


## GeoAI y segmentación espectral: análisis de territorios extremos mediante K-Means aplicado a imágenes satelitales

*GeoAI and spectral segmentation: analysis of extreme land cover using K-Means applied to satellite imagery*

Autor

Guillermo Guzmán-Chávez<sup>1</sup>   
[gguzman@pucesi.edu.ec](mailto:gguzman@pucesi.edu.ec)

### RESUMEN

La investigación determina la viabilidad de segmentación espectral usando el algoritmo K-Means, para clasificación e identificación de patrones territoriales, mediante el uso de imágenes satelitales RGB. La selección de los territorios parte de la premisa de variedad morfológica, así como de su diversidad espectral, permitiendo evaluar el desempeño del clustering en escenarios complejos, Definiendo cuatro territorios con distintas características: área afectada por erupción volcánica de La Palma en España 2021, litoral de Bangladesh 2023, lagos efímeros en el Sahara 2025 y Valles Secos de McMurdo en la Antártida. El objetivo fue analizar como el clustering no supervisado contribuye al reconocimiento automático de estructuras espaciales bajo condiciones ambientales contrastantes. La metodología se fundamentó en el procesamiento de imágenes RGB, conversión a matrices numéricas y uso de K-Means, seguido de reconstrucción visual. Los resultados evidencian la capacidad del algoritmo para reducir complejidad cromática, agrupar píxeles según similitudes espectrales, revelar patrones territoriales asociados a textura, cambios superficiales, gradientes ambientales y unidades estructurales diferenciadas. Los hallazgos demuestran que la segmentación no supervisada constituye un recurso valioso para el urbanismo computacional y planificación territorial, especialmente donde se requieren métodos accesibles y replicables capaces de aportar interpretaciones ágiles, y recomendaciones para futuras aplicaciones en análisis urbano-territorial.

**Palabras clave:** Análisis espectral, Clustering no supervisado, Teledetección, Urbanismo computacional.

### ABSTRACT

The research evaluates the feasibility of spectral segmentation using the K-Means algorithm for the classification and identification of territorial patterns based on RGB satellite imagery. The selection of study areas was guided by morphological variability and spectral diversity, enabling the assessment of clustering performance under complex environmental conditions. Four territories with distinct characteristics were analyzed: the area affected by the 2021 La Palma volcanic eruption in Spain, the Bangladesh coastline in 2023, ephemeral lakes in the Sahara in 2025, and the McMurdo Dry Valleys in Antarctica. Within this framework, the research question seeks to understand how this unsupervised method contributes to the automated recognition of spatial structures across highly contrasting surfaces. The methodology was based on RGB image preprocessing, conversion into numerical matrices, and implementation of the K-Means clustering algorithm, followed by visual reconstruction of the segmented outputs. Results demonstrate the algorithm's capacity to reduce chromatic complexity, group pixels according to spectral similarity, and reveal territorial patterns associated with texture, surface change, environmental gradients, and differentiated structural units. The findings indicate that unsupervised segmentation constitutes a valuable tool for computational urbanism and territorial planning, particularly in contexts requiring accessible, replicable, and scalable analytical approaches capable of providing rapid spatial interpretation, as well as informing recommendations for future urban-territorial analytical applications.

**Keywords:** Computational urbanism, Remote sensing, Spectral analysis, Unsupervised clustering.

<sup>1</sup> Pontificia Universidad Católica del Ecuador Sede Ibarra: Ibarra, Ecuador

Recepción: 28/11/2025  
Revisión: 02/03/2026  
Publicación: 31/05/2026

## 1. Introducción

La investigación relacionada al campo urbano-territorial ha experimentado un incremento en el uso de métodos computacionales, transformando la manera en que se profundiza y analiza los contextos geográficos (Ikotun et al., 2023), brindando la comprensión de fenómenos complejos a través de técnicas algorítmicas las cuales identifican patrones, estructuras y transiciones que en el pasado requerían análisis especializados de alto costo o procedimientos manuales que demandaban mucho tiempo. La correlación entre Teledetección, Inteligencia Artificial Geoespacial (GeoAI) y clustering no supervisado surge como un campo de investigación con creciente relevancia en los campos de la planificación urbana, estudios ambientales, así como las ciencias relacionadas al estudio de la tierra, siendo el algoritmo K-Means uno de los métodos elementales en este ecosistema (Na et al., 2010), el cual sido usado en análisis que requerían reducción de la complejidad cromática en imágenes satelitales, segmentación espectral y clasificación inicial de patrones espaciales (Metzler et al., 2025; Oyekola & Adewuyi, 2018). La capacidad de agrupamiento de píxeles con características equivalentes y sin la necesidad de datos previamente etiquetados que se convierte en una herramienta replicable, generando diagnósticos eficientes con una alta velocidad de procesamiento.

Oyekola & Adewuyi (2018) ponen de manifiesto que en áreas donde la diversidad ambiental complica la clasificación supervisada, o en las que los datos etiquetados escasean, los algoritmos no supervisados se han establecido. Por otro lado, análisis en estudios urbano-territoriales extremos han evidenciado que la segmentación espectral revela configuraciones espaciales inobservables en la imagen original, focalizando: contraste térmicos gradientes hídricos, formaciones geomorfológicas (Hamada et al., 2016; Ioannilli & Paregiani, 2008). De esta manera el análisis territorial mediante clustering no supervisado se aplica a estudios que buscan identificar cambios, alteraciones de cobertura, así como delimitación de unidades espaciales sin intervención humana directamente. La importancia de estos

estudios reside en la aplicabilidad, la simplificación de elementos visuales permite a los algoritmos interpretar superficies basadas en características espectrales que pueden extrapolarse a contextos climáticos, de riesgos, ambientales y por su puesto urbanos.

Respecto a las variables del estudio, la segmentación se fundamentó en agrupación de píxeles según su similitud cromática, representada por los valores de las bandas rojo, verde y azul. Cada píxel constituye una observación individual cuya posición en el espacio bidimensional depende de los valores espectrales. Las imágenes originales constituyen la variable independiente principal, mientras que los clusters obtenidos representan la variable dependiente derivada del análisis algorítmico. Se consideran también como variables analíticas el valor de  $k$ , que determina la cantidad de clusters, y la estructura espectral del territorio, que condiciona la distribución final de los grupos.

Se propone un análisis aplicado de la segmentación espectral mediante K-Means para responder a la siguiente pregunta: ¿Cómo contribuye la segmentación espectral mediante K-Means a la identificación y clasificación de patrones territoriales en contextos extremos a partir de imágenes satelitales RGB? Esta pregunta surge de la necesidad de evaluar la pertinencia de métodos no supervisados para interpretar formas, dinámicas y estructuras territoriales bajo condiciones ambientales altamente contrastantes.

En particular, el estudio se centra en cuatro territorios seleccionados por representar condiciones extremas de variabilidad espectral: depósitos volcánicos, dinámica sedimentaria costera, anomalías hidrológicas hiperáridas y superficies polares de bajo contraste, los que resultan difíciles de interpretar mediante observación directa. Así los territorios analizados fueron: La Palma España, la región costera de Bangladesh, los lagos efímeros del Sahara y los Valles Secos de McMurdo en la Antártida. En estos espacios, la combinación entre datos satelitales y segmentación espectral proporciona una ventana analítica para reconocer

unidades territoriales, delimitar zonas de transición, identificar superficies alteradas y estudiar dinámicas ambientales (Hamada et al., 2016; Vachmanus et al., 2021). Las características extremas de estos territorios permiten además evaluar la robustez del algoritmo frente a condiciones de ruido, saturación cromática, variabilidad reflectiva o estructuras geomorfológicas irregulares.

De esta manera la investigación y análisis se desarrolló a partir de imágenes satelitales RGB procesadas mediante un entorno computacional basado en Python, transformadas en matrices numéricas y sometidas a segmentación espectral. El trabajo se realizó durante 2024–2025, empleando imágenes correspondientes a diferentes años según la disponibilidad documental, sin alterar su composición original. La elección de imágenes RGB responde a la intencionalidad metodológica de evaluar cómo opera el algoritmo con información accesible, sin recurrir a sensores multiespectrales o hiperespectrales, los cuales, aunque enriquecen la capacidad analítica, no siempre se encuentran disponibles para equipos profesionales con recursos limitados. Esta elección metodológica permite demostrar que incluso con datos de espectro visible es posible obtener resultados significativos mediante clustering.

La capacidad de la segmentación para denotar áreas afectadas por acumulación de cenizas, flujos piroclásticos, así como áreas preexistentes con distintos rangos de alteración son abordados en el análisis de erupción en la Palma. Las diferenciaciones espectrales son importantes para comprender los procesos de reorganización territorial luego de la afectación por desastres naturales, en los cuales la identificación de límites, ubicación de unidades afectadas y la delimitación de áreas críticas se transforman en recursos fundamentales para la reconstrucción y recuperación (Ramírez-Juidias & Antón, 2025). En el área de Bangladesh, la zona costera tiene características como transiciones entre zonas de erosión y degradación, variación en humedad superficial, alta movilidad sedimentaria, ante lo cual la segmentación espectral brinda una representación simplificada que ofrece identificar zonas expuestas a erosión crónica, inundaciones, etc., aspectos

esenciales para la gestión del riesgo de desastres así como la planificación urbana en lo relacionado al uso de suelo en zonas altamente vulnerables al cambio climático (Bushra et al., 2025).

En el caso de los lagos efímeros del Sahara constituyen un fenómeno de gran interés que permite comprender dinámicas hidroclimáticas y patrones ambientales excepcionales en regiones hiperáridas. Por otro lado, la presencia o ausencia de cuerpos de agua temporales muestran variaciones abruptas en las condiciones atmosféricas lo cual brinda información para el análisis de transformaciones superficiales de constante evolución, desertificación y eventos extremos de precipitación (Hamada et al., 2016). Bajo esta conceptualización el caso de los Valles secos de McMurdo, considerado uno de los contextos con una singularidad excepcional en el planeta, la aplicación de la segmentación permite identificar entre superficies congeladas, sedimentos y formaciones geológicas.

Estos contextos geográficos, distinguidos por su extrema configuración y baja intervención humana, permite valorar la capacidad del algoritmo, para evaluar la eficiencia del clustering no supervisado, las coincidencias o discrepancias cromáticas fueron obtenidas mediante la aplicación del K-Means permitiendo la comprensión sobre redistribución de la variación espectral, surgimiento de estructuras territoriales ante reducción de la complejidad visual, elementos característicos para el agrupamiento.

La implementación de métodos derivados de GeoAI, se han acelerado notablemente sobre todo en el campo del urbanismo computacional, este incremento se debe a la facilidad y disponibilidad de acceso a datos satelitales, la necesidad de adoptar herramientas contemporáneas que permitan comprender las dinámicas urbano-territoriales, mejora en la capacidad de procesamiento, todo esto bajo el enfoque de automatización. Batty (2021) lo describe como una transformación desde herramientas clásicas para el análisis hacia modelos analíticos que se fundamentan en datos y algoritmos, subrayando la relevancia de

componentes que permitan identificar patrones espaciales, anticipar escenarios de cambio y detectar transformaciones morfológicas aceleradas. La elección de K-Means se da por la simplicidad matemática y la naturaleza replicable, aun cuando se ubica como un método básico en el repertorio de algoritmos no supervisados, de esta manera se facilita la incorporación en procesos de evaluación preliminar, así como diagnóstico territorial. De igual manera en entornos en los cuales las instituciones atraviesan limitaciones técnicas o presupuestarias, los algoritmos de baja complejidad computacional resultan más útiles que soluciones avanzadas puesto que necesitan entrenamiento intensivo o infraestructuras especializadas de cómputo (Li & Hsu, 2022).

La metodología considera la teledetección de mediana escala, automatización de procesos geoespaciales y análisis espectrales. El estudio se desarrolló enteramente desde imágenes satelitales, para luego ser procesadas en contextos computacionales adaptados al análisis matricial. El procedimiento consistió en la lectura de imágenes RGB, su conversión a matrices numéricas, la ejecución del algoritmo K-Means con distintos valores de  $k$  y la generación de segmentaciones reorganizadas cromáticamente para su interpretación visual. Este enfoque permite observar cómo varía la clasificación territorial según la complejidad cromática de la imagen, la cantidad de clusters seleccionados y la naturaleza espectral de cada territorio.

La segmentación espectral mediante K-Means adquiere importancia estratégica en la medida en que ofrece un puente entre el análisis territorial automatizado y el desarrollo de enfoques emergentes en urbanismo computacional. Este último con enfoque interdisciplinario ha incorporado modelación, simulación y análisis matemático para interpretar dinámicas urbanas y territoriales (Batty, 2021; Biljecki & Ito, 2021). La aplicación a territorios extremos permite observar patrones estructurales que pueden extrapolarse a la planificación, especialmente en escenarios donde el estudio de la morfología, la textura o la composición superficial

contribuyen a comprender dinámicas más amplias relacionadas con fenómenos naturales, vulnerabilidad ambiental o presiones antrópicas.

La revisión de literatura es un eje fundamental que permite entender la dinámica del estudio planteado en contextos globales, investigaciones recientes evidencian que los algoritmos de clustering se han transformado en una herramienta útil para análisis preliminar de imágenes satelitales, sobre todo en ambientes de interpretación territorial, contextos de exploración o monitoreo. Por ejemplo, investigaciones en geomorfología han empleado K-Means para identificar unidades superficiales a gran escala, determinar patrones de erosión, clasificación de formaciones rocosas (Ioannilli & Paregiani, 2008). En estudios de gestión ambiental, la segmentación permite diferenciar cuerpos de agua en contextos de difícil acceso, así como coberturas vegetales y suelos expuestos acceso (Oyekola & Adewuyi, 2018). De igual manera el clustering no supervisado ha sido utilizado en planificación regional para determinar el cambio de uso del suelo, identificar fragmentación espacial en contextos urbanos y rurales, áreas de expansión, conurbación (He et al., 2011). Estos antecedentes revalidan el valor del método, revelando su utilidad en múltiples campos de la ciencia que en muchos de los casos se vinculan al estudio del territorio.

La relevancia a nivel académico radica en evidenciar que la segmentación espectral con el uso de K-Means se convierte en una herramienta eficaz para acceder a información significativa, se posiciona como contribución en el fortalecimiento de metodologías accesibles basadas en GeoAI; desde el punto de vista profesional, apoya la toma de decisiones mediante análisis rápidos, de bajo costo y reproducibles. Desde un enfoque más puntual como el urbanismo permite identificar estructuras espaciales, cambios morfológicos, caracterización de superficies alteradas; en análisis territorial, proporcionan una base analítica para estudios comparativos entre regiones contrastantes. Adicional del marco conceptual generado la investigación contribuye al fortalecimiento de enfoques en urbanismo

computacional en los que se trabaja con algoritmos, denotando la jerarquía de incorporar métodos simples pero efectivos en procesos de análisis

A pesar de los avances en segmentación basada en aprendizaje profundo, muchas instituciones académicas y gobiernos locales carecen de datos etiquetados y capacidad computacional. Este estudio responde a la necesidad de métodos GeoAI accesibles y replicables para análisis preliminar de coberturas del suelo en territorios con información limitada.

Como limitante el estudio presenta limitaciones relacionadas con la ausencia de validación con datos de campo, así como la diferencia de resolución entre imágenes, por otro lado, la metodología también consideró las limitaciones inherentes al uso de imágenes RGB. El análisis espectral basado únicamente en las bandas del espectro visible excluye información asociada a longitudes de onda infrarrojas, térmicas o multiespectrales que suelen emplearse para diferenciar vegetación, humedad o temperatura superficial. Este enfoque restringido se adoptó deliberadamente, con el propósito de evaluar la capacidad del clustering para operar con insumos básicos accesibles para instituciones con limitados recursos tecnológicos. El análisis basado exclusivamente en RGB permite demostrar que aun con datos mínimos y no especializados es posible obtener resultados metodológicamente consistentes. Sin embargo, estas limitaciones orientan futuros trabajos investigativos hacia la integración de datos multiespectrales y análisis multitemporal en entornos SIG.

## **2. Metodología (Materiales y Métodos)**

La metodología empleada en esta investigación se fundamenta en el análisis computacional de imágenes satelitales RGB mediante técnicas de segmentación no supervisada, específicamente el algoritmo K-Means (Ahmed et al., 2020), implementado en un entorno Python orientado al procesamiento matricial ver Figura 1. El diseño metodológico se estructuró bajo un enfoque exploratorio. Este método contrasta con la idea de examinar la capacidad del clustering para identificar

características territoriales sin intervención directa humana, usando información accesible e independiente de clasificaciones preconcebidas (Liu et al., 2021).

Las imágenes satelitales que se usaron son productos Sentinel-2 MSI Nivel-1C, obtenidos de la plataforma Copernicus, la resolución espacial de 10m reproyectadas al sistema EPSG:4326 y posteriormente recortadas en las áreas de interés con el software QGIS y Python (Rasterio, GDAL). No se aplicó correcciones radiométricas adicionales con el fin de evaluar el desempeño del algoritmo en condiciones accesibles para instituciones con recursos limitados.


El desarrollo metodológico no incorporó técnicas previas, así como etapas de clasificación supervisada; al contrario, se basó en la agrupación automática de píxeles según similitud cromática, con el propósito de entender cómo estructuras internas del territorio surgen desde diferencias espectrales en el dominio visible. Permitiendo valorar el desarrollo del algoritmo en situaciones altamente contrastantes aportando contextos de análisis donde los datos etiquetados son nulos.

**Tabla 1. Características técnicas y linaje de los datos raster utilizados en los casos de estudio.**

Territorio	Sensor	Resolución	Fecha	Variables analizadas
La Palma	Sentinel-2 MSI	10 m	oct-21	RGB, k=2, k=9
Bangladesh	Sentinel-2 MSI	10 m	mar-23	RGB, k=2, k=9
Sahara	Sentinel-2 MSI	10 m	ene-25	RGB, k=2, k=9
McMurdo	Sentinel-2 MSI	10 m	feb-24	RGB, k=2, k=9

Fuente: Elaboración propia

El análisis consideró variables derivadas del procesamiento espectral, que corresponden a los valores RGB de cada píxel y a la asignación de clusters generada por el algoritmo K-Means (k=2 y k=9). Las variables cualitativas se interpretaron a partir de las coberturas del suelo identificadas en cada cluster, tales como lava reciente, sedimentos costeros, cuerpos de agua, arena desértica o superficies congeladas. Esta diferenciación permitió relacionar agrupamientos espectrales con unidades territoriales observables.



**Figura N.º 1.** Flujo de trabajo. Determinación de los procesos implementados. Elaboración propia.

Se inició con la selección de cuatro imágenes satelitales RGB representativas de territorios extremos. Cada imagen fue escogida por su singularidad geomorfológica y ambiental, así como por su potencial para representar desafíos espectrales sustanciales. La primera corresponde a la zona afectada por la erupción volcánica de La Palma España (2021), caracterizada por contrastes abruptos entre flujos de lava reciente, depósitos piroclásticos, cenizas y suelos no alterados. La segunda imagen proviene de la costa de Bangladesh (2003), región donde la interacción entre agua y sedimentos genera gradientes cromáticos asociados a procesos de erosión, deposición y variaciones hidrológicas. La tercera imagen representa lagos efímeros del Sahara (2025), donde la presencia temporal de agua en un entorno predominantemente árido crea contrastes espectrales inusuales. Los Valles secos de McMurdo ubicados en la Antártida (2024) en los cuales la uniformidad cromática, así como la baja reflectancia establecen un desafío ante cualquier herramienta de segmentación basada únicamente en el espectro visible se expone en la cuarta imagen.

Cada una de las imágenes seleccionadas fue procesada bajo una estructura metodológica uniforme para asegurar comparabilidad entre los casos. Las imágenes satelitales, originalmente en formato digital, fueron convertidas a matrices tridimensionales que representan la intensidad espectral de cada píxel en las bandas roja, verde y azul. Este paso fue fundamental, ya que el algoritmo K-Means opera sobre matrices numéricas y no sobre imágenes en formato gráfico. La conversión a matrices, por tanto, constituye el puente entre la imagen satelital y el análisis matemático de sus componentes.

Una vez transformadas las imágenes a matrices RGB, se procedió a reestructurar la información cromática en una matriz bidimensional donde cada fila corresponde a un píxel y cada columna representa un valor espectral (R, G o B). Este reordenamiento del espacio cromático permitió alimentar el algoritmo K-Means con un conjunto de datos adecuado para el proceso de clustering, este algoritmo parte del principio de agrupación basado en distancias dentro del espacio cromático; su objetivo es organizar la nube de píxeles en un número predefinido de grupos espectralmente coherentes. La estructura matricial generada contiene tantos registros como píxeles tiene la imagen original, formando un universo de análisis compuesto por cientos de miles de observaciones numéricas. Este enfoque permite un análisis exhaustivo de la imagen sin reducción previa de información, lo que garantiza que la segmentación sea producto directo de la similitud espectral entre píxeles.

El resultado de este proceso fue la asignación de cada píxel a un grupo espectral específico, lo cual permitió reconstruir la imagen segmentada mediante la atribución de un color representativo para cada cluster. Aunque estos colores no conservan el significado cromático original de la imagen, funcionan como una herramienta visual para interpretar la estructura emergente del territorio a partir del análisis algorítmico.

El algoritmo K-Means se aplicó mediante funciones disponibles en Python, siguiendo los principios matemáticos clásicos del método: asignación de centroides iniciales, cálculo de distancias euclidianas, reclasificación iterativa de los píxeles y actualización de los centroides hasta alcanzar la convergencia. El parámetro fundamental del algoritmo es  $k$ , el número de grupos a formar. En esta investigación se trabajó con valores moderados de  $k$ , definiendo los clusters, con el fin de capturar patrones territoriales relevantes sin atomizar en exceso la estructura cromática, esta elección metodológica se basó en el equilibrio entre interpretabilidad y granularidad, asegurando que los grupos resultantes fueran lo suficientemente contrastados para permitir una lectura clara de las estructuras territoriales sin generar ruido analítico. Este rango de valores permitió equilibrar la granularidad del análisis y su

interpretabilidad, evitando tanto la sobresegmentación como la pérdida de contrastes significativos.

Durante la ejecución del algoritmo, cada píxel fue asignado al cluster cuyo centroide presentaba la menor distancia euclidiana respecto a sus valores RGB. Este proceso iterativo se repitió hasta que las asignaciones dejaron de cambiar de manera significativa, lo que indica que el algoritmo alcanzó estabilidad. El resultado fue un conjunto de etiquetas numéricas que representan la membresía de cada píxel a un cluster particular. Posteriormente, estas etiquetas se reconfiguraron en una matriz tridimensional con la misma forma que la imagen original, permitiendo reconstruir visualmente el resultado de la segmentación mediante una representación cromática filtrada.

La reconstrucción visual de la segmentación se efectuó asignando a cada cluster una unidad cromática coherente en el plano territorial. Este procedimiento no tiene un significado espectral intrínseco, sino que se utiliza como mecanismo para visualizar las unidades territoriales emergentes y facilitar la interpretación cualitativa de los patrones generados. La segmentación presenta, de este modo, la estructura territorial del caso de estudio a través de una imagen simplificada donde las variaciones internas del paisaje se expresan mediante categorías cromáticas generadas algorítmicamente. Esta etapa de reconstrucción visual es clave para interpretar los resultados, ya que convierte los agrupamientos numéricos en estructuras espaciales perceptibles.

Una vez obtenidas las segmentaciones finales, se desarrolló un análisis comparativo entre los cuatro territorios. Este análisis se centró en examinar cómo el algoritmo respondió ante diferencias en la variabilidad espectral, la homogeneidad superficial y la presencia de elementos ambientales relevantes. En La Palma, por ejemplo, se observó que los clusters capturaban con claridad las zonas de lava reciente debido a su baja reflectancia y su tonalidad oscura característica. Las zonas de ceniza y vegetación residual fueron clasificadas en clusters diferenciados, lo que permitió observar la extensión de los flujos volcánicos y su relación con el sustrato previo a la erupción. En la costa de Bangladesh, el algoritmo distinguió patrones

sedimentarios e hídricos asociados a la dinámica costera, permitiendo visualizar transiciones entre agua, sedimentos finos y suelos saturados. En los lagos efímeros del Sahara, los grupos diferenciaron entre superficies húmedas, suelos desérticos y zonas de transición, revelando la estructura territorial generada por la presencia temporal de cuerpos de agua. En McMurdo, los clusters exhibieron diferencias sutiles entre superficies congeladas, sedimentos expuestos y formaciones rocosas, demostrando que incluso en territorios con mínima variabilidad espectral es posible identificar unidades cromáticas consistentes.

El enfoque metodológico también incluyó un análisis interpretativo orientado a comprender qué tipo de patrones territoriales emergieron, así como interpretar la forma en que el valor de  $k$  influye en la segmentación y cómo estos pueden contribuir a estudios territoriales más amplios. La comparación entre territorios permitió evaluar la sensibilidad del algoritmo ante fenómenos como variaciones abruptas del albedo, presencia de humedad superficial, transiciones entre materiales geológicos y estructuras cromáticas de baja intensidad. La segmentación mediante K-Means, al no depender de información temática previa, permitió obtener una lectura inicial del territorio que puede ser utilizada como base para procesos analíticos posteriores, tales como la delimitación de unidades morfológicas, el análisis multitemporal de cambios o la integración con modelos de riesgo.

Un número pequeño de clusters origina una segmentación más general que simplifica el territorio en unidades extensas y contrastadas. A medida que el número de clusters aumenta, la segmentación se vuelve más específica, revelando diferencias internas que pueden resultar útiles para estudios de detalle, pero que también corren el riesgo de sobrefragmentar la información. La metodología comparó estas variaciones con el fin de entender cómo los territorios responden a diferentes esquemas de agrupamiento. Esta reflexión permitió establecer criterios interpretativos sobre la pertinencia del valor de  $k$  según el tipo de territorio y el objetivo de análisis.

Asimismo, la segmentación no consideró relaciones espaciales explícitas entre píxeles. Es decir, el algoritmo agrupa los píxeles en función de su similitud espectral,

pero no incorpora criterios de distancia geográfica ni continuidad espacial. Como consecuencia, dos píxeles pertenecientes al mismo cluster pueden no estar ubicados uno junto al otro en la imagen original. Esta limitación es característica del enfoque no supervisado y debe ser interpretada como parte del diseño metodológico, no como un defecto. La metodología enfatiza que el objetivo del clustering no es producir una clasificación temática definitiva, sino identificar patrones espectrales que sirvan como base para análisis posteriores.

La reconstrucción visual de la segmentación se focalizó en facilitar la interpretación de los resultados sin alterar la estructura elemental de los clusters. Más que una cromática real la asignación de colores artificiales para cada grupo responde a una necesidad interpretativa. De esta manera cada cluster representa una unidad analítica derivada de una agrupación matemática de los píxeles, así su significado territorial urge del análisis contextual de las condiciones ambientales presentes en cada caso de estudio.

Por otro lado, se consideró un análisis integral que interrelaciona los resultados espectrales con procesos hidrológicos, ambientales o geológicos propios de cada territorio. Dicha interpretación comparativa permite evaluar de forma cualitativa la eficacia del método que destaca patrones territoriales importantes. En territorios con alta variabilidad espectral como Bangladesh, así como entornos como homogeneidad cromática como McMurdo, la segmentación evidenció fortalezas particulares, dichos contrastes metodológicos permitieron definir aspectos sobre la aplicabilidad del clustering en estudios territoriales, de igual manera se identificó áreas donde la segmentación se puede integrar a procesos analíticos complejos en el campo la planificación territorial basada en datos así como del urbanismo computacional,

Aun considerando las limitaciones, la metodología muestra que la segmentación espectral mediante K-Means, se configura como una herramienta replicable, accesible y eficaz para el trabajo e interpretación de patrones territoriales en contextos extremos mediante el uso exclusivo de imágenes RGB. La integración en investigaciones urbano-territoriales amplía la posibilidad del análisis algorítmico

contribuyendo enfoques del urbanismo computacional, donde la interpretación del territorio se sustenta cada día con mayor fuerza en estructuras matemáticas que son capaces de revelar patrones imperceptibles a simple vista.

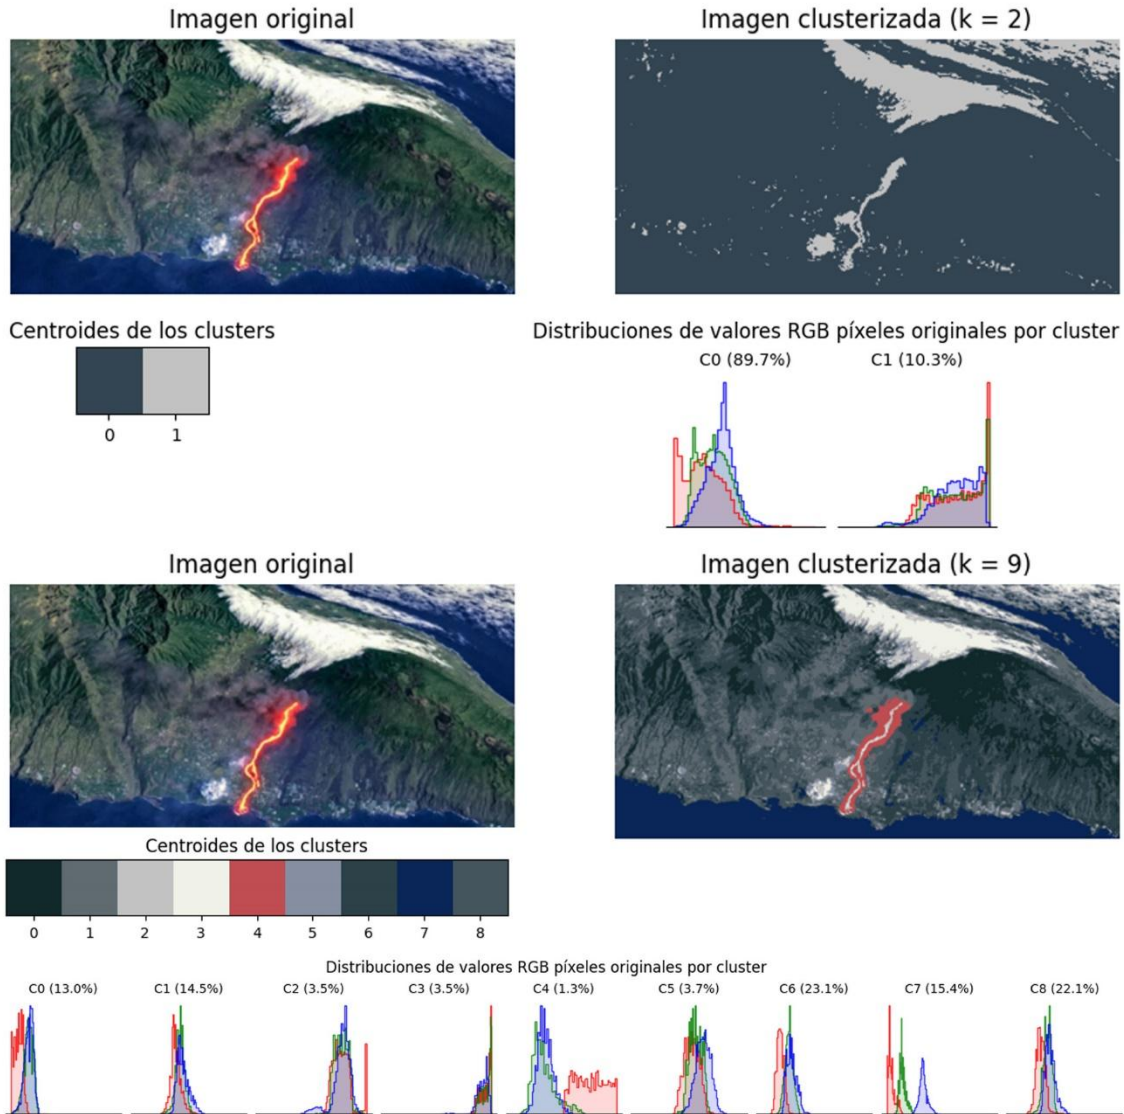
### 3. Resultados

Los resultados derivados de la segmentación espectral con el uso de K-Means revelan diferencias importantes sobre el comportamiento cromático, así como en la estructura interna de los territorios estudiados. Los agrupamientos generados por  $k=2$  y  $k=9$  evidencian que cada zona muestra una organización espectral particular, condicionada por sus características morfológicas y ambientales. El valor reducido de  $k$  produce un contraste binario que destaca la discontinuidad del paisaje, por otro lado, el valor aumentado de  $k$  permite distinguir con mayor detalle gradientes internos, transiciones y heterogeneidades que no son perceptibles en la imagen original. Dichas dualidades entre especificidad y simplificación forman parte del eje interpretativo principal de los resultados.

En el caso de La Palma, ver Figura 2., la segmentación con  $k=2$  muestra una división marcada entre las zonas de lava reciente y el resto del territorio. La clase dominante abarca el 89.7% de los píxeles, mientras que la segunda clase, que representa el 10.3%, agrupa las áreas asociadas al flujo de lava y materiales volcánicos. El patrón binario indica que el algoritmo identifica la lava como un elemento espectralmente diferenciado, caracterizado por tonos oscuros y valores bajos en las bandas RGB. La distribución de histogramas confirma que las intensidades cromáticas de esta clase presentan picos en el extremo inferior del espectro visible, particularmente en la banda azul, lo que explica su rápida separación respecto al fondo. Cuando se aumenta el valor a  $k=9$ , la segmentación revela subdivisiones internas significativas.

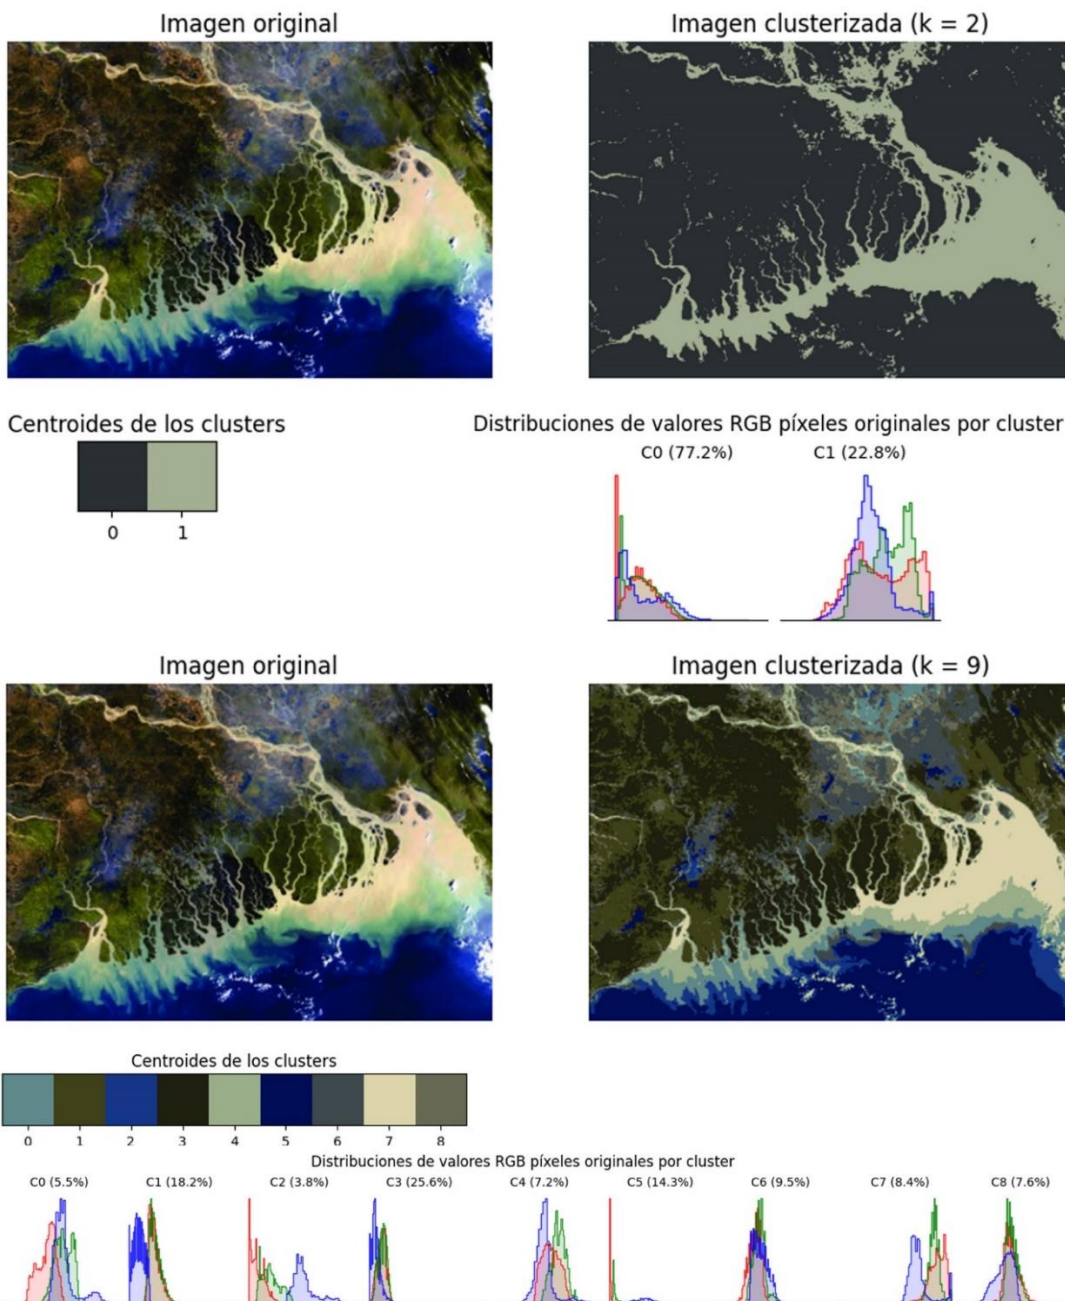
Los clusters se distribuyen de manera heterogénea: algunos representan zonas de vegetación residual, otros concentran áreas urbanas afectadas por la ceniza, y varios grupos se asocian a diferentes texturas y tonalidades dentro del flujo de lava. El cluster correspondiente a la lava activa adquiere un comportamiento distintivo y ocupa un porcentaje reducido (entre 1.3% y 3.7%), lo que indica su

estructura espectral altamente diferenciada. La fragmentación cromática observada evidencia que el territorio volcánico presenta variabilidad interna, incluso dentro de superficies que visualmente parecen homogéneas.



**Figura N.º.2.** La Palma-España, imagen original y segmentaciones K-Means ( $k=2$  y  $k=9$ ). El agrupamiento identifica la lava reciente y materiales volcánicos, diferenciándolos del entorno. Los histogramas muestran la distribución espectral de cada cluster.

En el territorio de Bangladesh ver Figura 3., la segmentación con  $k=2$  establece una distinción amplia entre las zonas de agua y sedimentos claros frente al territorio continental oscuro, donde la clase dominante representa el 77.2% de los datos.



**Figura N.º.3.** Costa de Bangladesh, imagen original y segmentaciones K-Means ( $k=2$  y  $k=9$ ). La técnica distingue cuerpos de agua, sedimentos y zonas continentales. Los histogramas evidencian variaciones hídricas y sedimentarias.

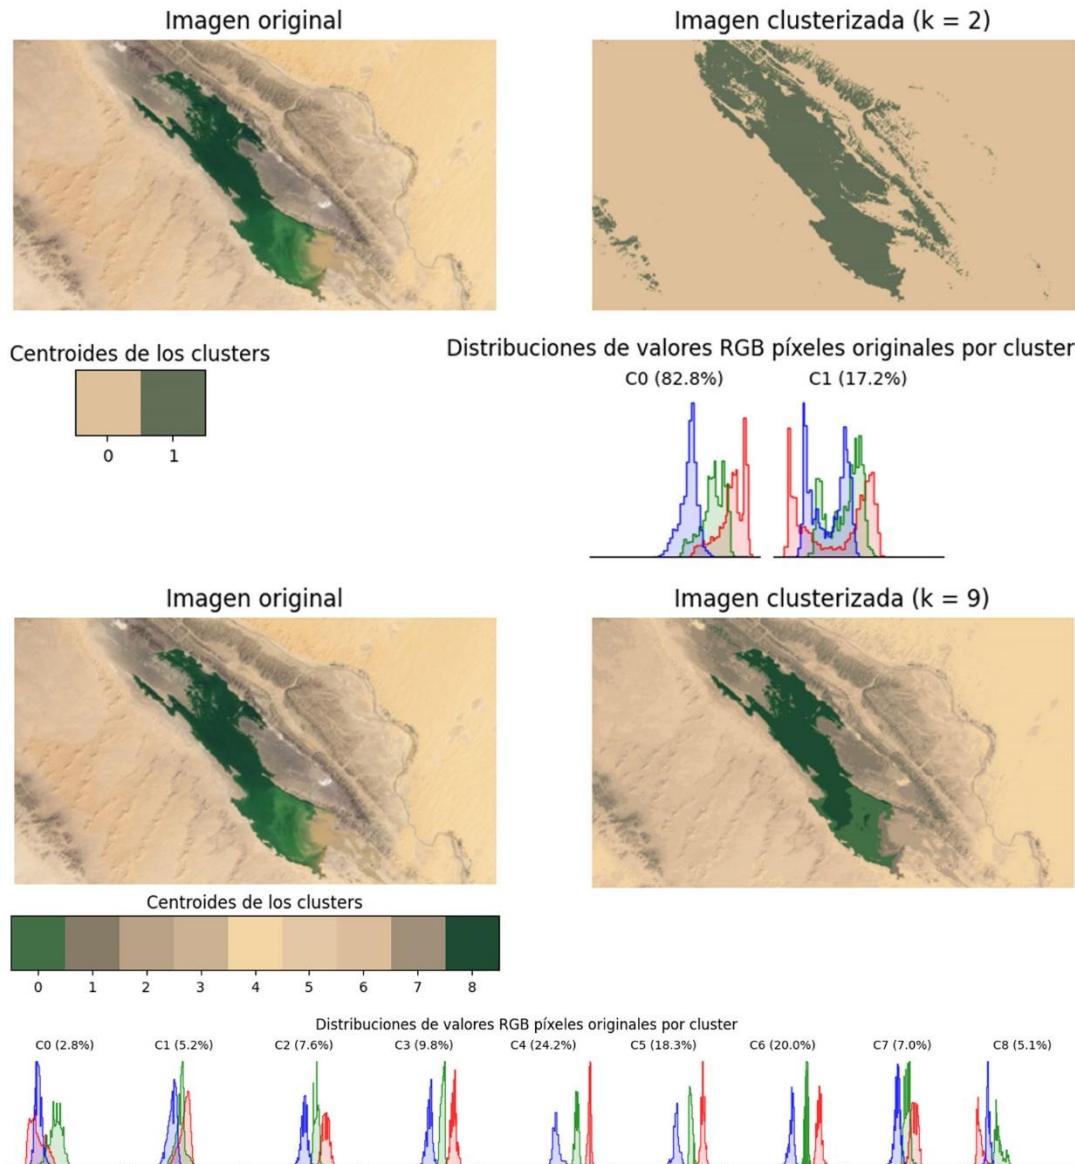
Los histogramas muestran que esta clase se caracteriza por intensidades altas en la banda verde y azul, lo cual coincide con la reflectancia del agua somera y los sedimentos en suspensión. La segunda clase (22.8%) reúne regiones de mayor

contenido de materia orgánica y vegetación, con patrones espectrales más dispersos. Cuando el algoritmo se ejecuta con  $k=9$ , la segmentación capta con detalle la complejidad hidrológica de la zona. Surgen grupos claramente diferenciados que representan cuerpos de agua de distintas profundidades, zonas de transición con sedimentos en suspensión, áreas de vegetación dispersa y regiones mixtas donde convergen suelos húmedos y variaciones cromáticas intermareales. Los porcentajes revelan que los clusters asociados a sedimentos finos y aguas turbias dominan la distribución, particularmente el cluster identificado como C3 (25.6%), lo que concuerda con la dinámica sedimentaria del delta. Este comportamiento indica que Bangladesh presenta gradientes espectrales finos que se intensifican cuando el algoritmo incrementa la resolución cromática.

En el caso de los lagos efímeros del Sahara, ver Figura 4., la segmentación con  $k=2$  produce un contraste evidente entre el entorno árido (82.8% de los píxeles) y las superficies húmedas u otras áreas asociadas a cuerpos de agua temporales (17.2%). Los histogramas muestran que la clase dominante presenta valores altos en la banda roja, lo que corresponde a los tonos arenosos que caracterizan estas regiones. La segunda clase, relacionada con los cuerpos de agua, presenta picos significativos en la banda azul y verde, reflejando la reflectancia propia del agua y sedimentos húmedos. Al aumentar a  $k=9$ , los clusters exhiben subdivisiones que permiten diferenciar zonas con humedad residual, transiciones entre arena y suelo húmedo, y variaciones internas dentro de los cuerpos de agua. Destaca la presencia de un cluster mayoritario (C4, 24.2%), el cual parece agrupar superficies de arena clara con ligeras variaciones cromáticas, mientras que los clusters asociados a agua u otros materiales saturados ocupan porcentajes menores, pero mantienen una coherencia espectral interna significativa. El comportamiento segmentado confirma que la presencia de agua introduce perturbaciones cromáticas marcadas que el algoritmo distingue incluso cuando el resto del territorio es altamente homogéneo.

Finalmente, en los Valles Secos de McMurdo, ver Figura 5., la segmentación con  $k=2$  muestra que el territorio se organiza principalmente en dos grupos: uno dominante que cubre el 78.5% de la imagen y se caracteriza por valores altos en la

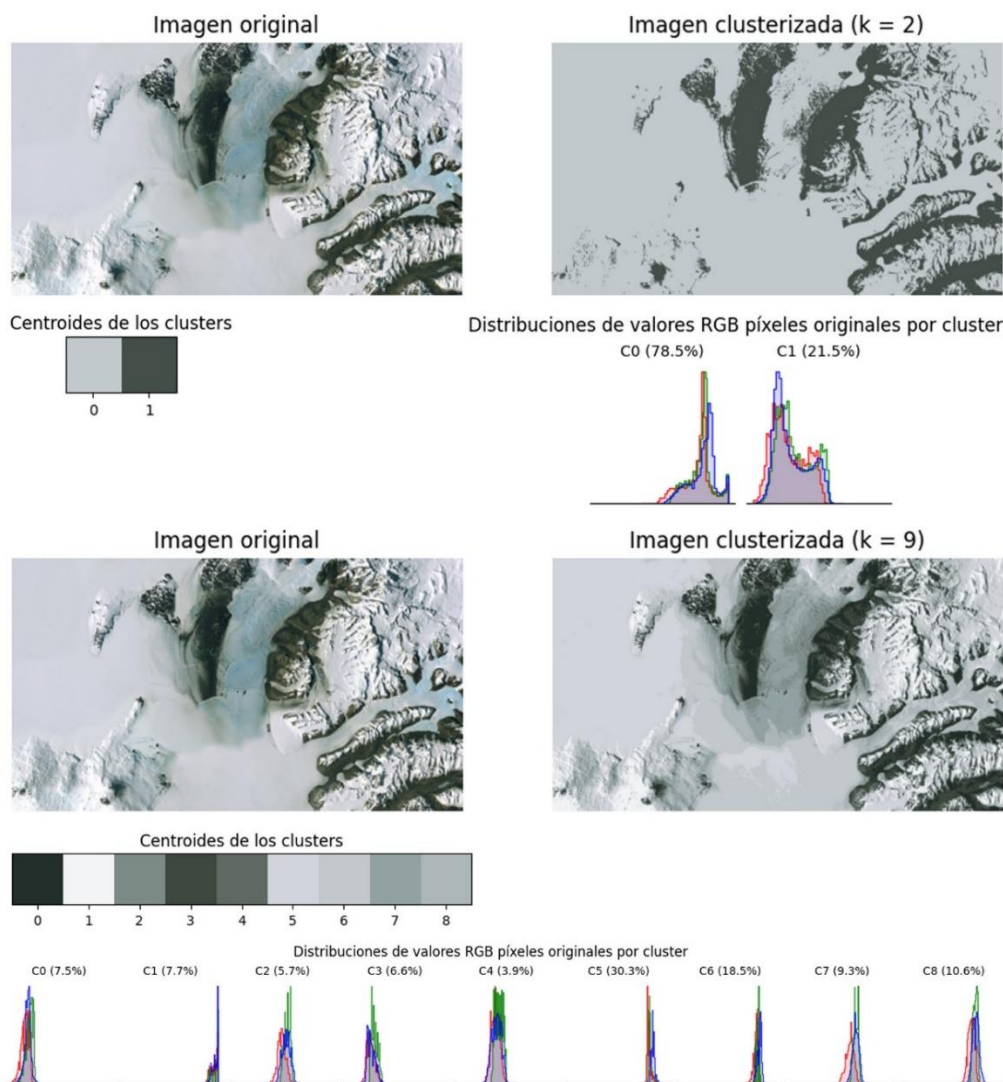
banda azul, y otro grupo (21.5%) que integra áreas de sedimentos expuestos y formaciones rocosas.



**Figura N.º.4.** Lagos efímeros del Sahara, imagen original y segmentaciones ( $k=2$  y  $k=9$ ). Se diferencian el entorno árido y las zonas con presencia de agua. Los histogramas reflejan contrastes entre arena seca y superficies húmedas.

Los histogramas muestran que estas diferencias, aunque sutiles, son detectables mediante la variación en los niveles de reflectancia. Con  $k=9$ , el territorio revela una estructura espectral más rica de lo esperado. La fragmentación cromática distingue superficies congeladas, zonas con acumulación de nieve, áreas de roca

expuesta, sedimentos con mayor contenido mineral y superficies parcialmente cubiertas por hielo. Los clusters más representativos corresponden a variaciones de tonos grisáceos y azulados, particularmente el grupo C5 (30.3%), que agrupa áreas de nieve compacta con alta reflectancia. La emergencia de estas categorías evidencia que incluso en territorios con baja heterogeneidad visual el algoritmo identifica microvariaciones en el espectro visible, lo que refleja la sensibilidad del método ante diferencias mínimas de textura, composición y reflectancia.



**Figura N.º 5. Valles Secos de Mc Murdo, Antártida, imagen original y segmentaciones K-Means ( $k=2$  y  $k=9$ ). La clasificación distingue superficies glaciares, formaciones rocosas expuestas y cuerpos de hielo. Los histogramas evidencian contrastes espectrales asociados a hielo, nieve compacta y material mineral.**

#### 4. Discusión y Recomendaciones

Los resultados obtenidos a partir de la segmentación espectral mediante K-Means en los cuatro territorios analizados permiten discutir, en primer lugar, la capacidad del algoritmo para identificar patrones espaciales relevantes a partir de información espectral mínima. El comportamiento observado confirma que K-Means opera de manera efectiva en contextos donde los contrastes cromáticos responden a dinámicas ambientales intensas, como en La Palma o Bangladesh, y presenta un desempeño adecuado incluso en escenarios cuya homogeneidad visual supone un desafío para los métodos no supervisados, como en McMurdo. La capacidad de distinguir unidades territoriales con base únicamente en valores RGB valida la pertinencia del método como herramienta exploratoria y como punto de partida para análisis más complejos. Este hallazgo coincide con investigaciones que señalan el rol de los algoritmos simples como componentes esenciales de pipelines de análisis territorial en GeoAI, especialmente en fases de presegmentación o reducción del espacio de búsqueda (Ioannilli & Paregiani, 2008; Oyekola & Adewuyi, 2018).

Por otro lado, a diferencia de estudios basados en segmentación profunda mediante redes neuronales convolucionales, los cuales alcanzan mayor precisión temática, el presente trabajo responde a la pregunta de investigación y evidencia que el algoritmo K-Means presenta ventajas en interoperabilidad, bajo costo computacional y aplicabilidad en contextos con limitación de datos etiquetados. Esta diferencia resulta relevante para territorios o instituciones con recursos limitados, donde la disponibilidad de imágenes multiespectrales y datasets de entrenamiento es restringida. La precisión con la que el algoritmo diferencia zonas de lava frente a vegetación o sedimentos frente a agua demuestra que las estructuras cromáticas del espectro visible contienen suficiente información para describir procesos superficiales relevantes. En los territorios áridos del Sahara y los entornos polares de McMurdo, donde los gradientes son sutiles, la segmentación revela microvariaciones que, aunque visualmente discretas, responden a diferencias en reflectancia y textura.

Investigaciones recientes en GeoAI aplicadas a la teledetección han evidenciado una transición hacia modelos híbridos que combinan clustering no supervisado con aprendizaje profundo para mejorar la clasificación temática de coberturas del suelo (Li & Hsu, 2022; Metzler et al., 2025). Así la discusión sugiere que el clustering con RGB, colabora para tener una lectura preliminar del contexto lo que facilita el entendimiento de dinámicas geográficas.

Respecto a la metodología, se pone de manifiesto el impacto que el nivel de granularidad tiene sobre la forma en que se representa el territorio computacionalmente, basado en la comparación entre los valores  $k=2$  y  $k=9$ . La segmentación binaria simplifica la estructura territorial y resalta las discontinuidades dominantes, resultando útil para delimitar áreas con grandes diferencias respecto a la reflectancia, así como identificar zonas homogéneas de gran extensión. En la Palma la lava destaca como una masa espectral visiblemente caracterizada por otro lado, en Bangladesh el algoritmo agrupa los sedimentos, así como los cuerpos de agua superficiales como una categoría dominante. La segmentación con  $k=9$  realiza mapas con mayor detalle, mostrando variaciones internas que no son visibles a primera vista en la imagen original. Esta resolución apoya el estudio y análisis de procesos territoriales complejos, como la dinámica sedimentaria del delta o las transiciones entre superficies áridas y húmedas en el Sahara. El comportamiento dual del algoritmo evidencia la flexibilidad analítica y responde a la necesidad de adaptar el nivel de abstracción según los objetivos del análisis, como lo señala He et al. (2011) en estudios de clasificación no supervisada aplicados a mosaicos urbanos.

Al integrar la segmentación espectral en metodologías para análisis de estudios urbano-territoriales posibilitan integrar el urbanismo computacional, con un enfoque de automatización para tareas de monitoreo, detección y clasificación. La segmentación RGB se establece como una capa inicial simplificada reduciendo la complejidad de las imágenes antes de la aplicación de técnicas avanzadas de GeoAI, como modelos basados en aprendizaje profundo o redes neuronales convolucionales. En estudios contemporáneos la pre-segmentación se usa para

mejorar la eficiencia de los modelos supervisados, así como la precisión, específicamente cuando los conjuntos de entrenamiento resultan limitados (Li & Hsu, 2022). Por otro lado, aunque el estudio no analiza entornos urbanos en una meso o microescala, los resultados en territorios extremos contribuyen evidencia acerca de la robustez del método sobre todo en contextos donde los contrastes cromáticos pueden ser heterogéneos o sutiles, convirtiéndose en una herramienta para el análisis varios contextos como; afectación por fenómenos naturales, entornos urbanos degradados, áreas en transición o periurbanas.

Por otro lado, el enfoque del estudio consideró el uso exclusivo de imágenes RGB como diseño metodológico, el cual buscaba evaluar la capacidad de trabajo del algoritmo con datos no especializados y accesibles, ante esto es importante exponer como transparencia metodológica las limitaciones identificadas, una de ellas es la ausencia de bandas infrarrojas o multiespectrales que limita la capacidad para discriminar fenómenos asociados a temperatura superficial, vegetación, humedad, etc. En análisis que requieren datos con mayor detalle, el uso de imágenes multiespectrales o hiperespectrales serían necesarios para superar las restricciones del espectro visible.

Otra limitación hace referencia a la naturaleza no espacial del algoritmo K-Means, en el cual la relación de vecindades no se incorpora, ante lo cual los clusters pueden agrupar píxeles que, siendo espectralmente similares, no conforman unidades geográficas contiguas. Sin embargo, este fenómeno se configura tanto como oportunidad, así como debilidad, aunque dificulta la interpretación territorial directa, también permite que la segmentación revele patrones espectrales que podrían pasar desapercibidos en técnicas fuertemente dependientes de la geometría

De igual manera, al operar el análisis no supervisado sin etiquetas ni categorías predefinidas, los resultados son agrupaciones espectrales. En estudios complementarios, se recomienda complementar la segmentación con datos levantados en campo, imágenes con mayor GSD o indicadores auxiliares que brinden la interpretación de los clusters de manera más robusta. Sin embargo, esta

investigación reconoce explícitamente estas limitaciones y asume que su objetivo no fue producir una clasificación definitiva, sino explorar la estructura interna del territorio, así como brindar herramientas analíticas para posteriores investigaciones.

Al realizar una comparativa con investigaciones previas, los resultados destacan la utilidad de K-Means como una herramienta previa para examinar estructuras espaciales emergentes. Oyekola & Adewuyi (2018) identificaron transiciones sedimentarias e hídricas en contextos costeros mediante algoritmos de clustering. De igual manera Ioannilli & Paregiani (2008) expusieron que la segmentación espectral permite reconocer unidades geomorfológicas en paisajes volcánicos, aun cuando la textura superficial es altamente variable. Las evidencias en la presente investigación muestran que la estructura espectral del territorio posee suficientes elementos diferenciales para que K-Means genere agrupamientos coherentes en territorios extremos. Sin embargo, también se observa una divergencia parcial respecto a estudios realizados en ambientes polares, donde la literatura reporta dificultades en la separación espectral debido a la homogeneidad cromática (Hamada et al., 2016). En el caso de McMurdo, el algoritmo logró identificar variaciones sutiles, lo que sugiere que la imagen analizada presentaba diferencias de reflectancia más marcadas de lo habitual o que la resolución del sensor permitió captar contrastes suficientes para el análisis.

Se sugiere implementar la segmentación espectral partiendo de un enfoque metodológico mixto en el cual se combinen clustering no supervisado con técnicas supervisadas. La integración permitirá desarrollar cartografía robusta sin incrementar la carga computacional sobre modelos territoriales, debido a que se operará sobre datos territoriales previamente simplificados.

Incorporar información multiespectral e hiperespectral dará mayor robustez en futuras investigaciones, sobre todo en el análisis en zonas en las cuales los contrastes cromáticos no son suficientes para definir unidades representativas. Como ejemplo las bandas infrarrojas aportarían información clave sobre cambios térmicos, humedad, vegetación, etc., fortaleciendo de esta manera el análisis conjunto.

Un aspecto para desarrollar en investigaciones complementarias es la inclusión de métricas cuantitativas de validación, como medidas de distancia intragrupo, índices de cohesión de clusters o análisis silhouette, permitiendo valorar la calidad del agrupamiento con un punto de vista estadístico

Como alcance efectivo el estudio aborda análisis urbanos computacionales, en los que los métodos accesibles, de bajo costo, así como computacionalmente eficientes aportan a la comprensión del territorio en todas sus escalas. Este aspecto es importante en instituciones donde los recursos resultan limitados, debido a la falta de acceso a herramientas tecnológicas. Análisis como la identificación de unidades territoriales, monitoreo ambiental, gestión del riesgo de desastres y generación de insumos para la planificación basada en datos pueden ser obtenidos mediante la segmentación RGB con el uso de clustering, lo cual posiciona como una técnica viable en el apoyo de estos procesos. Evidenciar que el uso de análisis algorítmico en contextos urbano-territoriales puede desarrollarse con recursos mínimos, sin arriesgar el rigor y la coherencia analítica, es el valor que la investigación permitió obtener.

## 5. Conclusiones

La segmentación espectral mediante el algoritmo K-Means es una herramienta que determina patrones urbano-territoriales a través del uso de imágenes satelitales RGB. Se confirma que las diferencias espectrales presentes en el dominio visible facilitan la discriminación de unidades territoriales importantes aun cuando superficies con contrastes cromáticos simulan ser mínimos o donde se generan transiciones complejas en dinámicas ambientales. Así se evidencia que los métodos de clustering no supervisado contribuyen con información específica sin por ello recurrir a modelos con mayor complejidad computacional o insumos multiespectrales.

En relación con los objetivos planteados, los resultados aseveran que K-Means apoya la clasificación inicial e identificación de patrones territoriales, logrando agrupamientos coherentes que evidencia estructuras internas del paisaje. El algoritmo logro distinguir sedimentos y cuerpos de agua en Bangladesh, separar

la lava en la Palma, revelar microvariaciones en la reflectancia de McMurdo, identificar diferencias entre arena seca, así como humedad residual en el Sahara. Confirmando que la segmentación RGB describe dinámicas superficiales relevantes, dependiendo del valor de  $k$ , se puede producir representaciones simplificadas, así como segmentaciones con mayor detalle revelando gradientes internos del territorio.

De esta manera, se constituye una contribución metodológica, ya que se evidencia que K-Means puede funcionar como una técnica exploratoria idónea para destacar estructuras espectrales, para posterior analizarlas desde enfoques geomorfológicos, ambientales, etc. Así la segmentación no solo clasifica, sino que se vuelve una herramienta para identificar unidades o transiciones que mediante inspección visual no son evidentes.

Es relevante mencionar que mediante la selección de imágenes RGB, uno de los insumos mayormente accesibles en teledetección se puede generar una base para procesos analíticos en urbanismo computacional. De esta manera la metodología se vuelve replicable pues no depende necesariamente de sensores avanzados o una infraestructura de cómputo especializada. Siendo esto significativo en ambientes como municipios, instituciones académicas, o equipos técnicos en los cuales el presupuesto es limitado, convirtiéndose en una de las principales limitaciones para acceder a datos y herramientas sofisticadas.

Además, la investigación plantea nuevas hipótesis. Una primera sugiere que la segmentación RGB mediante clustering genera información relevante en el estudio y análisis de territorios donde las transiciones materiales muestran variabilidad considerable o donde los contrastes cromáticos son intensos, como en áreas industrializadas, paisajes degradados o zonas periurbanas. Otra hipótesis establece que el desarrollo del algoritmo mejoraría sustancialmente al incorporar métricas de textura o variables espaciales, lo que permitiría a los clusters relejar similitud espectral, así como continuidad geográfica. Estas hipótesis incentivan la implementación de variantes como K-Means espacial o métodos integrados que combinen filtros de contigüidad y clustering.

Aun cuando K-Means presenta barreras tales como ausencia de criterios espaciales o dependencia del parámetro  $k$ , su contribución para evidenciar estructuras espectrales afirma que constituye un componente válido para desarrollar procesos de análisis urbano-territoriales con el apoyo de datos, afirmando el valor del análisis no supervisado. Su posterior aplicación a distintos contextos muestra que, en ambientes heterogéneos u homogéneos, el algoritmo es capaz de extraer elementos significativos que aporten a la comprensión de dinámicas territoriales, ambientales, geomorfológicas, etc.

Por otro lado, las líneas de investigación a desarrollar es la evaluación del algoritmo a series temporales en contextos en los cuales los cambios son acelerados y recurrentes; la evolución espectral de manera multitemporal respecto a fenómenos como las inundaciones estacionales, las erupciones volcánicas, la desertificación, la variación de hielo nieve permite valorar la capacidad de K-Means para identificar patrones de cambio y caracterizar dinámicas territoriales a partir de variaciones cromáticas mínimas; Relación con la integración del clustering RGB como etapa previa en modelos de aprendizaje profundo orientados a clasificación supervisada; planificación territorial basada en inteligencia artificial, permitiendo generar segmentaciones coherentes en entornos tan complejos y distintos. Así la segmentación podría actuar como un mecanismo de reducción de ruido que facilite la construcción de conjuntos de entrenamiento más representativos, especialmente en territorios donde las clases temáticas son difíciles de definir sin un procesamiento previo. De esta forma se alineará a tendencias en GeoAI respecto a procesos escalabres e híbridos articulando métodos avanzados y simples.

Las diferentes reflexiones aportan la idea de que el uso de segmentación espectral RGB mediante clustering no supervisado se transforma en una herramienta metodológica para estudios aplicados urbano-territoriales. Su reproductividad y accesibilidad lo transforma en un elemento clave en enfoques emergentes sobre todo en campos como el urbanismo computacional, la teledetección y el análisis geoespacial guiado por inteligencia artificial.

## 6. Referencias

- Ahmed, M., Seraj, R., & Islam, S. M. S. (2020). *The k-means Algorithm: A Comprehensive Survey and Performance Evaluation*. Electronics, 9(8), 1295. <https://doi.org/10.3390/electronics9081295>
- Batty, M. (2021). *Inventing future cities*. <https://mitpress.mit.edu/9780262038959/inventing-future-cities/>
- Biljecki, F., & Ito, K. (2021). *Street view imagery in urban analytics and GIS: A review*. Landscape and Urban Planning, 215, 104217. <https://doi.org/10.1016/j.landurbplan.2021.104217>
- Bushra, S., Mubbin, M., Haseeb, M., Tahir, Z., Hassan, S., Kucher, D., Kucher, O., & Al-Wadud, M. *Multisensor Remote Sensing and AI-Driven Analysis for Coastal and Urban Resilience Classification*. IEEE Journal of selected topics in applied earth observations and remote sensing, 18, 9166–9180. <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=10938888>
- Hamada, Y., O'Connor, B. L., Orr, A. B., & Wuthrich, K. K. (2016). *Mapping ephemeral stream networks in desert environments using very-high-spatial-resolution multispectral remote sensing*. Journal of Arid Environments, 130, 40–48. <https://doi.org/10.1016/j.jaridenv.2016.03.005>
- He, C., Wei, A., Shi, P., Zhang, Q., & Zhao, Y. (2011). *Detecting land-use/land-cover change in rural–urban fringe areas using extended change-vector analysis*. International Journal of Applied Earth Observation and Geoinformation, 13(4), 572–585. <https://doi.org/10.1016/j.jag.2011.03.002>
- Ikotun, A. M., Ezugwu, A. E., Abualigah, L., Abuhaija, B., & Heming, J. (2023). *K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data*. Information Sciences, 622, 178–210. <https://doi.org/10.1016/j.ins.2022.11.139>
- Ioannilli, M., Pargiani, A. (2008). *Automated Unsupervised Geomorphometric Classification of Earth Surface for Landslide Susceptibility Assessment*. In: Gervasi, O., Murgante, B., Laganà, A., Taniar, D., Mun, Y., Gavrilova, M.L. (eds) Computational Science and Its Applications – ICCSA 2008. ICCSA 2008. Lecture Notes in Computer Science, vol 5072. Springer, Berlin, Heidelberg. [https://doi.org/10.1007/978-3-540-69839-5\\_21](https://doi.org/10.1007/978-3-540-69839-5_21)
- Li, W., & Hsu, C.-Y. (2022). *GeoAI for Large-Scale Image Analysis and Machine Vision: Recent Progress of Artificial Intelligence in Geography*. ISPRS International Journal of Geo-Information, 11(7), 385. <https://doi.org/10.3390/ijgi11070385>

- Liu, Y., Liu, S., Xu, J., Wang, Y., Tan, G., Li, D., & Fan, B. (2021). *A new clustering algorithm toward building segmentation from aerial images by utilizing RGB-component differences*. *Earth and Space Science*, 8(8), e2020EA001571. <https://doi.org/10.1029/2020EA001571>
- Metzler, A. B., Nathvani, R., Sharmanska, V., Bai, W., Moulds, S., Owoo, N. S., Fynn, I. E. M., Muller, E., Dufitimana, E., Akara, G. K., Owusu, G., Agyei-Mensah, S., & Ezzati, M. (2025). *Unsupervised deep clustering of high-resolution satellite imagery reveals phenotypes of urban development in Sub-Saharan Africa*. *Science of The Total Environment*, 988, 179739. <https://doi.org/10.1016/j.scitotenv.2025.179739>
- Na, S., Xumin, L., & Yong, G. (2010). *Research on k-means clustering algorithm: An improved k-means clustering algorithm*. 2010 Third International Symposium on Intelligent Information Technology and Security Informatics (pp. 63–67). IEEE. <https://doi.org/10.1109/IITSI.2010.74>
- Oyekola, M. A., & Adewuyi, G. K. (2018). *Unsupervised classification in land cover types using remote sensing and GIS techniques*. *International Journal of Science and Engineering Investigations*, 7(72), 11-18. ISSN 2251-8843.
- Ramírez-Juidias E, Antón D. *Geospatial Analysis of the Roman Site of Munigua Based on RGB Airborne Imagery*. *Remote Sensing*. 2025; 17(18):3224. <https://doi.org/10.3390/rs17183224>
- Vachmanus, S., Ravankar, A. A., Emaru, T., & Kobayashi, Y. (2021). *An evaluation of RGB-thermal image segmentation for snowy road environment*. In 2021 IEEE International Conference on Mechatronics and Automation (ICMA) (pp. 224–230). IEEE. <https://doi.org/10.1109/ICMA52036.2021.9512708>