https://cicese.repositorioinstitucional.mx/jspui/bitstream/1007/436/1/236291.pdf>.
- [8] Definición de Banda, Diccionario SIG. <https://support.esri.com/es-es/gis-dictionary/band>.
- [9] O. Eduardo, R. Chavez, H. Alberto y A. Bautista, "Manual para el manejo y procesamiento de imágenes satelitales obtenidas del sensor remoto MODIS de la nasa, aplicado en estudios de ingeniería Civil". [Online]. Available: <https://repository.javeriana.edu.co/bitstream/handle/10554/7050/tesis123.pdf?sequence=3&isAllowed=y>.
- [10] EOS, Cómo hacer un análisis espectral. EOS, 2022, [Online]. Available: <https://eos.com/es/make-an-analysis/>.
- [11] Especificaciones de la cámara MODIS. Conae.gov.ar, 2024, [Online]. Available: <https://catalogos.conae.gov.ar/TERRA/camara.htm>.
- [12] Esri. Banda. Diccionario de SIG de Esri, 2023, [Online]. Available: <https://support.esri.com/es-es/gis-dictionary/band>.
- [13] L. Fernández y L. Rincón, Procesamiento de imágenes satelitales, 2020. [Online]. Available: <http://revistas.ustatunja.edu.co/index.php/lingeneieux/article/view/2332/>.
- [14] G. Ferrucci, A. Grzyb, B. Hammond, R. Knox y A. Montoya, Mina a cielo abierto Cerro Blanco en Guatemala. Cerro Blanco Mine Report 009, 2023. [Online]. Available: <https://sv.boell.org/es/2023/05/09/mina-cielo-abierto-Cerro-blanco-en-guatemala>.
- [15] "Fundamentos de fusión de imágenes—ArcGIS AllSource" Documentación. (n.d.). <https://doc.arcgis.com/es/allsource/latest/analysis/raster-functions/fundamentals-of-pan-sharpening-pro.htm>.
- [16] C. Gevaert y F. Javier García-Haro, A comparison of STARFM and an unmixing-based algorithm for Landsat and MODIS data fusion. Remote Sensing of Environment, 156, 34-44, 2015, <https://doi.org/10.1016/j.rse.2014.09.012>.
- [17] Gisandbeers, Pansharpening en Google Earth Engine para imágenes Landsat - Gis&Beers. Gis&Beers, 2020. [Online]. Available: <https://www.gisandbeers.com/pansharpening-en-google-earth-engine-imagenes-landsat/>.
- [18] Gisandbeers, Manual Landsat 9 Handbook - Gis&Beers. Gis&Beers, 2022. [Online]. Available: <https://www.gisandbeers.com/manual-landsat-9-handbook/>.
- [19] L- Giambelluca, L, Pansharpening en SNAP, "Mejora tus imágenes satelitales usando la banda pancromática", Geoinnova. Geoinnova, 2022. [Online].
- [20] T. Hastie, R. Tibshirani, y J. Friedman, "The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer. ISBN 978-0387848570", 2009.
- [21] Introducción a las imágenes multiespectrales multidimensionales. (n.d.). Learn ArcGIS. [Online]. Available <https://learn.arcgis.com/es/projects/get-started-with-multidimensional-multispectral-imagery/>.
- [22] A. Israa y Universidad De Granada Departamento de Ciencias de la Computación e Inteligencia Artificial, U, "Fusión de imágenes multiespectrales mediante métodos multiescala y super-resolución" 2010. [Online]. Available: <https://digibug.ugr.es/handle/10481/15457>.

