

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Ciencias de la Tierra

Mapeo de Susceptibilidad a Deslizamiento Mediante Comparación de
Evaluación Multicriterio y Machine Learning en los Andes Ecuatorianos.

Proyecto de Titulación

Previo la obtención del Título de:

Magíster en Ciencias de la Tierra

Presentado por:

Enrique David Colmont Villacres

Guayaquil - Ecuador

Año: 2025

Dedicatoria

A mi madre que me ha enseñado a seguir adelante, a creer y confiar en mí, a ese amor y apoyo incondicional. A mi padre que con sus palabras y su amor me ha sabido entender que siempre podemos ser mejores seres humanos. A Jonathan por ser mi apoyo en cada aspecto de mi vida, por hacer que confíe más en mí mismo, por su compañía y sus ánimos para continuar con todo lo que emprenda. A mi amada Espol que sigue siendo mi casa, mi escuela, que ha sabido enseñarme que soy capaz de lograr lo que al principio parecía tan difícil, siempre en base a mi esfuerzo y dedicación. A todos mis maestros, compañeros y amigos que este proceso me ha regalado, por ser de quienes he aprendido y compartido momentos y conocimientos gratos.

Agradecimientos

Mi más sincero agradecimiento al personal de la Secretaría de Gestión de Riesgos y del Gobierno Autónomo Descentralizado del Cantón Azogues, quienes han colaborado con este estudio facilitando información y recursos, especialmente durante la etapa de levantamiento de información, fundamental para el desarrollo de este trabajo. El desarrollo de este trabajo ha sido posible gracias al apoyo incondicional de mis grandes amigos Jorge Loy, Ángel Valdiviezo, Peter Olaya y Eddy Sanclemente, que han sabido apoyarme con su tiempo y conocimiento.

Declaración Expresa

Yo Enrique David Colmont Villacres acuerdo y reconozco que:

La titularidad de los derechos patrimoniales de autor del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por mí durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que me corresponda de los beneficios económicos que la ESPOL reciba por la explotación de mi innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique al autor que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, septiembre del 2025.

Enrique David Colmont Villacres

Evaluadores

Mónica Irene López Moncada, MSc.

Evaluada

Eddy Rubén Sanclemente Ordoñez, PhD.

Tutor de proyecto

RESUMEN

Los deslizamientos representan una amenaza importante en las regiones montañosas de los Andes ecuatorianos, cuya ocurrencia se ve condicionada por las características geomorfológicas, geológicas y antrópicas del terreno. El presente estudio evalúa la susceptibilidad a deslizamientos de una región de los andes en Ecuador aplicando tres metodologías: un enfoque híbrido de evaluación espacial multicriterio (SMCE) que combina Proceso Analítico Jerárquico (AHP) y Ratio de Frecuencia (FR); Random Forest (RF); y su versión optimizada que aplica Análisis de Componentes Principales (PCA). Se construyó un inventario de deslizamientos y se integraron 14 factores condicionantes que se derivan de datos de libre acceso, manteniendo una resolución espacial de 3 metros. La validación de los modelos se realizó empleando curvas ROC y métricas estadísticas. Los resultados muestran que el modelo que obtuvo el mejor desempeño es el modelo RF con factores condicionantes originales ($AUC = 0.947$, exactitud = 94.86%), influenciado mayormente por la distancia de vías y drenajes. Por otro lado, el modelo híbrido SMCE, a pesar de su menor rendimiento ($AUC = 0.843$), proporciona mayor interpretabilidad por el peso relativo de cada factor. La combinación de PCA con el algoritmo RF redujo la dimensionalidad alcanzando una buena precisión ($AUC = 0.906$). Estos modelos coinciden identificando a las modificaciones del terreno en áreas urbanas y rurales como las zonas de alta susceptibilidad. Este trabajo demuestra que RF con factores condicionantes originales es la técnica más efectiva para el mapeo de deslizamientos en contextos geodinámicos complejos.

Palabras Clave: Susceptibilidad a deslizamientos, Riesgo geológico, Random Forest, Componentes Principales, Evaluación Espacial Multicriterio.

Abstract

Landslides represent a significant hazard in the mountainous regions of the Ecuadorian Andes, where their occurrence is conditioned by the geomorphological, geological, and anthropogenic characteristics of the terrain. This study evaluates landslide susceptibility in a region of the Andes in Ecuador by applying three methodologies: a hybrid spatial multicriteria evaluation (SMCE) approach that combines the Analytic Hierarchy Process (AHP) and Frequency Ratio (FR); the Random Forest (RF) machine learning algorithm; and its optimized version using Principal Component Analysis (PCA). A landslide inventory was built, and 14 conditioning factors derived from open-access data were integrated, maintaining a spatial resolution of 3 meters. Model validation was performed using ROC curves and statistical metrics. The results show that the best-performing model is RF with the original conditioning factors ($AUC = 0.947$, accuracy = 94.86%), mainly influenced by road and drainage distance. On the other hand, although the hybrid SMCE model presented lower performance ($AUC = 0.843$), it offers greater interpretability through the relative weight of each factor. The combination of PCA with the RF algorithm reduced dimensionality while maintaining good accuracy ($AUC = 0.906$). All models consistently identify terrain modifications in urban and rural areas as zones of high susceptibility. This work demonstrates that RF with original conditioning factors is the most effective technique for landslide mapping in complex geodynamic contexts.

Keywords: *Landslide susceptibility, Geological Hazard, Random Forest, Principal Components, Geospatial Multicriteria Evaluation.*

Índice general

Resumen	I
<i>Abstract</i>	II
Índice general	III
Abreviaturas	VII
Simbología	VIII
Índice de figuras.....	IX
Índice de tablas	XI
Capítulo 1.....	1
1.1 Introducción	2
1.2 Descripción del Problema.....	5
1.3 Justificación del Problema.....	6
1.4 Objetivos	7
1.4.1 Objetivo general	7
1.4.2 Objetivos específicos.....	8
1.5 Marco teórico	8
1.5.1 Susceptibilidad	8
1.5.2 Deslizamientos	9
1.5.3 Factores condicionantes	14
1.5.3.1 Factores Morfológicos	15
1.5.3.2 Factores Geológicos e Hidrológicos.....	15
1.5.4 Evaluación Espacial Multicriterio	16
1.5.4.1 Proceso Analítico de Jerarquía (AHP).....	17
1.5.4.2 Ratio de frecuencia (FR)	17

1.5.5 Machine Learning	18
1.6 Zona De Estudio	20
1.7 Marco Geológico.....	22
1.8 Cobertura uso de suelo	26
1.9 Eventos de deslizamientos	27
Capítulo 2.....	31
2. Metodología.	32
2.1 Factores Condicionantes de Deslizamiento	33
2.1.1 Modelo Digital de Elevación (MDE)	35
2.1.2 Pendiente (Slope).....	37
2.1.3 Aspecto	37
2.1.4 STI (Sediment Transport Index)	38
2.1.5 SPI (Stream Power Index).....	38
2.1.6 TWI (Topographic Wetness Index)	39
2.1.7 Litología.....	39
2.1.8 Cobertura y uso de suelo.....	40
2.1.9 Distancia de Fallas	40
2.1.10 Distancia de Drenajes	41
2.1.11 Distancia de Vías	41
2.1.12 NDVI	42
2.1.13 NDMI.....	42
2.1.14 MNDWI	43
2.2 Inventario de Deslizamientos	43
2.3 Evaluación Espacial Multicriterio (SMCE).....	45

2.3.1	Proceso de Análisis Jerárquico (AHP)	45
2.3.2	Ratio de Frecuencia.....	48
2.4	Random Forest.....	50
2.4.1	Evaluación de desempeño	51
2.4.2	Matriz de confusión	52
2.4.3	Curva ROC (Receiver Operating Characteristic).....	53
2.5	Análisis de Componentes Principales.....	53
2.5.1	Evaluación de desempeño	54
Capítulo 3.....		55
3.	Resultados y análisis	56
3.1	Factores Condicionantes de Deslizamiento	56
3.2	Híbrido de Evaluación Espacial Multicriterio (SMCE).....	62
3.3	Random Forest (RF)	68
3.3.1	Preparación y descripción de los datos.....	68
3.3.2	Validación y evaluación del modelo	71
3.3.3	Mapa de susceptibilidad a deslizamientos generado	73
3.4	Análisis de Componentes Principales y Random Forest.....	74
3.5	Selección final de mapa de susceptibilidad a deslizamientos	79
3.6	Aplicación en Hidrocarburos	81
Capítulo 4.....		83
4.1	Conclusiones y recomendaciones	84
4.1.1	Conclusiones.....	84
4.1.2	Recomendaciones	86
Referencias.....		88

Abreviaturas

SMCA	Spatial Multicriteria Analysis
FR	Frequency Ratio
AHP	Analytic Hierarchy Process
RF	Random Forest
MSD	Mapeo de la Susceptibilidad a Deslizamiento
SNGR	Secretaría Nacional de Gestión de Riesgos
ML	Machine Learning
ROC	Receiver Operating Characteristic
AUC	Area Under the Curve
ODS	Objetivos de Desarrollo Sostenible
MDE	Modelo Digital de Elevación
ESDB	European Soil Database
PCA	Análisis de Componentes Principales
CP	Componentes Principales
GIS	Geographic Information System
USGS	United States Geological Survey
ANN	Redes Neuronales Artificiales
DT	Decision Tree
MTOP	Ministerio de Transporte y Obras Públicas
EEM	Evaluación Espacial Multicriterio
Ms	Magnitude of Surface waves

Simbología

Km	Kilometro
m	Metro
m ³	Metro Cúbico
cm	Centímetro
seg	Segundos
min	Minutos
msnm	Metros Sobre el Nivel del Mar

Índice de figuras

Figura 1	<i>Deslizamientos reportados en la zona de estudio</i>	5
Figura 2.	<i>Esquema de la problemática</i>	6
Figura 3.	<i>Caída de roca por plano de estratificación. (Fuente USGS)</i>	10
Figura 4	<i>Basculamiento de rocas por gravedad. (Fuente USGS)</i>	10
Figura 5	<i>Morfología de diferentes tipos de movimientos de masa</i>	12
Figura 6	<i>Eventos tipo deslizamientos</i>	13
Figura 7	<i>Arquitectura de una red neuronal tomada de (Lee et al., 2003)</i>	18
Figura 8	<i>Esquema de funcionamiento de árbol de decisiones</i>	19
Figura 9	<i>Esquema del algoritmo Random Forest</i>	20
Figura 10	<i>Mapa de ubicación de la zona de estudio</i>	21
Figura 11	<i>Mapa geológico del cantón Azogues</i>	25
Figura 12	<i>Mapa de cobertura y uso de suelo del cantón Azogues</i>	27
Figura 13	<i>Noticias de deslizamientos en la zona de estudio</i>	29
Figura 14	<i>Esquema de metodología aplicada en el proyecto</i>	32
Figura 15	<i>Esquema de Random Forest</i>	51
Figura 16	<i>Esquema de matriz de confusión.</i>	52
Figura 17	<i>Modelos de elevación resultantes.</i>	57
Figura 18	<i>Mapas de factores condicionantes</i>	61
Figura 19	<i>Pesos asignados a los factores condicionantes</i>	63
Figura 20	<i>Mapa de susceptibilidad a deslizamientos Híbrido SMCE</i>	67
Figura 21	<i>Curva ROC y el AUC modelo Híbrido SMCE.</i>	68
Figura 22	<i>Factores importantes en capacidad de predicción del modelo</i>	70
Figura 23	<i>Curva ROC del modelo de susceptibilidad empleando RF</i>	72
Figura 24	<i>Mapa de susceptibilidad a deslizamientos empleando RF</i>	74
Figura 25	<i>Gráfica de las componentes principales.</i>	75
Figura 26	<i>Métricas de exactitud</i>	76
Figura 27	<i>Gráfica de análisis de cambio</i>	77

Figura 28 <i>Curva ROC del modelo de susceptibilidad 14 PCA + RF</i>	78
Figura 29 <i>Biplot entre las dos PC más influyentes</i>	79
Figura 30 <i>Comparación de los valores de AUC de los tres modelos</i>	80

Índice de tablas

Tabla 1. <i>Clasificación de los deslizamientos de acuerdo con Varnes, 1978</i>	9
Tabla 2. <i>Clasificación por tamaño desplazado (Rodríguez Ortiz et al., 1978)</i>	13
Tabla 3. <i>Clasificación de deslizamientos por su velocidad (Hansen, 1984)</i>	14
Tabla 4. Unidades geológicas de la zona de estudio, cantón Azogues.	23
Tabla 5. <i>Información base de fuentes oficiales</i>	34
Tabla 6. <i>Inventario histórico de deslizamientos</i>	44
Tabla 7. <i>Escala fundamental de evaluación (Saaty, 1987)</i>	46
Tabla 8. <i>Matriz de comparación por pares (Saaty, 1987)</i>	48
Tabla 9. <i>Factores condicionantes y sus clases</i>	64
Tabla 10. <i>Matriz de confusión</i>	71
Tabla 11 <i>Rangos de clasificación de susceptibilidad</i>	73
Tabla 12 Comparación de porcentaje de área por rango	80

Capítulo 1

1.1 Introducción

Los deslizamientos representan el 4.9% de los desastres naturales registrados a nivel mundial y son responsables del 1.3% de muertes causadas por este tipo de eventos (Froude & Petley, 2018). En Sudamérica los deslizamientos son responsables de 14% de los desastres naturales y del 16% de muertes asociadas a estos eventos, las cuales se concentran notablemente en Perú, Ecuador y Colombia (World Meteorological Organization, 2021) siendo la degradación ambiental, la densificación y una creciente expansión de población urbana los principales responsables de que ocurran (Puente-Sotomayor et al., 2021).

En el mundo se han registrado eventos devastadores debido a deslizamientos, un ejemplo de ello es el ocurrido el 15 de septiembre de 2022 en el centro de Italia. Debido a lluvias excepcionales que se prolongaron por un periodo de 6 a 7 horas, ocurrieron 1.687 deslizamientos en la zona, provocando daños estructurales, cerca de 50 afectados y más de 100 evacuados (Donnini et al., 2023). Otro caso es el registrado el 15 de diciembre de 2005 en Vietnam, en el distrito de Van Canh, se produjo una serie de deslizamientos de tierra que desplazaron hasta 195.000 m³ de material suelto, como consecuencia de un período prolongado de lluvias entre septiembre y diciembre de 2005 (Duc, 2013).

En el caso de Ecuador, los deslizamientos son el segundo evento de mayor recurrencia, alcanzando el 14% de eventos adversos reportados en entre 2010 y 2022 (SGR, 2024). Aquí se han registrado eventos catalogados como catastróficos, como el ocurrido el 29 de marzo de 1993, donde se produjo un deslizamiento de grandes proporciones en el cerro Tamuga, en los límites entre Cuenca, Gualaceo y Paute, que desplazó 20 millones de m³ de material (Plaza et al., 2011), dejando más de 100 pérdidas humanas y provocando el represamiento del río Paute. Esto provocó que el agua acumulada se desborde destruyendo edificaciones y vías (D'Ercole & Trujillo, 2003), un evento sin precedentes.

Eventos como los mencionados, muestran la importancia de conocer y delimitar las zonas que tienen un alto grado de susceptibilidad frente a deslizamientos, lo que es

fundamental para salvaguardar la vida de las poblaciones en riesgo. Los deslizamientos pueden convertirse en eventos de alta peligrosidad debido a la ocurrencia de lluvias intensas o actividad sísmica en suelos erosionados o alterados por la actividad antropogénica (Gonzales de Vallejo, 2002).

El mapeo de la susceptibilidad a deslizamientos (MSD) brinda información sobre cuan probable es que ocurra un deslizamiento en un área determinada (Gudiyangada Nachappa et al., 2020). Existen diversos métodos para el MSD (Guzzetti et al., 2012) empleando modelos cualitativos y cuantitativos agrupadas en 5 categorías de acuerdo con Reichenbach et al (2018): (i) cartografía geomorfológica, (ii) análisis de inventarios de deslizamientos, (iii) enfoques heurísticos (modelos basados en conocimiento de expertos), (iv) métodos basados en procesos y (v) métodos de modelado basados en estadísticas. Hoy en día el uso de GIS, sensores remotos y la aplicación de principios de Machine Learning (ML) (Bui et al., 2020; Chen & Li, 2020), han permitido reducir el tiempo, uso de insumos y obtener resultados más precisos y fiables al momento de generar un MSD. Este producto se convierte en una herramienta para las autoridades locales y la comunidad, para tomar acciones informadas y tener una visión amplia de las zonas susceptibles, permitiendo prevenir y mitigar los peligros asociados a eventos de movimiento de masa.(Lynn Highland, 2004).

Dentro del grupo de métodos heurísticos está el Proceso Analítico de Jerarquía (Analytic Hierarchy Process - AHP) (Saaty, 1987) que es un método semi-cuantitativo de Evaluación Espacial Multicriterio (SMCE) ampliamente utilizada, la cual se basa en el conocimiento de expertos, mediante una matriz de evaluación por pares, donde se asigna un peso o ponderación a cada factor condicionante de acuerdo con su influencia a la ocurrencia de deslizamientos respecto a los demás factores. Por otro lado, el ratio de frecuencia (FR) es un método estadístico cuantitativo que mide el nivel de correlación que tiene el inventario de deslizamientos con las clases de cada factor condicionante seleccionado para el análisis, mostrando el nivel de importancia de cada clase para el mapeo de la susceptibilidad (Meena,

Mishra, et al., 2019; van Westen, 1997). Al final ambos métodos analizan el nivel de correlación que resulta entre cada evento de deslizamiento y los factores condicionantes para el mapeo de susceptibilidad a deslizamientos (Meena, Ghorbanzadeh, et al., 2019). Es posible combinar ambas metodologías generando un modelo híbrido de SMCE, cuyo resultado tendría mayor precisión en la identificación de zonas susceptibles a deslizamiento, y cuyo rendimiento se puede evaluar mediante el análisis de la curva operativa del receptor (ROC) (Fawcett, 2006), midiendo el área bajo la curva (AUC) (Lee & Dan, 2005).

El machine learning (ML) agrupa métodos estadísticos para el análisis de datos basados en inteligencia artificial, utilizando información preestablecida para obtener conocimiento de manera inducida. ML utiliza técnicas describen y descubren patrones que permiten predecir de sucesos futuros (Witter & Frank, 2005). El uso de machine learning para el mapeo de susceptibilidad a deslizamientos es cada vez más utilizado debido al grado de precisión de los modelos generados en comparación con otros enfoques (Huang et al., 2020). Uno de los algoritmos más empleados en el campo del ML es el Random Forest que combina una serie de árboles de decisiones durante el entrenamiento, combinando sus resultados para mejorar la precisión del modelo (Breiman, 2001). De acuerdo con autores como Merghadi et al. (2020), Random Forest es considerado uno de los métodos más eficientes para mapeo de susceptibilidad a deslizamientos, especialmente cuando se maneja grandes volúmenes de datos que no tienen relación lineal y se agregan múltiples factores condicionantes en el proceso analítico.

Autores como Abedini & Tulabi (2018); Huang et al. (2020); Romer & Ferentinou (2016); Zhang et al. (2017), han estudiado la susceptibilidad a deslizamientos, empleando análisis comparativos utilizando diferentes métodos para encontrar la alternativa más adecuada basados en el grado de eficiencia de los modelos resultantes. Estos estudios dan una visión de las ventajas y limitaciones de diferentes enfoques, resaltando los factores

condicionantes para el análisis. En ciertas regiones, los mapas de susceptibilidad disponibles presentan limitaciones en la incorporación de los factores condicionantes.

En este estudio se eligió el cantón Azogues en Ecuador, donde se busca generar un mapa de susceptibilidad a deslizamientos empleando técnicas cuantitativas y estadísticas, así como Machine Learning, para comparar la eficiencia y rendimiento de cada modelo generado. Se han seleccionado 14 factores catalogados como condicionantes a deslizamiento, que serán validados para evaluar su influencia a fin de refinar y aumentar la capacidad predictiva del modelo.

1.2 Descripción del Problema

El cantón Azogues enfrenta la problemática constante de eventos de deslizamientos de tierra, que representan el 6% de eventos adversos reportados en la última década, generando riesgos para diversos elementos expuestos, afectando directamente a la población en términos socioeconómicos (Figura 1). Los deslizamientos, al igual que los incendios forestales, inundaciones y precipitaciones intensas, representan una amenaza para las comunidades del cantón, en particular los deslizamientos recurrentes en zonas donde el entorno ha sido alterado por la apertura de vías o deforestación.

Figura 1

Deslizamientos reportados en la zona de estudio




Nota. Material deslizado al borde de la vía Matrama-Marzar en el sector de Pindilig y Shall. Fotografía tomada el 15 de noviembre de 2024

Conocer la distribución espacial y temporal de los deslizamientos es crucial para evaluar estos fenómenos, sin embargo, la zona de estudio no cuenta con un registro sistemático multitemporal de tales eventos. Además, para poder comprender a profundidad la ocurrencia de los deslizamientos, es esencial reconocer los factores que inciden en su ocurrencia. Sin embargo, no se dispone de una base de datos actualizada de alta resolución espacial que recopile factores geológicos, hidrológicos y ambientales del área de estudio. El gobierno local cuenta con un mapa de susceptibilidad a movimientos en masa basado en la distribución espacial de los deslizamientos, omitiendo su relación con factores condicionantes (Guzzetti et al., 1999) siendo imprecisa al momento de predecir zonas con un alto grado de susceptibilidad (Figura 2).

Figura 2.

Esquema de la problemática



1.3 Justificación del Problema

Actualmente el gobierno local no cuenta con un mapa que detalle el grado de susceptibilidad a deslizamientos de tierra en toda la extensión del área de estudio, limitada principalmente por la disponibilidad de información base y el empleo de técnicas integrales que incluyan factores condicionantes a deslizamientos. Esto no permite predecir sitios con

susceptibilidad a deslizamientos a pesar de no existir registros de su ocurrencia hasta ahora, con ello evaluar y diseñar planes de contingencia.

Los modelos resultantes identificarán con mayor precisión aquellos sectores en donde existe una alta probabilidad de amenaza a deslizamientos, facilitando la implementación de medidas preventivas y de mitigación en caso de que algún factor condicionante influyente llegue a estados críticos. El uso de técnicas heurísticas y basados en datos estadísticos como el Machine Learning puede adaptarse a nueva información y complementarse con avances en la teledetección.

Con este proyecto se contribuye en los Objetivos de Desarrollo Sostenible (ODS):

- ODS 1: Fin de la pobreza; Fomentar la resiliencia en las personas que se encuentran en situaciones vulnerables y reducir su exposición los fenómenos extremos del clima y a desastres ambientales.
- ODS 3: Salud y bienestar; Reforzar la capacidad de todos los países, en particular los países en desarrollo, en materia de alerta temprana, reducción de riesgos y gestión de los riesgos para la salud nacional y mundial
- ODS 11: Ciudades y comunidades sostenibles; reducir significativamente el número de muertes causadas por los desastres,
- ODS 13: Acción por el clima; Fortalecer la resiliencia y la capacidad de adaptación a los riesgos relacionados con el clima y los desastres naturales

1.4 Objetivos

1.4.1 Objetivo general

Generar un mapa de susceptibilidad a deslizamientos empleando evaluación espacial multicriterio, análisis de componentes principales y Random Forest, para la identificación de zonas más propensas a deslizamientos.

1.4.2 Objetivos específicos

- Utilizar factores condicionantes generados a partir de datos geoespaciales de libre acceso y alta resolución espacial.
- Realizar un inventario de deslizamientos del cantón Azogues en base a la información disponible de fuentes oficiales para el entrenamiento y validación de los modelos generados.
- Emplear un enfoque híbrido de Evaluación Espacial Multicriterio (SMCE) que combina el Proceso Analítico de Jerarquías (AHP) y el Ratio de Frecuencia (FR) para obtener un modelo de susceptibilidad a deslizamientos.
- Implementar el algoritmo de Random Forest para generar un modelo de susceptibilidad a deslizamientos.
- Aplicar el Análisis de Componentes Principales (PCA) y emplearlo en el algoritmo de Random Forest para obtener un modelo de susceptibilidad a deslizamientos.
- Comparar los resultados obtenidos en la evaluación espacial multicriterio, el análisis de componentes principales y Random Forest, en base a la capacidad predictiva y precisión de deslizamientos.
- Seleccionar el mapa de susceptibilidad a deslizamientos mediante el uso del modelo con mejor capacidad predictiva a deslizamientos.

1.5 Marco teórico

1.5.1 Susceptibilidad

El análisis de susceptibilidad de deslizamientos es uno de los principales procedimientos diseñados para comprender qué condicionantes ha sido los responsables de los deslizamientos históricos en una zona determinada, mismas que podrían ocasionar

deslizamientos en el futuro (Guzzetti et al., 2012). La susceptibilidad ante deslizamientos está directamente relacionada a las condiciones o factores desencadenantes, así como a las características propias de las zonas como la geología, la pendiente, la vegetación y otros (Dias et al., 2021).

1.5.2 Deslizamientos

Los deslizamientos corresponden a un tipo de proceso de remoción en masa donde el movimiento de suelo o roca sigue una superficie de ruptura. Estos pueden ser provocados por lluvias intensas, erosión, actividad sísmica o actividad antropogénica, convirtiéndolos en eventos de alta peligrosidad. (Gonzales de Vallejo, 2002). Una de las clasificaciones más utilizadas para categorizar los deslizamientos es la Varnes (1978) (Tabla 1) que relaciona el tipo del movimiento y la naturaleza del material.

Tabla 1.

Clasificación de los deslizamientos de acuerdo con Varnes, 1978


Tipo de movimiento		Tipo de material		
		Roca	Suelo	
			De grano grueso	De grano fino
Caídas		Caídas de rocas	Caídas de detritos	Caídas de suelos
Basculamientos		Basculamiento de rocas	Basculamiento de detritos	Basculamiento de suelos
Deslizamiento	Rotacionales	Deslizamiento rotacional de rocas	Deslizamiento rotacional de detritos	Deslizamiento rotacional de suelos
		Deslizamiento traslacional de rocas	Deslizamiento traslacional de detritos	Deslizamiento traslacional de suelos
	Traslacionales	Deslizamiento rotacional de rocas	Deslizamiento rotacional de detritos	Deslizamiento rotacional de suelos
		Deslizamiento traslacional de rocas	Deslizamiento traslacional de detritos	Deslizamiento traslacional de suelos
Separaciones Laterales		Separación lateral en roca	Separación lateral en detritos	Separación lateral en suelos
Flujos		Flujo de rocas	Flujo de detritos	Flujo de suelos
Complejos		Combinación de dos o más tipos		

Nota. La tabla presenta una clasificación detallada de los deslizamientos en función del tipo de material y movimiento. En la zona de estudio, los deslizamientos rotacionales y traslacionales son los más comunes, destacando los rotacionales por su mayor frecuencia.

Caídas: Son movimientos repentinos donde existe desprendimiento de suelo o roca sobre una pendiente abrupta, ocurre generalmente a lo largo de discontinuidades como fallas, diaclasas, entre otros, produciendo la caída libre del material de manera rápida (Figura 3).

Figura 3.

Caída de roca por plano de estratificación. (Fuente USGS)



Basculamientos: Estos se distinguen por la rotación hacia adelante de masas de roca o suelo alrededor de algún punto de pivote, causado por la gravedad o las fuerzas de empuje ejercidas por unidades adyacentes o por fluidos en grietas (Figura 4).

Figura 4

Basculamiento de rocas por gravedad. (Fuente USGS)




Flujos: Existen cinco categorías dentro de este tipo de deslizamiento (Figura 5), estos son:

- a) Flujo de escombros: Es una forma de movimiento masivo repentino de la mezcla de suelo, roca, aire y agua fluyendo pendiente abajo. Son principalmente causados el flujo de agua de escorrentías superficiales consecuencia de fuertes precipitaciones, así como efectos de otros tipos de deslizamientos de tierra que ocurren en pendientes pronunciadas.
- b) Avalancha de escombros: Cuando un flujo de escombros se desplaza muy rápidamente
- c) Flujo de tierra: Tienen una forma característica de “reloj de arena”. El material generalmente de grano fino presente en el talud se licua y se escurre formando una depresión en la cabecera.
- d) Flujo de lodo: Es un flujo de tierra que consiste en material lo suficientemente húmedo como para fluir rápidamente y que contiene al menos un 50 por ciento de partículas del tamaño de arena, limo y arcilla.
- e) Reptación: Movimiento lento, constante y descendente del suelo o roca que forma pendientes. El movimiento es causado por un esfuerzo cortante suficiente para producir una deformación permanente, pero demasiado pequeño para producir una falla por corte. Este movimiento se hace evidente por la inclinación de árboles, muros, postes, así como ligeras ondulaciones en la superficie del terreno.

Figura 5

Morfología de diferentes tipos de movimientos de masa




Nota: A) Flujo de escombros: caracterizado por un flujo turbulento de material. B) Avalancha de escombros: movimiento extremadamente rápido y destructivo. C) Flujo de tierra: material fino en forma de "reloj de arena". D) Reptación: movimiento lento, evidenciado por la inclinación de árboles y postes. (Fuente USGS)

Deslizamientos: En el uso más estricto del término, cuando nos referimos a “deslizamientos” se hace referencia a movimientos de masa donde existe un plano que separa el material del deslizamiento del material subyacente más estable. Los dos tipos principales de deslizamientos son los rotacionales o traslacionales. En un deslizamiento rotacional ocurre sobre una superficie de rotura curva o concoide (Figura 6a), es común en suelos cohesivos, pudiendo alcanzar dimensiones de cientos de metros y profundidades de hasta 10 metros. Por otro lado, un deslizamiento traslacional ocurre sobre superficies planas preexistentes (plano

de estratificación, contactos litológicos o planos estructurales) (Figura 6b), pudiendo abarcar grandes dimensiones sin estar condicionados a pendientes abruptas.

Figura 6

Eventos tipo deslizamientos



Nota: a) Deslizamiento rotacional: caracterizado por una superficie de rotura curva y común en suelos cohesivos. b) Deslizamiento traslacional: se produce a lo largo de una superficie plana, a menudo controlada por la estructura geológica (Fuente USGS)

Dentro de la categorización de los deslizamientos, se pueden considerar dos factores: tamaño y velocidad. Las magnitudes de la masa desplazada varían y la clasificación por tamaño más utilizada es la propuesta por Rodriguez Ortiz et al. (1978)

Tabla 2.

Clasificación por tamaño desplazado (Rodriguez Ortiz et al., 1978)

TAMAÑO	VOLUMEN (m ³)
Pequeña	1 – 50
Moderada	50 – 500
Grande	500 – 5.000
Muy grande	5.000 – 50.000
Excepcionalmente grande	>50.000

Nota: Un evento pequeño es el desprendimiento de rocas de un talud sobre la vía. Un deslizamiento de categoría moderada en una zona urbana causaría daños a propiedades. Un deslizamiento de gran tamaño puede incomunicar poblaciones, bloqueando vías completas. Las categorías de mayor tamaño representarían eventos catastróficos.

Hansen (1984), propone una categorización de acuerdo con la velocidad de desplazamiento del material. Por otro lado, la velocidad con la que se desplaza el material durante un deslizamiento se puede categorizar de acuerdo con la Tabla 3:

Tabla 3.

Clasificación de deslizamientos por su velocidad (Hansen, 1984).

VELOCIDAD	cm/seg	otras unidades
Extremadamente rápida	300	0,3 m/min
Muy rápida	0,5	
Rápida	17×10^{-4}	1,5 m/día
Moderada	6×10^{-5}	1,5 m/día
Lenta	5×10^{-6}	1,5 m/año
Muy lenta	1×10^{-7}	0,6 m/año
Extremadamente lenta	$< 1 \times 10^{-7}$	

1.5.3 Factores condicionantes

La ocurrencia de deslizamientos puede estar relacionada a diversos factores que incluyen la morfología, geología, hidrología, factores físicos de estabilidad y factores antrópicos (Varnes, 1978), los cuales pueden ser catalogados como factores condicionantes o desencadenantes, mismos que no necesariamente ocurren de manera individual sino más bien son el resultado de la combinación de algunos de ellos que condicionan la ocurrencia de estos fenómenos.

1.5.3.1 Factores Morfológicos

Los factores morfológicos representan características cuantitativas de la forma del terreno que se derivan de la topografía que influyen en la susceptibilidad a deslizamientos, dentro de los cuales se encuentra la elevación, pendiente, aspecto entre otros.

Elevación: La altitud suele representar un factor que afecta la susceptibilidad a deslizamientos en el sentido en que cuanto más elevado el terreno mayor susceptibilidad a deslizamientos.

Pendiente: Corresponde a la inclinación del terreno medido a partir de un plano horizontal, la misma que se mediría entre 0 y 90 grados. Generalmente mientras mayor sea la pendiente mayor será la susceptibilidad de ocurrencia de deslizamientos.

Aspecto: La superficie tiene orientaciones respecto a los puntos cardinales del planeta, representando la orientación de la pendiente misma que se medirá en función de ocho cuadrantes: norte, noreste, este, sureste, sur, suroeste, oeste y noroeste. De este factor dependen diferentes procesos como la evaporación del agua en el suelo, cobertura vegetal, erosión de las rocas, y todo aquello que pueda verse afectado por la radiación solar.

1.5.3.2 Factores Geológicos e Hidrológicos

Los factores geológicos e hidrológicos tienen un papel fundamental cuando nos referimos a la estabilidad del terreno, es por ello que, para el análisis de la susceptibilidad a deslizamientos son necesarios de considerar. Factores geológicos como la litología y la presencia de fallas, determinan la resistencia de la roca frente a inestabilidad. Por otro lado, la hidrología asociada con la influencia del agua en procesos de erosión incluye el análisis de ciertos índices derivados de la red hidrográfica.

Litología: Las propiedades mecánicas de las rocas presentes el área de estudio es indispensable para el análisis del terreno. La resistencia, distribución de tensiones internas y

demás factores que resultan ante esfuerzos de deformación y destrucción son diferentes para cada litología presente.

Fallas: La presencia de este tipo de estructuras geológicas debilitan el material rocoso y suelos, aumentando la susceptibilidad a que ocurran deslizamientos.

Hidrología: De esta se desprenden distintos índices que son claves para el análisis y evaluación de susceptibilidad a deslizamientos en una zona específica. Estos índices están relacionados a la proximidad de la red hidrográfica, la capacidad de transporte de sedimentos y de erosión, así como la distribución y acumulación de humedad y agua. Estos son factores que influyen en la estabilidad del terreno y con ello la ocurrencia de deslizamientos.

1.5.4 Evaluación Espacial Multicriterio

El mapeo de susceptibilidad a deslizamientos de tierra continúa siendo una herramienta fundamental para la mitigación de los riesgos que representan estos fenómenos, particularmente en las zonas que son propensas a la inestabilidad de laderas. Esta metodología ha surgido como un marco sólido para integrar diversos factores, sean estos físicos, ambientales, antropogénicos, entre otros, para ser usados en modelos predictivos. El SMCE (siglas en inglés para Spatial Multicriteria Evaluation) representa un proceso de evaluación por pesos mediante el uso de parámetros tanto cualitativos como cuantitativos, brindando soluciones alternativas con la posibilidad de seleccionar la mejor (Saaty, 1987; Vojteková & Vojtek, 2020). El uso de SMCE permite generar mapas con altos niveles de precisión y confiabilidad, los que pueden ser utilizados por los tomadores de decisiones como información para generar planes de gestión de desastres (Gudiyangada Nachappa et al., 2020). La combinación de datos geoespaciales, como geología, topografía e hidrología representada en sistemas de información geográfica (SIG), con datos no espaciales, como criterios de ponderación (Meena, Mishra, et al., 2019).

1.5.4.1 Proceso Analítico de Jerarquía (AHP)

Es un método semi-cuantitativo de evaluación espacial multicriterio (SMCE) ampliamente utilizada en el mapeo de susceptibilidad a deslizamientos. Este método se basa en el conocimiento de expertos, ejecutado mediante comparaciones por pares con el objetivo de encontrar el grado en el que una alternativa supera a las otras en función de criterios definidos (Saaty, 1987) lo que se resultará en la determinación del peso de influencia con el que una alternativa influye en la ocurrencia de deslizamientos (Sahnoun et al., 2012). En la matriz se establece el grado de importancia por cada par de factores analizados, asignando un valor que representa el grado en que aporta cada factor en la ocurrencia de un deslizamiento en base al conocimiento experto del fenómeno.

1.5.4.2 Ratio de frecuencia (FR)

Esta herramienta de evaluación espacial proporciona probabilidades de distribuir la presencia y ausencia de un fenómeno para cada factor condicionante en la extensión del área de estudio. Este se basa en observar la relación entre la distribución de los fenómenos y cada factor relacionado con estos, revelando la correlación entre las ubicaciones de los deslizamientos y los factores causales en el área de estudio (Pradhan, 2010)

El grado en el que se relacionan los factores condicionantes y la distribución espacial del fenómeno es posible representarlo mediante ponderaciones para cada clase dentro de cada factor considerado en el estudio. Para esto es necesario contar con un inventario de la ubicación de los fenómenos, el cual será superpuesto a los factores condicionantes, obteniendo el peso que resulta de dividir la relación de ocurrencia de deslizamiento en una clase por la relación de área de esa clase (Demir et al., 2013).

1.5.5 Machine Learning


El machine learning (ML) agrupa métodos de análisis de datos basados en inteligencia artificial (IA), utilizando información preestablecida para obtener conocimiento de manera inducida. Esta disciplina de la IA se basa en el desarrollo de algoritmos matemáticos y estadísticos con la capacidad de procesar gran volumen de información. Estos algoritmos pueden construir modelos matemáticos a partir de información de entrenamiento para describir y descubrir patrones que pueden aplicarse para predicciones de sucesos futuros (Witter & Frank, 2005).

De acuerdo con el estudio de Hong (2023), los modelos de ML más utilizados son: redes neuronales artificiales (ANN), árboles de decisión (Decision Tree - DT) y bosque aleatorios (Random Forest – RF).

Las redes neuronales artificiales, ha demostrado ser un método eficaz al momento de evaluar fenómenos naturales a partir de integrar un gran volumen de datos geoespaciales. Lee et al. (2003) en su estudio utiliza esta metodología, donde entrenó modelos utilizando una serie de factores condicionantes, de cuyos pesos asignados fueron optimizados en el proceso de entrenamiento teniendo como resultado la identificación de patrones y correlaciones entre la ocurrencia del evento estudiado y las características del terreno.

Figura 7

Arquitectura de una red neuronal tomada de (Lee et al., 2003)




Nota: Muestra las variables de entrada y ocultas que son parte de este algoritmo de ML

El algoritmo de árbol de decisión es un método analítico utilizado para modelar relaciones en un gran volumen de datos, con la finalidad de realizar análisis de decisión sobre un tema determinado (Saygin et al., 2023). La estructura de un árbol de decisión inicia de un “nodo raíz” y continua a través de ramas o “nodos hijos”. En la última etapa, el denominado “nodo terminal” explica finalmente el modelo sin necesidad de más divisiones (Park et al., 2018).

Figura 8

Esquema de funcionamiento de árbol de decisiones




Nota: El árbol de clasificación que opera en un espacio de características de cuatro dimensiones y clasifica los datos en tres clases distintas (A, B y C). Tomada de (Saygin et al., 2023)

Random Forest es un algoritmo de machine learning que combina una serie de árboles de decisiones durante el entrenamiento, combinando sus resultados para mejorar la precisión del modelo (Breiman, 2001; Chowdhury et al., 2024). De acuerdo con autores como Merghadi et al. (2020), random forest es uno de los métodos más eficientes para mapeo de susceptibilidad a deslizamientos, especialmente cuando se maneja grandes volúmenes de

datos que no tienen relación lineal y se agregan factores condicionantes en el proceso analítico.

Figura 9

Esquema del algoritmo Random Forest



Nota: donde múltiples árboles de decisión generan predicciones individuales a partir del conjunto de datos, y el resultado final se obtiene mediante votación por mayoría o promediado.

1.6 Zona De Estudio

El área de estudio corresponde al cantón Azogues, capital de la provincia de Cañar, ubicada en el corredor interandino de Ecuador a 130 km de la ciudad de Guayaquil, con una extensión de 163 km². Presenta topografías accidentadas hacia las zonas orientales y un relieve irregular en toda su extensión, con pendientes pronunciadas, lomas, llanuras onduladas y valles, que van de los 2000 m.s.n.m. hasta los 4000 m.s.n.m. (Figura 9). El clima está condicionado a la altitud del terreno, siendo más frío en las partes altas, no existen estaciones marcadas debido a la presencia de precipitaciones durante todo el año, siendo más recurrentes y prolongadas entre los meses de enero y agosto. Su vegetación está compuesta principalmente por grandes extensiones de gramíneas herbáceas que se han reducido progresivamente debido a la adecuación de espacios para pastoreo.


El cantón Azogues se divide políticamente en nueve parroquias, de las cuales ocho corresponden a parroquias rurales: Guapan, Luis Cordero, Cojitambo, Javier Loyola, Pindilig, Taday, Rivera y San Miguel, y una parroquia urbana: Azogues. Esta última corresponde a la cabecera cantonal, agrupando la mayor densidad poblacional con aproximadamente 86.200 habitantes

Su geología está conformada por rocas metamórficas indiferenciadas, destacando filitas y esquistos del Paleozoico junto con metavolcanitas del Jurásico como esquistos verdes, cuarcitas y mármoles, evidenciando un entorno tectónicamente activo. Rocas del Cretácico sugieren ambientes sedimentarios marinos debido a la presencia de limolitas con calizas y areniscas cuarzosas feldespáticas. Rocas del Mioceno que van cronológicamente de arcillas rojizas y yeso en las capas más antiguas, seguidas por lutitas con vetas de carbón, limolitas y areniscas, hasta areniscas tobáceas gruesas, localmente alteradas y niveles de conglomerados hacia los niveles estratigráficos superiores. Finalmente, el Cuaternario representado por travertinos y aglomerados volcánicos con predominio de tobas, depósitos aluviales y coluviales, evidenciando procesos volcánicos hidrotermales recientes y dinámicas sedimentarias continentales.

La zona de estudio está inmersa en un proceso continuo de expansión territorial, donde las modificaciones antrópicas del terreno (cultivos, construcciones y apertura de vías), se dan principalmente sobre pendientes fuertes debido a su topografía (Sacoto Flores & Sánchez-García, 2023; SNI, 2018). Estas modificaciones son un factor determinante en la ocurrencia de deslizamientos (Carrión-Mero et al., 2021) debido a que facilita la infiltración de agua durante las precipitaciones, saturando el suelo e incrementando el riesgo ante este tipo de amenazas (Cobos-Mora et al., 2023).

Figura 10

Mapa de ubicación de la zona de estudio



Nota: La zona de estudio se ubica en el corredor interandino del Ecuador, presenta una topografía abrupta que va de los 1984 a los 4085 m.s.n.m. Se muestra la distribución histórica de deslizamiento en Azogues, Ecuador entre el 2010 y 2024.

1.7 Marco Geológico

La zona de estudio se ubica en la depresión de Azogues, hacia la parte central de la cuenca de Cuenca, entre las vertientes de la cordillera Occidental del Parque Nacional del Cajas, donde afloran los volcánicos del Grupo Saraguro de edad Eoceno medio tardío a Mioceno temprano (Dunkley y Gaibor, 1997), y la prolongación sur de la Cordillera Real, donde afloran principalmente rocas metamórficas antiguas e incluyendo a rocas sedimentarias de la Formación Yunguilla (Figura 10).

El cantón presenta una topografía irregular con pendientes pronunciadas, lomas, llanuras onduladas y el valle alto andino del río Burgay. La geología del área de estudio es descrita en la Tabla 4, presentando los depósitos de los más recientes a los más antiguos:

Tabla 4.

Unidades geológicas de la zona de estudio, cantón Azogues.

FORMACIÓN GEOLÓGICA	SÍMBOLO	EDAD	LITOLOGÍA
Coluviales	De	Cuaternario	Mezcla heterogénea de materiales finos y fragmentos angulares rocosos, con ausencia de estratificación y estructuras de ordenamiento interno.
Depósitos coluvio	Dc	Cuaternario	Limo-arcillas, arenas, gravas y bloques
Depósitos aluviales (cono de deyección)	Da		Limo-arcillas y arenas, gravas y bloques en proporciones variables
Depósitos aluviales (terrazas)	T4	Cuaternario	Conglomerado, limo, arenoso, arcilla limosa
Depósitos kársticos (travertinos)	Tv	Cuaternario	Travertino
Tablas de Gualaceo y volcánicos de Llacao	QLI	Cuaternario	Aglomerado volcánico con matriz de vidrio blanco (Llacao) y secuencia bien estratificada con predominio de tobas (Gualaceo)
Formación Tarqui	PT	Mioceno	Tobas y aglomerados (dacíticos, riolíticos y andesíticos) caolinizados, con bajo porcentaje de lava

Formación Azogues	MAz	Mioceno	Areniscas tobáceas de grano medio grueso; niveles de conglomerados y capas poco potentes de arcillas, limos y lutitas
Formación Mangán	MM	Mioceno	Limolitas, lutitas y areniscas de grano fino interestratificadas; lutitas con vetas de carbón; areniscas de grano grueso y conglomeráticas
Formación Loyola	ML	Mioceno	Lutitas laminadas claras, con yeso; localmente, areniscas y conglomerados basales con niveles de arcillas y limolitas
Formación Guapán	MG	Mioceno	Lutitas laminadas, areniscas tobáceas oscuras
Formación Biblián	MI	Mioceno	Arcillas arenosas, a menudo rojizas y con presencia de yeso, y areniscas tobáceas gruesas
Formación Yunguilla	K7	Cretácico	Limolitas masivas gris oscuras y areniscas cuarzo-feldespáticas; calizas, grauvacas y areniscas tobáceas
Unidad Alao Paute	L	Jurásico	Metavulcanitas con débil metamorfismo, lavas masivas y filitas verdes, esquistos verdes, cuarcitas y mármoles
Rocas metamórficas	PMzpq	Paleozoico	Rocas metamórficas indiferenciadas

Nota. Se describen las unidades geológicas del cantón Azogues, incluyendo simbología y edad geológica para cada caso


Formación Azogues (MAz), compuesta principalmente por areniscas tobáceas color marrón de grano medio a grueso, fracturada, moderadamente dura, intercalada con lutita marrón muy fisil ligeramente meteorizada y conglomerado, ocasionalmente húmeda

Formación Loyola (ML), compuesta por lutitas de color blanco marrón y gris claro en secciones frescas; se encuentra fracturada a muy fracturada, moderadamente meteorizada (IGM, 2018).

Formación Guapán (MG), compuesta por areniscas tobáceas de color marrón, diaclasadas, moderadamente duras, intercaladas con lutita de color café oscuro a gris claro, fracturada a muy fracturada y ligeramente meteorizada

Figura 11

Mapa geológico del cantón Azogues



Nota: i) Depósitos cuaternarios del tipo coluvial y aluvial de sedimentos limo-arcillosos, arenas, gravas y bloques; travertino. Aglomerado volcánico hacia la base de los depósitos de esta época. ii) Formaciones Mioceno, conformados por las Formaciones: Tarqui

(PT), Azogues (MAz), Mangán (MM), Loyola (ML), Guapán (MG) y Biblian (MI). iii)

Formaciones del Cretácico, Jurásico y Paleozoico. Mapa resultante del compilado de la carta de Azogues y Cañar del IGM 1978

1.8 Cobertura uso de suelo

La zona de estudio cuenta con una diversidad de uso de suelos, relacionados a sus características naturales y a las actividades antrópicas que se dan lugar en el territorio. Se han definido diferentes categorías que se agrupan en niveles de uso de suelo, de acuerdo al detalle propuesto por el Ministerio de Agricultura y Ganadería de Ecuador (MAG, 2020).

La mayor extensión del territorio corresponde a áreas de conservación y protección, compuesta por bosques nativos, vegetación arbustiva y páramo, donde la cobertura natural desempeña un papel importante en la regulación ambiental y estabilidad del suelo. En contraste a esta, se encuentran las zonas catalogadas como áreas de protección o producción y áreas de conservación y producción, aquí predominan plantaciones forestales y herbáceas, esto da una visión de como las actividades productivas coexisten con estrategias de conservación, lo que garantiza la sostenibilidad en el uso de recursos naturales.


Amplias zonas de pastizales componen la zona de estudio, están se han catalogado como pecuario, ocupando una extensión significativa, ocurre algo similar con el uso de suelo agropecuario, siendo estas áreas donde se combinan las actividades agrícolas y ganaderas, la misma que se concentra principalmente hacia el sur del cantón Azogues a los alrededores de la cabecera cantonal, es preciso mencionar que estas áreas que han sido resultado de modificaciones y alteraciones del suelo, suelen aportar en los procesos de erosión y filtración de agua, generando cierto grado de inestabilidad del suelo.

Por otro lado, se identifican zonas antrópicas, que se relacionan directamente con las zonas netamente urbanas del área de estudio, donde existe presencia de infraestructura vial, áreas industriales y otras zonas de ocupación del suelo por parte del hombre. En esta categoría se delimita claramente la parroquia Azogues que concentra la mayor densidad

poblacional del cantón. Las demás categorías que comprenden la cobertura y uso de suelo, sin ser menos importantes, ocupan áreas poco significativas, dentro de este grupo están: acuícola, avícola y tierras improductivas.

Figura 12

Mapa de cobertura y uso de suelo del cantón Azogues



Nota: Se observa una gran predominancia de zonas de conservación y protección, seguido por zonas destinadas a actividades pecuarias, tomado del mapa nacional escala 1:25.000 de elaborado por el Ministerio de Agricultura y Ganadería de Ecuador (2020)

1.9 Eventos de deslizamientos

De acuerdo con el Servicio Nacional de Gestión de Riesgos del Ecuador (SNGR, 2024), los deslizamientos ocupan el segundo lugar de los eventos adversos de mayor recurrencia que afecta la zona de estudio, concentrados principalmente en las zonas bajas y rurales del noreste y sur del cantón.

Pequeños deslizamientos de tierra sobre la vía Cuenca – Azogues, consecuencia de intensas lluvias son continuamente reportados por el MTOP, quien moviliza maquinaria para despejar las vías afectadas. Los últimos diez años, el cantón Azogues ha experimentado movimientos de tierra en época invernal, la mayoría de estos son catalogados como eventos de magnitud pequeña a moderada, que resultan de desprendimiento de taludes y derrumbes que provocan el bloqueo de vías que conectan este cantón con poblaciones vecinas. Ejemplo de ello es el evento ocurrido en abril de 2015, donde debido a una fuerte lluvia se produjeron deslizamientos que bloquearon completamente vías principales, dejando vehículos atrapados temporalmente tanto en la vía Azogues-Cañar-Tambo como en la autopista Cuenca-Azogues. De acuerdo con las autoridades locales, estos eventos ocurren con frecuencia durante el periodo invernal, donde se alcanza a registrar múltiples eventos en distintos sectores del cantón. En ocasiones se han registrado incluso eventos de mayor magnitud, destruyendo viviendas e infraestructuras, a pesar de una menor recurrencia en este tipo de eventos, es posible evidenciar la existencia de una alta susceptibilidad a deslizamientos en ciertas zonas del cantón Azogues.

Sin duda factores como la topografía, influyen considerablemente en la ocurrencia de estos eventos. Las características tanto del suelo como la roca de algunos sectores permiten la erosión y acumulación de agua, debilitando el terreno y dejándolo expuesto a esas amenazas. Existen reportes técnicos que descartan la presencia de fallas responsables de deslizamientos, lo que sugiere que la geología por si sola no es un condicionante. Por otro lado, las lluvias intensas y prolongadas han demostrado ser un detonante para la ocurrencia de deslizamientos, debido a que la infiltración de agua en taludes reduce considerablemente la cohesión del suelo. Históricamente, gran parte de los deslizamientos reportados por las entidades responsables, han ocurrido durante picos de lluvia, ejemplo de ello son las precipitaciones entre los meses de marzo y abril de 2021 que desencadenaron una serie de deslizamientos en la zona de estudio.

Este comportamiento del terreno se ve agravado por la actividad humana. Estudios sugieren que la poca planificación territorial, así como obras inadecuadas de drenaje han sido los principales contribuyentes. Bloqueo de drenajes naturales y quebradas, así como la falta de un sistema de alcantarillado en laderas pobladas, todo esto en combinación con la deforestación, adecuación de terrenos para el cultivo y pastoreo, provocan la acumulación excesiva de agua que termina debilitando el terreno. El sector Zhapacal, es un ejemplo de ello, aquí técnicos señalan que la recurrencia de deslizamientos se debe principalmente a las intervenciones humanas inadecuadas en terreno de ladera, como parte de la expansión territorial sin planificación en el sector.

Figura 13

Noticias de deslizamientos en la zona de estudio



Nota. Miembros del Grupo de Operaciones Especiales (GOE) en labores de rescate de las personas sepultadas por el deslizamiento del 10 de marzo de 2015 en el cantón Azogues, evento que se produjo durante obras en el proyecto hidroeléctrico Mazar-Dudas.

Uno de los eventos más graves reportado los últimos diez años corresponde al ocurrido la noche del 10 de marzo de 2015, donde un deslizamiento de gran magnitud entre las parroquias Taday, Pindilig y Rivera, afectó una obra de instalación de una tubería de presión de la hidroeléctrica Mazar-Dudas, sepultando tres trabajadores y dejando un fallecido

(Figura 13). Este evento no solo dejó pérdidas humanas, sino que produjo daños en la infraestructura de la hidroeléctrica.


Capítulo 2

2. Metodología.

El proyecto se llevó a cabo de acuerdo con el esquema que presenta la Figura 14. La primera etapa corresponde a la recopilación de información, esto es: (i) generar un inventario histórico de deslizamientos a partir de la información disponible en fuentes oficiales, análisis de imágenes satelitales y levantamiento de campo. (ii) Elaborar el conjunto de factores condicionantes que se utilizarán para el análisis y construcción del modelo de susceptibilidad. (iii) Aplicar los métodos de: Evaluación Espacial Multicriterio, Random Forest y Análisis de Componentes Principales combinado con Random Forest, para generar modelos de susceptibilidad a deslizamientos. (iv) Finalmente se compararon los modelos de susceptibilidad empleando métricas de exactitud y precisión para seleccionar el modelo que demuestra la mayor eficiencia y capacidad predictiva.

Figura 14

Esquema de metodología aplicada en el proyecto



2.1 Factores Condicionantes de Deslizamiento

Para el desarrollo del proyecto se utilizó una serie de variables que serán consideradas como posibles factores que condicionan la ocurrencia a deslizamientos. Estudios similares utilizan en promedio 9 factores condicionantes (Chowdhury & Hafsa, 2022; Cobos-Mora et al., 2023; Günther et al., 2014; Guzzetti et al., 2006; Meena, Mishra, et al., 2019; Mulugeta et al., 2024; Vojteková & Vojtek, 2020), sin embargo, debido a las condiciones geomorfológicas y topográficas del área de estudio se ha decidido utilizar 14 factores condicionantes, como parte de la metodología empleada (Figura 14). A continuación, se presentan estos factores agrupados por categorías:

Geomorfológicos (Topográficos):

- Modelo Digital de Elevación (MDE)
- Pendiente
- Aspecto
- STI (Sediment Transport Index)
- SPI (Stream Power Index)

Geológicos

- Litología
- Distancia a fallas
- Hidrológicos
- Distancia a drenajes
- TWI (Topographic Wetness Index)
- MNDWI (Modified Normalized Difference Water Index)

Vegetación/Ambientales

- NDVI (Normalized Difference Vegetation Index)
- NDMI (Normalized Difference Moisture Index)
- Antrópicos

- Uso y cobertura del suelo (LULC)
- Distancia a vías

Para obtener los factores condicionantes usados en el estudio se emplearon diferentes procedimientos. Un grupo de estos factores fueron obtenidos a partir de fuentes oficiales (Tabla 5), estos fueron tomados como información base, a partir de la cual, empleando ArcGIS Pro® (ESRI, 2024) se generó otro grupo de factores condicionantes. Adicionalmente se empleó el análisis de imágenes satelitales para obtener índices de vegetación y de humedad.

Tabla 5.

Información base de fuentes oficiales.

DATO	FORMATO	FUENTE
Modelo Digital de Elevación (resolución 3 m)	Raster (.tif)	SIGTIERRAS
Topografía	Vector (.shp)	Universidad de California
Topografía	Vector (.shp)	Google Earth
Modelo Digital de Elevación (resolución 12.5 m)	Raster (.tif)	ALOS - PALSAR
Litología (escala 1:100.000)	Pdf	IGM
Uso de Suelos (escala 1:25.000)	Vector (.shp)	MAGAP
Imágenes Lansat-9 (resolución 30 m)	GeoTIFF	USGS - EarthExplorer

Nota. Esta corresponde a la información base, obtenida mediante fuentes oficiales, que han sido empleada para elaborar diferentes mapas de factores condicionantes

2.1.1 Modelo Digital de Elevación (MDE)

Para obtener el MDE adecuado, se han comparado cuatro resultados producto de emplear diferentes técnicas, así como utilizar datos de distintas fuentes y cuyos resultados han sido evaluados en términos de resolución espacial. Este MDE seleccionado sirvió para determinar las pendientes, aspecto, drenaje, entre otros factores necesarias para el cálculo de la susceptibilidad.

“Extract XYZ Grid – Topography”

La primera metodología utilizada consistió en extraer información topografía de la plataforma “Extract XYZ Grid – Topography” (University of California San Diego, 2014), que cuenta con información topográfica a nivel global generada a partir de aplicar un filtro gaussiano a la información gravimétrica satelital, calibrando regionalmente la relación topografía/gravedad con puntos topográficos conocidos (Smith & Sandwell, 1997). Esta plataforma permitió seleccionar el área de estudio para obtener su información topográfica, teniendo como resultado una grilla de 700 puntos con datos de localización geográfica y elevación. Estos puntos fueron exportados y procesados utilizando la herramienta de geoprocesamiento de interpolación utilizando distancia inversa ponderada (IDW) que genera una superficie de ráster a partir de puntos.

Datos de elevación de Google Earth

Para este caso se generó un MDE a partir de datos altimétricos tomados de Google Earth, mismo que utiliza la información obtenida del satélite Shuttle Radar Topography Mission (SRTM) para obtener su línea base de elevación (Hoffmann & Winde, 2010). Se tomó un total de 35.946 puntos que cubren toda el área del cantón Azogues, de los cuales se extrajeron los datos de elevación para procesarlos en ArcGIS Pro, del cual se obtuvo un modelo digital de terreno empleando el método IDW, que estima los valores vecinos a partir de los puntos conocidos. Se obtuvo una imagen cuya resolución de acuerdo con el tamaño de pixel resultante es de 186 metros, y cuya desviación estándar 419.82.

MDE ALOSPALSAR

Se realizó la descarga del modelo digital del terreno del Satélite de Observación Terrestre Avanzada, ALOS por sus siglas en inglés, este cuenta con un instrumento “Phased Array type L-band Synthetic Aperture Radar” (PALSAR), este satélite de observación terrestre, mejor conocido como ALOSPALSAR, es operado por la Agencia Japonesa de Exploración Aeroespacial (JAXA), permite la descarga libre por medio de la plataforma del Alaska Satellite Facility, para ello se seleccionó un polígono que cubre el cantón Azogues, aplicando filtros de búsqueda para obtener imágenes con Terreno Corregido de Alta Resolución de doble polarización (FBD), obteniendo dos imágenes satelitales del mes de octubre de 2010. Estas imágenes procesadas en ArcGis Pro, compilándolas una sola imagen utilizando la herramienta de geoprocesamiento “Mosaic to new raster”, como resultado, se obtuvo un MDE con una resolución espacial de 12.5 metros.

MDE SIGTIERRAS

Este modelo se obtuvo a partir de la información disponible del Sistema Nacional de Información de Tierras (SIGTIERRAS), que cubre todo el territorio nacional en una extensión total de 225.449 km², con datos obtenidos a partir de LIDAR con una resolución

espacial de 3x3 metros y una exactitud altimétrica de 1.5m. Para el presente estudio se seleccionó un área que cubre la extensión del cantón Azogues, obteniendo como resultado 161 archivos tipo Geotiff de 32bits, a partir del cual se generó un mosaico que posteriormente fue procesado utilizando herramientas de ArcGis Pro. El resultado fue un MDE tipo raster de alta resolución espacial (3 metros), al cual se realizaron correcciones para eliminar posibles vacíos.

2.1.2 Pendiente (Slope)

La pendiente es considerado uno de los factores más importantes e influyentes que condicionan la estabilidad de las laderas, el aumento en el ángulo de la pendiente incrementa la fuerza de las tensiones de corte asociadas a la gravedad y con ello la probabilidad de deslizamiento (Dehnavi et al., 2015). Para obtener este factor condicionante se utilizó el modelo digital de elevación de la zona de estudio, a partir de este se calculó la pendiente empleando la herramienta “Slope” del paquete “Spatial Analyst” disponible en ArcGis Pro. Esta herramienta identifica la inclinación en cada celda de una superficie de ráster expresando los resultados en grados. Esto indica que mientras menor sea el valor de la pendiente, más plano será el terreno; mientras más alto sea el valor de la pendiente, más empinado será el terreno.

2.1.3 Aspecto

Este factor describe la dirección de la pendiente respecto a los puntos cardinales del planeta, este parámetro se mide en función de ocho cuadrantes: norte, noreste, este, sureste, sur, suroeste, oeste y noroeste. La importancia de incluir esta característica del terreno radica en que la orientación de la pendiente condiciona el terreno (Meena, Mishra, et al., 2019) debido a la influencia de procesos como la evaporación del agua en el suelo, cobertura vegetal, erosión de las rocas, y todo aquello que pueda verse afectado por la radiación solar.

La obtención de este factor condicionante se realizó tomando como base el MDE y empleando la herramienta Aspect del paquete Spatial Analyst de ArcGis Pro. La herramienta Aspect identifica la dirección de la pendiente, resultando en un raster donde cada celda indica la dirección geográfica a la que apunta la superficie en esa ubicación, medida de forma horaria representada en grados de 0 (hacia el norte) a 360 (hacia el norte, nuevamente).

2.1.4 STI (*Sediment Transport Index*)

El índice de transporte de sedimentos (STI) mide la capacidad de transporte de sedimentos en un flujo superficial en función de la pendiente del terreno y la acumulación de flujo, este sirve para determinar la cantidad de pérdida de suelo o el poder erosivo causado por el flujo de agua (Cobos-Mora et al., 2023) se ha calcula mediante la ecuación (1) (Moore & Wilson, 1992):

$$STI = \left(\frac{\alpha}{22.13} \right)^{0.6} * \left(\frac{\text{Sen } \beta}{0.0896} \right)^{1.3} \quad (1)$$

Siendo α el área de acumulación de flujo de agua en un punto del terreno y β la pendiente en grados en dicho punto. Para obtener este factor condicionante se utilizó el MDE y la pendiente como datos base, a partir del MDE se calculó el área de acumulación de flujo, para ello se empleó la herramienta Flow Accumulation del paquete Spatial Analyst de ArcGis Pro y finalmente la calculadora raster para utilizar la ecuación (2.1).

2.1.5 SPI (*Stream Power Index*)

Índice de Potencia de Erosión (SPI), representa la potencia del flujo de agua en términos de su capacidad de erosión, pudiendo predecir la erosión neta en áreas de convergencia y aceleración del flujo (Cobos-Mora et al., 2023) calculado a partir de la ecuación (2.2) (Moore & Burch, 1986):

$$SPI = \ln(\alpha * \tan \beta) \quad (2)$$

En este cálculo α corresponde al área de acumulación de flujo de agua o área de captación mientras que β es el gradiente de pendiente en grados, suponiendo que la descarga es proporcional al área de captación. Con este factor es posible asumir que si la capacidad del cauce es mayor para erosionar entonces existe mayor probabilidad de inestabilidad en la base de vertientes, taludes o en los bancos de los ríos. La obtención de este factor se realizó utilizando la herramienta Raster Calculator de ArcGis Pro, usando los parámetros de la ecuación (2)

2.1.6 TWI (Topographic Wetness Index)

El Índice de humedad topográfico permite cuantificar el control topográfico sobre los procesos hidrogeológicos del terreno (Devkota et al., 2013). Se calcula a partir de la acumulación de flujo de agua considerando la tendencia del flujo aguas abajo debido a la gravedad. La importancia de considerarlo como factor condicionante radica en que refleja la influencia en la topografía en la distribución espacial de humedad en el suelo (Cobos-Mora et al., 2023). Su cálculo se hace mediante la ecuación (3) (Beven & Kirby, 1979):

$$TWI = \ln \frac{\alpha}{\tan \beta} \quad (3)$$

Donde α corresponde a la cantidad de flujo por unidad del ancho de contorno y β la pendiente en radianes. Para obtener este factor se utilizó la herramienta Raster Calculator del Spatial Analyst disponible en ArcGis Pro.

2.1.7 Litología

La litología es un factor que influye en la estabilidad del terreno y condicionan la recurrencia, magnitud y ubicación de los deslizamientos (Junquera-Torrado et al., 2019). El mapa de litología fue generado a partir de las hojas 72 y 73 de los mapas geológicos de Ecuador, edición de 1980, a escala 1:100.000. Se analizaron las formaciones geológicas

presentes donde se agruparon por similitudes litológicas reclasificandolas en 9 categorías según el European Soil Database (ESDB) (Günther et al., 2014). Utilizando ArcGis Pro se generó el mapa de litología a partir de datos vectoriales tipo shapefile, los cuales fueron transformados a formato raster utilizando herramienta Feature to Raster manteniendo la resolución espacial de los factores ya generados en etapas previas.

2.1.8 Cobertura y uso de suelo

La cobertura y uso de suelo resulta un factor importante en el análisis de susceptibilidad a deslizamientos siendo ampliamente utilizado en estudios previos (Gudiyangada Nachappa et al., 2020). Las variaciones en el uso del suelo pueden explicar la inestabilidad de las pendientes (Devkota et al., 2013), como en el caso donde áreas cubiertas de bosque permiten regular el flujo y la infiltración de agua mientras que áreas de cultivo pueden afectar la estabilidad de las pendientes debido a que facilitan la saturación del suelo. Para elaborar el mapa de cobertura y uso de suelo empleado en este estudio, se tomó el mapa nacional de cobertura y uso de la tierra del Ecuador, elaborado por el Ministerio de Agricultura y Ganadería (MAG) en el año 2020 a escala 1:25.000 (MAG, 2020). Para el análisis se utilizó la clasificación de nivel I de cobertura de suelo que tiene como categorías: tierra forestal, tierra arbustiva y herbácea, tierra agropecuaria, cuerpo de agua, zona antrópica y tierras improductivas. A partir de este mapa base a escala nacional, se utilizó la herramienta “Extract by Mask” de ArcGis Pro para recortar el área de estudio, asegurando la coherencia espacial en relación con los demás factores.

2.1.9 Distancia de Fallas

La presencia de fallas y otros lineamientos geológicos como diaclasas, pliegues entre otros, es considerado un factor determinante en la ocurrencia de deslizamientos (Chowdhury & Hafsa, 2022). Las fallas generan la separación de unidades geológicas y fracturas que

reducen la resistencia del material rocoso lo que favorece en la actividad de deslizamientos (Gudiyangada Nachappa et al., 2020). Para generar el mapa de distancia de fallas se ha utilizado la información disponible en el portal de Instituto Geográfico Militar del Ecuador, que cuenta con información a escala nacional para la descarga de archivos formato shapefile (.shp) a partir del cual se empleó la herramienta Euclidean Distance del ArcGis Pro para generar el mapa de distancias.

2.1.10 Distancia de Drenajes

El drenaje es otra causa importante en la ocurrencia de deslizamientos (Chowdhury & Hafsa, 2022), los ríos y quebradas pueden inducir la inestabilidad en las pendientes debido a la erosión que provoca el flujo de agua sobre los materiales geológicos así como a la acumulación de humedad y la elevación del nivel freático (Mulugeta et al., 2024). Para lograr generar el mapa de distancia de drenaje se generó el sistema de drenaje del área de estudio a partir del modelo digital de elevación, posteriormente utilizando la herramienta Euclidean Distance de ArcGis Pro se obtuvo un archivo raster que muestra la proximidad al drenaje, el cual fue posteriormente reclasificado.

2.1.11 Distancia de Vías

Las carreteras son consideradas uno de los factores antrópicos más críticos que influyen significativamente en la inestabilidad del terreno que pudieran provocar deslizamientos (Gudiyangada Nachappa et al., 2020). En el área de estudio un gran porcentaje de los eventos de deslizamientos son inducidos por la construcción de carreteras, ocurriendo sobre la red vial. Como en el caso de los factores previamente descritos, se utilizó la herramienta Euclidean Distance de ArcGis Pro para obtener el mapa tipo raster de la distancia de vías, asegurando que mantenga coherencia espacial con los demás factores generados.

2.1.12 NDVI

El índice de vegetación de diferencia normalizada (NDVI), está estrechamente relacionada con la cobertura vegetal y a su vez con la estabilidad del terreno debido a la presencia de raíces, reducción de humedad del suelo como resultado de la transpiración y sobrecarga generada por el peso de los árboles (Devkota et al., 2013). En general, en terrenos donde hay mayor cobertura forestal existen menor ocurrencia de deslizamientos. Para calcular este factor se utilizó la siguiente ecuación (4):

$$NDVI = \frac{NIR-Red}{NIR+Red} \quad (4)$$

Donde IR y R representan las bandas del Infrarrojo cercano y rojo, respectivamente. Para obtener este mapa se utilizaron dos imágenes que cubren el área de estudio, del satélite Landsat-9 del nivel 2, descargadas de la plataforma EarthExplorer de la USGS, que cuentan con una resolución espacial de 30 metros. Se utilizó el software ArcGis Pro para realizar un mosaico de ambas imágenes, a partir de este se empleó la herramienta para generar índices multibanda disponible en este software, para el cálculo del NDVI. El mosaico generado fue recortado para mantener únicamente la información del área de estudio.

2.1.13 NDMI

El índice de humedad en la vegetación de diferencia normalizada (NDMI) indica la cantidad de humedad presente en la vegetación, este factor influye también sobre la estabilidad del suelo y por lo tanto en la susceptibilidad a deslizamientos. Mayor humedad en la vegetación reduce la erosión del terreno y aumenta la cohesión del suelo, contrario a la vegetación seca (Wilson & Sader, 2002). Para el cálculo de este factor se utilizó la ecuación (5):

$$NDVI = \frac{NIR-SWIR1}{NIR+SWIR1} \quad (5)$$

Donde IR y SWIR representan las bandas del infrarrojo cercano y el infrarrojo de onda corta, respectivamente. Para generar este mapa, se utilizaron las imágenes de Landsat-9 nivel 2, empleando ArcGis Pro y la herramienta de generador de índices multibanda.

2.1.14 MNDWI

El índice de agua modificado de diferencia normalizada (MNDWI) es un indicador clave para detectar zonas saturadas de agua, permitiendo evaluar su impacto en la estabilidad del terreno, donde los valores altos indican la presencia de agua superficial y los valores bajos podrían relacionarse con áreas secas (H. Xu, 2006). Para su cálculo se empleó la ecuación (6):

$$MNDWI = \frac{Green - SWIR1}{Green + SWIR1} \quad (6)$$

Donde G y SWIR representan las bandas del verde y el infrarrojo de onda corta, respectivamente. El mapa se obtuvo procesando el mosaico de imágenes de Landsat-9 nivel 2, utilizados en los factores previamente calculados, empleando la herramienta

2.2 Inventario de Deslizamientos

Contar con un inventario de deslizamientos es fundamental para el análisis de susceptibilidad, ya que es la base para identificar patrones espaciales y validar los modelos predictivos. Contar con un inventario robusto permite relacionar la ocurrencia de deslizamiento con las características de los factores condicionantes, aumentando la precisión y confiabilidad de los resultados.

Para el desarrollo de este estudio se recopiló información de fuentes oficiales, inspección de imágenes satelitales y levantamiento de campo. En primer lugar, se analizaron los registros de los últimos 10 años de eventos adversos que mantiene la Secretaría de Gestión de Riesgos de Ecuador (SGR) y el Gobierno Autónomo Descentralizado del cantón

Azogues (GAD Azogues), los cuales fueron revisados y ajustados para corregir inconsistencias en su ubicación geográfica (coordenadas) tomando de referencia la descripción de cada evento. Este trabajo se realizó con ayuda de los técnicos del departamento de Gestión de Riesgos del GAD de Azogues.

Para complementar el inventario se realizó una inspección visual a detalle de cicatrices de deslizamientos presentes en imágenes satelitales disponibles en Google Earth. Para esto se utilizó como herramienta la opción disponible de visualizar historial de imágenes, agregando al inventario la ubicación geográfica de la cicatriz de deslizamiento incluida la fecha de la imagen satelital de donde se tomó la información.

Al este inventario se sumó el trabajo de campo, que permitió realizar el levantamiento de deslizamientos recientes en diferentes parroquias del cantón. Con la ayuda de técnicos de gestión de riesgo de gobierno local, se realizó el recorrido por diferentes puntos catalogados como “críticos” debido a la recurrencia de deslizamientos. Para esto se utilizó una ficha de levantamiento de información que incluye la descripción detallada del deslizamiento y ubicación. Estas fuentes fueron integradas para generar el inventario histórico de deslizamientos (Tabla 6), fundamental para el desarrollo de los modelos de susceptibilidad y su evaluación de desempeño. Las fuentes fueron clasificadas en función de la calidad de información siendo: Baja, información extraída de mapas, imágenes satelitales y aquella cuya La ubicación solo se refiere a los asentamientos cercanos; Media, inventarios parciales, tomado a partir de datos históricos o noticias; Buena, para inventarios detallados con información de respaldo (Günther et al., 2014).

Tabla 6.

Inventario histórico de deslizamientos.

FUENTE	n	TIPO	CALIDAD
SNGR	59	Base de Dato	Baja
GAD	192	Base de Dato	Buena

GoogleEarth	46	GoogleEarth™	Baja
Levantamiento de campo	25	Fichas de levantamiento	Media
TOTAL	322		

Nota. Inventario histórico de deslizamientos de los últimos 10 años elaborado a partir de registros de 4 fuentes, siendo “n” el número de deslizamientos tomados de cada fuente y el grado de calidad de los datos.

2.3 Evaluación Espacial Multicriterio (SMCE)

La evaluación espacial multicriterio o SMCE por sus siglas en inglés (Spatial Multi-Criteria Evaluation), es una técnica que ha sido ampliamente utilizada en el estudio de susceptibilidad a deslizamientos (Gudiyangada Nachappa et al., 2020; Günther et al., 2014; Meena, Mishra, et al., 2019; Vojteková & Vojtek, 2020). Uno de los primeros trabajos destacados es el desarrollado por Carrara et al. (1995), quienes elaboraron un mapa de predicción de deslizamientos en áreas montañosas de Italia, para lo que combinaron datos geológicos, geomorfológicos y factores ambientales. Este trabajo demostró que el emplear modelos jerárquicos y procesos de comparación por pares para asignar pesos a los factores que pudieran desencadenar los deslizamientos, es de alta utilidad para manejar la incertidumbre y subjetividad en estos casos. Para el presente estudio se han combinado dos técnicas dentro del desarrollo de la evaluación espacial multicriterio, a manera de un modelo híbrido, se aplica el análisis de jerarquía y el método de ratio de frecuencia.

2.3.1 Proceso de Análisis Jerárquico (AHP)

El proceso de análisis jerárquico o AHP por sus siglas en inglés (Analytic Hierarchy Process), es una herramienta de toma de decisiones que permite resolver problemas complejos, donde múltiples atributos influyen en la ocurrencia de un fenómeno. Este método

fue desarrollado por Saaty (1987) y ampliamente utilizado en varios campos, incluyendo el análisis de susceptibilidad a deslizamientos (Gudiyangada Nachappa et al., 2020; Günther et al., 2014; Meena, Mishra, et al., 2019; Vojteková & Vojtek, 2020).

La aplicación del análisis jerárquico corresponde a una evaluación por pares, mediante la cual se establecen pesos a los factores atribuidos a la susceptibilidad a deslizamientos, esto se consigue aplicando una matriz de comparación de pares, evaluando las filas entre las columnas, donde se agrupan los criterios o factores condicionantes seleccionados, que para el presente estudio son 14 factores mencionados anteriormente. Las comparaciones para la asignación de una calificación consideran el grado de importancia relativa de los dos criterios analizados, para la determinación de la idoneidad en el fenómeno analizado. Las calificaciones se proporcionan en una escala continua de 9 puntos: 1, 2, 3, 4, 5, 6, 7, 8, 9 (Tabla 7). Siendo 1 la calificación para determinar igual grado de importancia entre ambos criterios analizados, mientras que 9 es asignado cuando un criterio es extremadamente más importante respecto con el que se está comparando (Saaty, 1987).

Tabla 7.

Escala fundamental de evaluación (Saaty, 1987)

Escala	Grado de preferencia	Explicación
1	Igualmente	Dos actividades contribuyen de manera igual al objetivo
3	Moderadamente	La experiencia y el juicio favorecen moderadamente una actividad sobre otra
5	Fuertemente	La experiencia y el juicio favorecen fuertemente una actividad sobre otra
7	Muy fuertemente	Una actividad es fuertemente favorecida y su dominancia ha sido demostrada en la práctica
9	Extremadamente	La evidencia que favorece una actividad sobre otra es de la más alta posible, sin lugar a duda.
2, 4, 6, 8	Valores intermedios entre dos juicios adyacentes	Se utilizan cuando se necesita un compromiso entre dos valores

Recíprocos	Inversos de los valores	Si la actividad i tiene uno de los valores anteriores al compararse con la actividad j , entonces j tiene el valor recíproco al compararse con i
-------------------	-------------------------	--

La asignación de la calificación en la comparación por pares se realiza en base al conocimiento experto. Es importante mencionar que al aplicar AHP, es necesario garantizar que se cumpla el principio de transitividad, esto es que, para cualquier conjunto de factores, por ejemplo: F1, F2 y F3, si la calificación define que $F1 > F2 > F3$, entonces $F1 > F3$. Este principio constituye la base en el proceso de ponderar los factores condicionantes de manera coherente, siendo que, si $2F1 > F2$ (es decir, F1 es dos veces más preferible que F2), y $4F2 > F3$, entonces $8F1 > F3$, para respetar la transitividad (Gudiyangada Nachappa et al., 2020)

Para corroborar la idoneidad en los pesos calculados mediante la matriz de comparación por pares (Tabla 8), se calcula el índice de consistencia (CR), este procedimiento indica la probabilidad de que las calificaciones de la matriz se hayan generado aleatoriamente. Para que esta premisa se cumpla, el cálculo del CR tendrá que ser <0.10 , en caso de ser mayor es necesario reevaluar la matriz de comparación por pares (Saaty 1977). La inconsistencia puede definirse a partir de la observación de que $\lambda_{\max} > n$ en matrices de comparación, y $\lambda_{\max} = n$ si C es una matriz de comparación consistente. El índice de consistencia (CR) se puede definir mediante la ecuación (7):

$$CR = (\lambda_{\max} - n) / (RI (n - 1)) \quad (7)$$

Donde RI es el índice aleatorio de una matriz de comparación por pares creada aleatoriamente, para $n = 2, 3, 4, 5, 6, 7, 8$ y 9 , los valores de RI son $0.00, 0.52, 0.89, 1.11, 1.25, 1.35, 1.40$ y 1.45 , respectivamente.

Al final, lo que resulta de emplear AHP es la asignación de los pesos para cada factor condicionante utilizando en el estudio, mostrando el grado de influencia de cada uno en la ocurrencia de deslizamientos.

Para este estudio se obtuvo un $CR=0.076$, estando por debajo del umbral crítico indicando que la clasificación y la asignación de pesos son apropiadas para el análisis de susceptibilidad.

Tabla 8.

Matriz de comparación por pares (Saaty, 1987)

	Pendiente	Litología	Uso de Suelo	D. de drenaje	SPI	TWI	MDE	NDVI	D. de Falla	Aspecto	D. de Vías	STI	NDMI	MNDWI
Pendiente	1	2	5	3	3	3	5	6	5	6	7	7	6	7
Litología	1/2	1	4	2	3	3	4	4	5	5	6	6	6	6
Uso de Suelo	1/5	1/4	1	3	4	4	3	4	5	5	5	6	6	6
D. de drenaje	1/3	1/2	1/3	1	2	2	3	3	3	4	5	5	5	6
SPI	1/3	1/3	1/4	1/2	1	2	2	3	2	3	4	4	4	5
TWI	1/3	1/3	1/4	1/2	1/2	1	2	3	2	3	4	4	4	4
MDE	1/5	1/4	1/3	1/3	1/2	1/2	1	2	3	3	4	5	5	6
NDVI	1/6	1/4	1/4	1/3	1/3	1/3	1/2	1	2	3	4	3	4	5
D. de Falla	1/5	1/5	1/5	1/3	1/2	1/2	1/3	1/2	1	2	2	2	3	3
Aspecto	1/6	1/5	1/5	1/4	1/3	1/3	1/3	1/3	1/2	1	2	2	2	2
D. de Vías	1/7	1/6	1/5	1/5	1/4	1/4	1/4	1/4	1/2	1/2	1	4	4	5
STI	1/7	1/6	1/6	1/5	1/4	1/4	1/5	1/3	1/2	1/2	1/4	1	2	2
NDMI	1/6	1/6	1/6	1/5	1/4	1/4	1/5	1/4	1/3	1/2	1/4	1/2	1	2
MNDWI	1/7	1/6	1/6	1/6	1/5	1/4	1/6	1/5	1/3	1/2	1/5	1/2	1/2	1

Nota. La tabla fue construida comparando los 14 factores condicionantes

seleccionados para el estudio, haciendo uso de la escala de evaluación.

2.3.2 Ratio de Frecuencia

El siguiente paso empleado en el SMCE, es aplicar el método de ratio de frecuencia o FR por sus siglas en inglés (Frequency Ratio), esta es una herramienta de evaluación espacial que proporciona la probabilidad de distribución de la presencia y ausencia de un fenómeno para cada factor condicionante en la extensión del área de estudio (Gudiyangada Nachappa et al., 2020). Este modelo probabilístico se basa en observar la relación entre la distribución de los fenómenos y cada factor relacionado con estos, revelando la correlación entre las ubicaciones de los deslizamientos y los factores causales en el área de estudio (Meena, Mishra, et al., 2019; Pradhan, 2010).

Este método permite mostrar la correlación que existe entre las ubicaciones de los deslizamientos y los factores condicionantes que influyen en la ocurrencia de estos en una

zona determinada. Esta correlación es posible calcularla a partir de las clases que conforman cada factor condicionante, aumentando la precisión en la evaluación geoespacial, lo que la convierte en una herramienta de gran utilidad (Gudiyangada Nachappa et al., 2020). Para calcular los pesos mediante FR es necesario utilizar el inventario de deslizamientos de la zona de estudio. Este cálculo resultará entonces de la relación entre la distribución espacial de los registros de deslizamiento respecto a con las clases de cada factor, para lo cual se emplea la ecuación (8):

$$FR = \frac{LS_{ji}/LS}{A_{ji}/A} \quad (8)$$

Donde LS_{ji} es el número de píxeles de los deslizamientos del inventario en cada clase i del factor j , LS es el número total de píxeles de deslizamientos, A_{ji} es el número de píxeles que conforman la clase i del factor j , y A es el número total de píxeles del factor. Finalmente empleando el método FR, se consigue ponderar cada clase en función de los eventos deslizamientos que caen sobre la misma, de esta manera se logra asignar un valor que representa la influencia de cada clase de los factores condicionantes en la ocurrencia de deslizamientos, determinada directamente por su relación espacial con el inventario de deslizamientos.

Una vez empleadas ambas técnicas, se utilizó ArcGis Pro para reclasificar cada mapa de los factores condicionantes asignándole los pesos calculados mediante FR, siendo ahora estos factores formato raster las variables a utilizar en el cálculo de la susceptibilidad. El modelo de susceptibilidad resulta de realizar una suma lineal ponderada de los pesos asignados a cada parámetro y sus clases, empleando la ecuación (9):

$$LS = \sum_{j=1}^{n=14} w_j * x_{ji} \quad (9)$$

Donde w_j es el peso del factor j calculado mediante AHP y x_{ji} es el peso de la clase i del factor j . Para esto se utilizó la calculadora raster disponible en ArcGis Pro, empleando la ecuación (2.9) lo que resulta en un mapa de susceptibilidad que fue reclasificado analizando

los valores máximos y mínimos del resultado para dividirlos en 5 clases que corresponden a los grados de susceptibilidad.


2.4 Random Forest

El método de Random Forest (RF), corresponde a un algoritmo de aprendizaje de maquina o Machine Learning (ML) desarrollado por Leo Breiman y Adele Cutler a principios de 1990 (Breiman, 2001). Este se basa en el concepto de los árboles de decisión, el cual es otro método de aprendizaje de máquina. Random Forest construye una serie de árboles de decisión durante el proceso de entrenamiento, obteniendo como resultado la moda de sus predicciones en tareas de clasificación, o el promedio de sus predicciones en tareas de regresión. La construcción de cada árbol de decisión que conforma el RF utiliza un subconjunto aleatorio de los datos y una selección aleatoria de variables, lo que garantiza la precisión del modelo y reduce el riesgo de sobreajuste.

Una de las principales ventajas de emplear este método, es su capacidad de procesar grandes volúmenes de datos, por ello RF es utilizado en el estudio de susceptibilidad a deslizamientos (Chen et al., 2018; Nam & Wang, 2020; Sajadi et al., 2022; K. Zhang et al., 2017; X. Zhang et al., 2024). La figura 15 muestra el proceso de modelamiento del método RF utilizado en el presente estudio.

Figura 15

Esquema de Random Forest



Nota. Esquema de proceso para la obtención de modelo de susceptibilidad a deslizamientos, modificado de K. Zhang et al. (2017)

2.4.1 Evaluación de desempeño

El modelo de susceptibilidad a deslizamientos empleando RF, fue evaluado para medir su grado de desempeño. Esta etapa es fundamental, ya que permite medir la capacidad del modelo para clasificar la zona de estudio por el grado de susceptibilidad adecuado. La evaluación de desempeño cuantifica la precisión y la capacidad del modelo para discriminar entre aciertos y errores, asegurando su solidez y aplicabilidad en diferentes escenarios. Este análisis permite conocer si el resultado es confiable para ser utilizado como herramienta en la toma de decisiones en contexto de la gestión de riesgos y desastres. Para ello se emplean dos herramientas estadísticas ampliamente reconocidas: la matriz de confusión y la curva ROC (Receiver Operating Characteristic), las cuales analizan el porcentaje de predicciones

correctas y la capacidad del modelo de diferenciar zonas susceptibles y no susceptibles a deslizamientos en el área de estudio.

2.4.2 Matriz de confusión

Empleando la matriz de confusión fue posible evaluar el desempeño del algoritmo de clasificación. Esta matriz contiene en las filas los valores predichos por el algoritmo, mientras que en las columnas se muestran los valores reales (Figura 16). Para el presente trabajo corresponde a la relación entre sitios donde se han registrado deslizamientos y los sitios donde el algoritmo ha predicho la ocurrencia de uno.

Figura 16

Esquema de matriz de confusión.

		Valores reales	
		+	-
Valores de predicción	+	Verdaderos Positivos	Falsos Positivos
	-	Falsos Negativos	Verdaderos Negativos

Nota. La matriz de confusión, compuesta por valores verdades positivos/negativos (V_p/V_n) y valores falsos positivos/negativos (F_p/F_n).

Es posible determinar las métricas de precisión, sensibilidad y especificidad por medio de la matriz de confusión. La exactitud mide el porcentaje de acontecimientos clasificados correctamente (ecuación 10), la sensibilidad mide la proporción de acontecimientos positivos que fueron clasificados correctamente (ecuación 11) y la especificidad mide la proporción de acontecimientos negativos clasificados correctamente (ecuación 12).

$$Exactitud = (Vp + Vn)/(Vp + Vn + Fn + Fp) \quad (10)$$

$$Sensibilidad = Vp/(Vp + Fn) \quad (11)$$

$$Especificidad = Vn/(Vn + Fp) \quad (12)$$

2.4.3 Curva ROC (Receiver Operating Characteristic)

Esta herramienta estadística permite evaluar el desempeño predictivo del modelo de clasificación, esto incluye la modelización de susceptibilidad a deslizamientos. La curva ROC muestra la relación entre la sensibilidad y la especificidad del modelo, permitiendo visualizar su capacidad de predecir correctamente entre eventos y no eventos. El área bajo la curva o AUC (Area Under the Curve) es el indicador cuantitativo del rendimiento del modelo, si el valor AUC es igual o muy cercano a 1, indica que el modelo tiene un buen rendimiento.

2.5 Análisis de Componentes Principales

El análisis de componentes principales (ACP) corresponde a una técnica de análisis multivariable para la reducción de dimensión de datos (Z. Xu et al., 2024) mediante la transformación de variables correlacionadas en un conjunto de variables no correlacionadas las que se conocen como componentes principales (CP). Estas componentes principales resultan de la combinación lineal de las variables originales, cuyo resultado se ordena de tal forma que la primera componente principal contiene la mayor varianza posible de los datos, definida mediante la ecuación (2.12)

$$Y_1 = t_{1,1}X_1 + t_{2,1}X_2 + \dots + t_{p,1}X_p \quad (13)$$

Donde $t_{j,1}$ son los coeficientes por estimar, de tal manera que la varianza de Y_1 alcance el máximo valor, siempre que el vector formado por los coeficientes tenga norma 1.

Esta reducción de la dimensionalidad mantiene la capacidad de clasificación de los datos originales, esto facilita que la clasificación sea más intuitiva y eficaz.

Puesto a que las variables utilizadas en el presente estudio poseen diferentes escalas, se realizó la estandarización de los datos, para garantizar que cada variable o factor condicionante tenga media cero y desviación estándar uno. Este procedimiento es fundamental cuando se trata de datos ambientales, geológicos, entre otros.

El resultado del cálculo de las CP permite identificar el número de componentes principales que consiguen estabilizar el incremento del porcentaje acumulado de la varianza, con ello retener aquellas componentes cuya contribución marginal a la varianza sea significativa antes de que lograr que el cambio se estabilice (Jolliffe & Cadima, 2016). De esta manera se selecciona el número de componentes principales que contengan el mayor porcentaje de varianza acumulada, considerando el punto en la varianza se estabiliza.

El presente trabajo propone generar dos modelos que empleen CP, de los se selecciona el resultado que presente una mejor evaluación de desempeño, comparando el resultado de emplear el algoritmo de random forest con las mismas configuraciones iniciales donde se utilizará a modo de raster multibanda el total CP, así como el grupo de CP que cumplen con el mayor porcentaje de varianza acumulada, como variables predictoras de entrada en el algoritmo, de la manera en la que se ha explicado en el apartado anterior.

2.5.1 Evaluación de desempeño

Una vez entrenado ambos modelos de susceptibilidad a deslizamiento empleando random forest con los dos grupos de CP utilizados como variables predictoras, se evalúa el desempeño utilizando métricas estadísticas como en el apartado anterior, incluyendo la matriz de confusión y la curva ROC (Receiver Operating Characteristic). Estas métricas permiten calcular la precisión, sensibilidad y especificidad del modelo, así como medir la capacidad de predecir correctamente entre eventos y no eventos en base a la relación entre la sensibilidad y la especificidad del modelo.

Capítulo 3

3. Resultados y análisis


En este capítulo se presentan los resultados del procesamiento y análisis de la información generada en el presente estudio, esto incluye la generación de los factores condicionantes, la elaboración de los modelos de susceptibilidad empleando las tres metodologías descritas y finalmente la validación y evaluación del rendimiento de cada modelo. Primero se describen los mapas de los factores condicionantes que resultaron de emplear diferentes técnicas basadas en SIG. Posteriormente, se presentan los resultados del modelo de Evaluación Espacial Multicriterio (SMCE), Random Forest (RF) y Análisis de Componentes Principales (PCA). Finalmente, los resultados obtenidos son comparados y analizados, permitiendo conocer el grado de eficiencia y su capacidad de predicción de las zonas de susceptibilidad.

3.1 Factores Condicionantes de Deslizamiento

Para obtener el Modelo Digital de Elevación (MDE) se emplearon cuatro metodologías, con el fin de obtener el resultado que con mayor precisión en términos de resolución espacial y detalle de información. Los resultados de utilizar la información obtenida a partir de la plataforma “Extract XYZ Grid – Topography” (University of California San Diego, 2014) y de Google Earth, son modelos digitales de elevación de baja resolución espacial y poco nivel de detalle (Figura 17a, 17b). Por otro lado, el resultado del modelo elaborado a partir de los datos de ALOS PALSAR tiene una mejor resolución espacial, de 12.5 metros (Figura 17c). Finalmente, el modelo elaborado a partir de la información obtenida de la plataforma de SIGTIERRAS (Figura 17d), tiene una resolución espacial de 3 metros, la cual es adecuada para la generación precisa de varios factores condicionantes, al tener una mejor resolución espacial habrá más detalle en la variación de la topografía, detectando detalles finos al calcular la pendiente, aspecto, y demás índices que se desprenden de la delimitación de las redes de drenaje como el TWI, SPI y STI.

Figura 17

Modelos de elevación resultantes.



Nota. Modelos de elevación resultantes de emplear cuatro técnicas e información base diferente, demuestra de manera visual que el modelo a partir de la información de SIGTIERRAS es el ideal para el objetivo del presente estudio.

El modelo seleccionado fue dividido en seis clases a partir de los valores máximos y mínimos de elevación, obteniendo los siguientes rangos de clasificación en metros: <2400, 2400 – 2700, 2700 – 3000, 3000 – 3300, 3300 – 3600, >3600 (Figura 18-a).

A partir del MDE se han calculado seis factores condicionantes: Pendiente, Aspecto, STI, SPI, TWI y Distancia de drenaje; para ello se ha utilizado ArcGis Pro como herramienta de procesamiento de estos datos geospaciales, cuyos procedimientos han sido descritos a detalle en el capítulo anterior. Como resultado se han obtenido mapas en formato raster, los

cuales mantienen configuraciones propias del MDE, como su resolución espacial y manteniendo su coherencia espacial, esto es que cada pixel que compone estos mapas esté alineado para evitar inconsistencias en los cálculos posteriores.

El mapa de pendiente fue dividido en cinco clases en rangos de grados: $<10^\circ$, $10^\circ - 20^\circ$, $20^\circ - 30^\circ$, $30^\circ - 50^\circ$, $>50^\circ$ (Figura 18-c), siendo las clases más frecuentes la de los rangos intermedios entre los 10 y 30 grados, mientras que, hacia el norte de la zona de estudio se identifican mayor presencia de pendientes pronunciadas.

El mapa de aspecto, su clasificación se realizó de acuerdo con cuadrantes de orientación geográfica, resultando en ocho clases: Norte, Noreste, Este, Sureste, Sur, Suroeste, Oeste y Noroeste (Figura 18-b). Para este factor, el mapa muestra una distribución relativamente homogénea, sin una dominancia clara para un cuadrante específico, sin embargo, se observa una ligera concentración de laderas orientadas hacia el este y sureste.

Los mapas resultantes de calcular los índices STI, SPI y TWI, fueron clasificados utilizando el método de clasificación por “Natural Breaks (Jenks)”, el cual está basado en un algoritmo que identifica agrupaciones naturales en el conjunto de datos, minimizando la varianza interna de cada clase y maximizándola entre clases, estableciendo los quiebres donde se producen cambio evidentes en la distribución de los datos (Jenks, 1967). El resultado fue, para STI cuatro clases: $0.001 - 43.014$, $43.015 - 344.113$, $344.114 - 1161.382$, $1161.383 - 10968.608$. Las cinco clases calculadas para el factor SPI fueron: $-27.448 - -3.367$, $-3.366 - -1.084$, $-1.083 - 0.785$, $0.786 - 2.238$, $2.239 - 25.489$. Para el factor TWI, se seleccionaron 5 clases: $-0.281 - 3.028$, $3.029 - 4.682$, $4.683 - 6.772$, $6.773 - 9.819$, $9.820 - 21.921$ (Tabla5).

Para obtener el mapa de distancia de drenaje se generó la red de drenaje del área de estudio a partir del MDE seleccionado, siguiendo los procedimientos descritos en el capítulo anterior. A partir de esta red se calculó la distancia euclidiana, que representa la distancia horizontal a partir del cauce de dicha red de drenaje, el cual fue clasificado en 5 clases dada

en metros: <100, 100 – 200, 200 – 300, 300 – 400, >400 (Figura 18-d). El mapa resultante muestra que gran parte del territorio del área de estudio está por debajo del rango de los 300m de distancia, debido a la densa red de drenaje del lugar, siendo además las zonas donde se localiza gran número de eventos de deslizamientos reportados.

El mapa litológico se generó a partir de analizar las formaciones geológicas presentes donde se agruparon por similitudes litológicas, para lo cual se tomó como referencia el European Soil Database (ESDB) (Günther et al., 2014) clasificándolas en 9 categorías: Aluvial / Coluvial, Rocas cristalinas, Esquistos, Rocas volcánicas, Esquistos, Rocas volcánicas, Formaciones detriticas, Material organico, Areniscas, Material limoso / arcilloso, Material glaciofluvial (Figura 18-h). El mapa resultante muestra una distribución homogénea de rocas tipo esquistos, rocas volcánicas y formaciones detríticas, concentradas en el centro y norte del área de estudio. Por otro lado, material limoso / arcilloso y aluviales / coluviales se concentran en zonas bajas y de acumulación cercanas a drenajes en las partes bajas del sur del área de estudio.

La información que corresponde al cobertura y uso de suelo se extrajo del mapa escala nacional 1:25.000 (MAG, 2020), se utilizó la clasificación de nivel I de cobertura de suelo, resultando en seis categorías: tierra forestal, tierra arbustiva y herbácea, tierra agropecuaria, cuerpo de agua, zona antrópica y tierras sin cobertura vegetal (Figura 18-g). El mapa muestra una evidente predominancia de las tierras arbustivas y herbáceas hacia la zona norte de la zona de estudio, expandiéndose hacia el centro. Por otro lado, las tierras agropecuarias están concentradas principalmente en zonas orientales y meridionales, lo que refleja una alta actividad productiva y la transformación del medio para estos objetivos. Las tierras forestales ocupan extensiones importantes principalmente al norte, esto generalmente brinda mayor estabilidad en el terreno.

Para el caso del mapa de distancia de fallas y mapa de distancia de vías fueron elaborados a partir de información base de las fallas del área de estudio y la red vial

disponibles en fuentes oficiales, una vez procesados estos datos empleando ArcGis Pro como herramienta, se obtuvieron los mapas correspondientes, los cuales fueron clasificados en 5 clases, siendo para la distancia de fallas: <200, 200 – 400, 400 – 600, 600 – 800, >800 (Figura 18-e); mientras que para la distancia de vías: <100, 100 – 200, 200 – 300, 300 – 400, >400, los mapas mantienen la resolución espacial base del MDE, asegurando su alineación y coherencia espacial respecto con los demás factores (Figura 18-f).

Los mapas que resultaron de generar diferentes índices a partir de imágenes satelitales Landsat-9 nivel 2, de la zona de estudio, presentan una variabilidad significativa, mostrando diferencias en la cobertura vegetal (NDVI), el contenido de humedad (NDMI) y la presencia de agua superficial (MNDWI). El NDVI es esencial para evaluar la densidad de la cobertura vegetal lo que está directamente relacionado con la estabilidad del terreno, el mapa muestra predominantemente valores moderados a altos concentrados en el centro y norte del área de estudio hacia las partes bajas, alcanzando hasta 0.558. Por otro lado, los valores bajos se concentran en las partes altas, zonas urbanas y sectores agrícolas.


El NDMI muestra el contenido de humedad en el dosel vegetal, esta característica determina el grado de cohesión del terreno, siendo los suelos más húmedos los que tienen valores más alto, contrario a suelos secos. El mapa muestra valores entre -0.226 y 0.346. La distribución de los valores es similar al NDVI, concentrando los valores altos hacia las zonas bajas, clasificando el mapa en 5 escalas: -0.226 – -0.002, -0.001 – 0.055, 0.056 – 0.111, 0.112 – 0.162, 0.163 – 0.346.


El MNDWI permite identificar la presencia de agua superficial o suelos saturadas, esta información proporciona posibles patrones de inestabilidad del terreno. El mapa resultante tiene valores que van del -0.437 y 0.141, donde los valores altos se encuentran distribuidos en las inmediaciones de cuerpos de agua o drenajes hacia las partes bajas de la zona de estudio. En contraste, las zonas con valores bajos están focalizados en zonas vegetadas o secas. El mapa fue clasificado en cinco clases que permite visualizar de manera

precisa la variabilidad de este factor: $-0.437 - -0.229$, $-0.228 - -0.192$, $-0.191 - -0.152$, $-0.151 - -0.061$, $-0.06 - 0.141$.

Figura 18

Mapas de factores condicionantes.





Nota. (a) Elevación, (b) Aspecto, (c) Pendiente, (d) Distancia de drenaje, (e) Distance de falla, (f) Distance de vías, (g) Uso de suelo, (h) Litología, (i) TWI, (j) SPI, (k) STL, (l) MNDWI, (m) NDVI, (n) NDMI.

3.2 Híbrido de Evaluación Espacial Multicriterio (SMCE)


El método híbrido de evaluación espacial multicriterio combina dos técnicas que permiten asignar pesos a cada factor condicionante a deslizamiento y pesos a cada clase de los factores condicionantes. La asignación de los pesos relativos para los factores condicionantes a deslizamiento resulta a partir de determinar el grado de importancia basado en la opinión de expertos y el análisis de la distribución espacial del inventario de deslizamientos de tierra en la zona de estudio. Para esto fue necesario construir una matriz por pares, a partir de la cual se calcularon los pesos para cada factor condicionantes (Tabla 6).

Para garantizar que la matriz de decisión haya sido generada aleatoriamente, se calculó el índice de consistencia, mismo que deberá ser menor que 0.1 (Saaty 1977). Para este estudio el resultado del índice de consistencia es $CR=0.076$, lo que significa que los pesos relativos fueron apropiados y las comparaciones fueron consistentes (Saaty 1977; Feizizadeh y Blaschke 2013).

El factor al cual se asignó el peso más alto corresponde a la pendiente, esto en contraste con la distribución espacial de los deslizamientos un alto porcentaje de deslizamientos ocurren sobre pendientes mayores a 50 grados de inclinación. Factores como litología, uso de suelo y distancia de drenajes, ocupan los pesos más altos asignados, mientras que factores como el STI, NDMI Y MNDWI se identificaron como menos importantes (Figura 19).

Figura 19

Pesos asignados a los factores condicionantes



Nota. La asignación de pesos se realizó en base al conocimiento experto empleando matriz de evaluación por pares mediante el AHP.

El método de ratio de frecuencia relaciona de manera directa la distribución de los deslizamientos y las diferentes clases que conforman los factores condicionantes, este cálculo

otorga la correlación entre estos dos atributos. Utilizando el inventario de deslizamientos que contiene la ubicación geográfica, dada como un punto de coordenadas, fue calculada un área de 5 metros a la redonda, considerando la extensión promedio de incidencia de los eventos de deslizamientos registrados. Esta información fue convertida a un archivo formato raster, a partir del cual se trabaja en término de pixeles. Para cada mapa de los factores condicionantes se calculó el número de pixeles para cada clase de los factores condicionantes. Aplicando la ecuación (8) se obtuvieron los pesos para cada clase, mostrando cuanto mucho se relacionan los deslizamientos con cada clase específica de los factores condicionantes (Tabla 9).

Tabla 9.

Factores condicionantes y sus clases

No	Parámetros	Clases	Pixel/clase	%Pixel	LS/Pixels	%LS/Pixels	FR	Peso Clase	Peso Factor
1	Elevación (m)	< 2400	2672367	3.92	111	4.08	1.04	17	6.340
		2400 - 2700	11957335	17.56	1341	49.25	2.80	47	
		2700 - 3000	14808425	21.75	1033	37.94	1.74	29	
		3000 - 3300	16990657	24.95	170	6.24	0.25	4	
		3300 - 3600	16087736	23.63	60	2.20	0.09	2	
		> 3600	5574962	8.19	8	0.29	0.04	1	
2	Aspecto	Norte	8171983	12.00	379	13.92	1.16	15	2.700
		Noreste	7878483	11.57	161	5.91	0.51	6	
		Este	8492269	12.47	298	10.94	0.88	11	
		Sureste	10363143	15.22	400	14.69	0.97	12	
		Sur	8622103	12.66	342	12.56	0.99	12	
		Suroeste	8982737	13.19	414	15.20	1.15	14	
		Oeste	7820820	11.49	344	12.63	1.10	14	
		Noroeste	7759944	11.40	385	14.14	1.24	16	
3	Pendiente (°)	< 10	7654882	11.24	606	22.25	1.98	26	20.612
		10 - 20	19714671	28.95	915	33.60	1.16	15	
		20 - 30	21061111	30.93	641	23.54	0.76	10	
		30 - 50	19150340	28.12	499	18.33	0.65	9	
		> 50	510478	0.75	62	2.28	3.04	40	
4	Litología	Aluvial / Coluvial	2387998	3.51	262	9.62	2.74	18	15.915
		Rocas cristalinas	2152572	3.16	120	4.41	1.39	9	
		Esquistos	20253308	29.74	521	19.13	0.64	4	
		Rocas volcánicas	20514555	30.13	450	16.53	0.55	4	
		Formaciones detriticas	19187489	28.18	936	34.37	1.22	8	
		Material organico	122936	0.18	9	0.33	1.83	12	
		Areniscas	1892106	2.78	158	5.80	2.09	14	
		Material limoso / arcilloso	1402372	2.06	267	9.81	4.76	31	

No	Parámetros	Clases	Pixel/clase	%Pixel	LS/Pixels	%LS/Pixels	FR	Peso Clase	Peso Factor
		Material glaciofluvial	178247	0.26	0	0.00	0.00	0	
5	Uso de Suelo	Tierra de cultivo	59106	0.09	0	0.00	0.00	0	13.733
		Arbustos	9907720	14.55	1778	65.30	4.49	80	
		Urbano	1296009	1.90	17	0.62	0.33	6	
		Suelo desnudo	30918470	45.41	644	23.65	0.52	9	
		Bosque	25728819	37.79	284	10.43	0.28	5	
		Cuerpo de agua	181459	0.27	0	0.00	0.00	0	
6	Distancia de Drenaje (m)	< 100	9280481	13.63	699	25.67	1.88	35	9.801
		100 - 200	8461187	12.43	345	12.67	1.02	19	
		200 - 300	7952248	11.68	280	10.28	0.88	16	
		300 - 400	7401675	10.87	227	8.34	0.77	14	
		> 400	34995992	51.40	1172	43.04	0.84	16	
7	Distancia de Vías (m)	<100	17353303	25.49	2266	83.22	3.27	73	3.128
		100 - 200	9098341	13.36	221	8.12	0.61	14	
		200 - 300	5705275	8.38	84	3.08	0.37	8	
		300 - 400	3964887	5.82	20	0.73	0.13	3	
		> 400	31969777	46.95	132	4.85	0.10	2	
8	Distancia de Falla (m)	< 200	3977878	5.84	222	8.15	1.40	14	3.559
		200 - 400	3563093	5.23	328	12.05	2.30	24	
		400 - 600	3242817	4.76	321	11.79	2.48	26	
		600 - 800	3014106	4.43	345	12.67	2.86	29	
		> 800	54293689	79.74	1507	55.34	0.69	7	
9	TWI	< 3.25	25195332	37.00	900	33.05	0.89	15	6.757
		3.25 - 4.88	20643912	30.32	797	29.27	0.97	16	
		4.88 - 6.93	14954691	21.96	554	20.35	0.93	15	
		6.93 - 9.93	5673112	8.33	365	13.40	1.61	27	
		> 9.93	1624435	2.39	107	3.93	1.65	27	
10	SPI	< -2.66	5486335	8.06	141	5.18	0.64	14	7.502
		-2.66 -1.42	10661634	15.66	446	16.38	1.05	23	
		-1.42 -0.42	23992709	35.24	1227	45.06	1.28	28	
		-0.42 0.37	21755957	31.95	715	26.26	0.82	18	
		> 0.37	6194847	9.10	194	7.12	0.78	17	
11	STI	< 43.01	66578898	97.78	2671	98.09	1.00	40	1.936
		43.01 - 344.11	1432604	2.10	50	1.84	0.87	34	
		344.11 - 1'161.38	75412	0.11	2	0.07	0.66	26	
		> 1'162.38	4568	0.01	0	0.00	0.00	0	
12	MNDWI	< -0.195	12086468	17.75	241	8.85	0.50	13	1.407
		-0.195 -0.166	22074457	32.42	1098	40.32	1.24	34	
		-0.166 -0.133	19151314	28.13	1007	36.98	1.31	36	
		-0.133 -0.06	14554606	21.38	377	13.85	0.65	17	
		> -0.06	224645	0.33	0	0.00	0.00	0	
13	NDVI	< 0.182	5362997	7.88	803	29.49	3.74	56	4.896
		0.182 - 0.244	16671786	24.48	642	23.58	0.96	14	
		0.244 - 0.301	17103916	25.12	720	26.44	1.05	16	
		0.301 - 0.36	17466641	25.65	336	12.34	0.48	7	
		> 0.36	11486150	16.869	222	8.153	0.483	7	
14	NDMI	< -0.015	8217127	12.068	580	21.300	1.765	32	1.710
		-0.015 - 0.068	13929989	20.458	900	33.052	1.616	30	
		0.068 - 0.121	13828455	20.309	711	26.111	1.286	24	
		0.121 - 0.170	19120154	28.080	354	13.000	0.463	8	
		> 0.170	12995765	19.086	178	6.537	0.343	6	

Nota El cuadro presenta el porcentaje de pixeles que conforma cada clase y los pixeles de deslizamientos presentes en cada una, la relación espacial entre los deslizamientos y los factores condicionantes a deslizamientos se cuantifica en pesos mediante FR.


Después de aplicar las técnicas descritas, utilizando ArcGis Pro, se reclasificaron los factores condicionantes, asignando a cada clase el valor del peso calculado mediante FR, con estos datos se obtuvo el modelo final de susceptibilidad a deslizamientos empleando la ecuación (14). El mapa resultante se reclasificó en cinco niveles significativos de susceptibilidad: muy baja, baja, moderada, alta y muy alta (Figura 20). Esto es útil para fines de presentación y evaluación.

$$LS = \sum_{j=1}^{n=14} w_j * x_{ji}$$

$$\begin{aligned} SD = & (Elevación \times 6.340) + (Aspecto \times 2.7) + (Pendiente \times 20.613) \\ & + (Litología \times 15.915) + (Uso \text{ de } suelos \times 13.733) \\ & + (Distancia \text{ de } drenaje \times 9.802) + (Distancia \text{ de } vías \times 3.128) \\ & + (Distancia \text{ de } fallas \times 3.559) + (TWI \times 6.757) + (SPI \times 7.502) \\ & + (STI \times 1.936) + (MNDWI \times 1.407) + (NDVI \times 4.896) \\ & + (NDMI \times 1.71) \end{aligned} \tag{14}$$

Figura 20

Mapa de susceptibilidad a deslizamientos Híbrido SMCE




El mapa de susceptibilidad a deslizamientos resultante muestra la distribución espacial de las zonas de susceptibilidad, con una clara variabilidad. Hacia la parte suroccidental de la zona de estudio, está controlada principalmente por zonas catalogadas como alta y muy alta susceptibilidad, coincidiendo con características del uso de suelo como zonas antrópicas y tierras agropecuarias, además de otro tipo de modificaciones antrópicas como la presencia de vías. En contraste, sectores catalogados de susceptibilidad baja y moderada se centran principalmente hacia el noreste del territorio, controlada por la red de drenaje y tierras agropecuarias.

La validación del modelo fue realizada calculando el área bajo la curva (AUC) lo que resultó en un valor de 84.3%, lo que indica un desempeño bueno del modelo. La sensibilidad o tasa de verdaderos positivos, mide la proporción de casos positivos correctamente identificados por el clasificador. La curva ROC se sitúa por encima de la línea negra

discontinua, la cual representa el rendimiento de una predicción aleatoria. El valor del AUC del clasificador es de 0.843, superando significativamente el valor de 0.5 que caracteriza una predicción al azar (Figura 21). Esto indica que el clasificador posee una alta capacidad de discriminación entre los dos grupos analizados: zonas susceptibles a deslizamientos y regiones no susceptibles.

Figura 21

Curva ROC y el AUC modelo Híbrido SMCE.



3.3 Random Forest (RF)

3.3.1 Preparación y descripción de los datos

Generar el mapa de susceptibilidad empleando el algoritmo de Random Forest para requiere de un conjunto de datos geospaciales que han sido previamente procesados. Estos datos corresponden a: un raster multibandas que contiene los 14 factores condicionantes considerados en el presente estudio: Aspecto, Elevación, Distancia a fallas, Litología, MNDWI, NDMI, NDVI, Distancia a vías, SPI, STI, Pendiente, Distancia a drenajes, TWI y Uso del suelo; un archivo tipo shapefile que contiene la delimitación del área de estudio; un archivo tipo shapefile para el entrenamiento del modelo, el mismo que contiene el 70% de datos totales clasificados en presencia y ausencia de deslizamientos (3812 puntos); un archivo

tipo shapefile para la validación del modelo, que contiene el 30% restante de los datos totales, clasificados en presencia y ausencia de deslizamientos (1634 puntos). Los puntos de deslizamiento corresponden a los píxeles que hay en un radio de 5 metros teniendo como centro la coordenada del inventario. Mientras que los píxeles de no deslizamiento fueron asignados de manera aleatoria considerando una distancia no menor a los 30 metros desde un punto de deslizamiento. Estos datos son fundamentales para la ejecución del algoritmo, por lo que fueron obtenidos y revisados de manera rigurosa empleando herramientas especializadas de QGIS.

El algoritmo empleando utiliza librerías especializadas del lenguaje R, siendo las principales:

- RandomForest: permite implementar y ejecutar el algoritmo de Random Forest, con el cual es posible obtener el modelo final.
- Terra: permite el procesamiento y uso de datos vectoriales y tipo raster
- Caret: librería utilizada para la etapa de validación del modelo empleando métodos estadísticos por medio de la matriz de confusión.
- ROCR: proporciona las herramientas para generar y analizarlas curvas ROC, permitiendo la evaluación de desempeño predictivo del modelo final.


El modelo de random forest fue configurado para ejecutar un total de 500 árboles de decisión con tres variables predictoras para cada división del árbol. Además, dentro del algoritmo empleado se incluyó el análisis de la importancia relativa de cada variable o factor condicionante considerado en el estudio, por medio del análisis de incremento porcentual del error cuadrático medio (%IncMSE) y del incremento en la pureza de los nodos (IncNodePurity).

La Figura 22 muestra los resultados de este análisis, identificando aquellos factores condicionantes que son más importantes en la precisión del modelo, al ser estos los que provocan el mayor incremento del porcentaje del error cuadrático. Aquí, “distancia de vías”,

“elevación” y “distancia de drenaje” con un %IncMSE de 102.2%, 76.19% y 61.44% respectivamente son las variables que influyen mayormente en la capacidad predictiva del modelo final. En el caso del incremento de pureza de los nodos, corresponde a la suma de las reducciones de impureza que aporta cada factor al dividir los nodos. Es así como, el factor que más incrementa la pureza al separar las clases es el más relevante para el modelo. En este caso “distancia de vías” y “elevación” destacan con valores de 248.96 y 181.03 respectivamente, resultando ser claves para la precisión del modelo final.

Figura 22

Factores importantes en capacidad de predicción del modelo



Nota. Gráficas del porcentaje de incremento del error cuadrático medio y el incremento de la pureza de nodos del algoritmo de random forest para los factores condicionantes considerados en el estudio.

3.3.2 Validación y evaluación del modelo

Para validar el modelo se ha utilizado el 30% de la muestra total, la misma que resulta de combinar puntos que representan la ubicación de deslizamientos reportados y de no deslizamientos. Para ello se emplearon dos técnicas de evaluación:

Matriz de Confusión

La evaluación mediante la matriz de confusión se basa en mostrar la cantidad de puntos que el modelo ha clasificado de manera correcta (verdaderos positivos y negativos) y cuántos ha clasificado de manera errónea (falsos positivos y negativos). Además, esta técnica nos permite calcular métricas de exactitud, sensibilidad y especificidad en relación con las predicciones generadas por el modelo (Tabla 10).

Tabla 10.

Matriz de confusión

		Valores reales	
		0	1
Valores de Predicción	0	734	1
	1	83	816

Nota. La tabla muestra que el modelo ha clasificado correctamente 1550 puntos (verdaderos positivos + negativos) y ha clasificado erróneamente 84 puntos (falsos positivos + negativos).

- Exactitud (Accuracy): 94,86% indica que el modelo ha acertado cerca del 95% de las predicciones.
- Índice Kappa: 0,8972 demuestra una excelente concordancia entre las predicciones y las etiquetas reales.
- Sensibilidad: 89,84% muestra que el modelo es capaz de detectar cerca del 90% de las zonas susceptibles a deslizamiento.

- Especificidad: 99,88% revela que el modelo ha podido identificar cerca del 100% de las zonas no susceptibles a deslizamiento.


Estos valores indican un excelente desempeño predictivo del modelo para distinguir entre áreas susceptibles y no susceptibles.

Curva ROC

La curva ROC (Receiver Operating Characteristic) indica el rendimiento del modelo, esta curva muestra la relación entre la sensibilidad y la especificidad en sitios donde han ocurrido deslizamientos y donde no han ocurrido. El calculando el área bajo la curva o AUC (Area Under the Curve) representa la capacidad discriminativa del modelo, cuando el AUC es más cercano a 1 (100%), indica que el rendimiento del modelo es muy alto. Para el caso de estudio, el área bajo la curva (AUC) es de 0.949, considerado excelente para estudios predictivos (Figura 23).

Figura 23

Curva ROC del modelo de susceptibilidad empleando RF



3.3.3 Mapa de susceptibilidad a deslizamientos generado

Por último, aplicando el modelo Random Forest se logra obtener un mapa de susceptibilidad empleando los coeficientes de predicción que se obtuvieron empleando el algoritmo (Figura 24). Para esto se utilizó la función “predict” del paquete terra, para aplicar el modelo de RF al raster multibanda que contiene los 14 factores condicionantes, teniendo como resultado el modelo de susceptibilidad, el cual es exportado como raster (.tif) empleando la función “writeRaster”. Este producto fue procesado utilizando ArcGis Pro para clasificar el mapa en 5 clases de susceptibilidad: Muy Baja, Baja, Moderada, Alta y Muy Alta, para lo cual se utilizaron rango propuestos por Quevedo et al (2022) (Tabla 11).


Tabla 11

Rangos de clasificación de susceptibilidad

0 – 0.25	Muy Baja
0.25 – 0.50	Baja
0.50 – 0.70	Moderada
0.70 – 0.90	Alta
0.90 - 1	Muy Alta

Figura 24

Mapa de susceptibilidad a deslizamientos empleando RF




3.4 Análisis de Componentes Principales y Random Forest

El cálculo de las CP se llevó a cabo utilizando la herramienta “Principal Components” disponible en el catálogo de geoprocursos del software ArcGis Pro, el cual analiza un conjunto de bandas de raster, que corresponden a los 14 factores condicionantes utilizados en el estudio (previamente estandarizados empleando el software SAGA) del cual se obtiene como resultado un raster multibandas que contiene un número de componentes principales igual al número de factores condicionantes utilizadas (14 CP). Este proceso arroja los resultados de “eigenvalues” de cada componente principal, el cual permite identificar la componente principal donde se estabiliza el incremento del porcentaje acumulado de la varianza. Adicionalmente se tiene los “eigenvectors” de cada CP, lo que permite identificar el grado en influyen los factores condicionantes en cada CP. El análisis de la varianza acumulada entre las CP permite identificar que las ocho primeras componentes son capaces de explicar el 84.91% de la varianza total del conjunto de datos (Figura 25).

Figura 25

Gráfica de las componentes principales.



Nota. La gráfica muestra el porcentaje de varianza individual para cada CP y la curva de la varianza acumulada, a partir de ella se detecta la componente en que se estabilización de la varianza.


El conjunto de 14 CP originales, así como las 8 primeras CP identificadas como las que acumulan el mayor porcentaje de varianza previo a su estabilización, se utilizaron como datos de ingreso en el algoritmo de random forest, resultando en dos diferentes modelos de susceptibilidad que fueron evaluados comparando métricas de precisión, sensibilidad y especificidad.

Los resultados resultan que el modelo que emplea 14 componentes principales posee una mayor capacidad de predicción con un accuracy de 90.60%, en comparación con el que emplea los 8 primeros componentes principales, cuyo valor es 88% (Figura 26). Ocurre igual en las métricas de sensibilidad y especificidad, siendo en ambos casos mayor cuando se emplearon las 14 PCs. La manera en que random forest aprovecha las interacciones sutiles

entre variables para generar el modelo de susceptibilidad, explicaría la reducción de la precisión cuando se reduce el número de PCs en random forest.

Figura 26

Métricas de exactitud



Además, se considera el análisis de cambio tomando como punto de comparación el modelo que resulta de utilizar los 14 factores condicionantes originales como variables en random forest. Para esto se establecen índices de cambio, que representan el grado en que cambian las clases entre los modelos comparados, categorizados en:


- Sin cambio: cuando las clases de susceptibilidad se mantienen;
- Cambio medio: cuando la clase cambia a una clase adyacente dentro del rango de susceptibilidad;
- Cambio mayor: cuando la clase cambia en más de dos categorías.

Como resultado de la comparación se obtuvo que 68% de pixeles del modelo que utiliza las 14 PC no han tenido cambio en relación con el modelo de 14 factores condicionantes, con solamente 5% de cambios drásticos. Por otro lado, en el modelo que emplea 8 PC el 65% de los pixeles presentan coincidencia con el modelo de 14 factores

condicionantes, pero con el 8% cambios drásticos (Figura 27). Esto confirma que de ambos modelos basados en PCA, el modelo que emplea 14 PC logra un equilibrio entre compresión de la información y fidelidad espacial. Siendo este el seleccionado para el objeto del presente estudio.

Figura 27

Gráfica de análisis de cambio.




Nota. las barras muestran comparativamente la magnitud del cambio entre el modelo de RF utilizando los 14 factores condicionantes y los modelos 14 PCA + RF y 8 PCA + RF.

El cálculo de AUC del modelo seleccionado resulta en 0.906 (Figura 28), lo que indica que el modelo final tiene una excelente capacidad predictora, reflejando una alta precisión espacial frente al inventario de deslizamiento.

Figura 28


Curva ROC del modelo de susceptibilidad 14 PCA + RF



Los componentes principales que el algoritmo a identificado como predictores de acuerdo con su porcentaje de error cuadrático medio (%IncMSE) muestra que las más importantes son la PC4, PC12 y PC2. Estas componentes a su vez están influenciadas principalmente por factores topográficos, hidrológicos, estructurales y de uso de suelo, una evaluación de los eigenvectores de las dos PC más influyentes permite identificar que road distance es crítica en ambos casos lo que describe que el valor de la componente aumenta con la cercanía a vías, este comportamiento es igual con la distancia de drenaje, mientras que la elevación se comporta de manera contraria para ambos factores (Figura 29), esto explicaría como este factor influye para PC4 en zonas de baja elevación cercano a cuerpos de agua y zonas sin cobertura vegetal, mientras que para el PC14 en zonas de alta elevación relacionadas a bosques.

Figura 29

Biplot entre las dos PC más influyentes




3.5 Selección final de mapa de susceptibilidad a deslizamientos

Los resultados presentados demuestran la utilidad de los tres métodos aplicados para el mapeo de la susceptibilidad a deslizamientos en el presente estudio, destacando cada uno con diferentes ventajas operativas y grados de precisión distintos de los modelos resultantes. El modelo con mayor precisión fue RF, utilizando los 14 factores de condicionamiento originales ($AUC = 0,947$), aunque muy cercano al modelo RF aplicand 14 CP ($AUC = 0,906$) (Figura 30). Ambos modelos, con valores de AUC superiores a 0,9, presentan una excelente capacidad discriminativa (Chen y Li, 2020; Zhang et al., 2017), por lo que también es importante considerar su relación con las características del terreno.

Figura 30

Comparación de los valores de AUC de los tres modelos



Nota. La evaluación de los modelos resultantes, el AUC de Random Forest es mayor.

Comparando la distribución de clases de susceptibilidad entre los tres modelos (Tabla 12) refuerza que el modelo RF proporciona una mejor discriminación y distribución de clases, especialmente en las categorías de mayor susceptibilidad, manteniendo una estrecha relación con la distribución espacial de los deslizamientos reportados.

Tabla 12

Comparación de porcentaje de área por rango

	% Area rango de Susceptibilidad		
	Híbrido SMCE	RF	PCA + RF
Muy Baja	74.0	77.5	59.7
Baja	21.7	13.0	24.7
Moderada	3.2	6.1	11.3
Alta	1.1	3.3	4.2
Muy Alta	0	0.1	0.1

Nota. Porcentaje de área para cada clase de susceptibilidad en los tres modelos generados.

3.6 Aplicación en Hidrocarburos

El mapeo de susceptibilidad a deslizamiento empleando modelos predictivos como Random Forest son ideales para ser integrados en la gestión de integridad de ductos y en la selección de rutas para instalación de oleoductos y gasoductos, que permitan priorizar zonas de baja susceptibilidad definiendo franjas críticas de monitoreo, para las cuales se pueden emplear tecnologías tipo InSAR o LiDAR.

Esta propuesta se alinea con las prácticas recomendadas por el American Petroleum Institute que establece un marco para la identificación, evaluación, monitoreo y mitigación de riesgos de deslizamientos, como el caso de API RP 1187 para la gestión de “Geohazards” en ductos y marcos de integridad ASME M31.8S.

Un ejemplo que demuestra la importancia de aplicar estos principios en el campo de hidrocarburos es el caso de Hendek (Turquía), donde un gasoducto falló debido a un deslizamiento, por lo cual fue necesario la elaboración de un mapa de susceptibilidad para la propuesta de rediseño del trazado del tramo expuesto a estos eventos (Çevik & Topal, 2003).

En Ecuador, deslizamientos de tierra han provocado daños en infraestructura hidrocarburífera ocasionando interrupciones, roturas y derrames. En 1987, deslizamientos masivos desencadenados por sismos ($M_s=6.1$) que destruyeron cerca de 60 Km de tubería del Sistema de Oleoducto Transecuatoriano (SOTE), mientras que en el año 2025, este mismo sistema se vio afectado por rupturas de en la tubería en la provincia de Esmeraldas por deslizamientos asociados a fuertes precipitaciones. El Oleoducto de Crudo Pesado (OCP) en 2020 sufrió efectos similares debido a deslizamientos relacionados a la erosión regresiva de la cuenca del río Coca, ocasionando derrames sobre el río Coca y Napo. Estos eventos dejan en evidencia la importancia de considerar el análisis de susceptibilidad a deslizamientos en el diseño del trazado de las líneas de distribución.

Últimas investigaciones, han demostrado un incremento considerable en la capacidad de detectar de manera temprana eventos de inestabilidad, permitiendo priorizar las acciones de mitigación por segmentos, esto se debe a la integración de técnicas de teledetección, como InSAR, con algoritmos de Machine Learning son Más recientemente, la industria y la academia han mostrado que combinar teledetección (incluido InSAR) con aprendizaje automático (Medici et al., 2025).

Capítulo 4

4.1 Conclusiones y recomendaciones

4.1.1 Conclusiones

Los deslizamientos representan el segundo evento adverso de mayor recurrencia en el área de Azogues en Ecuador, por lo cual este estudio aplicó tres metodologías para el mapeo de susceptibilidad a deslizamientos integrando datos de libre acceso y técnicas que emplean herramientas de geoprocésamiento que garantizan su replicabilidad en escenarios con características similares. Los resultados fueron comparados y analizados empleando diferentes criterios en base a los deslizamientos reportados y curvas ROC. A partir del análisis de los resultados se concluye que:

- El modelo híbrido de evaluación espacial multi criterio (SMCE), que combina AHP y FR permite identificar que del conjunto de 14 factores condicionantes empleados en el estudio son la pendiente, litología, uso de suelo y distancia de drenaje los factores determinantes, acumulando el 60% de importancia relativa. El modelo resultante ofrece una alta interpretabilidad y un buen desempeño predictivo con un AUC de 0.843.
- El algoritmo de Random Forest que aplica directamente los 14 factores condicionantes ha demostrado tener una excelente capacidad discriminatoria con un AUC de 0.947. Este método supervisado, al considerar la distribución de los deslizamientos en su entrenamiento, permite relacionar de manera lógica los factores con el fenómeno, priorizando así aquellas variables que discriminan mejor el grado de susceptibilidad en el cantón Azogues. Es así como el modelo resalta los factores de distancia de vías y elevación como los más influyentes durante la predicción del modelo, esto se alinea con la realidad del área de estudio, ya que los deslizamientos reportados ocurren con frecuencia sobre taludes junto a vías y cerca de las quebradas. Adicionalmente las métricas de exactitud, sensibilidad y especificidad aseguran un

balance entre la identificación efectiva a áreas susceptibles y la reducción de errores de clasificación.

- Aplicar PCA como input del algoritmo de RF permitió la reducir la dimensionalidad de los datos y aumentar la robustez y eficiencia en términos de procesamiento, resultando en un modelo con AUC de 0.906. Sin embargo, PCA al basarse enteramente en la estructura estadística de los datos, podría afectar la representatividad física del fenómeno en términos geológicos. El resultado de emplear PC en el algoritmo RF, muestra que el modelo está influenciado por la distancia de vías, elevación y distancia de drenaje. Estos resultados son consistentes con las características del terreno y los deslizamientos registrados, demostrando que susceptibilidad a deslizamientos está influenciada por modificaciones como la apertura de vías y el sistema natural de drenajes.
- Los resultados comparativos y la validación de los modelos sugieren que el mapa de susceptibilidad a deslizamientos generado mediante el uso de Random Forest con los factores condicionantes originales, es el modelo con mejor desempeño predictivo y alto equilibrio entre precisión y sensibilidad. Además, demuestra ser el modelo más conservador en la clasificación de susceptibilidad, con un porcentaje menor de áreas clasificadas como de muy alta y alta susceptibilidad, lo que reduce la posibilidad de sobreestimar el riesgo en zonas donde los deslizamientos son poco probables.
- El modelo seleccionado identifica que las clases de alta y muy alta susceptibilidad se concentran en la zona centro sur del área de estudio, que corresponde al área urbana del cantón Azogues y hacia el NE donde se ubican asentamientos rurales, sitios donde la ocurrencia a deslizamientos es alta y se encontraría controlada por la cercanía de infraestructura vial y redes de drenaje natural.
- Random Forest demuestra ser un método ideal para el mapeo de la susceptibilidad a deslizamientos, su precisión dependerá de la calidad y cantidad de información

proporcionada al algoritmo, así como del tamaño del área de estudio y su escala de análisis.

- El mapa final seleccionado puede ser utilizado para la gestión del territorio ante la amenaza a deslizamientos en el cantón Azogues, demostrando ser idóneo para replicar en zonas con características complejas propias de zonas montañosas de los andes. Este producto facilita la toma de decisiones informadas, para la mitigación del riesgo asociado.
- El mapa resultante puede ser considerado en el plan de ordenamiento territorial del cantón Azogues, para la correcta gestión del uso de suelo en las zonas que han sido categorizadas como de Alta y Muy Alta susceptibilidad a deslizamientos.

4.1.2 Recomendaciones

La replicabilidad de la metodología planteada en el presente trabajo depende del acceso a información con un alto grado de confiabilidad y precisión, y una alta resolución espacial.

Este estudio consideró un área de influencia promedio de 5 metros de radio por cada ubicación de deslizamiento parte del inventario, sin embargo, el tener el área exacta de afectación de cada deslizamiento podría mejorar considerablemente la delimitación e identificación de áreas con alta susceptibilidad. Se debe considerar emplear otras técnicas basadas en machine learning como Support Vector Machine y Redes Neuronales (Deep learning) para asegurar la interacción de los factores condicionantes identificados por este estudio como los más influyentes con la ocurrencia de deslizamientos.

Al considerar Azogues como zona de estudio, cuya topografía y otras características del terreno resultan complejas, se sugiere que, para una futura línea de investigación se emplee esta metodología en otras regiones del país, con características diferentes a fin de identificar patrones que pudieran condicionar los deslizamientos de diferente manera según la

realidad de cada lugar. Además, se puede considerar incluir data de precipitación y reducir el número de factores condicionantes lo que podría agregar mayor precisión en el resultado.

Referencias

- Abedini, M., & Tulabi, S. (2018). Assessing LNRF, FR, and AHP models in landslide susceptibility mapping index: a comparative study of Nojian watershed in Lorestan province, Iran. *Environmental Earth Sciences*, 77(11), 405. <https://doi.org/10.1007/s12665-018-7524-1>
- Beven, K. J., & Kirby, M. J. (1979). A physically based, variable contributing area model of basin hydrology / Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological Sciences Bulletin*, 24(1), 43–69. <https://doi.org/10.1080/02626667909491834>
- Breiman, L. (2001). Random Forests. *The Netherlands*, 45, 5–35. <https://doi.org/10.1023/A:1010933404324>
- Bui, D. T., Tsangaratos, P., Nguyen, V.-T., Liem, N. Van, & Trinh, P. T. (2020). Comparing the prediction performance of a Deep Learning Neural Network model with conventional machine learning models in landslide susceptibility assessment. *CATENA*, 188, 104426. <https://doi.org/10.1016/j.catena.2019.104426>
- Carrara, A., Cardinali, M., Guzzetti, F., & Reichenbach, P. (1995). *Gis Technology in Mapping Landslide Hazard* (pp. 135–175). https://doi.org/10.1007/978-94-015-8404-3_8
- Carrión-Mero, P., Briones-Bitar, J., Morante-Carballo, F., Stay-Coello, D., Blanco-Torrens, R., & Berrezueta, E. (2021). Evaluation of Slope Stability in an Urban Area as a Basis for Territorial Planning: A Case Study. *Applied Sciences*, 11(11), 5013. <https://doi.org/10.3390/app11115013>
- Çevik, E., & Topal, T. (2003). GIS-based landslide susceptibility mapping for a problematic segment of the natural gas pipeline, Hendek (Turkey). *Environmental Geology*, 44(8), 949–962. <https://doi.org/10.1007/s00254-003-0838-6>
- Chen, W., & Li, Y. (2020). GIS-based evaluation of landslide susceptibility using hybrid computational intelligence models. *CATENA*, 195, 104777. <https://doi.org/10.1016/j.catena.2020.104777>
- Chen, W., Peng, J., Hong, H., Shahabi, H., Pradhan, B., Liu, J., Zhu, A.-X., Pei, X., & Duan, Z. (2018). Landslide susceptibility modelling using GIS-based machine learning techniques for Chongren

- County, Jiangxi Province, China. *Science of The Total Environment*, 626, 1121–1135.
<https://doi.org/10.1016/j.scitotenv.2018.01.124>
- Chowdhury, M. S., & Hafsa, B. (2022). Landslide Susceptibility Mapping Using Bivariate Statistical Models and GIS in Chattagram District, Bangladesh. *Geotechnical and Geological Engineering*, 40(7), 3687–3710. <https://doi.org/10.1007/s10706-022-02111-y>
- Chowdhury, M. S., Rahman, M. N., Sheikh, M. S., Sayeid, M. A., Mahmud, K. H., & Hafsa, B. (2024). GIS-based landslide susceptibility mapping using logistic regression, random forest and decision and regression tree models in Chattogram District, Bangladesh. *Heliyon*, 10(1), e23424. <https://doi.org/10.1016/j.heliyon.2023.e23424>
- Cobos-Mora, S. L., Rodriguez-Galiano, V., & Lima, A. (2023). Analysis of landslide explicative factors and susceptibility mapping in an andean context: The case of Azuay province (Ecuador). *Heliyon*, 9(9), e20170. <https://doi.org/10.1016/j.heliyon.2023.e20170>
- D'Ercole, R., & Trujillo, M. (2003). *Amenazas, vulnerabilidad, capacidades y riesgo en el Ecuador*.
- Dehnavi, A., Aghdam, I. N., Pradhan, B., & Morshed Varzandeh, M. H. (2015). A new hybrid model using step-wise weight assessment ratio analysis (SWARA) technique and adaptive neuro-fuzzy inference system (ANFIS) for regional landslide hazard assessment in Iran. *CATENA*, 135, 122–148. <https://doi.org/10.1016/j.catena.2015.07.020>
- Demir, G., Aytakin, M., Akgün, A., İközler, S. B., & Tatar, O. (2013). A comparison of landslide susceptibility mapping of the eastern part of the North Anatolian Fault Zone (Turkey) by likelihood-frequency ratio and analytic hierarchy process methods. *Natural Hazards*, 65(3), 1481–1506. <https://doi.org/10.1007/s11069-012-0418-8>
- Devkota, K. C., Regmi, A. D., Pourghasemi, H. R., Yoshida, K., Pradhan, B., Ryu, I. C., Dhital, M. R., & Althuwaynee, O. F. (2013). Landslide susceptibility mapping using certainty factor, index of entropy and logistic regression models in GIS and their comparison at Mugling–Narayanghat road section in Nepal Himalaya. *Natural Hazards*, 65(1), 135–165. <https://doi.org/10.1007/s11069-012-0347-6>
- Dias, H. C., Hölbling, D., & Grohmann, C. H. (2021). Landslide susceptibility mapping in brazil: A review. *Geosciences (Switzerland)*, 11(10), 1–15. <https://doi.org/10.3390/geosciences11100425>

- Donnini, M., Santangelo, M., Gariano, S. L., Bucci, F., Peruccacci, S., Alvioli, M., Althuwaynee, O., Ardizzone, F., Bianchi, C., Bornaetxea, T., Brunetti, M. T., Cardinali, M., Esposito, G., Grita, S., Marchesini, I., Melillo, M., Salvati, P., Yazdani, M., & Fiorucci, F. (2023). Landslides triggered by an extraordinary rainfall event in Central Italy on September 15, 2022. *Landslides*, 20(10), 2199–2211. <https://doi.org/10.1007/s10346-023-02109-4>
- Duc, D. M. (2013). Rainfall-triggered large landslides on 15 December 2005 in Van Canh District, Binh Dinh Province, Vietnam. *Landslides*, 10(2), 219–230. <https://doi.org/10.1007/s10346-012-0362-4>
- ESRI. (2024). *ArcGIS Pro*®. Environmental Systems Research Institute, Inc. <https://www.esri.com>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Froude, M. J., & Petley, D. N. (2018). Global fatal landslide occurrence from 2004 to 2016. *Natural Hazards and Earth System Sciences*, 18(8), 2161–2181. <https://doi.org/10.5194/nhess-18-2161-2018>
- Gonzales de Vallejo, L. (2002). *Ingenieria Geológica*. Pearson.
- Gudiyangada Nachappa, T., Kienberger, S., Meena, S. R., Hölbling, D., & Blaschke, T. (2020). Comparison and validation of per-pixel and object-based approaches for landslide susceptibility mapping. *Geomatics, Natural Hazards and Risk*, 11(1), 572–600. <https://doi.org/10.1080/19475705.2020.1736190>
- Günther, A., Van Den Eeckhaut, M., Malet, J.-P., Reichenbach, P., & Hervás, J. (2014). Climate-physiographically differentiated Pan-European landslide susceptibility assessment using spatial multi-criteria evaluation and transnational landslide information. *Geomorphology*, 224, 69–85. <https://doi.org/10.1016/j.geomorph.2014.07.011>
- Guzzetti, F., Carrara, A., Cardinali, M., & Reichenbach, P. (1999). Landslide hazard evaluation: a review of current techniques and their application in a multi-scale study, Central Italy. *Geomorphology*, 31(1–4), 181–216. [https://doi.org/10.1016/S0169-555X\(99\)00078-1](https://doi.org/10.1016/S0169-555X(99)00078-1)
- 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>

- Guzzetti, F., Reichenbach, P., Ardizzone, F., Cardinali, M., & Galli, M. (2006). Estimating the quality of landslide susceptibility models. *Geomorphology*, 81(1–2), 166–184. <https://doi.org/10.1016/j.geomorph.2006.04.007>
- Hansen, A. (1984). Landslide Hazard Analysis. In D. Brunsten & D. B. Prior (Eds.), *Slope Instability* (pp. 523–602). John Wiley & Sons.
- Hoffmann, E., & Winde, F. (2010). Generating high-resolution digital elevation models for wetland research using Google Earth™ imagery – an example from South Africa. *Water SA*, 36(1). http://www.scielo.org.za/scielo.php?script=sci_arttext&pid=S1816-79502010000100007&lng=en&nrm=iso
- Hong, H. (2023). Assessing landslide susceptibility based on hybrid Best-first decision tree with ensemble learning model. *Ecological Indicators*, 147, 109968. <https://doi.org/10.1016/j.ecolind.2023.109968>
- Huang, F., Cao, Z., Guo, J., Jiang, S.-H., Li, S., & Guo, Z. (2020). Comparisons of heuristic, general statistical and machine learning models for landslide susceptibility prediction and mapping. *CATENA*, 191, 104580. <https://doi.org/10.1016/j.catena.2020.104580>
- Jenks, G. F. (1967). The Data Model Concept in Statistical Mapping. *International Yearbook of Cartography*, 7, 186–190.
- Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065), 20150202. <https://doi.org/10.1098/rsta.2015.0202>
- Junquera-Torrado, S., Moreiras, S. M., & Sepúlveda, S. A. (2019). Distribution of landslides along the Andean active orogenic front (Argentinean Precordillera 31–33° S). *Quaternary International*, 512, 18–34. <https://doi.org/10.1016/j.quaint.2019.01.030>
- Lee, S., & Dan, N. T. (2005). Probabilistic landslide susceptibility mapping in the Lai Chau province of Vietnam: focus on the relationship between tectonic fractures and landslides. *Environmental Geology*, 48(6), 778–787. <https://doi.org/10.1007/s00254-005-0019-x>

- Lee, S., Ryu, J.-H., Lee, M.-J., & Won, J.-S. (2003). Use of an artificial neural network for analysis of the susceptibility to landslides at Boun, Korea. *Environmental Geology*, 44(7), 820–833. <https://doi.org/10.1007/s00254-003-0825-y>
- Lynn Highland. (2004). *Landslide Types and Processes*. <https://doi.org/10.3133/fs20043072>
- MAG. (2020). *Metodología unificada del levantamiento de Cobertura y Uso de la Tierra y Sistemas Productivos Agropecuarios del Ecuador Continental, escala 1:25.000*.
- Medici, C., Novellino, A., Dashwood, C., & Bianchini, S. (2025). Machine learning and clustering for supporting the identification of active landslides at national scale. *International Journal of Applied Earth Observation and Geoinformation*, 140, 104608. <https://doi.org/10.1016/j.jag.2025.104608>
- Meena, S. R., Ghorbanzadeh, O., & Blaschke, T. (2019). A Comparative Study of Statistics-Based Landslide Susceptibility Models: A Case Study of the Region Affected by the Gorkha Earthquake in Nepal. *ISPRS International Journal of Geo-Information*, 8(2), 94. <https://doi.org/10.3390/ijgi8020094>
- Meena, S. R., Mishra, B. K., & Tavakkoli Piralilou, S. (2019). A Hybrid Spatial Multi-Criteria Evaluation Method for Mapping Landslide Susceptible Areas in Kullu Valley, Himalayas. *Geosciences*, 9(4), 156. <https://doi.org/10.3390/geosciences9040156>
- 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>
- Moore, I. D., & Burch, G. J. (1986). Sediment Transport Capacity of Sheet and Rill Flow: Application of Unit Stream Power Theory. *Water Resources Research*, 22(8), 1350–1360. <https://doi.org/10.1029/WR022i008p01350>
- Moore, I. D., & Wilson, J. P. (1992). Length-slope factors for the revised universal soil loss equation: simplified method of estimation. *Journal of Soil and Water Conservation*, 47(5), 423–428.
- Mulugeta, T., Shano, L., & Jothimani, M. (2024). Landslide susceptibility modeling in the Kulfo river catchment, rift valley, Ethiopia: An integrated geospatial and statistical analysis. *Quaternary Science Advances*, 14, 100191. <https://doi.org/10.1016/j.qsa.2024.100191>

- Nam, K., & Wang, F. (2020). An extreme rainfall-induced landslide susceptibility assessment using autoencoder combined with random forest in Shimane Prefecture, Japan. *Geoenvironmental Disasters*, 7(1), 6. <https://doi.org/10.1186/s40677-020-0143-7>
- Park, S.-J., Lee, C.-W., Lee, S., & Lee, M.-J. (2018). Landslide Susceptibility Mapping and Comparison Using Decision Tree Models: A Case Study of Jumunjin Area, Korea. *Remote Sensing*, 10(10), 1545. <https://doi.org/10.3390/rs10101545>
- Plaza, G., Zevallos, O., & Cadier, É. (2011). *La Josefina Landslide Dam and Its Catastrophic Breaching in the Andean Region of Ecuador* (pp. 389–406). https://doi.org/10.1007/978-3-642-04764-0_14
- Pradhan, B. (2010). Landslide susceptibility mapping of a catchment area using frequency ratio, fuzzy logic and multivariate logistic regression approaches. *Journal of the Indian Society of Remote Sensing*, 38(2), 301–320. <https://doi.org/10.1007/s12524-010-0020-z>
- Puente-Sotomayor, F., Egas, A., & Teller, J. (2021). Land policies for landslide risk reduction in Andean cities. *Habitat International*, 107, 102298. <https://doi.org/10.1016/j.habitatint.2020.102298>
- Quevedo, R. P., Maciel, D. A., Uehara, T. D. T., Vojtek, M., Rennó, C. D., Pradhan, B., Vojteková, J., & Pham, Q. B. (2022). Consideration of spatial heterogeneity in landslide susceptibility mapping using geographical random forest model. *Geocarto International*, 37(25), 8190–8213. <https://doi.org/10.1080/10106049.2021.1996637>
- Reichenbach, P., Rossi, M., Malamud, B. D., Mihir, M., & Guzzetti, F. (2018). A review of statistically-based landslide susceptibility models. *Earth-Science Reviews*, 180, 60–91. <https://doi.org/10.1016/j.earscirev.2018.03.001>
- Rodriguez Ortiz, J. M., Prieto, C., & Hinojosa, J. A. (1978). Regional studies on mass movements in Spain. *II International Congress of the I.A.E.G. Asociación Española de Geología Aplicada a La Ingeniería*, 1, 267–277.
- Romer, C., & Ferentinou, M. (2016). Shallow landslide susceptibility assessment in a semiarid environment — A Quaternary catchment of KwaZulu-Natal, South Africa. *Engineering Geology*, 201, 29–44. <https://doi.org/10.1016/j.enggeo.2015.12.013>
- Saaty, R. W. (1987). The analytic hierarchy process—what it is and how it is used. *Mathematical Modelling*, 9(3–5), 161–176. [https://doi.org/10.1016/0270-0255\(87\)90473-8](https://doi.org/10.1016/0270-0255(87)90473-8)

- Sacoto Flores, M. A., & Sánchez-García, C. (2023). Vulnerabilidades de los elementos esenciales y evaluación integral del riesgo de desastres para la planificación urbana y la gestión del riesgo en Azogues, Ecuador. *Cuadernos de Investigación Geográfica*, 49(1), 163–190. <https://doi.org/10.18172/cig.5628>
- Sahnoun, H., Serbaji, M. M., Karray, B., & Medhioub, K. (2012). GIS and multi-criteria analysis to select potential sites of agro-industrial complex. *Environmental Earth Sciences*, 66(8), 2477–2489. <https://doi.org/10.1007/s12665-011-1471-4>
- Sajadi, P., Sang, Y.-F., Gholamnia, M., Bonafoni, S., & Mukherjee, S. (2022). Evaluation of the landslide susceptibility and its spatial difference in the whole Qinghai-Tibetan Plateau region by five learning algorithms. *Geoscience Letters*, 9(1), 9. <https://doi.org/10.1186/s40562-022-00218-x>
- Saygin, F., Şişman, Y., Dengiz, O., & Şişman, A. (2023). Spatial assessment of landslide susceptibility mapping generated by fuzzy-AHP and decision tree approaches. *Advances in Space Research*, 71(12), 5218–5235. <https://doi.org/10.1016/j.asr.2023.01.057>
- SGR. (2024). *SitRep No. 120 año 2023 – Lluvias, Cierre año 2023*. <https://www.gestionderiesgos.gob.ec/wp-content/uploads/downloads/2024/01/SITREP-Nro.-120-Lluvias-Cierre.01012023-al-31122023.pdf>
- Smith, W. H. F., & Sandwell, D. T. (1997). Global Sea Floor Topography from Satellite Altimetry and Ship Depth Soundings. *Science, New Series*, 277, 1956–1962.
- SNGR. (2024). *SitRep No. 83 año 2024 - Afectaciones por lluvias en el Ecuador*. https://www.gestionderiesgos.gob.ec/wp-content/uploads/2024/05/Infografia_Nacional_Lluvias_29012024_29052024-SitRep83-12h00.pdf
- SNI. (2018). *Plan del Buen Vivir y Ordenamiento Territorial (PBVOT) del cantón de Azogues – Ecuador*. <https://multimedia.planificacion.gob.ec/PDOT/descargas.html>
- University of California San Diego. (2014, November 29). *XYZ data*. https://topex.ucsd.edu/cgi-bin/get_data.cgi
- van Westen, C. J. (1997). Statistical landslide hazard analysis. In *ILWIS Applications Guide* (pp. 73–84).

- Varnes, D. J. (1978). Slope movement types and processes. In *Transportation research board special report 176*.
- Vojteková, J., & Vojtek, M. (2020). Assessment of landslide susceptibility at a local spatial scale applying the multi-criteria analysis and GIS: a case study from Slovakia. *Geomatics, Natural Hazards and Risk*, 11(1), 131–148. <https://doi.org/10.1080/19475705.2020.1713233>
- Wilson, E. H., & Sader, S. A. (2002). Detection of forest harvest type using multiple dates of Landsat TM imagery. *Remote Sensing of Environment*, 80(3), 385–396. [https://doi.org/10.1016/S0034-4257\(01\)00318-2](https://doi.org/10.1016/S0034-4257(01)00318-2)
- Witter, I. H., & Frank, E. (2005). *Data Mining: Practical machine learning tools and techniques* (2nd ed.). Elsevier.
- World Meteorological Organization. (2021). *WMO Atlas of Mortality and Economic Losses from Weather, Climate and Water Extremes (1970–2019)* (WMO-No. 1267). https://library.wmo.int/viewer/57564?medianame=1267_Atlas_of_Mortality_en_#page=1&viewer=picture&o=bookmarks&n=0&q=
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033. <https://doi.org/10.1080/01431160600589179>
- Xu, Z., Che, A., & Zhou, H. (2024). Seismic landslide susceptibility assessment using principal component analysis and support vector machine. *Scientific Reports*, 14(1), 3734. <https://doi.org/10.1038/s41598-023-48196-0>
- Zhang, K., Wu, X., Niu, R., Yang, K., & Zhao, L. (2017). The assessment of landslide susceptibility mapping using random forest and decision tree methods in the Three Gorges Reservoir area, China. *Environmental Earth Sciences*, 76(11), 405. <https://doi.org/10.1007/s12665-017-6731-5>
- Zhang, X., Xie, H., Xu, Z., Li, Z., & Chen, B. (2024). Evaluating landslide susceptibility: an AHP method-based approach enhanced with optimized random forest modeling. *Natural Hazards*, 120(9), 8153–8207. <https://doi.org/10.1007/s11069-023-06306-1>