

Diseño de geometría para levantamientos de gravimetría y magnetometría con aprendizaje profundo

Sebastián Martínez-Acevedo^{1*} ; Sait Khurama¹ ;
Luis Carlos Mantilla-Figueroa¹ ; Paul Goyes-Peñafiel¹ 

¹Escuela de Geología, Universidad Industrial de Santander, Bucaramanga, Colombia.
(*): juan2208447@correo.uis.edu.co; skhurama@uis.edu.co; lcmantil@uis.edu.co;
ypgoype@correo.uis.edu.co

Resumen

En la exploración geofísica, el análisis del terreno es fundamental para planificar la adquisición de datos de gravimetría y magnetometría. No obstante, en la actualidad dichos análisis requieren el uso supervisado de información secundaria extensa. Por este motivo, en este estudio se propone una metodología que utiliza el aprendizaje profundo para evaluar el impacto de la cobertura vegetal y la topografía en la adquisición geofísica. Se usó una red neuronal artificial perceptrón multicapa para considerar cinco variables terrestres, y una red neural convolucional para la clasificación automatizada de coberturas vegetales sobre imágenes satelitales. A partir de esto, se obtuvieron puntos para la localización de estaciones de levantamiento geofísico que cumplen con un criterio de favorabilidad por accesibilidad, distancias, restricciones por cuerpos de agua y coberturas boscosas. La geometría obtenida se evaluó en la exploración del Granito de Durania en Colombia, y los resultados se analizaron utilizando transectas de adquisición y modelado computacional de anomalías magnéticas y de gravedad. Finalmente, se aplicaron técnicas de interpolación donde el método Ponderación de Distancia Inversa (IDW) mostró la mejor imagen para interpretar la delimitación del cuerpo intrusivo.

Palabras clave: Aprendizaje profundo; Exploración geofísica; Modelamiento; Diseño de adquisición.

Geometry design for gravimetry and magnetometry surveys using deep learning

Abstract

In geophysical exploration, terrain analysis is fundamental for planning the gravity and magnetic surveys. However, current analyses necessitate supervised use of extensive secondary information. Consequently, this study proposes a methodology that leverages deep learning to assess the impact of vegetation coverage and topography in geophysical acquisition. An artificial neural network multilayer perceptron was used to consider five terrain-related variables, while a convolutional neural network is used for automated classification of vegetation cover on satellite imagery. From this, geophysical acquisition points are obtained, adhering to criteria involving accessibility favourability, distances, restrictions imposed by bodies of water, and forested cover. The obtained geometry was tested in the exploration of the Granito de Durania in Colombia, and the results were analysed using acquisition transects and computational modelling of gravity and magnetic anomalies. Interpolation techniques were applied, with the Inverse Distance Weighting (IDW) method yielding the most informative map for interpreting the delineation of the intrusive body.

Keywords: Deep learning; Geophysical exploration; Forward modeling; Acquisition design.

Introducción

La exploración geofísica desempeña un papel esencial en la caracterización subsuperficial de cuerpos de interés minero-económicos para diversos fines, incluyendo la evaluación de recursos y estudios medioambientales (Kearey *et al.*, 2002). El diseño de geometrías de adquisición en geofísica representa un elemento crucial en el proceso de obtención de datos. A menudo, este proceso implica desafíos relacionados con restricciones ambientales y topográficas que requieren adaptaciones sobre el terreno. Estas adaptaciones pueden resultar en estrategias de recolección de datos menos eficientes y, en última instancia, afectar la calidad de los resultados (Hernández *et al.*, 2011). Anticipar los posibles impactos en la geometría de adquisición antes de la campaña de campo es una estrategia valiosa. Esto permite no solo analizar distintas estrategias computacionales para abordar la dispersión de datos, sino también optimizar el uso del tiempo y recursos (Hernandez-Rojas y Arguello, 2022). En la última década, la integración de técnicas de aprendizaje profundo con el conocimiento experto ha emergido como un enfoque prometedor para el análisis de grandes conjuntos de datos (Gardner y Nichols, 2017; Goyes-Peña *et al.*, 2023), lo que supone una oportunidad para su uso en la exploración del subsuelo enfocado en mejorar la calidad y eficiencia en el diseño de geometrías de adquisición geofísica.

El aprendizaje profundo, en particular, ha demostrado ser eficaz en agilizar ciertos aspectos del proceso de diseño. Por ejemplo, las Redes Neuronales Convolucionales (CNN, por sus siglas en inglés) pueden clasificar rápidamente la cobertura vegetal en áreas extensas, mientras que redes completamente conectadas permiten estimar regiones de alta complejidad topográfica a partir de modelos digitales del terreno. El impacto del Aprendizaje Profundo ha tenido un auge en años recientes y ha dado lugar a investigaciones en las ciencias de la Tierra que involucran análisis de deforestación, usos del suelo, entre otros (Gardner y Nichols, 2017; Pritt y Chern, 2017; Prathap y Afanasyev, 2018; Ball *et al.*, 2022). Adicionalmente, los avances de este campo de estudio se han observado en la clasificación de imágenes (Simonyan y Zisserman, 2014; Zeiler y Fergus, 2014; Krizhevsky *et al.*, 2017) donde, los resultados,

apuntan al mejoramiento de las estructuras con el fin de optimizar la profundización del método a través de regresiones logísticas multinomiales (Simonyan y Zisserman, 2014). Esta integración de información desempeña un papel crucial en el diseño de geometrías de adquisición basadas en las mediciones localizadas en datos puntuales, como la exploración con los métodos de gravimetría y magnetometría.

En este trabajo se presenta una metodología donde se implementa el Aprendizaje Profundo como una herramienta para la clasificación de imágenes satelitales (proyectos Sentinel-2 y ALOS-PALSAR) con redes neuronales convolucionales (CNN). Para la predicción de variables asociadas al terreno se usó una red neuronal artificial perceptrón multicapa (RNAPM) considerando restricciones ambientales y topográficas. El enfoque propuesto se llevó a cabo en un área caracterizada por tener una complejidad topográfica asociada a un cuerpo intrusivo geológicamente denominado “Granito de Durania” en Norte de Santander, Colombia. Las geometrías resultantes se utilizaron en adquisiciones sintéticas/modeladas y se obtuvieron delineaciones de anomalías gravimétricas y magnéticas aplicando métodos de interpolación basados en Kriging Ordinario (OK), Ponderación de Distancia Inversa (IDW) (Li y Heap, 2014; Borges *et al.*, 2016), y Bosque Aleatorio (RF) (Pouladi *et al.*, 2019; Sekulić *et al.*, 2020). Este trabajo representa una contribución significativa al diseño de geometrías de adquisición que tienen en cuenta los factores del terreno en la exploración geofísica, mejorando en última instancia la eficacia de los procesos de recopilación de datos gravimétricos y magnetométricos.

Métodos y datos

Zona de estudio

En este trabajo se propone analizar la zona geológicamente relacionada con el Granito de Durania en Norte de Santander (Figura 1). Esta área tiene un interés geológico debido a su potencial minero-económico asociado (Mantilla *et al.*, 2009, 2011) y por la presencia conocida de zonas de difícil acceso, boscosas y de vegetación espesa, topografía irregular y cuerpos de agua, en la cual es clave una correcta definición de los puntos para la medición de datos gravimétricos y magnéticos.

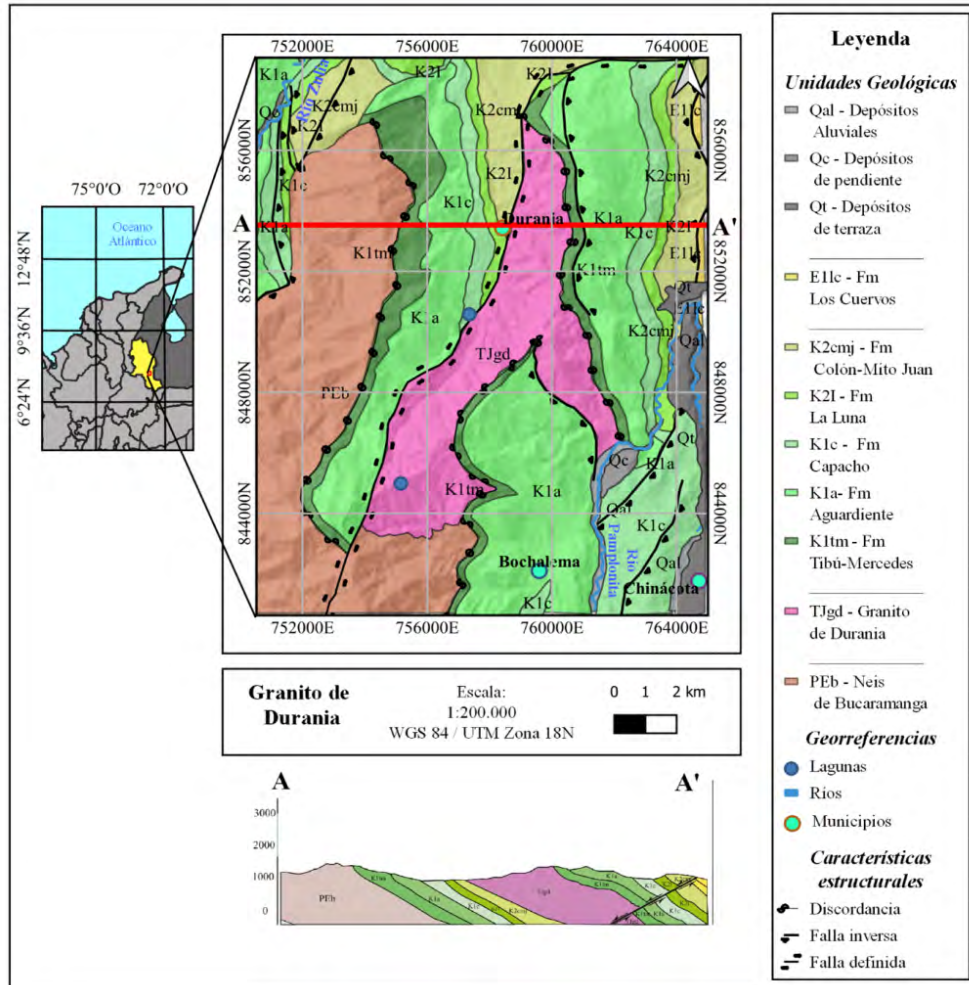


Figura 1. Mapa geológico de la zona de estudio con una extensión de 269,8 km². Geográficamente cercano al municipio de Durania, Norte de Santander. Adaptado de Fúquen *et al.* (2010).

Geológicamente este cuerpo corresponde a un granito blanco moscovítico (Ward *et al.*, 1973) originado por la inyección de magmas mantélicos en la corteza. La edad de este cuerpo se ha determinado por el método U-Pb en circones, resultando 442,6 Ma (+7,4/-6,0 Ma) (Botello-Becerra, 2014) correspondiente al Triásico-Jurásico. Adicionalmente, se considera que el Granito de Durania intruyó el basamento metamórfico del Macizo de Santander (Alarcón *et al.*, 2020) y se emplazó durante el Cretácico (Rojas-Barbosa, 2013) en las formaciones sedimentarias. Estas consideraciones geológicas sugieren, además del potencial extractivo mencionado, altos contrastes en las propiedades físicas (densidad y susceptibilidad magnética) entre la litología intrusiva y la sedimentaria que requieren de una geometría de exploración adecuada que permitan una correcta interpretación.

Clasificación de coberturas y predicción de variables del terreno

Clasificación de coberturas: la clasificación de coberturas se realizó usando una imagen Sentinel-2 y EUROSAT aplicando aprendizaje profundo a través de la potencialidad que tienen estos métodos en la tarea de clasificación, y especialmente con el uso de redes convolucionales sobre imágenes (Guo *et al.*, 2017). Para Sentinel-2, se consideró una adquisición con cobertura de nubes del 3% con fecha 4 de febrero de 2021; disponible en el portal *Earth Explorer* del Servicio Geológico de Estados Unidos (Figura 2) (Copernicus Sentinel Data, 2021) y el conjunto de imágenes Sentinel-2 clasificadas EUROSAT (22000 imágenes) (Helber *et al.*, 2018, 2019) donde hay imágenes dentro de las siguientes etiquetas: cultivo anual, bosque, vegetación herbácea, pasto, cultivo permanente, residencial, río y mar-lago.

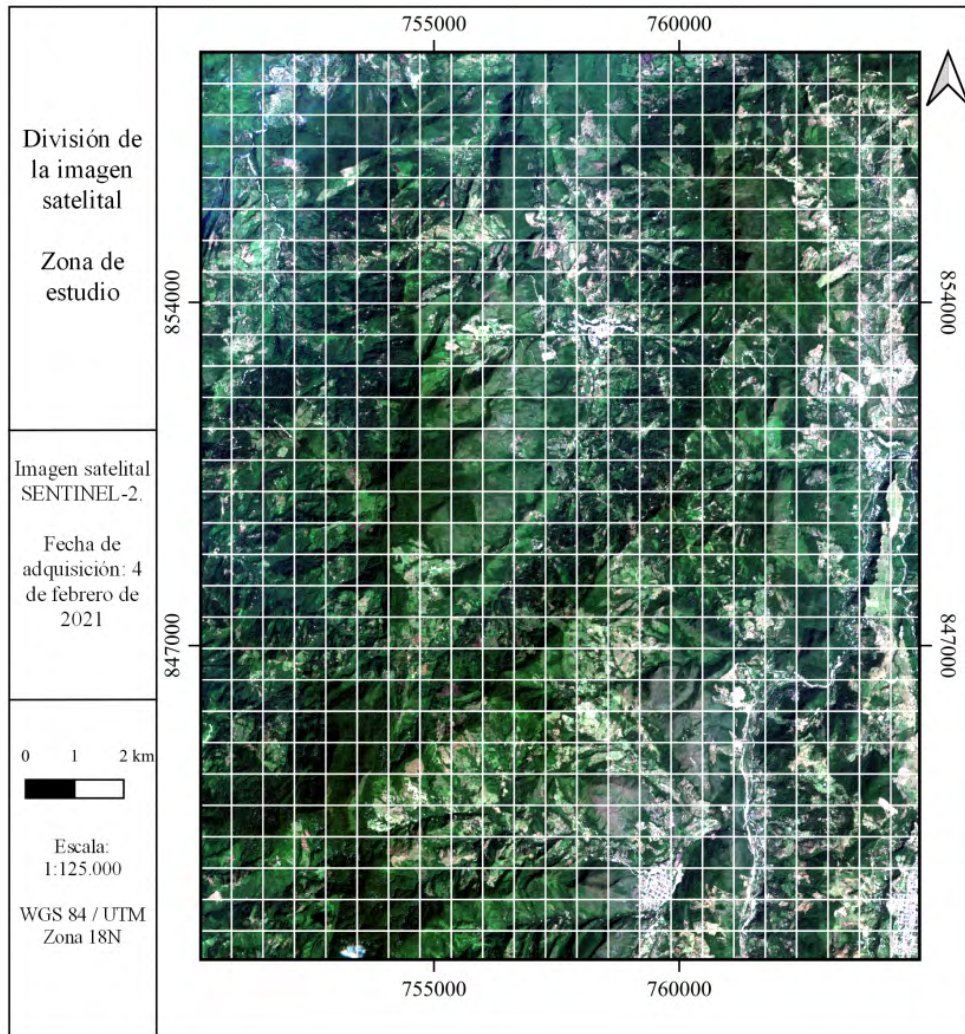


Figura 2. División de la imagen satelital en ventanas de clasificación. Las ventanas de clasificación en bordes blancos se delimitaron según las dimensiones del conjunto de datos de entrenamiento EUROSAT, cuyas dimensiones eran de 64 x 64 píxeles y 3 bandas (R, G, B) para un total de 667 ventanas.

En esta investigación se usó el aprendizaje profundo para analizar la favorabilidad de los siguientes factores condicionantes: 1) las coberturas vegetales debido al efecto multitrayecto que generan zonas espesas sobre el posicionamiento GPS y a las zonas de propiedad privada donde el acceso sería restringido, 2) las características del terreno como la inestabilidad, la irregularidad y la inclinación de zonas que dificultarían el acceso y afectarían la calidad del dato, y 3) los cuerpos de agua debido a la carencia de equipos adecuados para adquisiciones en medio acuático y sus efectos sobre la calidad del dato.

Para la clasificación de coberturas se implementó una Red Neuronal Convolutiva (CNN), donde se incluyeron las imágenes de EUROSAT como datos de

entrenamiento. Así, y a partir de pruebas de verificación y evaluación hechas durante la arquitectura, se determinó un 75% (16500) de las imágenes para el grupo de entrenamiento (subdividido a 12375 de entrenamiento y 4125 de validación) y, el 25% (5500) restante, se consideró como grupo de prueba. El diseño de la red se hizo de tipo secuencial (un solo valor de salida para un valor de entrada) donde se incluyó un optimizador de tipo *RMSprop*, una función de pérdida tipo *categorical Crossentropy* y una métrica de precisión *accuracy*. Estos parámetros permiten a la CNN desarrollar una clasificación multiclase como se describe en [Guo et al. \(2017\)](#) y [Sultana et al. \(2018\)](#); y se configuró de acuerdo con el mejor desempeño obtenido siguiendo los detalles de implementación mostrados en [Developers \(2022\)](#). En la [Figura 3](#) se

muestran los tamaños y cantidad de filtros, además de cada operación convolucional dentro de la red, finalizando con una capa de salida completamente conectada (*fully-connected*).

Variabes del terreno: para llevar a cabo la predicción de las variables asociadas al terreno se implementó una Red Neuronal Artificial Perceptrón Multicapa (RNAPM) como se muestra en la [Figura 4](#), la cual contiene una capa de entrada con 5 neuronas, una capa oculta con 12 neuronas que usan la función de activación *ReLU*, y una capa de salida con la función de salida *Sigmoid*, para los cálculos del gradiente y su propagación hacia atrás se usó el optimizador *Adam* (Kingma y Ba, 2015), y la función de pérdida *Binary Crossentropy* con una métrica de precisión *accuracy*. Esta configuración permite a la red clasificar a la zona de estudio entre 0 y 1, donde los valores superiores a 0 corresponden a las zonas donde se consideraría favorable la adquisición. Esta arquitectura de red completamente conectada se diseñó siguiendo las definiciones y parámetros trabajados en Goyes-Peñafliel y Hernández-Rojas (2021a, 2021b).

Para el entrenamiento se usaron 500 coordenadas con datos extraídos del modelo de elevación digital DEM (ASF DAAC, 2015). Sobre esos datos se consideró una división de la siguiente forma: 60% datos de entrenamiento y 40% de validación. Esta división es producto de la verificación y evaluación de rendimiento computacional de la red durante las pruebas. Para los

datos extraídos por las coordenadas, se consideraron 5 variables asociadas al terreno: pendiente, rugosidad, orientación, curvatura tangencial y curvatura de perfil. La incorporación de estas variables permite eliminar el sesgo univariable asociado a la predicción. Asimismo, previo al entrenamiento de la red, se realizó una clasificación binaria sobre la variable pendiente ([Figura 5](#)) para la solución del diseño de adquisición. La clasificación binaria se realizó a partir de pruebas de verificación y evaluación donde se estimó que las pendientes favorables estaban en un rango inferior a 10° y que están relacionadas con la ejecución real de proyectos de adquisición en zonas montañosas, donde la logística se ve afectada principalmente por la pendiente del terreno.

Cuerpos de agua: el análisis de factores condicionantes presentes en la zona de estudio se complementó con la ubicación e identificación de cuerpos de agua presentes en la zona. Así, se consideró la información georreferenciada disponible desde el Instituto Geográfico Agustín Codazzi (IGAC) (planchas 98IB, 98ID, 98IIA, 98IIC, 98IIIB y 98IVA) donde se delimitaron los ríos Pamplonita y Zulia, al igual que dos lagunas no nombradas (Instituto Geográfico Agustín Codazzi, 2018). Con esta información georreferenciada se complementa y fortalece la estimación de la favorabilidad de puntos de adquisición geofísica implementada en la clasificación resultante. Así, se garantizará que las coordenadas de adquisición no coincidan con la ubicación de los cuerpos de agua.




Figura 3. Arquitectura de la Red Neuronal Convolutional. La función de activación empleada en las capas ocultas es de tipo ReLu, mientras que la de salida es la softmax.

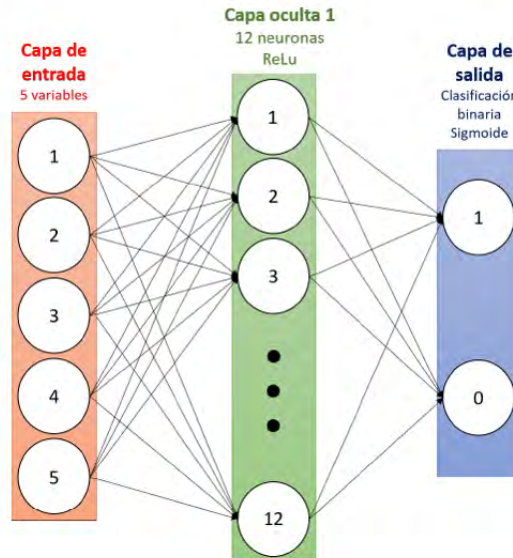


Figura 4. Modelo de Red Neuronal Artificial Perceptrón Multicapa para predecir la favorabilidad de la medición en puntos de adquisición a partir del análisis de terreno con 5 variables de entrada.

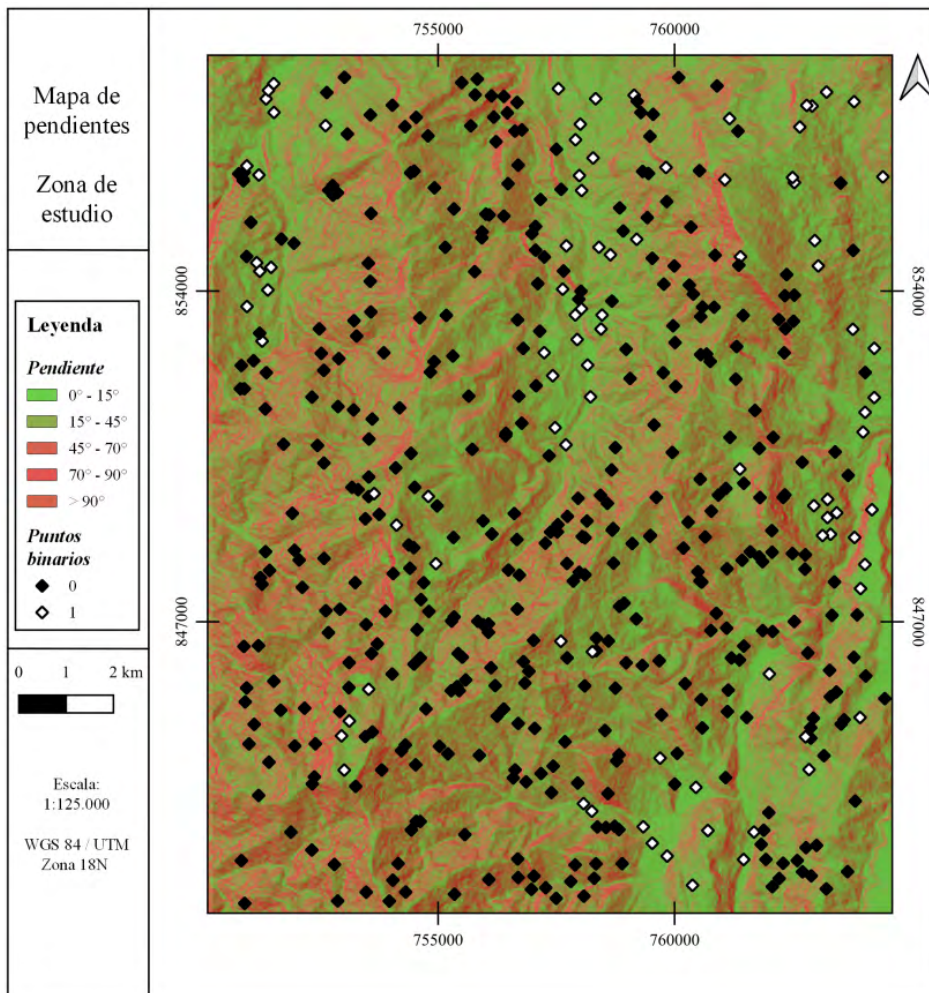


Figura 5. Puntos de entrenamiento sobre la variable pendiente del terreno.

Evaluación del diseño de adquisición

Para evaluar las geometrías obtenidas, se usaron los puntos de muestreo sobre una adquisición simulada en los levantamientos de gravimetría y magnetometría con la librería SIMPEG (Cockett *et al.*, 2015). La construcción del modelo 3D se realizó con una malla refinada sobre el cuerpo intrusivo, esta estrategia permite optimizar la discretización de modelos geológicamente complejos (Torres y Goyes-Peñañiel, 2013). Posteriormente, y siguiendo un flujo típico en la interpretación de datos geofísicos, se aplicaron técnicas de interpolación para generar imágenes geofísicas que cubran el área de estudio y determinar anomalías asociadas al levantamiento. Las técnicas de interpolación usadas fueron Kriging Ordinario (OK), Ponderación de Distancia Inversa (IDW), y un método basado en *machine learning* llamado Bosque Aleatorio (RF). Así, mediante los algoritmos de la librería *PyKrig* en Python (OK), el módulo de IDW en QGIS y la librería *Sklearn* de Python (RF), se ejecutaron las

interpolaciones de datos simulados. Cabe destacar que para IDW y RF se establecieron los valores por defecto para la ejecución de los códigos. Los resultados finales se evaluaron mediante tres métricas de error que relacionan al dato simulado con el resultado de la interpolación. Las tres métricas de error implementadas fueron Error Absoluto Medio (MAE), Error Cuadrático Medio (MSE) y coeficiente de determinación (r^2).

Resultados

Clasificación de coberturas y predicción de variables del terreno

Una vez entrenadas la CNN y la RNAPM, se obtuvieron las clasificaciones correspondientes para la cobertura del suelo y la predicción de la favorabilidad en función de las variables del terreno. De esta forma, el etiquetado de coberturas obtenido arrojó zonas de bosque, pasto, vegetación herbácea, residencia, cultivos anuales y cultivos permanentes (Figura 6).

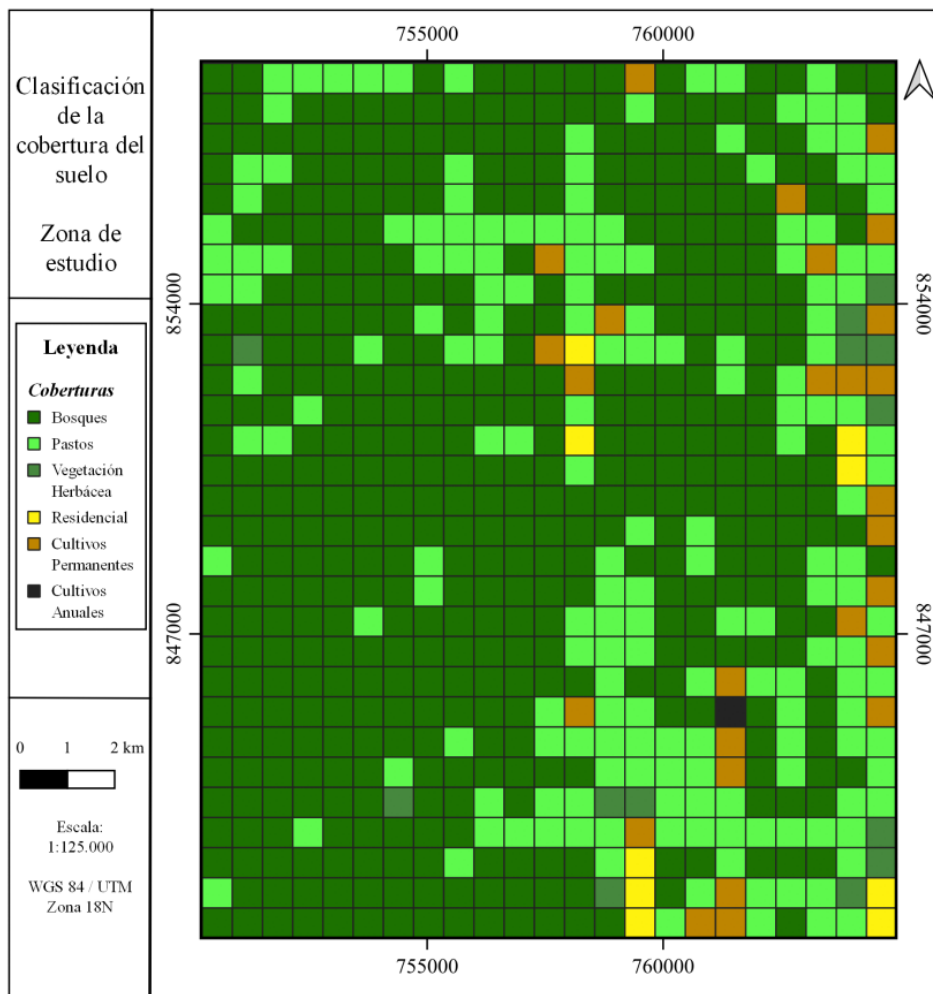


Figura 6. Clasificación de la cobertura del suelo con la red neuronal convolucional e imágenes satelitales.

La predicción realizada en función de las variables del terreno (pendiente, rugosidad, orientación, curvatura tangencial y curvatura de perfil) se ejecutó en 200 épocas con una exactitud de prueba 0,87 y una pérdida de prueba de 0,3. La predicción arrojó un ráster multibanda de 1791305 píxeles donde se encontraron tres rangos de favorabilidad: 1) píxeles con un valor mayor a 0,1507 favorables, 2) entre 0,027 y 0,1507, medianamente favorables y 3) menores a 0,027 zonas de baja favorabilidad para la adquisición (Figura 7).

Para el diseño final de la geometría de adquisición, se trazaron 31 transectas sobre zonas donde surgiera una continuidad entre probabilidades medias y altas (amarillo y verde, respectivamente) de tal manera que se lograra una extensión de terreno aceptable para realizar las adquisiciones de los métodos de gravimetría y magnetometría; además de evitar los cuerpos de agua georeferenciados. Estas transectas suponen

recorridos para ambos métodos con el fin de optimizar la logística de adquisición. Sobre las transectas trazadas, se puntualizaron zonas de adquisición cada 100 m generando un total de 234 puntos sugeridos para las adquisiciones (Figura 8). Durante el trazado de puntos se ubicaron 5 transectas sobre el afloramiento del cuerpo intrusivo (transectas 10, 15, 16, 20 y 26) de acuerdo con los puntos de acceso y la favorabilidad. En las zonas donde no aflora el Granito de Durania, se trazaron 26 transectas en función de los puntos de acceso, cercanía a los municipios y la favorabilidad de la zona. Por ejemplo, al oeste de Durania se trazaron 7 transectas, mientras que al este otras 5. Al norte de Chinácota se ubicaron 2, mientras que en cercanías de Bochalema se trazaron 12. Cabe mencionar que las vías de acceso están trazadas, en su mayoría, siguiendo la trayectoria del Río Pamplonita y conectando a los municipios. Por esto, la mayoría de las transectas buscan las zonas de favorabilidad en cercanía a los municipios.

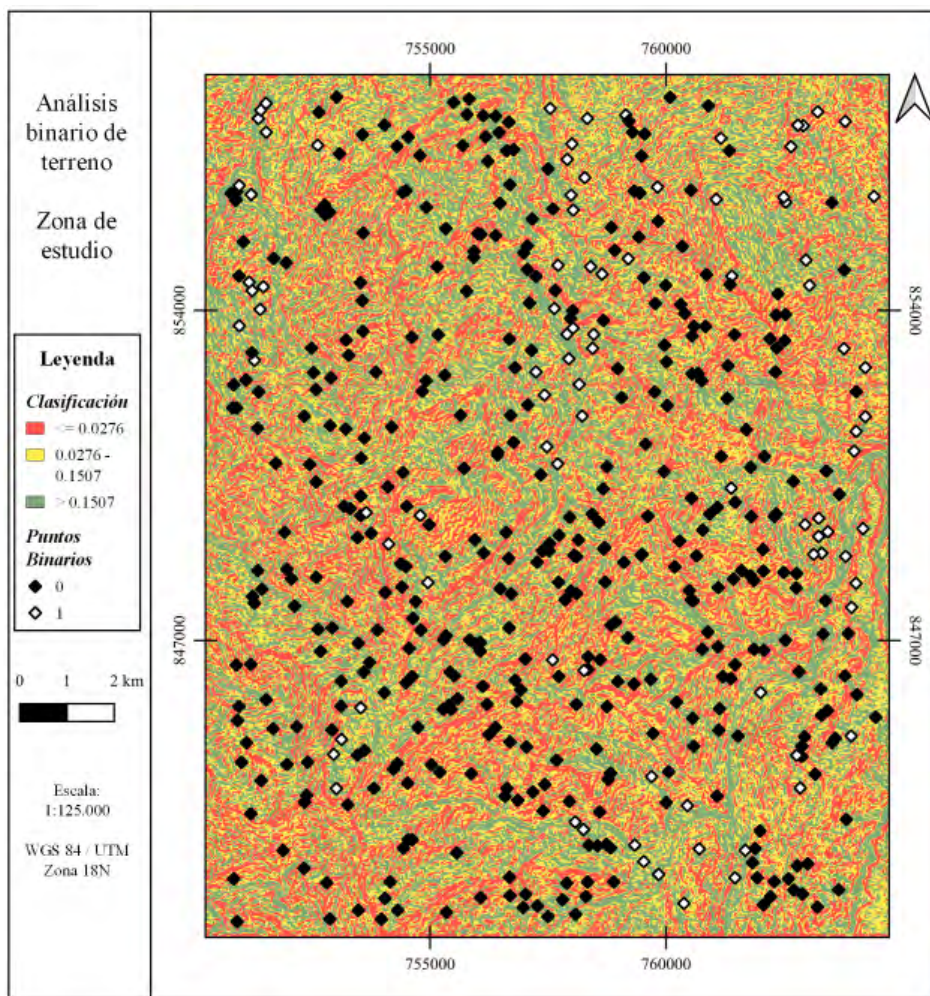


Figura 7. Análisis binario del terreno. Las zonas verdes corresponden con una favorabilidad alta en la medición de datos puntuales, y las zonas rojas indican una mayor restricción.

Evaluación del diseño: simulación e interpolación espacial de datos

La evaluación del diseño se realizó mediante la simulación de una adquisición de gravimetría y magnetometría sobre la zona de estudio. Para esto, se utilizó la geometría obtenida (Figura 8) y se elaboró un modelo tridimensional del Granito de Durania para evaluar el impacto de la limitada cantidad de puntos de adquisición diseñados respecto al área de estudio y realizar una interpolación de mediciones geofísicas usada con frecuencia para la elaboración de mapas asociados a la interpretación de datos geofísicos.

El modelo 3D de la Figura 9 consiste en la construcción computacional del Granito de Durania donde se incluyen las propiedades físicas de interés como la densidad y susceptibilidad magnética, el cual

está basado en el corte geológico de la plancha 98 (Fúquen *et al.*, 2010) que se muestra en la Figura 1. La reconstrucción computacional y la simulación de datos se realizaron con la librería SimPEG (Cockett *et al.*, 2015). Con el fin de establecer un contraste sobre el cuerpo intrusivo, se establecieron dos litologías en la zona: una sedimentaria (densidad: 2,42 y susceptibilidad magnética de 0,0001 SI; Lowrie, 2007) y otra intrusiva (2,61 y 0,01 SI; Lowrie, 2007), con un contraste positivo de densidad de 0,19 g/cm³. Adicionalmente, para la simulación de la respuesta del campo magnético se asumió la dirección de un campo inductivo con inclinación (31,06°), declinación (-9,25°) e intensidad horizontal (27117 nT), correspondientes a la ubicación geográfica del área de estudio (NCEI Geomagnetic Modelling Team, 2009).

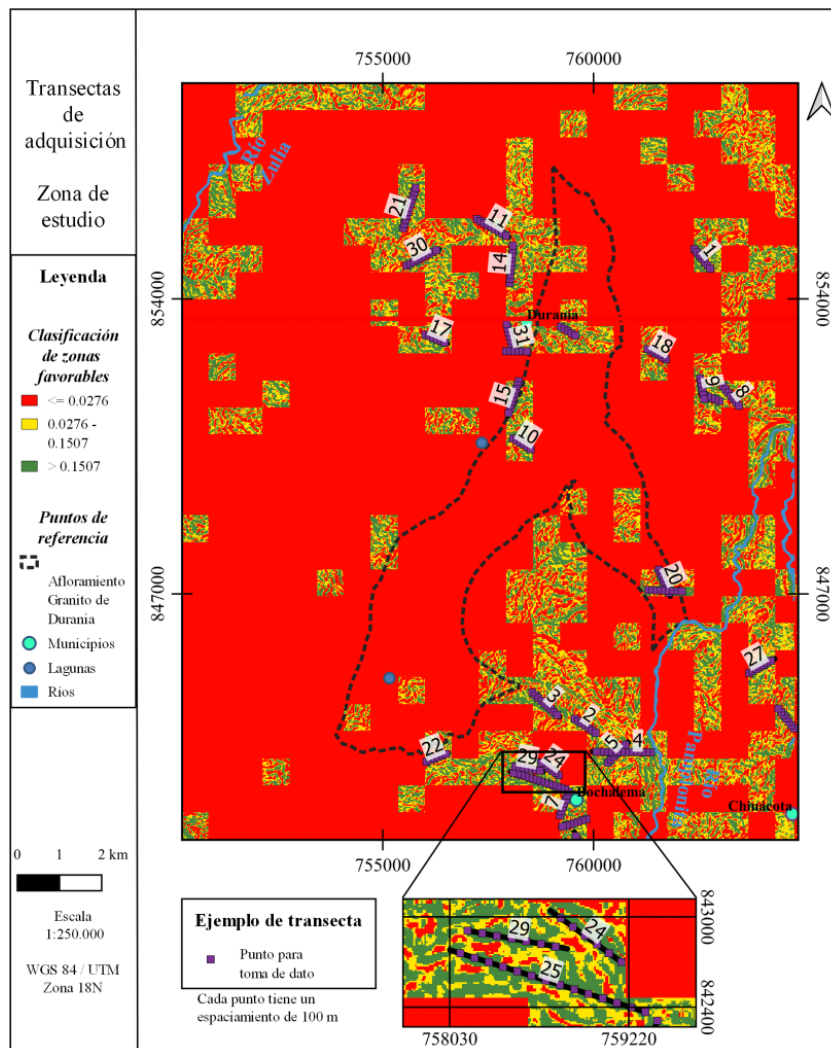


Figura 8. Transectas de adquisición. Las zonas poco favorables para la adquisición se muestran en color rojo con probabilidad $\leq 0,0276$ y las cuales se excluyen completamente del análisis. En la parte inferior se observa un acercamiento a una de las zonas y se muestra un ejemplo del resultado de dividir una transecta en puntos separados cada 100 m.




Figura 9. Modelo de densidades y susceptibilidades en los cortes $z=-500$, $y=0$, $x=2500$. La discretización usada corresponde a una malla refinada sobre el Granito de Durania.

De la simulación se obtuvo un conjunto de datos de gravimetría y magnetometría (Figuras 10A y 10B) en las posiciones de la geometría obtenida por el método propuesto sobre los 234 puntos de muestreo. Además, la medición fue contaminada con ruido gaussiano con desviación estándar de 0,001 mGal más 1% de la medición máxima para simular condiciones de campo típicas de este tipo de adquisiciones. Posteriormente, se llevó a cabo la interpolación de las mediciones aplicando los métodos de Kriging Ordinario (OK) (Figuras 11A, 11B), Ponderación de Distancia Inversa (IDW) (Figuras 11C, 11D) y Bosque Aleatorio (RF) (Figuras 11E, 11F). En el caso de OK se implementó un modelo de semi-variograma esférico y un número de intervalo promedio de 30, mientras que para IDW se utilizó el coeficiente de distancia de 2 y un número de intervalo promedio de 30, mientras que para RF se usaron los valores predeterminados en la librería de Python.

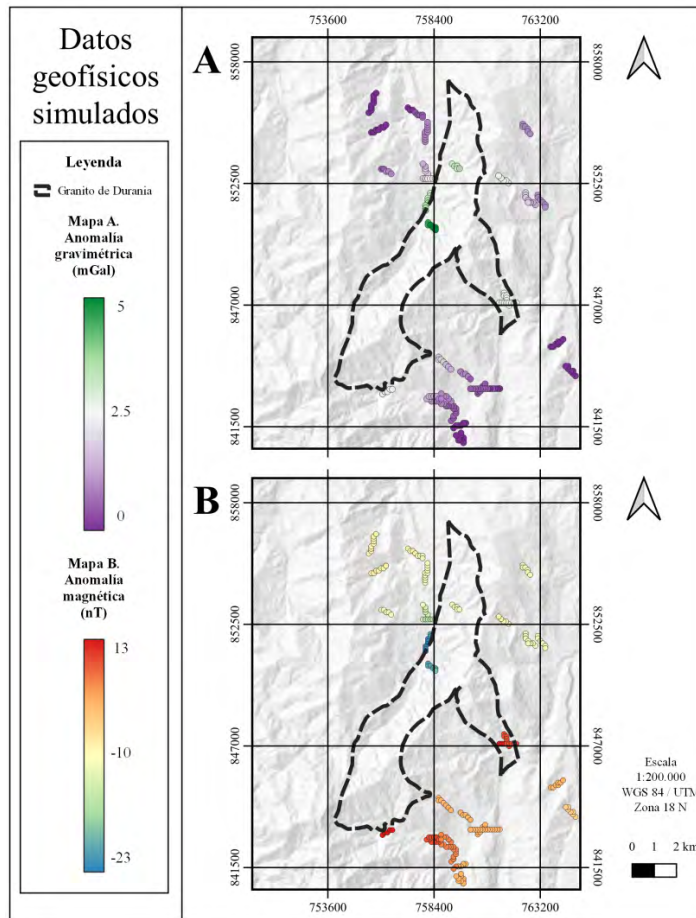


Figura 10. Datos geofísicos simulados con la geometría de adquisición obtenida a partir del análisis de restricciones ambientales y topográficas. **A.** Anomalia gravimétrica y **B.** Anomalia magnética de campo total.

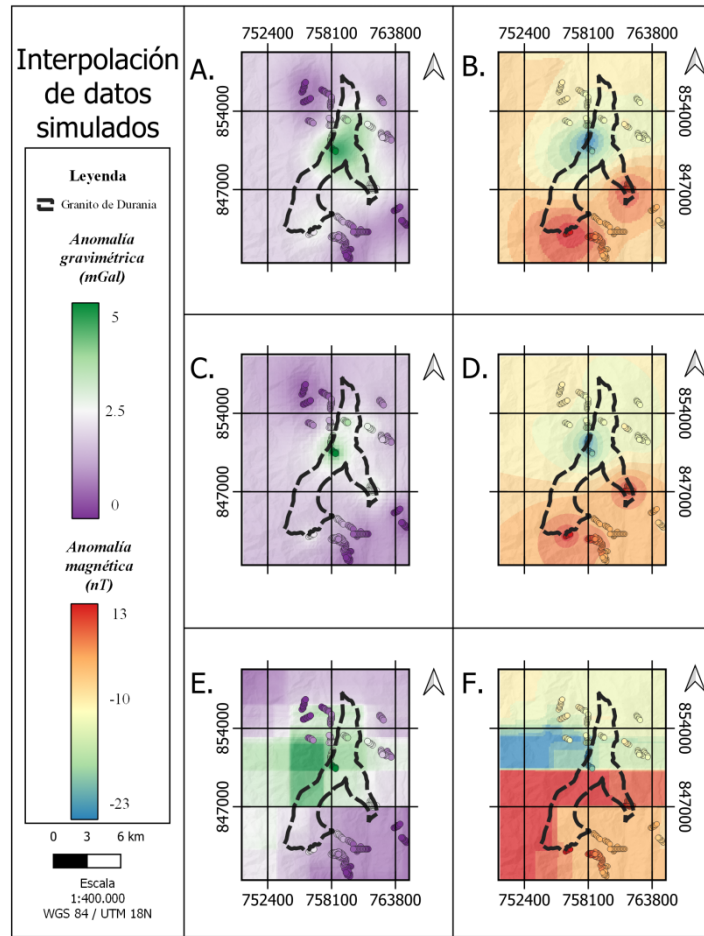


Figura 11. Interpolación de datos simulados. A y B corresponden a la interpolación con OK; C y D a los resultados con IDW; E y F representan la interpolación con RF.

El método de interpolación que obtuvo mejor métrica fue el IDW donde los valores promedio fueron 0,047 (MAE), 0,01 (MSE) y 0,99 (r^2). Por su parte, el método OK obtuvo valores de 0,0474 (MAE), 1,7 (MSE) y 0,989 (r^2); mientras que el método RF obtuvo 3,95 (MAE), 28,95 (MSE) y 0,76 (r^2).

En la **Figura 11** se destaca una zona con valores de 2,5 a 5,0 mGal en la zona central del afloramiento del Granito de Durania para la anomalía gravimétrica (**Figuras 11A, 11C y 11E**). Se observa que la zona central, donde aflora el cuerpo intrusivo, tiene una anomalía más alta que el entorno sedimentario que lo rodea, coincidiendo con el contraste positivo ($\Delta\rho = 0,19 \text{ g/cm}^3$) resultante de la asignación de los valores de densidad para las dos litologías ($\Delta\rho = \rho_2 - \rho_1$; $\Delta\rho = 2,61 \text{ g/cm}^3 - 2,42 \text{ g/cm}^3$). Por su parte, la anomalía de campo total en el caso de magnetometría (**Figuras 11B, 11D y 11F**) muestra un comportamiento de tipo dipolo entre la zona central y sur del afloramiento, sugiriendo una unidad magnética amplia.

Discusión

Los resultados del análisis realizado para las coberturas y usos del suelo a través de la CNN (**Figura 6**) se consideran una buena aproximación teniendo en cuenta las coberturas conocidas en el sector. Sin embargo, la clasificación presentó como inexistente el etiquetado de cuerpos de agua a pesar del conocimiento de cuerpos como los ríos Pamplonita y Zulia, y algunas lagunas. Esto lleva a considerar que las diferencias geográficas, culturales o de desarrollo entre el conjunto de datos de entrenamiento EUROSAT y la zona de estudio pueden provocar etiquetados erróneos o inexistentes. Estas diferencias se pueden minimizar al realizar un etiquetado de imágenes de control en cada área de estudio para considerar las particularidades de los terrenos colombianos. Adicionalmente, considerando que los cuerpos de agua se pueden incorporar en la metodología del diseño de geometrías desde otra perspectiva como la información georreferenciada (planchas del IGAC), los resultados presentados para

el análisis de este factor se consideran coherentes en el área de aplicación sobre el Granito de Durania.

Los resultados obtenidos para el análisis de variables del terreno mediante la RNAPM mostraron ser un complemento apropiado para los resultados de coberturas (Figura 7). Sin embargo, es necesario considerar que el interés de adquisición en el sitio se centra en el mapeo del cuerpo intrusivo. Teniendo en cuenta lo anterior, se considera que la clasificación binaria realizada en función de la variable de pendiente (favorabilidad $<10^\circ$) promueve principalmente la zonificación de baja favorabilidad de adquisición en terrenos montañosos (Figura 8). Adicionalmente, aunque este trabajo se enfocó en el uso de variables continuas derivadas del modelo digital de terreno, también es posible la integración de variables discretas como geomorfología, generando un análisis de geometrías de adquisición más robusto y considerando más factores que condicionen o promuevan las zonas favorables para el muestreo. Un ejemplo lo anterior es presentado por Goyes-Peñañiel y Hernández-Rojas (2021a), donde se propone una integración de variables continuas y discretas para tareas de clasificación binaria.

Conclusiones

La metodología propuesta con aprendizaje profundo resulta óptima en la clasificación de coberturas y análisis de terreno. Mediante estas clasificaciones se logró identificar zonas de favorabilidad teniendo en cuenta los criterios de rechazo como la presencia de vegetación espesa, cultivos, bosques y cuerpos de agua. Además, la incorporación de datos georreferenciados, cuerpos de agua y vías de acceso, resultan en un complemento ideal para el trazado de adquisición. La geometría de adquisición obtenida se analizó agrupándose en 31 transectas, las cuales se localizan principalmente al Este del afloramiento del cuerpo intrusivo y en la zona aflorante cercana al municipio de Durania, y están asociadas principalmente a las zonas favorables por su acceso, pendiente y coberturas que permiten un despliegue logístico con los equipamientos típicos usados en la adquisición de gravimetría y magnetometría.

A través de la modelación computacional tridimensional del Granito de Durania, y la asignación de propiedades físicas respectivas, se simuló una adquisición para evaluar la geometría sobre los puntos de medición de la anomalía magnética y de gravedad. Además, los datos adquiridos en la simulación fueron

interpolados y, a partir de las imágenes obtenidas, se estimó que las estructuras interpretadas son congruentes con las características geológicas del área de estudio, especialmente asociadas a la interpretación y delimitación de un cuerpo intrusivo referente al Granito de Durania. Finalmente, se encontró que el método de interpolación IDW obtuvo el menor error con $MSE=0,01$, superando a los métodos OK y RF.

Agradecimientos

Los autores de este trabajo agradecen a los evaluadores por sus comentarios que permitieron mejorar la calidad del manuscrito; al grupo de investigación IGGA de la escuela de Geología por el acompañamiento durante la investigación, así como a Andrés Felipe Laverde-Martínez por sus recomendaciones y préstamo del equipo de cómputo usado para las simulaciones. Este trabajo recibió el apoyo del proyecto 1216877806350 titulado “Modelo sismotectónico de la región centro oriente del Valle Medio del Magdalena como insumo al conocimiento de los modelos de exploración y desarrollo de campos de hidrocarburos”, financiado a través del acuerdo 785-2019 entre la Agencia Nacional de Hidrocarburos, MINCIENCIAS y el Fondo Francisco José de Caldas.

Referencias

- Alarcón, C.M.; Clavijo-Torres, J.; Mantilla-Figueroa, L.C.; Rodríguez, J.G. (2020). Nueva propuesta de edades para el registro sedimentario de las formaciones Bocas y Jordán y su relación con el desarrollo de la actividad magmática del Grupo Plutónico de Santander (Cordillera Oriental, Colombia). *Revista de la Academia Colombiana de Ciencias Exactas, Físicas y Naturales*, 44(173), 1137-1151. <https://doi.org/10.18257/racefyn.1208>
- ASF DAAC, (2015). ALOS PALSAR_Radiometric_Terrain_Corrected_low_res. Includes Material © JAXA/METI 2007. <https://doi.org/10.5067/JBYK3J6HFSVF>
- Ball, J.G.; Petrova, K.; Coomes, D.A.; Flaxman, S. (2022). Using deep convolutional neural networks to forecast spatial patterns of Amazonian deforestation. *Methods in Ecology and Evolution*, 13(11), 2622-2634. <https://doi.org/10.1111/2041-210X.13953>
- Botello-Becerra, F.M. (2014). Aportes al conocimiento geológico del Granito de Durania (Silúrico

- temprano): Macizo de Santander (Colombia). Tesis, Universidad Industrial de Santander, Bucaramanga, Colombia.
- Borges, P.d.A.; Franke, J.; da Anunciação, Y.M.T.; Weiss, H.; Bernhofer, C. (2016). Comparison of spatial interpolation methods for the estimation of precipitation distribution in Distrito Federal, Brazil. *Theoretical and Applied Climatology*, 123, 335-348. <https://doi.org/10.1007/s00704-014-1359-9>
- Cockett, R.; Kang, S.; Heagy, L.J.; Pidlisecky, A.; Oldenburg, D.W. (2015). SimPEG: An open source framework for simulation and gradient based parameter estimation in geophysical applications. *Computers & Geosciences*, 85(Part A), 142-154. <https://doi.org/10.1016/j.cageo.2015.09.015>
- Copernicus Sentinel data (2021). Imágenes recuperadas de USGS EROS Archive – Sentinel-2. <https://doi.org/10.5066/F76W992G>
- Developers, TF. (2022). TensorFlow: Convolution Neural Network (CNN) tutorial. *Zenodo*. <https://doi.org/10.5281/zenodo.4724125>
- Fúquen, J.; Ceballos, L.; Pedraza, A.; Marín, E. (2010). Geología de la Plancha 98 Durania [Plancha geológica]. 1:100.000. Bogotá: Ministerio de minas y energía: INGEOMINAS.
- Gardner, D.; Nichols, D. (2017). Multi-label classification of satellite images with Deep Learning. Stanford University.
- Goyes-Peñañiel, P.; Hernandez-Rojas, A. (2021a). Doble evaluación de la susceptibilidad por movimientos en masa basada en redes neuronales artificiales y pesos de evidencia. *Boletín de Geología*, 43(1), 173-191. <https://doi.org/10.18273/revbol.v43n1-2021009>
- Goyes-Peñañiel, P.; Hernandez-Rojas, A. (2021b). Landslide susceptibility index based on the integration of logistic regression and weights of evidence: A case study in Popayan, Colombia. *Engineering Geology*, 280, 105958. <https://doi.org/10.1016/j.enggeo.2020.105958>
- Goyes-Peñañiel, P.; Vargas, E.; Correa, C.V.; Sun, Y.; Kamilov, U.S.; Wohlberg, B.; Arguello, H. (2023). Coordinate-based seismic interpolation in irregular land survey: a deep internal learning approach. *IEEE Transactions on Geoscience and Remote Sensing*, 61. <https://doi.org/10.1109/TGRS.2023.3290468>
- Guo, T.; Dong, J.; Li, H.; Gao, Y. (2017). Simple convolutional neural network on image classification. *IEEE 2nd International Conference on Big Data Analysis*, Beijing, China. <https://doi.org/10.1109/ICBDA.2017.8078730>
- Helber, P.; Bischke, B.; Dengel, A.; Borth, D. (2018). Introducing EUROSAT: A novel dataset and deep learning benchmark for land use and land cover classification. *International Geoscience and Remote Sensing Symposium*, Valencia, España. <https://doi.org/10.1109/IGARSS.2018.8519248>
- Helber, P.; Bischke, B.; Dengel, A.; Borth, D. (2019). EUROSAT: A novel dataset and deep learning benchmark for land use and land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(7), 2217-2226. <https://doi.org/10.1109/JSTARS.2019.2918242>
- Hernández, O.; Khurama, S.; Alexander, G.C. (2011). Structural modeling of the Vichada impact structure from interpreted ground gravity and magnetic anomalies. *Boletín de Geología*, 33(1), 15-26.
- Hernandez-Rojas, A.; Arguello, H. (2022). 3D Geometry Design via End-To-End Optimization for Land Seismic Acquisition. *2022 IEEE International Conference on Image Processing*, Bordeaux, Francia. <https://doi.org/10.1109/ICIP46576.2022.9897295>
- Instituto Geográfico Agustín Codazzi. (2018). Cartografía Básica Digital Integrada [Bases vectoriales]. 1:25.000. Bogotá: Instituto Geográfico Agustín Codazzi.
- Kearey, P.; Brooks, M.; Hill, I. (2002). *An introduction to geophysical exploration*. Vol. 4. John Wiley & Sons.
- Kingma, D.P.; Ba, J.L. (2015). Adam: A method for stochastic optimization. *ArXiv preprint ArXiv:1412.6980*. <https://doi.org/10.48550/arXiv.1412.6980>

- Krizhevsky, A.; Sutskever, I.; Hinton, G.E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. <https://doi.org/10.1145/3065386>
- Li, J.; Heap, A. (2014). Spatial interpolation methods applied in the environmental sciences: A review. *Environmental Modelling and Software*, 53, 173-189. <https://doi.org/10.1016/j.envsoft.2013.12.008>
- Lowrie, W. (2007). *Fundamentals of Geophysics. 2nd ed.* Cambridge University Press. <https://doi.org/10.1017/CBO9780511807107>
- Mantilla, L.C.; Valencia, V.A.; Barra, F.; Pinto, J.; Colegial, J. (2009). Geocronología U-Pb de los cuerpos porfiríticos del distrito aurífero de Vetas, California (Dpto de Santander, Colombia). *Boletín de Geología*, 31(1), 31-43.
- Mantilla, L.C.; Mendoza, H.; Bissig, T.; Craig, H. (2011). Nuevas evidencias sobre el magmatismo Miocénico en el distrito minero de Vetas-California (Macizo de Santander, Cordillera Oriental, Colombia). *Boletín de Geología*, 33(1), 43-58.
- NCEI Geomagnetic Modelling Team. (2009). Magnetic Field Calculators. NOAA National Centers for Environmental Information. <https://www.ngdc.noaa.gov/geomag/calculators/magcalc.shtml>
- Pouladi, N.; Møller, A.B.; Tabatabai, S.; Greve, M.H. (2019). Mapping soil organic matter contents at field level with Cubist, Random Forest and kriging. *Geoderma*, 342, 85-92. <https://doi.org/10.1016/j.geoderma.2019.02.019>
- Prathap, G.; Afanasyev, I; (2018). Deep learning approach for building detection in satellite multispectral imagery. *IEEE International Conference on Intelligent Systems*. Funchal, Portugal. <https://doi.org/10.1109/IS.2018.8710471>
- Pritt, M.; Chern, G. (2017). Satellite image classification with deep learning. *IEEE Applied Imagery Pattern Recognition Workshop*. Washington, USA. <https://doi.org/10.1109/AIPR.2017.8457969>
- Rojas-Barbosa, S. (2013). Metalogenia de las mineralizaciones auríferas en la zona de Vetas, Santander. Tesis. Universidad Nacional de Colombia, Bogotá, Colombia.
- Sekulić, A.; Kilibarda, M.; Heuvelink, G.B.; Nikolić, M.; Bajat, B. (2020). Random forest spatial interpolation. *Remote Sensing*, 12(10), 1687. <https://doi.org/10.3390/rs12101687>
- Simonyan, K.; Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations*, San Diego, USA. arXiv. <https://doi.org/10.48550/arXiv.1409.1556>
- Sultana, F.; Sufian, A.; Dutta, P. (2018). Advancements in image classification using convolutional neural network. *4th International Conference on Research in Computational Intelligence and Communication Networks*, Kolkata, India. <https://doi.org/10.1109/ICRCICN.2018.8718718>
- Torres, J.A.; Goyes-Peñañiel, Y. (2013). Seismic Processing a Synthetic Structural Section Perijanero Flank Central, Central Basin of Venezuela. *1st Latin American Geosciences Student Conference*, Medellín, Colombia. <https://doi.org/10.3997/2214-4609.201318003>
- Ward, D.E.; Goldsmith, R.; Cruz, J.; Restrepo, H. (1973). Geología de los cuadrángulos H-12 Bucaramanga y H-13 Pamplona, departamento de Santander. *Boletín Geológico*, 21(1-3), 1-134. <https://doi.org/10.32685/0120-1425/bolgeol21.1-3.1973.383>
- Zeiler, M.D.; Fergus, R. (2014). Visualizing and understanding convolutional networks. *Computer vision – ECCV 2014*. (pp. 818-833). Springer, Cham, Zurich, Suiza. https://doi.org/10.1007/978-3-319-10590-1_53

Fecha de recibido: 28 de septiembre de 2022
Fecha de aceptado: 21 de noviembre de 2023
