




Análisis espacial de la susceptibilidad a deslizamientos con uso de geomática en la vía E20 Alóag-Santo Domingo

*Spatial analysis of landslide susceptibility using geomatics along the E20
Alóag–Santo Domingo Road, Ecuador*

- ¹ Alexis Gonzalo Cifuentes Moya  <https://orcid.org/0009-0008-5670-1697>
Universidad Estatal de Bolívar (UEB), Guaranda, Ecuador.
Maestría en Prevención y Gestión de Riesgos
alexis.cifuentes@ueb.edu.ec
- ² Luis Hernán Villacís Taco  <https://orcid.org/0000-0002-7062-4471>
Universidad Estatal de Bolívar (UEB), Guaranda, Ecuador.
lhvillacis@ueb.edu.ec



Artículo de Investigación Científica y Tecnológica

Enviado: 14/01/2026

Revisado: 10/02/2026

Aceptado: 18/03/2026

Publicado: 08/04/2026

DOI: <https://doi.org/10.33262/concienciadigital.v9i2.3621>

Cítese:

Cifuentes Moya, A. G., & Villacís Taco, L. H. (2026). Análisis espacial de la susceptibilidad a deslizamientos con uso de geomática en la vía E20 Alóag-Santo Domingo. *ConcienciaDigital*, 9(2), 6-35.

<https://doi.org/10.33262/concienciadigital.v9i2.3621>



CONCIENCIA DIGITAL, es una revista multidisciplinar, **trimestral**, que se publicará en soporte electrónico tiene como **misión** contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://concienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec



Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: <http://creativecommons.org/licenses/by-nc-sa/4.0/>



Palabras claves:

Susceptibilidad, deslizamiento, geomática, sistemas de información geográfica, sensores remotos.

Keywords:

Susceptibility, landslide, geomatics, geographic information systems, remote sensing.

Resumen

Introducción: la vía que conecta Alóag–Santo Domingo es uno de los ejes que conecta las regiones costa y sierra del Ecuador, presenta alta recurrencia de deslizamientos debido a condiciones geomorfológicas, climáticas y antrópicas, mientras que la información existente resulta limitada y poco dinámica; en este contexto, la geomática y la teledetección permiten generar cartografía actualizada para la identificación de zonas críticas.

Objetivos: Analizar espacialmente la vulnerabilidad a deslizamientos en la vía Alóag–Santo Domingo, durante el período julio 2024 – junio 2025, mediante el uso geomática para generar cartografía técnica y especializada que permita delimitar zonas críticas. **Metodología:** el estudio se realizó utilizando un diseño no experimental, transversal y correlacional con enfoque mixto. Para procesar y descargar datos de sensores remotos (SRTM, CHIRPS, Sentinel-1 y Sentinel-2), se utilizó Google Earth Engine. Las variables se normalizaron a través de la lógica difusa para realizar un análisis multicriterio y evaluar la susceptibilidad, que fue validada usando métricas estadísticas como tasa de éxito y AUC.

Resultados: las variables con mayor peso fueron la pendiente, acumulación de flujo y orientación, con un índice de consistencia AHP de 0.04, las métricas de validación indicaron un AUC de 0.82 y un 85.71% de deslizamientos concentrados en zonas de alta y muy alta susceptibilidad. **Conclusiones:** la integración de geomática, análisis multicriterio y lógica difusa permite generar modelos robustos, reproducibles y actualizables para la evaluación de susceptibilidad, siendo una metodología replicable que fortalece la gestión preventiva del riesgo. **Área de estudio general:** Ambiente. **Área de estudio específica:** Gestión de Riesgos y Desastres Naturales. **Tipo de artículo:** Artículo original.

Abstract

Introduction: The road connecting Alóag and Santo Domingo is one of the main routes linking Ecuador's coastal and highland regions. It experiences frequent landslides due to geomorphological, climatic, and anthropogenic factors, while existing information is limited and outdated. In this context, geomatics and remote sensing enable the creation of up-to-date maps for identifying critical areas. **Objectives:** To spatially analyze landslide vulnerability along the Alóag–Santo Domingo Road

during the period July 2024–June 2025, using geomatics to generate technical and specialized maps that enable the delineation of critical zones. **Methodology:** The study was conducted using a non-experimental, cross-sectional, and correlational design with a mixed-methods approach. Google Earth Engine was used to process and download remote sensing data (SRTM, CHIRPS, Sentinel-1, and Sentinel-2). The variables were normalized using fuzzy logic to perform a multi-criteria analysis and assess susceptibility, which was validated using statistical metrics such as the success rate and AUC. **Results:** The variables with the highest weights were slope, flow accumulation, and aspect, with an AHP consistency index of 0.04; validation metrics indicated an AUC of 0.82 and 85.71% of landslides concentrated in areas of high and exceedingly high susceptibility. **Conclusions:** The integration of geomatics, multi-criteria analysis, and fuzzy logic enables the creation of robust, reproducible, and updatable models for assessing vulnerability, providing a replicable methodology that strengthens preventive risk management. **General Area of Study:** Environment. **Specific area of study:** Risk and Natural Disaster Management. **Type of study:** Original article.

1. Introducción

La vía E20 Alóag–Santo Domingo es uno de los caminos más importantes de Ecuador, ya que une directamente la sierra con la costa, facilitando el comercio entre provincias, el transporte de viajeros y la entrega de productos hacia el puerto de Guayaquil y otras ciudades. No obstante, este trayecto de cerca de 93 kilómetros enfrenta constantes problemas de inestabilidad en las laderas, que se producen principalmente en forma de deslizamientos de tierra de diferentes tamaños. Estos incidentes provocan cortes en las carreteras, pérdidas de vidas, daños a la propiedad y costos económicos importantes para el Estado, las comunidades cercanas y los sectores productivos que dependen de este camino (Rivadeneira & Ortiz, 2024).

En la literatura a escala global, la geomática muestra un alto potencial para evaluar la susceptibilidad a deslizamientos, gracias a la fusión de datos satelitales de acceso libre, modelos digitales de elevación y series temporales climáticas que se procesan a través de plataformas de análisis masivo como *Google Earth Engine* (Gorelick et al., 2017). Varios autores han utilizado técnicas como la interferometría SAR, índices espectrales y análisis

multicriterio para identificar áreas críticas, alcanzando logros importantes en la predicción y monitoreo de movimientos en masa (Intrieri et al., 2018; Mondini et al., 2019). En el ámbito regional, investigaciones en Ecuador utilizaron índices de vegetación, análisis de pendientes y modelos de decisión multicriterio, obteniendo resultados que favorecen el ordenamiento territorial y la planificación preventiva en áreas de alta montaña y corredores viales (Mejía et al., 2021; Cargua et al., 2024; Velastegui et al., 2022).

En particular, para la carretera Alóag–Santo Domingo, estudios anteriores señalaron áreas que se ven afectadas de forma habitual y han sugerido modelos predictivos que utilizan lógica difusa, correlaciones con lluvias y caracterización geotécnica a través de drones (Montalvo et al., 2017; Ramírez & Melo, 2020). Lastimosamente los datos producidos son fragmentarios y en muchos casos están desactualizados, lo que restringe su uso para una gestión proactiva del riesgo.

Aunque la Secretaría Nacional de Gestión de Riesgos y los Gobiernos Autónomos Descentralizados desarrollaron diversos esfuerzos orientados a la generación de información y cartografía técnica sobre la región, la mayoría de estos productos no posibilitan una actualización o un seguimiento dinámico a lo largo del tiempo, pues su creación es estática. En este marco, se enfatiza la importancia de incluir instrumentos tecnológicos que permitan crear cartografía reproducible y fiable. Según esta perspectiva, el objetivo principal de este trabajo es examinar la vulnerabilidad a deslizamientos en la carretera Alóag - Santo Domingo entre julio de 2024 y junio de 2025.

La selección de este período específico se basa en dos condiciones climáticas extremas históricas a nivel nacional, con un segundo semestre de 2024 caracterizado por una sequía que provocó una crisis energética a nivel nacional y una presión sobre los ecosistemas (Cardona, 2024), En otro extremo se ubicó el primer semestre de 2025, donde predominaron precipitaciones intensas que causaron numerosos eventos adversos por lluvias, afectando a 23 provincias, 176 cantones y 514 parroquias (El Comercio, 2025). Estos episodios extremos de variación en las condiciones climáticas permiten un análisis bajo escenarios que amplifican los factores condicionantes y desencadenantes de deslizamientos.

Este estudio no solo pretende generar cartografía de susceptibilidad actualizada, sino también aportar al avance metodológico acerca del uso de geomática en la gestión de y reducción de los riesgos de desastres en Ecuador. La técnica aplicada tiene la posibilidad de ser reproducida en otros corredores estratégicos del país, ya que se basa en datos abiertos y plataformas de acceso libre. Esto reforzaría el fortalecimiento de la resiliencia comunitaria y el desarrollo de tácticas preventivas ante un riesgo que se presenta repetidamente en la infraestructura vial nacional.

2. Metodología

El estudio presenta un diseño no experimental y de corte transversal, ya que busca caracterizar la susceptibilidad a deslizamientos en el corredor vial Alóag-Santo Domingo mediante la observación y análisis de variables geoespaciales en su entorno natural sin manipular los factores condicionantes (Younes & Erazo, 2016). El tipo de investigación es descriptivo y correlacional, orientado a detallar la influencia de parámetros morfométricos, climáticos y de cobertura mediante el uso de sensores remotos.

La modalidad es documental y tecnológica, sustentada en el procesamiento de información primaria de las constelaciones Sentinel-1, Sentinel-2, SRTM y CHIRPS dentro de la plataforma *Google Earth Engine*. Los métodos empleados incluyen la deducción para la selección de variables condicionantes; el análisis multicriterio, mediante el Proceso de Jerarquía Analítica (AHP) para la ponderación de factores; y la lógica difusa (Fuzzy), para la normalización de datos heterogéneos.

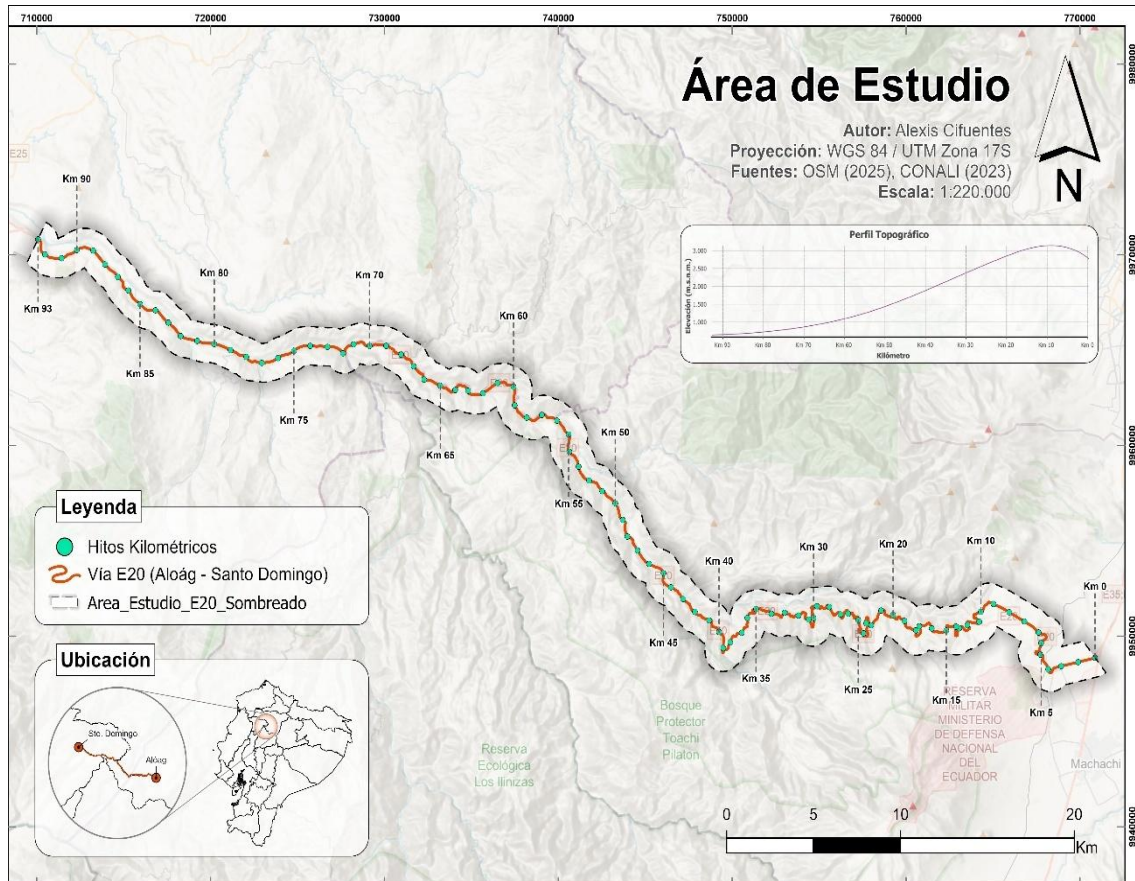
Las técnicas de investigación aplicadas fueron la teledetección y el análisis espacial automatizado, utilizando como instrumentos matrices de comparación por pares basadas en la escala de Saaty (1977) y algoritmos de validación estadística como la tasa de éxito, índice de concentración y el Área Bajo la Curva (AUC), contrastados con el inventario histórico de eventos de la Secretaría de Gestión de Riesgos.

2.1. Delimitación del área de estudio

Se tomó como área de análisis el tramo de la vía E20 entre Alóag y Santo Domingo, con base en la cartografía de *OpenStreetMap* y se generó hitos kilométricos (**Figura 1**). A partir de esta carretera se generó un buffer de 1 kilómetro a cada lado para considerar factores que influyen en la saturación del suelo y en la presión de poros incluso en distancias alejadas, comprometiendo la estabilidad de los taludes (Çellek, 2023).

Figura 1

Delimitación del área de estudio de la vía Alóag - Santo Domingo (Ecuador)



Para garantizar la consistencia de los datos *raster* y evitar la influencia de valores nulos o extrapolados fuera del buffer, en *Google Earth Engine (GEE)* se definió un polígono rectangular que abarca completamente la zona de estudio. Esto permitió asegurar que todos los píxeles exportados contuvieran datos válidos y homogéneos.

2.2. Adquisición de datos geospaciales y climáticos con Google Earth Engine

Se creó scripts para automatizar la descarga de datos morfométricos, climáticos, de cobertura, radar y de uso de suelo, los mismos que utilizaron las múltiples colecciones de *Google Earth Engine*, filtraron fechas, aplicaron correcciones y procesaron los datos para el estudio (Tabla 1).

Tabla 1

Colecciones de Google Earth Engine utilizadas para generar las variables morfológicas, climáticas, de cobertura, radar y de uso de suelo

Categoría	Colección GEE	Variable
Morfométrica	'USGS/SRTMGL1_003'	DEM SRTM
		Pendiente (Slope)
		Orientación (Aspect)
Climática	'UCSB-CHG/CHIRPS/DAILY'	Precipitación
Cobertura	'COPERNICUS/S2_SR'	Índice NDVI
		Índice NDWI
Radar SAR	'COPERNICUS/S1_GRD'	Polarización VV
		Polarización VH
		Anomalías VV
Uso de Suelo	'GOOGLE/DYNAMICWORLD/V1'	Cobertura y Uso de Suelo

A partir de la colección SRTM mediante un recorte se obtuvo el modelo de elevación del que también se calculó la Pendiente (Slope) en grados y la Orientación (Aspect). Además con el uso de ArcGIS Pro con el algoritmo D ∞ se calculó la acumulación de flujo por considerarse más adecuado para zonas de topografía compleja o montañosa (Tarboton, 1997). La colección CHIRPS sirvió para obtener la precipitación acumulada semestral. En cuanto a los índices NDVI y NDWI son calculados a partir de Sentinel-2, procesados en medianas semestrales con umbral de nubosidad del 40% y usando la función 'SCL' y 'MSK_CLDPRB' para enmascarar nubes.

Las polarizaciones VV y VH provienen de Sentinel-1 en modo IW y órbita ascendente, procesadas en promedios semestrales, aplicando corrección topográfica Gamma-Nought para normalizar efectos del relieve y filtrado speckle (50m) para reducir el ruido granular. El cálculo de anomalías con VV se realizó mediante la diferencia entre valores observados semestrales y la media anual, mostrando su utilidad para detectar variaciones inusuales en la cubierta forestal y condiciones de saturación del terreno en zonas montañosas (Walker et al., 2014; Mei et al., 2022). Por último, Dynamic World es un conjunto de datos de cobertura terrestre filtrado durante el periodo de estudio y con la extracción de la clase dominante.

2.3. Normalización de resoluciones y de variables temáticas

Los productos ráster fueron remuestreados a 30 metros mediante interpolación bicúbica en *Google Earth Engine*, a excepción de CHIRPS cuya resolución nativa es de ~5.5 km, siendo la mejor opción realizar el remuestreo en ArcGIS Pro empleando el método bilineal, ya que preserva la coherencia espacial, suaviza transiciones evitando la generación de patrones o valores extremos no presentes en los datos originales (Ulloa

et al., 2017). Además, se llevó a cabo un corte espacial uniforme de todas las capas desde un polígono de referencia, con la finalidad de estandarizar el tamaño de las variables y suprimir valores incorrectos, garantizando así que todos los ráster tuvieran la misma extensión y malla de análisis al trabajar con diferentes sensores.

Para trabajar en TerrSet las capas en formato *.tif requieren una conversión a su formato nativo *.rst lo cual se realizó mediante *GDAL Raster Conversion Utility*. Ya en referencia a la normalización solo la Orientación se ejecutó en GEE considerando su naturaleza circular, realidad geométrica y la influencia diferencial que ejerce la exposición de la pendiente sobre los procesos de inestabilidad (Jiang et al., 2018), quedando para el Norte: 1, Este/Oeste: 0.75, Sureste/Suroeste: 0.60 y Sur: 0.3, no se penaliza completamente el Sur porque existen tramos en esa dirección.

El resto de variables se trabajaron con las funciones de pertenencia difusa (Fuzzy) de TerrSet, gracias a su capacidad para representar las transiciones de forma gradual (Abdi et al., 2021; Eastman, 2024). La función lineal creciente fue usada para la acumulación de flujo que según Bièvre et al. (2016) solo las zonas de alto drenaje concentrado presentan mayor riesgo por erosión.

Mediante funciones Sigmoidal Creciente se modeló la pendiente, que de acuerdo con Zhao et al. (2021) indica que a mayor ángulo de pendiente la probabilidad de falla aumenta, la retrodispersión VV y las anomalías VV que a criterio de Feizizadeh et al. (2014) y Wang et al. (2022) la retrodispersión aumenta con la humedad del suelo y con superficies que devuelven mayor energía, el NDWI de acuerdo a lo señalado por Avtar et al. (2020) que valores altos corresponde mayor humectación del suelo y la precipitación que según Gonzalez et al. (2024) aumenta la presión de los poros ya sea con lluvias intensas o largos periodos húmedos.

En contraste, mediante funciones Sigmoidal Decreciente se modeló el NDVI que a criterio de Niraj et al. (2023) los valores altos indican vegetación densa que refuerza las pendientes y la polarización VH que como lo hace notar Srivastava et al. (2015) los valores altos indican estructura vegetal y mayor cohesión superficial.

Por último mediante reclasificación se trabajó el uso de suelo ya que Pacheco et al. (2023) destacan que la presencia de vegetación, remoción de pendientes e imperfecciones del suelo afectan sustancialmente el riesgo de deslizamiento. Por ello se asignaron valores de susceptibilidad relativos a la cobertura del suelo: 0 (mínima susceptibilidad) los bosques densos, cultivos y áreas construidas (por ubicarse en terrenos estabilizados, si bien en otros contextos pueden incrementar la inestabilidad del terreno debido a la labranza y pérdida de estructura, en este estudio podrían ocasionar falsos positivos), así como cuerpos de agua y nieve/hielo, que no contribuyen a la inestabilidad. 0.5 (susceptibilidad intermedia) los pastos y arbustos (suelos parcialmente estables). Y 1 (susceptibilidad

máxima) el suelo desnudo (expuesto a erosión) y vegetación inundada (suelos saturados). Estos valores fueron asignados tomando en consideración que en estudios espaciales la susceptibilidad no depende del tipo de cobertura, sino de cómo esta refleja el grado de alteración del suelo, infiltración, retención de humedad y erosión.

2.4. *Análisis Jerárquico de Procesos (AHP) para ponderación de variables*

Para evaluar los factores que condicionan la susceptibilidad a deslizamientos, se utilizó el método de Análisis Jerárquico de Procesos (AHP), que fue propuesto por Saaty (1977) y es ampliamente aceptado en la investigación sobre riesgos geológicos, gracias a su habilidad para organizar decisiones multicriterio de manera clara y lógica (Pourghasemi et al., 2012; Feizizadeh & Blaschke, 2013). La jerarquización de las variables se basó en una revisión de la literatura y en un análisis espacial apoyado por la base histórica de deslizamientos de la SNGRE.

- **Pendiente (V_1):** es el factor más determinante, al regular la componente gravitacional que actúa sobre las laderas y controlar el equilibrio entre fuerzas estabilizadoras y desestabilizadoras (Shahabi & Hashim, 2015; Chen et al., 2025).
- **Acumulación de flujo (V_2):** indica las zonas donde se acumula el escurrimiento superficial, aumentando la pérdida de soporte del talud debido a la saturación (Montgomery & Dietrich, 1994).
- **Orientación (V_3):** condiciona la exposición del talud hacia la calzada en ejes viales de montaña, además influye los patrones de evapotranspiración y la retención de humedad en el suelo al ser responsable de la recepción de radiación solar (Shahabi & Hashim, 2015).
- **Anomalías VV (V_4):** identifica valores anormales que podrían señalar incrementos en la humedad o cambios en la superficie, relacionados con la deformación y la inestabilidad (Ferretti et al., 2001; Crosetto et al., 2016).
- **Cobertura del suelo (V_5):** es un factor que agrava la inestabilidad de las laderas, debido a que cualquier cobertura que aumente la escorrentía, eleve la carga o reduzca la cohesión hace que el terreno sea más susceptible a los deslizamientos (Chen et al., 2019).
- **NDVI (V_6):** indica la densidad y la salud de la cobertura verde; cuando esta es mayor, se incrementa la cohesión y se reduce la inestabilidad (Kang et al., 2024).
- **Polarización VH (V_7):** responde a los cambios en la superficie terrestre y brinda información acerca de la dispersión volumétrica relacionada con la vegetación (Lee & Pottier, 2017).
- **Precipitación (V_8):** es un elemento desencadenante porque reduce la estabilidad de las laderas al incrementar la presión que el agua ejerce sobre el suelo. Sin embargo, perdió relevancia en el estudio debido a la resolución espacial de aproximadamente 5

km, que limita la precisión en áreas con una gran variabilidad topográfica (Abdi et al., 2021; Liu et al., 2024).

- **Polarización VV (V_9):** responde a los cambios en la altura y la rugosidad de las superficies, lo que brinda información importante para detectar zonas húmedas y cuerpos de agua (Lee & Pottier, 2017).
- **NDWI (V_{10}):** mide la humedad superficial y es esencial para determinar zonas que puedan sufrir una disminución de la resistencia del suelo (Kang et al., 2024).

Pendiente, acumulación de flujo y orientación dominan porque controlan directamente la fuerza desestabilizante. Anomalías VV detectan cambios anormales de la humedad o en la superficie. Cobertura, NDVI y VH marcan sectores vegetados frente a desnudos, mientras la precipitación semestral actúa como trigger regional. VV y NDWI aportan información útil de humedad, pero menos decisiva que los factores topográficos y de cubierta, al perder eventos críticos con sus señales semestrales promediadas.

Para calcular los pesos relativos de cada variable, se utilizó la herramienta Weight de TerrSet para crear una matriz de comparación por pares (**Tabla 2**) con la escala de Saaty que va del 1 a 1/9, y garantizar una consistencia inferior a 0.1 que es lo aceptable.

Tabla 2

Matriz de comparación por pares de las variables de estudio empleada en el Análisis Jerárquico de Procesos (AHP). Escala de Saaty (1 – 1/9)

	V ₁	V ₂	V ₃	V ₄	V ₅	V ₆	V ₇	V ₈	V ₉	V ₁₀
V ₁	1									
V ₂	1/2	1								
V ₃	1/2	1/2	1							
V ₄	1/3	1/3	1/2	1						
V ₅	1/4	1/4	1/3	1/3	1					
V ₆	1/4	1/4	1/3	1/3	1/2	1				
V ₇	1/4	1/4	1/3	1/3	1/2	1/2	1			
V ₈	1/5	1/5	1/4	1/4	1/3	1/3	1/2	1		
V ₉	1/6	1/6	1/5	1/5	1/4	1/4	1/3	1/2	1	
V ₁₀	1/6	1/6	1/5	1/5	1/4	1/4	1/3	1/2	1/2	1

2.5. *Evaluación multicriterio y generación del mapa de susceptibilidad*

Se incorporaron las variables temáticas usando el Método de Evaluación Multicriterio (MCE) con los pesos que se obtuvieron por medio de la herramienta Weight, esto posibilitó la elaboración de modelos continuos que muestran la susceptibilidad a deslizamientos para los semestres julio–diciembre de 2024 y enero–junio de 2025.

La división de las clases de susceptibilidad muy baja, baja, media, alta y muy alta se basa en el algoritmo de Jenks (1963) en el que las rupturas de clase se crean de manera que los valores similares se agrupan mejor y se maximizan las diferencias entre clases.

Se fusionaron los mapas semestrales de enero-junio de 2025 y julio-diciembre de 2024 a través de la herramienta *Cell Statistics* de ArcGIS Pro a través de la opción Maximum que mantiene el valor máximo de susceptibilidad por píxel. Esta técnica asegura que las áreas críticas identificadas en cualquiera de los dos periodos se muestren en el mapa final para lograr que el modelo más sensible frente a la variabilidad estacional.

2.6. Validación del modelo y delimitación de zonas críticas

Debido a que se identificaron durante la georreferenciación y depuración de la base de datos de deslizamientos de la SNGRE coordenadas fuera del área de estudio, duplicidad de eventos y puntos sin ubicación precisa, fue necesario aplicar acciones antes de su utilización. En primer lugar, filtrando la base de datos para conservar únicamente los eventos ocurridos en la vía Alóag-Santo Domingo, posteriormente cada registro fue revisado para mejorar la precisión en la georreferenciación asignándole el hito kilométrico donde ocurrió, revisando a detalle la descripción del evento.

Con la información depurada se generó en ArcGIS Pro un mapa de densidad de eventos empleando un radio de influencia de 1 km, ya que es bastante útil al emplear el método de coincidencia espacial con sucesos históricos apoyado por Karakas et al. (2023) que menciona que al validar con inventarios multitemporales de deslizamientos se pueden obtener perspectivas más realistas sobre los mapas de susceptibilidad.

Para conocer la coincidencia espacial además de hacerlo de manera visual, mediante la herramienta *Extract Values to Points* se extrajo la clase de susceptibilidad asociada a cada punto de evento, lo que permitió cuantificar y verificar la coincidencia espacial entre los deslizamientos históricos y las categorías del modelo.

Para mejorar la validación se optó por calcular la tasa de éxito (**Ecuación 1**), que cuantifica la fracción de eventos reales que caen dentro de las clases de susceptibilidad, con ello se reporta la capacidad práctica del mapa de priorizar áreas críticas (Rasyid et al., 2016).

$$\text{Tasa de Éxito} = \frac{\text{Número de Eventos de la Clase}}{\text{Número Total de Eventos}} \quad (1)$$

En cuanto al índice de concentración (**Ecuación 2**), compara la densidad de eventos de una clase con los eventos ocurridos en el área de estudio, cuando es mayor a 1 significa que la cantidad de deslizamientos en esa clase es superior a la media del área lo que ayuda a cuantificar la concentración espacial de eventos (Shano et al., 2020).

$$\text{Índice de Concentración} = \frac{\text{Número de Eventos de la Clase} / \text{Área de la Clase}}{\text{Número Total de Eventos} / \text{Área Total}} \quad (2)$$

Por último la curva de éxito (**Ecuación 3**), muestra cómo la fracción acumulada de eventos detectados aumenta a medida que se considera un porcentaje acumulado del área del modelo, ordenada según su nivel de susceptibilidad, valores mayores a 0.8 indican gran eficacia del modelo detectando que deslizamientos históricos se encuentran en las zonas identificadas como de mayor susceptibilidad (Silalahi et al., 2019).

$$AUC = \sum (X_i - X_{i-1}) \left(Y_i - \frac{(X_i - X_{i-1})(Y_i - Y_{i-1})}{2} \right) \quad (3)$$

$$AUC = \sum (X_i - X_{i-1}) \left(Y_i - \frac{(Y_i - Y_{i-1})}{2} \right)$$

X corresponde al porcentaje de área acumulada, mientras Y corresponde al porcentaje acumulado de deslizamientos ocurridos.

3. Resultados

Los resultados logrados derivan de la integración de variables morfométricas, de cobertura y climáticas mediante un enfoque de análisis multicriterio normalizado con lógica difusa, permitiendo la generación de un modelo espacial de susceptibilidad a deslizamientos en el área de estudio. Se logró una zonificación en cinco diferentes niveles de susceptibilidad, cuya validez fue evaluada mediante estadística y la comparación con registros históricos de eventos, permitiendo así la identificación patrones espaciales consistentes en zonas críticas que evidencian la influencia de cada uno de los factores analizados.

3.1. Recopilación de información geoespacial y climática

Se recopiló y procesó variables geoespaciales y climáticas provenientes de sensores remotos de acceso abierto en el periodo julio de 2024 a junio de 2025 mediante la plataforma *Google Earth Engine* (**Figura 2**). Gracias a esta plataforma se facilitó considerablemente los análisis espaciales a gran escala al combinar un extenso catálogo de datos geoespaciales con una potente infraestructura en la nube.


Como parte de las variables geomorfológicas se calculó la pendiente con valores entre 0° a 78.51°, la orientación de laderas normalizada y la acumulación de flujo que mostró un rango de 1 a 5422, gracias al DEM capturado por SRTM de alta calidad. El uso y cobertura del suelo adquirido del proyecto Dynamic World permitió identificar árboles, vegetación inundada, arbustos, cultivos, pastos, áreas construidas, suelo desnudo y zonas de nieve o hielo en la zona.

La precipitación acumulada del conjunto de datos de alta resolución CHIRPS que combina datos satelitales infrarrojos con mediciones de estaciones terrestres permitió obtener una marcada variabilidad estacional: de 239,07 a 510,41 mm en julio-diciembre de 2024 y de 777,63 a 2704,06 mm en enero-junio de 2025. Se calculó como variables de cobertura el NDWI (humedad) cuyos valores oscilaron entre -0,62 y 0,17 en el segundo semestre de 2024 y entre -0,66 y 0,29 en el primer semestre de 2025 y el NDVI (vegetación) con rangos de -0,12 a 0,70 y de -0,20 a 0,72 para los mismos periodos antes mencionados respectivamente.

Por último, las variables de radar Sentinel-1 se incluyó la polarización VV, con valores de -26,61 a 12,05 dB (jul-dic 2024) y de -26,77 a 12,73 dB (ene-jun 2025), y la polarización VH, cuyos intervalos fueron de -32,50 a -2,72 dB y de -31,91 a -2,64 dB, respectivamente. A partir de estas polarizaciones se generaron anomalías en VV, que variaron entre -4,34 y 5,97 dB en el segundo semestre de 2024, y entre -3,88 y 2,82 dB en el primer semestre de 2025.

Figura 2

Variables temáticas utilizadas en el análisis de susceptibilidad a deslizamientos



Este conjunto de información geoespacial y climática, obtenido de fuentes abiertas y preprocesado para el análisis, permitió integrar las condiciones topográficas, de

cobertura, precipitación, humedad y respuesta radar asociadas a la dinámica de inestabilidad de laderas.

3.2. Análisis multicriterio de susceptibilidad a deslizamientos

El análisis multicriterio integró las variables temáticas luego de ser normalizadas mediante funciones de pertenencia difusas, lo que permitió transformar sus unidades originales (grados, mm, clases categóricas, tasa de flujo, entre otras) a una escala común de 0 a 1 que expresa el grado de contribución relativa a la susceptibilidad. Para cada variable se definió una función fuzzy coherente con su relación teórica con los deslizamientos: pendiente y acumulación de flujo se modelaron con funciones crecientes, al incrementarse la probabilidad de inestabilidad conforme aumentan los valores; la orientación de ladera se representó mediante una función simétrica, distinguiendo exposiciones más propensas a saturación hídrica; y la cobertura del suelo se asignó mediante una función categórica donde los valores más expuestos (suelo desnudo, vegetación inundada) tomaron pertenencias altas, mientras que coberturas estabilizadoras (bosque denso, áreas construidas) adoptaron valores bajos.

La matriz de comparación por pares resultó coherente, con el índice de consistencia (CR) de 0.04, inferior al umbral recomendado de 0.10, lo que valida los juicios empleados para asignar pesos (**Tabla 3**).

Tabla 3

Pesos de las variables obtenidos mediante AHP para el análisis de susceptibilidad a deslizamientos.


Número	Variable	Peso
1	Pendiente	0.2420
2	Acumulación de Flujo	0.2107
3	Orientación	0.1490
4	Anomalías VV	0.1232
5	Uso de Suelo	0.0763
6	NDVI	0.0664
7	Precipitación	0.0508
8	Polarización VV	0.0341
9	Polarización VH	0.0254
10	NDWI	0.0222

La modelación en TerrSet (**Figura 3**), permitió calcular dos periodos con alta variabilidad climática registrada, para los semestres julio–diciembre de 2024 caracterizado por una sequía prolongada y en contraste, por precipitaciones intensas enero–junio de 2025. Al fusionar ambos escenarios en un mapa integrado de susceptibilidad se logró capturar escenarios de déficit hídrico en los que se debilita la cobertura vegetal favoreciendo la

erosión, como también escenarios de exceso de precipitación, directamente vinculados al desencadenamiento de deslizamientos, siendo un insumo de mayor confiabilidad para la identificación de zonas críticas. Las clases de susceptibilidad considerada fueron muy baja, baja, media, alta y muy alta basada en el algoritmo de rupturas de clase Jenks.

Figura 3

Mapas semestrales de susceptibilidad a deslizamientos para julio–diciembre 2024 (arriba) y enero–junio 2025 (abajo)



La comparación de los mapas semestrales de susceptibilidad a deslizamientos posibilitó detectar cambios relacionados con la variación geográfica de las precipitaciones en enero–junio 2025 donde la precipitación fue mayor en la zona baja y en julio–diciembre 2024 en que la mayor cantidad de lluvia se concentró en la zona de montaña. Es importante considerar que a pesar de que por la resolución espacial de CHIRPS (~5 km) en el análisis AHP la variable precipitación tuvo un peso bajo, pero es evidente que su impacto sobre la susceptibilidad sigue siendo considerable, puesto que regula notoriamente la reclasificación estacional en ciertas secciones de la vía.

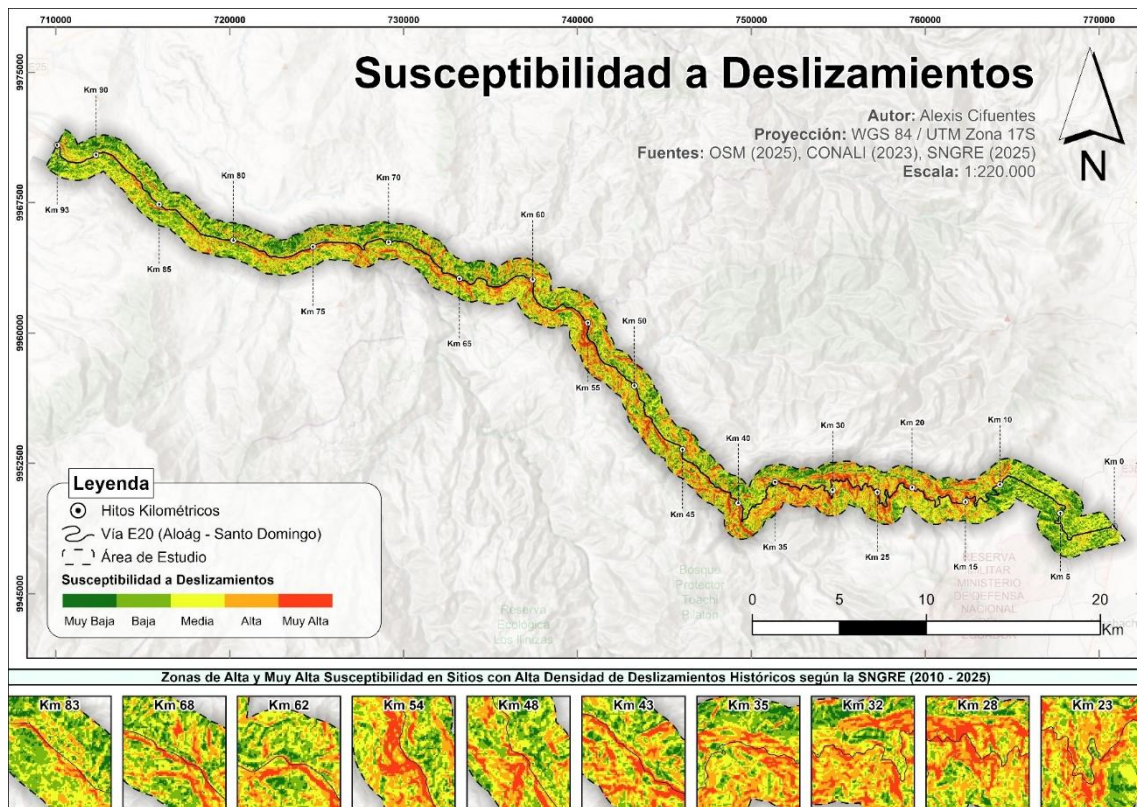
Esto ocasionó que las clases suban un escalón en la susceptibilidad pasando de baja a media o de media a alta. Además, se demostró que, aunque su resolución sea inferior, es

esencial incluir esta variable para poder captar la dinámica temporal de los deslizamientos.

La combinación de los escenarios semestrales extremos de sequía y de fuertes precipitaciones, fue crucial para crear un mapa integrado de susceptibilidad (**Figura 4**), pues permitió identificar áreas con gran riesgo de deslizamientos tomando en cuenta condiciones climáticas extremas.

Figura 4

Mapa integrado de susceptibilidad a deslizamientos para el periodo julio 2024–junio 2025. Fuente: Elaboración propia con datos SRTM, CHIRPS, Dynamic World, Sentinel-1 y 2




Esta perspectiva mejoró la capacidad del modelo al detectar áreas críticas con registros recurrentes como es el caso de los kilómetros 23, 28, 32, 35, 43, 48, 54, 62, 68 y 83. Cabe destacar que casi en su totalidad la vía cuenta con sitios clasificados como de alta y muy alta susceptibilidad, pero no se registraron gran cantidad de eventos, como en los sitios antes mencionados hasta el día de hoy.

3.3. Validación de la confiabilidad del mapa de susceptibilidad a deslizamientos

Los datos obtenidos por la SNGRE tuvieron inconvenientes de georreferenciación, lo que dificultó una validación precisa a nivel espacial del modelo. Esto no permitió realizar verificaciones cuantitativas directas, por ende, fue necesario un procesamiento manual de esta información, colocando la ubicación de acuerdo con la descripción del evento, permitiendo así la generación de mapas de densidad (**Figura 5**), para identificar los tramos de mayor concentración de deslizamientos a lo largo de la vía.

Figura 5

Mapa de densidad de deslizamientos históricos (2010–2025), calculado con radio de influencia de 1 km. Elaboración propia con datos de la SNGRE

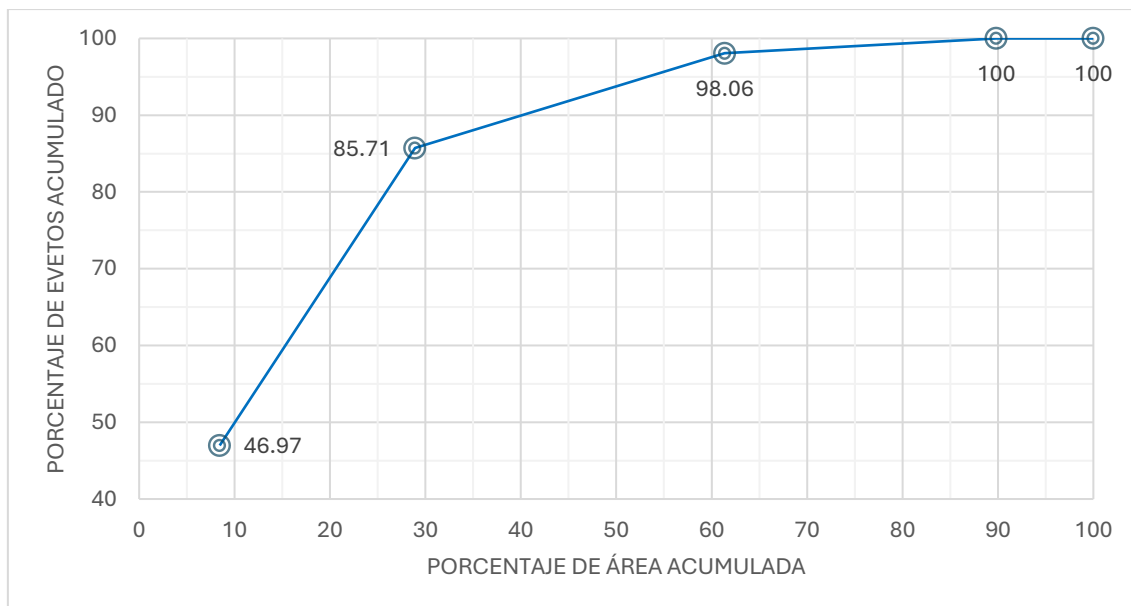


Los datos indicaron que los puntos críticos identificados en los archivos históricos son alrededor de los kilómetros 23, 28, 32, 35, 43, 48, 54, 62, 68 y 83 que superan los 15 deslizamientos registrados entre 2010 y 2025. Los puntos críticos mostraron una superposición evidente con zonas que se categorizan como de susceptibilidad alta y muy alta. Además, según Karakas et al. (2023) se debe tener en cuenta que otros desastres o eventos extremos pueden desencadenar deslizamientos en regiones que no se consideran propensas, o aumentar la probabilidad en zonas de baja o media susceptibilidad.

La capacidad predictiva del modelo fue sólida, según la evaluación estadística. La curva de éxito (**Figura 6**), se ubicó muy por encima de la línea aleatoria y tuvo un AUC de 0.82, lo cual demostró una predicción eficaz. En la base de datos se registró 413 deslizamientos, de los cuales el 85.71% estuvo en las clases de alta y muy alta susceptibilidad, demostrando una excelente tasa de éxito.

Figura 6

Curva de éxito del modelo de susceptibilidad con un AUC de 0.82. Elaboración propia a partir de datos SNGRE y resultados del modelo AHP-Fuzzy



El análisis de concentración espacial reveló que la categoría Alta tuvo un índice de concentración de 1.89, lo que indicó que la densidad de eventos en estas áreas es casi el doble. Para la categoría Muy Alta, el índice se elevó a 5.57, es decir, más de cinco veces por encima del promedio de densidad en el área estudiada. De esta manera se confirma que el modelo tiene la capacidad de predecir áreas de deslizamiento con precisión, además de concentrar los eventos en las clases de mayor susceptibilidad, fortaleciendo su aplicabilidad para la planificación y gestión del riesgo en la vía Alóag-Santo Domingo.

4. Discusión

Utilizar técnicas geomáticas para evaluar la susceptibilidad a deslizamientos en la carretera E20 Alóag-Santo Domingo demostró ser una técnica eficaz y reproducible. Se pudo modelar semestralmente la susceptibilidad con una resolución espacial y temporal elevada gracias al empleo de los sensores CHIRPS, SRTM, Sentinel-1 y 2, que fueron procesadas en *ArcGIS Pro*, *TerrSet* y *Google Earth Engine*. Esta perspectiva se alinea con

el trabajo realizado por Younes & Erazo (2016) quienes confirmaron que la teledetección es útil para marcar zonas críticas en los Andes de Ecuador.

La integración del Proceso Analítico Jerárquico (AHP) con funciones de pertenencia difusa logró un índice de consistencia de 0.04, lo que asegura la solidez en la ponderación de factores. Feizizadeh & Blaschke (2013) demostraron que la combinación de AHP y lógica difusa disminuye la subjetividad y aumenta la exactitud de los modelos de susceptibilidad. También se demuestra la viabilidad de integrar datos abiertos y procesamiento en la nube, lo que permite una cartografía de susceptibilidad reproducible y de bajo costo. Este enfoque complementa estudios como el de Montalvo et al. (2017) que utilizó de drones para la caracterización de taludes en sectores críticos, donde se obtuvieron nubes de puntos de alta resolución que mejoran la identificación de zonas de falla y los cálculos de volumen inestable. La combinación de monitoreo aéreo de alta precisión con análisis regional SIG constituye un camino prometedor para una gestión de riesgos integral.

Los resultados indican que la morfometría del terreno es el principal factor que causa inestabilidad en las laderas de la ruta Alóag–Santo Domingo. Esto coincide con investigaciones anteriores, como la de Palacios (2020) quien utilizó lógica difusa junto con AHP en la misma vía y obtuvo una precisión del 75% al contrastar con datos históricos, identificando a la precipitación y a la pendiente como variables importantes. Cargua et al. (2024) lograron un 83.7% de exactitud en el modelo utilizando AHP en otros corredores andinos, como la ruta Puyo–Tena, indicando que la pendiente era la variable predominante. La concordancia entre estos estudios posibilita que la ponderación efectuada se confirme como sólida.

La precipitación permitió captar la variabilidad estacional para generar modelos semestrales tanto en época seca como en una situación de lluvias intensas pese a su baja resolución espacial. Esto se confirma con el estudio de Palenzuela et al. (2020) donde mencionan que para el áreas húmedas de Ecuador se necesitan valores más bajos de lluvia acumulada para desencadenar un deslizamiento, probablemente por la alta saturación del suelo, también consideran que el mayor número de días de lluvia favorecen un alto grado de saturación.

A pesar de su utilidad, CHIRPS enfrenta una restricción significativa, su resolución espacial de aproximadamente 5 km. Ulloa et al. (2017) y Liu et al. (2024) alertan en sus investigaciones que información pluviométrica de baja resolución puede infravalorar la variabilidad orográfica e influir en la predicción de deslizamientos en zonas de montaña. La posibilidad de que eventos de lluvia intensa y corta duración, que son detonantes fundamentales, se vean suavizados al captarse la precipitación acumulada semestralmente es otra variable importante a tener en cuenta (Gonzalez et al., 2024). En futuras investigaciones, se podrían incorporar nuevas colecciones de datos que se suman

continuamente a GEE, e incluso productos de radar como GPM IMERG de 0.1° y 30 minutos de resolución, los cuales Liu et al. (2024) emplearon para aumentar la exactitud y la identificación de fenómenos extremos.

Trabajos como el de Palacios (2024) respalda la idea de que los modelos probabilísticos y multicriterio son útiles para capturar la variabilidad de los factores condicionantes y disparadores en zonas con una topografía compleja. No obstante, investigaciones recientes registraron que los métodos de aprendizaje automático pueden lograr una mayor exactitud en las predicciones. Merghadi et al. (2020) llevaron a cabo un estudio minucioso de 162 investigaciones sobre la susceptibilidad a deslizamientos, observando que algoritmos de aprendizaje automático como las redes neuronales, el Support Vector Machine y el Random Forest suelen ser más precisos que los métodos convencionales, con valores del AUC entre 0.85 y 0.93 en comparación con los métodos heurísticos (AHP y Multicriterio), que tienen valores entre 0.75 y 0.85. Dou et al. (2020) subieron el nivel mejorando la precisión del AUC a un rango entre 0.90 y 0.95 con técnicas que combinan múltiples algoritmos para capturar relaciones no lineales complejas entre variables.

Aunque hay métodos con precisiones cercanas al 100%, no están disponibles para todos, porque los recursos computacionales son un elemento importante que a menudo es subestimado, sobre todo en profesionales autónomos y entornos institucionales donde la infraestructura tecnológica es limitada. Metodologías computacionalmente eficientes como la empleada en este estudio facilitan su adopción por gobiernos autónomos descentralizados y entidades de gestión de riesgos con capacidades técnicas y financieras variables. Puede llevarse a cabo en equipos estándar sin necesidad de hardware especializado y con tiempos de procesamiento relativamente breves que posibilitan iteraciones veloces durante el desarrollo del modelo. Superando la disparidad en accesibilidad técnica y económica en instituciones con recursos limitados, con una capacidad predictiva aceptable.

Por otro lado, los métodos de aprendizaje automático requieren mucho más tiempo de computación. Por ejemplo, el algoritmo SVM y Random Forest puede necesitar entre 10 y 50 veces más tiempo que otros métodos para optimizar hiperparámetros a través de la validación cruzada exhaustiva, lo cual puede tomar desde horas hasta días, dependiendo del tamaño del conjunto de datos y la resolución espacial (Zhang et al., 2022). Los métodos de aprendizaje profundo son los que más recursos utilizan, ya que las arquitecturas especializadas como LSNet y las Redes Neuronales Convolucionales (CNN) necesitan Procesadores Gráficos (GPU) potentes para un entrenamiento eficaz, lo cual puede llevar desde días hasta semanas con conjuntos de datos regionales de alta resolución (Zhang et al., 2022).

Por lo general, la infraestructura necesaria incluye procesadores de alta gama y GPU de última generación, más de 8 GB de VRAM, más de 32 de memoria RAM y

almacenamiento SSD rápido, lo cual implica una inversión económica significativa. Además, se requiere de una pericia técnica específica en programación Python, marcos de trabajo como TensorFlow o PyTorch y un entendimiento de las arquitecturas de redes neuronales, habilidades que son menos frecuentes en el campo de la gestión de riesgos ecuatoriana en comparación con las competencias SIG tradicionales.

Por último, la validación del modelo presenta limitaciones relacionadas a la imprecisión geográfica de los registros históricos de la SNGRE que puede resultar en subestimación de la capacidad predictiva real del modelo, coincidiendo con las observaciones de Guzzetti et al. (2012) acerca de la incompletitud intrínseca que presentan los inventarios regionales de deslizamientos. Pese a ello la coincidencia espacial reveló una alta concordancia entre las zonas de alta susceptibilidad y los eventos ocurridos, que se complementó con métricas estadísticas que respaldan su capacidad predictiva. La tasa de éxito mostró que el 85.7% de los 413 deslizamientos se localizaron en las clases de alta y muy alta susceptibilidad, mientras que el índice de concentración alcanzó valores de 1.89 y 5.57 en dichas categorías, evidenciando una marcada concentración de eventos en las zonas críticas.

Complementando con la curva de éxito que arrojó un AUC de 0.82 siendo muy bueno si se toma en consideración a Rasyid et al. (2016) que califica valores entre 0.8 a 0.9 son señal de un buen modelo, Chowdhury (2023) comparte que en ese rango los modelos son de muy buen desempeño y precisión, mientras que Meena et al. (2022) confirman que valores próximos a 1 indican un modelo con alta fortaleza discriminatoria.

Al detectar segmentos críticos donde se debe dar prioridad a las obras de estabilización de taludes y drenaje, los resultados brindan información directa para el Ministerio de Transporte y Obras Públicas y los Gobiernos Autónomos Descentralizados. Según Shano et al. (2020) los mapas de vulnerabilidad de este tipo pueden incorporarse en los planes de mantenimiento vial y en los sistemas de alerta temprana, lo que permite optimizar recursos y disminuir el cierre de carreteras. Asimismo, al demostrar zonas que tienen una alta sensibilidad a las lluvias extremas, contribuyen a las políticas de adaptación frente al cambio climático (Palenzuela et al., 2020).

5. Conclusiones

- La unión de datos topográficos SRTM, precipitación CHIRPS, información de radar Sentinel-1 y sensores remotos multiespectrales Sentinel-2, además de la normalización Fuzzy y el análisis jerárquico de procesos para ponderar, posibilitó la creación de un modelo de susceptibilidad con un índice de consistencia de 0.04, lo que señala fortaleza en la estructura de pesos e integridad en la combinación de variables.

- La pendiente (0,2420), acumulación del flujo (0,2107) y dirección (0,1490) son los factores más relevantes de inestabilidad, pues afectan la fuerza de gravedad, la saturación del suelo y cómo se distribuye la humedad. La información de humedad y cobertura, importantes para complementar la caracterización de la dinámica de laderas son proporcionados por variables como NDVI, NDWI y polarizaciones SAR.
- La precipitación, aunque con su baja resolución, ejerce la función de un desencadenante estacional. El contraste entre semestres secos y húmedos permitió obtener escenarios de saturación extrema y déficit hídrico, lo que mejoró la representatividad del mapa final.
- Las metodologías que se basan en datos abiertos y plataformas en la nube pueden aplicarse a otros corredores estratégicos del país, ya sea en planificación territorial, priorizar obras de mitigación y formular estrategias para disminuir el riesgo.
- Se abre la posibilidad de actualizar el mapa de susceptibilidad anualmente sin necesidad de hacer inversiones notables, gracias a la constante evolución de la toma de datos abiertos y al procesamiento en la nube con funciones de inteligencia artificial, favoreciendo el monitoreo constante de los cambios que ocurren en la cobertura vegetal, el uso del suelo y las alteraciones climáticas.
- Con una recolección de datos más sistemática y precisa por parte de las instituciones públicas permitiría crear modelos de susceptibilidad con validaciones estadísticas sólidas, mejorar la capacidad predictiva de áreas críticas y progresar hacia sistemas de alerta temprana que incorporen escenarios climáticos en tiempo real.
- La detección de patrones estacionales y la sensibilidad del modelo a contextos de saturación del agua aportan información valiosa para las políticas de adaptación al cambio climático, lo que permite reforzar la capacidad de recuperación de los corredores viales montañosos frente a lluvias extremas y variaciones climáticas en el futuro.
- Instituciones con capacidad computacional especializada podrían realizar investigaciones comparativas utilizando algoritmos de aprendizaje profundo (LSNet, LSTM, CNN) y de aprendizaje automático (XGBoost, SVM, Random Forest), empleando las diez variables geospaciales utilizadas en este estudio con el fin de asegurar una comparabilidad metodológica directa.
- La validación espacial a través de mapas de densidad mostró una relación significativa entre puntos críticos históricos (km 23, 28, 32, 35, 43, 48, 54, 62, 68 y 83) y las zonas que se clasificaron con una susceptibilidad más alta. Esto corroboró su utilidad para la gestión de riesgos, la planificación territorial en el corredor vial y la priorización de inversiones destinadas a estabilizar taludes.
- El modelo de susceptibilidad desarrollado mostró una sólida capacidad predictiva con un AUC de 0.82. La tasa de éxito del 85.71% confirma que la mayor parte de los deslizamientos históricos sucedieron en áreas con alta o muy alta susceptibilidad. Por otro lado, los índices de concentración espacial (1.89 y 5.57 respectivamente)

demuestran que el modelo tiene la habilidad para distinguir entre zonas estables e inestables de manera efectiva.

6. Conflicto de intereses

Los autores declaran que no existe conflicto de intereses en relación con el artículo presentado.

7. Declaración de contribución de los autores

Todos los autores contribuyeron significativamente en la elaboración del artículo.

8. Costos de financiamiento

La presente investigación fue financiada en su totalidad con fondos propios de los autores.

9. Referencias bibliográficas

- Abdi, A., Bouamrane, A., Karech, T., Dahri, N., & Kaouachi, A. (2021). Landslide susceptibility mapping using gis-based fuzzy logic and the analytical hierarchical processes approach: a case study in Constantine (North-East Algeria). *Geotechnical and Geological Engineering*, 39(8), 5675-5691. <https://doi.org/10.1007/s10706-021-01855-3>
- Avtar, R., Komolafe, A. A., Kouser, A., Singh, D., Yunus, A. P., Dou, J., Kumar, P., Gupta, R. D., Johnson, B. A., Thu Minh, H. V., Aggarwal, A. K., & Kurniawan, T. A. (2020). Assessing sustainable development prospects through remote sensing: a review. *Remote Sensing Applications: Society and Environment*, 20, 100402. <https://doi.org/10.1016/j.rsase.2020.100402>
- Bièvre, G., Jongmans, D., Goutaland, D., Pathier, E., & Zumbo, V. (2016). Geophysical characterization of the lithological control on the kinematic pattern in a large clayey landslide (Avignonet, French Alps). *Landslides*, 13(3), 423-436. <https://doi.org/10.1007/s10346-015-0579-0>
- Cardona, A. P. (2024). Balance ambiental de Ecuador: sequías y la amenaza de la minería ilegal marcaron el 2024. *Noticias ambientales*. Mongabay. <https://es.mongabay.com/2024/12/balance-ambiental-ecuador-sequias-amenaza-mineria-ilegal-marcaron-2024/>
- Cargua, C. J., Espin, R., Valencia, B. G., Simbaña, M., Araujo, S., Ocampos, A., & Cornejo, C. (2024). Análisis de susceptibilidad a deslizamientos empleando el proceso de jerarquía analítica en una carretera Amazónica del Ecuador. *La Granja*, 39(1), 117-138. <https://doi.org/10.17163/lgr.n39.2024.07>

- Çellek, S. (2023). Linear parameters causing landslides: a case study of distance to the road, fault, drainage. *Kocaeli Journal of Science and Engineering*, 6(2), 94-113. <https://doi.org/10.34088/kojose.1117817>
- Chen, G., Zeng, T., Liu, D., Chen, H., Wang, L., Wang, L., Zhang, K., & Glade, T. (2025). Geomorphological and geological characteristics slope unit: advancing township-scale landslide susceptibility assessment strategies. *Land*, 14(2), 355. <https://doi.org/10.3390/land14020355>
- Chen, L., Guo, Z., Yin, K., Shrestha, D. P., & Jin, S. (2019). The influence of land use and land cover change on landslide susceptibility: a case study in Zhushan Town, Xuan'en County (Hubei, China). *Natural Hazards and Earth System Sciences*, 19(10), 2207-2228. <https://doi.org/10.5194/nhess-19-2207-2019>
- Chowdhury, S. (2023). A review on landslide susceptibility mapping research in Bangladesh. *Heliyon*, 9(7), e17972. <https://doi.org/10.1016/j.heliyon.2023.e17972>
- Crosetto, M., Monserrat, O., Cuevas-González, M., Devanthéry, N., & Crippa, B. (2016). Persistent scatterer interferometry: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 78-89. <https://doi.org/10.1016/j.isprsjprs.2015.10.011>
- Dou, J., Yunus, A. P., Bui, D. T., Merghadi, A., Sahana, M., Zhu, Z., Chen, C.-W., Han, Z., & Pham, B. T. (2020). Improved landslide assessment using support vector machine with bagging, boosting, and stacking ensemble machine learning framework in a mountainous watershed, Japan. *Landslides*, 17(3), 641-658. <https://doi.org/10.1007/s10346-019-01286-5>
- Eastman, R. (2024). *TerrSet liberaGIS Geospatial Monitoring and Modelling System*. Clark University. <https://s45055.pcdn.co/centers/geospatial-analytics/www-content/blogs.dir/7/files/sites/354/2024/11/Terrset-liberaGIS-Manual.pdf>
- El Comercio. (2025). *Lluvias ya dejan 16 fallecidos durante 2025 en Ecuador ¿Cuáles son los lugares más afectados?* <https://www.elcomercio.com/actualidad/ecuador/lluvias-16-fallecidos-2025-ecuador-lugares-mas-afectados/>
- Feizizadeh, B., & Blaschke, T. (2013). GIS-multicriteria decision analysis for landslide susceptibility mapping: comparing three methods for the Urmia lake basin, Iran. *Natural Hazards*, 65(3), 2105-2128. <https://doi.org/10.1007/s11069-012-0463-3>
- Feizizadeh, B., Shadman Roodposhti, M., Jankowski, P., & Blaschke, T. (2014). A GIS-based extended fuzzy multi-criteria evaluation for landslide susceptibility

- mapping. *Computers & Geosciences*, 73, 208-221.
<https://doi.org/10.1016/j.cageo.2014.08.001>
- Ferretti, A., Prati, C., & Rocca, F. (2001). Permanent scatterers in SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing*, 39(1), 8-20.
<https://doi.org/10.1109/36.898661>
- Gonzalez, F. C. G., Cavacanti, M. D. C. R., Nahas Ribeiro, W., Mendonça, M. B. D., & Haddad, A. N. (2024). A systematic review on rainfall thresholds for landslides occurrence. *Heliyon*, 10(1), e23247.
<https://doi.org/10.1016/j.heliyon.2023.e23247>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Guzzetti, F., Mondini, A. C., Cardinali, M., Fiorucci, F., Santangelo, M., & Chang, K.-T. (2012). Landslide inventory maps: New tools for an old problem. *Earth-Science Reviews*, 112(1-2), 42-66. <https://doi.org/10.1016/j.earscirev.2012.02.001>
- Intrieri, E., Raspini, F., Fumagalli, A., Lu, P., Del Conte, S., Farina, P., Allievi, J., Ferretti, A., & Casagli, N. (2018). The Maoxian landslide as seen from space: detecting precursors of failure with Sentinel-1 data. *Landslides*, 15(1), 123-133.
<https://doi.org/10.1007/s10346-017-0915-7>
- Jenks, G. (1963). Generalization in statistical mapping. *Annals of the Association of American Geographers*, 53, 15-26.
<https://onlinelibrary.wiley.com/doi/10.1111/j.1467-8306.1963.tb00429.x>
- Jiang, L., Diao, M., Sun, H., & Ren, Y. (2018). Numerical modeling of flow over a rectangular broad-crested weir with a sloped upstream face. *Water*, 10(11), 1663.
<https://doi.org/10.3390/w10111663>
- Kang, J., Wan, B., Gao, Z., Zhou, S., Chen, H., & Shen, H. (2024). Research on machine learning forecasting and early warning model for rainfall-induced landslides in Yunnan province. *Scientific Reports*, 14(1).
<https://doi.org/10.1038/s41598-024-64679-0>
- Karakas, G., Unal, E. O., Tunar Ozcan, N., Cetinkaya, S., Can, R., Gokceoglu, C., & Kocaman, S. (2023). Co-seismic landslide-based validation of susceptibility mapping after kahramanmaras earthquakes (feb 6, 2023) in amanos mountains. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVIII-1/W2-2023, 429-436.
<https://doi.org/10.5194/isprs-archives-XLVIII-1-W2-2023-429-2023>

- Lee, J.-S., & Pottier, E. (2017). *Polarimetric radar imaging: from basics to applications* (J.-S. Lee & E. Pottier, Eds.; 1.^a ed.). CRC Press.
<https://doi.org/10.1201/9781420054989>
- Liu, Y., Ma, S., Dong, L., Xiao, R., Huang, J., & Zhou, P. (2024). A comparative study of regional rainfall-induced landslide early warning models based on RF, CNN and MLP algorithms. *Frontiers in Earth Science*, 12.
<https://doi.org/10.3389/feart.2024.1419421>
- Meena, S. R., Puliero, S., Bhuyan, K., Floris, M., & Catani, F. (2022). Assessing the importance of conditioning factor selection in landslide susceptibility for the province of Belluno (region of Veneto, northeastern Italy). *Natural Hazards and Earth System Sciences*, 22(4), 1395-1417. <https://doi.org/10.5194/nhess-22-1395-2022>
- Mei, W., Wang, H., Fouhey, D., Zhou, W., Hinks, I., Gray, J. M., Van Berkel, D., & Jain, M. (2022). Using deep learning and very-high-resolution imagery to map smallholder field boundaries. *Remote Sensing*, 14(13), 3046.
<https://doi.org/10.3390/rs14133046>
- Mejía, L., Troya, J., & Avilés, E. (2021). *Evaluación de la susceptibilidad a movimientos de masas por deslizamientos mediante los índices de vegetación NDVI y SBI del cantón Alausí, provincia de Chimborazo* [Trabajo de titulación, Universidad Politécnica Salesiana, Cuenca].
<https://dspace.ups.edu.ec/handle/123456789/21413>
- Merghadi, A., Yunus, A. P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D. T., Avtar, R., & Abderrahmane, B. (2020). Machine learning methods for landslide susceptibility studies: a comparative overview of algorithm performance. *Earth-Science Reviews*, 207, 103225. <https://doi.org/10.1016/j.earscirev.2020.103225>
- Mondini, A. C., Santangelo, M., Rocchetti, M., Rossetto, E., Manconi, A., & Monserrat, O. (2019). Sentinel-1 SAR amplitude imagery for rapid landslide detection. *Remote Sensing*, 11(7), 760. <https://doi.org/10.3390/rs11070760>
- Montalvo, P., Sánchez, S., López, J., & Estévez, A. (2017, junio). *Los taludes de la vía Alóag-Santo Domingo. Empleo de drones para la caracterización de inestabilidades* [IX Simposio Nacional sobre Taludes y Laderas Inestables].
<https://www.researchgate.net/publication/318419660>
- Montgomery, D. R., & Dietrich, W. E. (1994). A physically based model for the topographic control on shallow landsliding. *Water Resources Research*, 30(4), 1153-1171. <https://doi.org/10.1029/93wr02979>

- Niraj, K. C., Singh, A., & Shukla, D. P. (2023). Effect of the Normalized Difference Vegetation Index (NDVI) on GIS-Enabled bivariate and multivariate statistical models for landslide susceptibility mapping. *Journal of the Indian Society of Remote Sensing*, 51(8), 1739-1756. <https://doi.org/10.1007/s12524-023-01738-5>
- Pacheco Quevedo, R., Velastegui-Montoya, A., Montalván-Burbano, N., Morante-Carballo, F., Korup, O., & Daleles Rennó, C. (2023). Land use and land cover as a conditioning factor in landslide susceptibility: a literature review. *Landslides*, 20(5), 967-982. <https://doi.org/10.1007/s10346-022-02020-4>
- Palacios, I. (2020). Susceptibilidad a deslizamientos en la vía Alóag – Santo domingo, mediante lógica difusa. *Revista geoespacial*, 17(2), 01-12. <https://journal.espe.edu.ec/ojs/index.php/revista-geoespacial/es/article/view/1571>
- Palacios Orejuela, I. F. (2024). Comparación entre Mora-Vahrson y Lógica difusa en la susceptibilidad a movimientos de tierra en el cantón Morona – Amazonía ecuatoriana. *Revista Cartográfica*, 108, 117-135. <https://doi.org/10.35424/rcarto.i108.4894>
- Palenzuela Baena, J. A., Soto Luzuriaga, J., & Irigaray Fernández, C. (2020). Characteristics of rainfall events triggering landslides in two climatologically different areas: southern Ecuador and southern Spain. *Hydrology*, 7(3), 45. <https://doi.org/10.3390/hydrology7030045>
- Pourghasemi, H. R., Mohammady, M., & Pradhan, B. (2012). Landslide susceptibility mapping using index of entropy and conditional probability models in GIS: Safarood Basin, Iran. *CATENA*, 97, 71-84. <https://doi.org/10.1016/j.catena.2012.05.005>
- Ramírez, M., & Melo, P. (2020). *Precipitaciones y movimientos en masa entre los km 14+000 y 77+000 de la vía Alóag – Santo Domingo en el año 2014* [Tesis de Maestría, Instituto De Altos Estudios Nacionales (IAEN), Quito, Ecuador]. <https://repositorio.iaen.edu.ec/jspui/handle/24000/6609>
- Rasyid, A. R., Bhandary, N. P., & Yatabe, R. (2016). Performance of frequency ratio and logistic regression model in creating GIS based landslides susceptibility map at Lompobattang Mountain, Indonesia. *Geoenvironmental Disasters*, 3(1), 19. <https://doi.org/10.1186/s40677-016-0053-x>
- Rivadeneira Cedeño, J. G., & Ortiz Hernández, E. (2024). Estabilización de laderas y protección ante los deslizamientos con túneles falsos: caso de estudio vía Alóag

- Santo Domingo. *Revista Científica Arbitrada Multidisciplinaria Pentaciencias*, 6(4), 36-56. <https://doi.org/10.59169/pentaciencias.v6i4.1121>
- Saaty, T. L. (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15(3), 234-281. [https://doi.org/10.1016/0022-2496\(77\)90033-5](https://doi.org/10.1016/0022-2496(77)90033-5)
- Shahabi, H., & Hashim, M. (2015). Landslide susceptibility mapping using GIS-based statistical models and Remote sensing data in tropical environments. *Scientific Reports*, 5(1). <https://doi.org/10.1038/srep09899>
- Shano, L., Raghuvanshi, T. K., & Meten, M. (2020). Landslide susceptibility evaluation and hazard zonation techniques – a review. *Geoenvironmental Disasters*, 7(1), 18. <https://doi.org/10.1186/s40677-020-00152-0>
- Silalahi, F. E. S., Pamela, Arifianti, Y., & Hidayat, F. (2019). Landslide susceptibility assessment using frequency ratio model in Bogor, West Java, Indonesia. *Geoscience Letters*, 6(1), 10. <https://doi.org/10.1186/s40562-019-0140-4>
- Srivastava, P. K., O'Neill, P., Cosh, M., Lang, R., & Joseph, A. (2015). Evaluation of radar vegetation indices for vegetation water content estimation using data from a ground-based SMAP simulator. *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 1296-1299. <https://doi.org/10.1109/IGARSS.2015.7326012>
- Tarboton, D. G. (1997). A new method for the determination of flow directions and upslope areas in grid digital elevation models. *Water Resources Research*, 33(2), 309-319. <https://doi.org/10.1029/96WR03137>
- Ulloa, J., Ballari, D., Campozano, L., & Samaniego, E. (2017). Two-step downscaling of Trmm 3b43 V7 precipitation in contrasting climatic regions with sparse monitoring: the case of Ecuador in tropical South America. *Remote Sensing*, 9(7), 758. <https://doi.org/10.3390/rs9070758>
- Velastegui Cáceres, L. A., Velastegui Cáceres, J. D., & Chamorro Sevilla, H. E. (2022). *Evaluación de vulnerabilidad sísmica apoyada en tecnologías de información geográfica*. Ciencia Digital Editorial. <https://doi.org/10.33262/cde.11>
- Walker, J. J., De Beurs, K. M., & Wynne, R. H. (2014). Dryland vegetation phenology across an elevation gradient in Arizona, USA, investigated with fused MODIS and Landsat data. *Remote Sensing of Environment*, 144, 85-97. <https://doi.org/10.1016/j.rse.2014.01.007>

Wang, Q., Jin, T., Li, J., Chang, X., Li, Y., & Zhu, Y. (2022). Modeling and assessment of vegetation water content on soil moisture retrieval via the synergistic use of sentinel-1 and sentinel-2. *Earth and Space Science*, 9(5), e2021EA002063. <https://doi.org/10.1029/2021EA002063>

Younes Cárdenas, N., & Erazo Mera, E. (2016). Landslide susceptibility analysis using remote sensing and GIS in the western Ecuadorian Andes. *Natural Hazards*, 81(3), 1829-1859. <https://doi.org/10.1007/s11069-016-2157-8>

Zhang, T., Li, Y., Wang, T., Wang, H., Chen, T., Sun, Z., Luo, D., Li, C., & Han, L. (2022). Evaluation of different machine learning models and novel deep learning-based algorithm for landslide susceptibility mapping. *Geoscience Letters*, 9(1), 26. <https://doi.org/10.1186/s40562-022-00236-9>

Zhao, Z., Liu, Z. Y., & Xu, C. (2021). Slope unit-based landslide susceptibility mapping using certainty factor, support vector machines, random forest, CF-SVM and CF-RF models. *Frontiers in Earth Science*, 9, 589630. <https://doi.org/10.3389/feart.2021.589630>

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Conciencia Digital**.



El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Conciencia Digital**.

