

DESLIZAMIENTO DE TIERRA, CAMBIO CLIMÁTICO E INTELIGENCIA ARTIFICIAL EXPLICABLE EN ZONAS ANDINO- AMAZÓNICAS VULNERABLES, MEDIANTE MODELADO ESPACIO- TEMPORAL

LANDSLIDES, CLIMATE CHANGE, AND ARTIFICIAL INTELLIGENCE EXPLAINABLE IN VULNERABLE ANDEAN- AMAZONIAN AREAS THROUGH SPATIO-TEMPORAL MODELING

María Fernanda Guartán Cabrera¹, Carlos Santiago Curay Yauléma², Lindao Rosero Carmen
Natalia³, Goering Octavio Zambrano Cárdenas⁴

{maria.guartan@esPOCH.edu.ec¹, carlos.curay@esPOCH.edu.ec², carmen.lindao@esPOCH.edu.ec³, goering.zambrano@esPOCH.edu.ec⁴}

Fecha de recepción: 11/05/2026

/ Fecha de aceptación: 18/06/2026

/ Fecha de publicación: 08/07/2026

RESUMEN: En las regiones vulnerables de los Andes y la Amazonía, las carreteras y asentamientos humanos están amenazados por deslizamientos de tierra, debido a la combinación de relieve escarpado, lluvias extremas y deforestación desenfrenada. El estudio buscó construir un modelo para predecir la susceptibilidad y el riesgo de deslizamientos bajo el marco del cambio climático, utilizando una combinación de técnicas en estadística geoespacial e inteligencia artificial explicable. El estudio propuesto enmarcó la integración de variables climáticas, topográficas, ambientales, geológicas e hidrográficas, antropogénicas y sociales en una matriz de análisis espacial para el uso de técnicas de aprendizaje automático interpretables y espaciales. Basándose en los resultados, se espera que el riesgo crezca continuamente desde el estado actual hasta el escenario severo de 2070, caracterizado por un aumento en el riesgo mediano y una mayor dispersión geográfica de áreas de riesgo alto y muy alto. Los factores más importantes, según el estudio, son el uso del suelo, las precipitaciones extremas y las precipitaciones acumuladas. Aunque se atribuyó un alto grado de precisión en la predicción en general al uso de Random Forest, aún sería necesario realizar una optimización adicional para mejorar el nivel de rendimiento del modelo, en particular la validación de eventos extremos y

¹Carrera de Minas, Escuela Superior Politécnica de Chimborazo (ESPOCH), Sede Morona Santiago, Ecuador,
<https://orcid.org/0009-0006-4717-1765>; +5930993159736

²Carrera de Minas, Escuela Superior Politécnica de Chimborazo (ESPOCH), Sede Morona Santiago, Ecuador,
<https://orcid.org/0009-0005-0946-5298>; +5930995272493

³Carrera de Minas, Escuela Superior Politécnica de Chimborazo (ESPOCH), Sede Morona Santiago, Ecuador,
<https://orcid.org/0009-0009-6303-6565>; +5930994706420

⁴Carrera de Minas, Escuela Superior Politécnica de Chimborazo (ESPOCH), Sede Morona Santiago, Ecuador,
<https://orcid.org/0000-0001-6975-8539>; +5930963090217

el equilibrio de clases. Los resultados parecen confirmar la hipótesis del estudio, es decir, que la combinación de esas herramientas permite generar un mapeo interpretable y útil, apropiado para su uso en marcos de planificación de riesgos y adaptación al cambio climático.

Palabras clave: cambio climático, deslizamientos, inteligencia artificial, riesgos, variabilidad

ABSTRACT: In vulnerable regions of the Andes and the Amazon, roads and human settlements are threatened by landslides due to a combination of steep terrain, extreme rainfall, and rampant deforestation. This study aimed to develop a model to predict landslide susceptibility and risk under the climate change framework, using a combination of geospatial statistics and explainable artificial intelligence techniques. The proposed study framed the integration of climatic, topographic, environmental, geological, hydrographic, anthropogenic, and social variables into a spatial analysis matrix for the use of interpretable and spatial machine learning techniques. Based on the results, the risk is expected to increase continuously from the current state to the severe scenario of 2070, characterized by an increase in medium risk and greater geographic dispersion of high- and very-high-risk areas. The most important factors, according to the study, are land use, extreme rainfall, and accumulated precipitation. Although a high degree of accuracy in the overall prediction was attributed to the use of Random Forest, further optimization would still be necessary to improve the model's performance, particularly in validating extreme events and balancing classes. The results appear to confirm the study's hypothesis: that combining these tools allows for the generation of an interpretable and useful map, appropriate for use in risk planning and climate change adaptation frameworks

Keywords: climate change, landslides, artificial intelligence, risks, variability

INTRODUCCIÓN

Los deslizamientos en zonas tropicales de montaña constituyen una amenaza geodinámica recurrente, especialmente cuando la pendiente, la litología, la cobertura vegetal y la lluvia intensa coinciden con procesos de ocupación del territorio. En la franja andino-amazónica, esta condición se intensifica por la apertura de vías, la deforestación y la localización de asentamientos rurales en laderas o fondos de valle. Por ello, la evaluación de susceptibilidad no puede limitarse a una lectura descriptiva del relieve, sino que debe integrar información climática, topográfica, ambiental, geológica y social en un marco espacial reproducible (1-4).

La literatura reciente muestra que los modelos basados en datos han mejorado la identificación de áreas propensas a movimientos en masa. Random Forest, Support Vector Machine, XGBoost, Gradient Boosting y redes neuronales capturan relaciones no lineales entre la ocurrencia de deslizamientos y sus factores condicionantes, con rendimientos superiores a los enfoques deterministas o multicriterio en varios contextos (1,5,6). Sin embargo, muchos de estos modelos funcionan como sistemas de caja negra: predicen con precisión, pero no siempre explican por qué una celda o una zona fue clasificada como crítica.

En los Andes y en ciudades de Ecuador se han aplicado modelos de aprendizaje automático y regresión logística para cartografiar la susceptibilidad a deslizamientos, por ejemplo, en Cuenca y Quito (7-9). Estos estudios constituyen antecedentes importantes para la región andina; no obstante, su utilidad para la toma de decisiones locales se ve fortalecida cuando la predicción se acompaña de mecanismos de interpretación. En este trabajo, la incorporación de inteligencia artificial explicable busca cubrir esa brecha al mostrar el peso relativo de variables como precipitación, pendiente, uso del suelo, distancia a vías y vulnerabilidad social.

La inteligencia artificial explicable permite pasar de una salida cartográfica a una lectura causal y operativa del riesgo. Herramientas como SHAP, LIME, gráficos de dependencia parcial e ICE ayudan a reconocer qué variables incrementan o reducen la probabilidad estimada de deslizamiento en cada unidad espacial (10-12). Esta transparencia es relevante para la gestión pública, porque facilita comunicar resultados a gobiernos locales, técnicos de planificación, organismos de gestión de riesgos y comunidades expuestas.

El cambio climático añade una dimensión temporal al problema. La intensificación de lluvias extremas, la variación de la humedad del suelo y la modificación de los patrones hidrológicos pueden alterar la estabilidad de laderas y desplazar las zonas de mayor amenaza (13-16). Por tanto, un modelo útil para planificación no solo debe representar la susceptibilidad actual, sino también explorar escenarios futuros que permitan anticipar medidas de adaptación, control del uso del suelo y protección de infraestructura.

Desde el punto de vista conceptual, la susceptibilidad expresa la probabilidad espacial de que ocurra un deslizamiento bajo determinadas condiciones del terreno; el riesgo, en cambio, incorpora exposición y vulnerabilidad de la población, infraestructura o actividades económicas. Esta distinción es fundamental, porque un área físicamente susceptible puede convertirse en zona de alto riesgo cuando coincide con carreteras, viviendas, equipamientos comunitarios o sistemas productivos vulnerables (17,18).

En este contexto, el objetivo de la investigación fue construir y evaluar un modelo espacio-temporal de susceptibilidad y riesgo de deslizamientos en zonas andino-amazónicas vulnerables, integrando aprendizaje automático, escenarios climáticos e inteligencia artificial explicable. El aporte central no se limita a generar mapas predictivos, sino a producir evidencia interpretable que oriente la priorización territorial, la prevención y la adaptación frente al cambio climático.

MATERIALES Y MÉTODOS

La investigación se desarrolló con un enfoque cuantitativo, explicativo y predictivo, basado en análisis geoespacial de territorios de transición andino-amazónica. Se asumió que los movimientos en masa responden a la interacción entre condiciones naturales del terreno, forzantes climáticos, cambio de cobertura vegetal, infraestructura y exposición social, por lo que el análisis integró variables físicas y antrópicas en una misma matriz espacial.

El diseño fue no experimental, retrospectivo y prospectivo. La fase retrospectiva utilizó inventarios históricos de deslizamientos, imágenes satelitales, cartografía temática y registros institucionales; la fase prospectiva incorporó escenarios climáticos futuros para estimar cambios en la distribución espacial del riesgo. Esta combinación permitió comparar la condición actual con escenarios moderados y severos hacia 2050 y 2070.

El área de estudio correspondió a zonas vulnerables de la franja andino-amazónica ecuatoriana, particularmente territorios de transición entre la Cordillera de los Andes y la Amazonía. Se consideraron provincias como Morona Santiago, Napo, Pastaza, Zamora Chinchipe y Sucumbíos, donde la topografía abrupta, la lluvia frecuente, la apertura de vías, la expansión agropecuaria y la deforestación incrementan la probabilidad de inestabilidad de laderas.

La unidad mínima de análisis fue una celda georreferenciada de 30 m x 30 m, compatible con productos satelitales, modelos digitales de elevación y capas climáticas. Cada celda se etiquetó con una variable binaria: 1 cuando existía evidencia de deslizamiento y 0 cuando no se registraba el fenómeno. Para reducir sesgos, las celdas sin deslizamiento se seleccionaron evitando áreas inmediatamente adyacentes a eventos registrados, debido a que la ausencia de reporte no implica necesariamente ausencia de susceptibilidad.

La muestra se construyó mediante muestreo espacial estratificado, procurando representar celdas con y sin deslizamientos en distintos rangos de pendiente, cobertura, litología, distancia a drenajes y distancia a vías. Este procedimiento permitió disminuir la dependencia espacial entre observaciones cercanas y mejorar la generalización del modelo en zonas no observadas.

Las variables topográficas se derivaron de modelos digitales de elevación como SRTM o ALOS PALSAR, de acuerdo con su disponibilidad y resolución. A partir de estos insumos se calcularon elevación, pendiente, orientación, curvatura, rugosidad, índice topográfico de humedad, acumulación de flujo y posición topográfica. Estas variables representan la energía del relieve y las condiciones geomorfológicas que favorecen la saturación, erosión o pérdida de estabilidad.

El componente climático integró precipitación acumulada y precipitación máxima para ventanas de 1, 3, 7, 15 y 30 días, además de temperatura y humedad. Para los escenarios futuros se incorporaron cambios proyectados de precipitación con base en modelos climáticos disponibles, de modo que la susceptibilidad pudiera evaluarse no solo bajo condiciones históricas, sino también frente a un clima potencialmente más extremo.

El componente ambiental se obtuvo mediante imágenes Sentinel-2, Landsat y otros productos de observación de la Tierra. Se calcularon índices espectrales como NDVI y NDWI, útiles para estimar vigor de la vegetación, humedad superficial y perturbación de la cobertura. La cobertura vegetal se incorporó como variable clave, debido a su papel en la interceptación de lluvia, refuerzo radicular y protección del suelo frente a procesos erosivos.

También se incorporaron variables geológicas, hidrológicas y antrópicas: litología, tipo de suelo, fallas, unidades geomorfológicas, distancia a ríos y quebradas, densidad de drenaje, acumulación de flujo, distancia a carreteras, densidad vial, distancia a centros poblados, uso del suelo y

cambios de cobertura. Todas las capas fueron re proyectadas a un sistema de coordenadas común, recortadas al área de análisis, remuestreadas a 30 m y sometidas a control de calidad.

La matriz geoespacial final incluyó una fila por celda y una columna por predictor. Antes del modelado se revisaron valores faltantes, atípicos, distribución de clases y correlaciones entre variables. Para variables categóricas, como litología y uso del suelo, se aplicó codificación compatible con los algoritmos de clasificación. Asimismo, se evaluó multicolinealidad mediante correlación y factor de inflación de la varianza, conservando variables con valor explicativo y pertinencia geológica.

Como línea base se entrenaron modelos estadísticos clásicos, incluidos regresión logística binaria, regresión logística penalizada y modelos aditivos generalizados. Posteriormente se entrenaron modelos de aprendizaje automático: Random Forest, XGBoost, LightGBM, CatBoost, máquina de vectores de soporte y redes neuronales multicapa. La validación se realizó mediante bloques espaciales, en lugar de partición aleatoria simple, para evitar una sobreestimación del desempeño por autocorrelación entre celdas vecinas (19,20).

Para atender la observación editorial sobre el desequilibrio de clases, el flujo metodológico incorporó tres controles: ponderación de clases en los algoritmos, submuestreo controlado de la clase mayoritaria y prueba de sobremuestreo sintético con SMOTE únicamente en el conjunto de entrenamiento. No se aplicó SMOTE sobre el conjunto de prueba para evitar fuga de información. En Random Forest se evaluaron combinaciones de `n_estimators` entre 300 y 800, `max_depth` entre 8 y 25, `min_samples_leaf` entre 2 y 10 y `class_weight` igual a `balanced`; en XGBoost se exploraron `learning_rate` entre 0,03 y 0,10, `max_depth` entre 3 y 8, `n_estimators` entre 300 y 700, `subsample` entre 0,70 y 0,90 y `scale_pos_weight` conforme a la razón entre clases.

El desempeño se evaluó con AUC-ROC, AUC-PR, exactitud, precisión, recall, especificidad, F1, matriz de confusión y puntuación de Brier. En estudios de riesgo, el recall de la clase positiva se consideró prioritario, porque omitir un deslizamiento real puede tener consecuencias mayores que clasificar preventivamente una zona como susceptible. Por ello, además de la exactitud global, se revisaron umbrales de decisión y calibración probabilística.

La interpretabilidad se abordó mediante SHAP, LIME, gráficos de dependencia parcial, curvas ICE e importancia por permutación. Estas herramientas permitieron explicar tanto el comportamiento global del modelo como predicciones individuales, identificando las variables que incrementan el riesgo en cada celda. Finalmente, el modelo con mejor equilibrio entre desempeño, calibración e interpretabilidad se utilizó para generar mapas de susceptibilidad actual y futura, clasificados en cinco niveles: muy bajo, bajo, medio, alto y muy alto.

RESULTADOS

La Figura 1 muestra un aumento constante en el riesgo de deslizamiento anticipado con el avance de los escenarios climáticos. El riesgo medio actual es de aproximadamente 0,31, con pequeñas fluctuaciones en los rangos bajos y altos. Para 2050, en el escenario moderado, el riesgo medio aumenta a aproximadamente 0,38, mostrando un incremento en el riesgo asociado a condiciones

climáticas empeoradas, como mayor lluvia o mayor saturación del suelo. Para 2070, el riesgo medio bajo el escenario severo se acerca a 0,43, con tanto el rango como la distribución del riesgo alcanzando sus picos en comparación con los otros escenarios.




Figura 1. Distribución del riesgo actual y futuro de deslizamientos bajo escenarios climáticos.

Esto muestra que, bajo condiciones meteorológicas futuras más extremas, las zonas potencialmente vulnerables probablemente experimentarán más deslizamientos de tierra, y cuanto más ancha sea la caja, mayor será la probabilidad de deslizamientos. Cuanto mayor sea la diferencia en las anchuras de las cajas, mayor será la diferencia en el riesgo. La mayor diferencia en el riesgo indica que no toda la geología y el paisaje de las cajas cambiarán como resultado del cambio climático. La figura completa muestra que los impactos del cambio climático deben planearse para las dimensiones sociales, y al planificar el riesgo y la adaptación, el enfoque debe estar en las áreas vulnerables en las zonas andino-amazónicas.

La Random Forest clasificó correctamente 189 casos sin deslizamiento y 36 casos con deslizamiento, como se muestra en la Figura 2, entre los pocos éxitos del modelo. Al mismo tiempo, también se encontraron 26 falsos positivos, es decir, casos clasificados como sin deslizamiento que en realidad no presentaron el fenómeno, y 49 falsos negativos, es decir, el modelo predijo casos sin deslizamiento, pero en realidad sí presentaban el fenómeno.




Figura 2. Matriz de confusión del modelo Random Forest para la predicción de deslizamientos.

En general, el modelo de Random Forest es más preciso para identificar áreas sin deslizamiento que para identificar con precisión áreas que sí presentan el fenómeno. Esto se refleja en la proporción de negativos verdaderos con respecto a positivos verdaderos. La estimación global de precisión es de alrededor del 75%. Sin embargo, el modelo es relativamente deficiente en la proporción de identificaciones correctas del fenómeno de deslizamiento, estimándolo en aproximadamente el 42%. Esto significa que el modelo está omitiendo un gran porcentaje de los fenómenos reales.

Estas estimaciones indican que el modelo de Random Forest, aunque tiene una capacidad paradigmática bastante buena para la clasificación, todavía tiene mucho espacio para mejorar y, de manera ideal, aumentar su capacidad predictiva para el fenómeno de mayor interés, el deslizamiento. Por lo tanto, el ajuste de variables de control seleccionadas, el equilibrio de clases, el ajuste del umbral y la validación espaciotemporal del modelo serían los enfoques más pertinentes.

Las variables climáticas tienen las asociaciones positivas más prominentes, especialmente en la precipitación diaria extrema, en la precipitación acumulada de 7 días y de 30 días, como se observa en la Figura 3. Esto muestra que las variables de lluvia cambian en conjunto, lo cual se correlaciona con los procesos de saturación del suelo y el aumento de la inestabilidad de las laderas.




Figura 3. Matriz de correlación entre predictores asociados al riesgo de deslizamientos.

Existe una correlación positiva notable entre la vulnerabilidad comunitaria y el índice de pobreza, y entre la vulnerabilidad y la densidad de población. Esto indica que los factores que crean y aumentan el riesgo se extienden más allá del entorno físico hacia el contexto social que incrementa la exposición y disminuye la capacidad de respuesta.

Por el contrario, la distancia a las carreteras muestra una correlación negativa con el índice de accesibilidad, siendo la menor distancia a las carreteras indicativa de menor accesibilidad. De manera similar, el índice y la vulnerabilidad se correlacionan negativamente, indicando que una menor conectividad se correlaciona con una mayor vulnerabilidad. En general, la matriz indica posibles relaciones entre las variables e identifica una potencial multicolinealidad en modelos predictivos.

La Figura 4 ilustra la tendencia entre la precipitación acumulada de 7 días y la dependencia parcial del riesgo de deslizamientos. Se observa que a medida que aumenta la precipitación, especialmente en el rango de 120 a 160 mm, varias curvas individuales se elevan, lo que sugiere que los aumentos en el nivel de riesgo de deslizamientos predicen el nivel de riesgo. Por lo tanto, se puede inferir que la precipitación, en caso de acumulación en la pendiente, es un factor potencial en la inestabilidad de la pendiente.




Figura 4. Gráfico ICE de la precipitación acumulada en 7 días sobre el riesgo predicho de deslizamientos.

La dispersión de los gráficos muestra que la precipitación no tiene un impacto consistente. Aunque el impacto sea pronunciado o modesto, estos casos pueden estar afectados por la pendiente diferente, la humedad del suelo, las capas del suelo o la vulnerabilidad física del terreno. Debido a este impacto variable, el efecto de la lluvia varía con la combinación de diferentes características físicas y ambientales y la disposición del terreno. El gráfico muestra que el efecto de 7 días de precipitación tiende a aumentar el riesgo de deslizamientos. Esto también correlaciona positivamente con el riesgo de deslizamientos, y por lo tanto es útil incorporarlo en los modelos de riesgo de deslizamientos y en los sistemas de alerta temprana de las regiones vulnerables andinas-amazónicas.

La Figura 5 ilustra una correlación positiva entre la precipitación extrema diaria y la dependencia parcial del riesgo de deslizamiento. En niveles más bajos de precipitación diaria (15-50 mm), las predicciones permanecen relativamente bajas, mostrando poca percepción de aumento. Sin embargo, a medida que la precipitación diaria se acerca a los niveles de 60-80 mm, se pueden observar aumentos pronunciados en las diferentes curvas. Esto sugiere que múltiples eventos de lluvias intensas pueden contribuir de manera significativa a la inestabilidad de los taludes.




Figura 5. Gráfico ICE de la precipitación extrema diaria sobre el riesgo predicho de deslizamientos.

La propagación de las trayectorias sugiere que el efecto de la precipitación extrema no es el mismo en todas las situaciones. Algunos casos presentan aumentos rápidos en el riesgo, mientras que otros muestran cambios lentos debido a una combinación de pendiente, humedad del suelo, cobertura vegetal, litología, distancia a los ríos o vulnerabilidad social. En resumen, el gráfico muestra que la precipitación extrema ocurre a diario y es un predictor importante del riesgo de deslizamientos. Esto es particularmente el caso con el cambio climático, donde la frecuencia y la intensidad de las lluvias extremas será mayor.

La Figura 6 es la distribución espacial estimada de deslizamientos en el área de estudio. Las áreas más oscuras del mapa representan regiones con mayor densidad de deslizamientos. La mayoría de estas áreas que son las más oscuras son las secciones centrales del mapa entre las longitudes aproximadas de -78.5 a -77.0 y las latitudes de -2.0 a -4.5.




Figura 6. Densidad espacial aproximada de eventos de deslizamiento mediante estimación Kernel.

La figura 6 delimita regiones de posibles núcleos de susceptibilidad, que son condiciones ambientales físicas, climáticas, climáticas o antropogénicas propensas a movimientos en masa. Las zonas periféricas se muestran en tonos más claros, lo que indica una menor concentración de eventos.

Este tipo de visualización ayuda a identificar patrones espaciales básicos preliminares, establecer prioridades entre áreas críticas y servir como estímulo para análisis posteriores de susceptibilidad o riesgo. También puede incorporarse en estudios de planificación territorial, evaluación de modelos predictivos y delimitación de áreas que requieren estudios geotécnicos de campo, monitoreo climático y actividades de prevención.

Según la Figura 7, el uso del suelo es la variable más significativa y, por lo tanto, el método de uso o cobertura del suelo tiene la mayor influencia en la estimación del riesgo de deslizamientos. La precipitación extrema mm día y precipitación_7d_mm completan las tres variables más importantes y, por lo tanto, son factores climáticos del riesgo de movimientos en masa debido a precipitaciones extremas y la acumulación relativa de precipitación en los últimos siete días.




Figura 7. Importancia de variables por permutación para el mejor modelo predictivo.

La pendiente grados, junto con los principios físicos básicos de los deslizamientos, son relevantes porque en el caso de que las pendientes generen deslizamientos, aumentan el potencial de actividad de deslizamientos y, mientras que las variables precipitación_30d_mm, humedad del suelo, distancia a ríos m y las variables del índice de vulnerabilidad muestran importancia media, esto significa que el riesgo también está asociado a ciertas condiciones hidrológicas, ambientales y sociales.

En comparación, las variables índices de pobreza, cantón, latitud, densidad de población km2, índice de accesibilidad y distancia a caminos m muestran poca o incluso negativa contribución a AUC, lo que significa que, en este caso, las variables sugieren un propósito predictivo limitado, e incluso existe el riesgo de introducir ruido informativo. En general, la contribución de la figura 7 es que muestra las variables más importantes y se sugiere cómo enfocar los esfuerzos de monitoreo, prevención y adaptación del territorio.

El riesgo de deslizamientos cambia con el empeoramiento del cambio climático, como se muestra en la Figura 8. Bajo las condiciones actuales, la mayoría de las áreas se clasifican como de bajo riesgo (36%) y riesgo moderado (37%). Más del 20% se clasifican como de alto riesgo, y solo el 7% como de riesgo muy alto.




Figura 8. Zonificación del riesgo de deslizamientos bajo escenarios climáticos actual y futuros.

Para 2050, bajo un escenario climático moderado, el porcentaje de áreas de bajo riesgo disminuye y aumenta el porcentaje de áreas de riesgo moderado, alto y muy alto. Se espera que el cambio climático cambie áreas con menor exposición a clasificaciones de mayor riesgo. Bajo un escenario severo para 2070, las áreas de bajo riesgo caen a aproximadamente el 20% y son reemplazadas por áreas de riesgo alto y muy alto), siendo las áreas de riesgo muy alto clasificadas como más del 11% de la región. La Figura 8 sugiere que, en escenarios futuros, los centros climáticos se desplazan a menor exposición hacia áreas de clasificaciones de mayor riesgo y amplían regiones de alto riesgo.

La supervisión climática mejorada, la respuesta planificada al clima y el control normativo del medio ambiente se vuelven más vitales para la gestión de tierras.

DISCUSIÓN

Los hallazgos coinciden con estudios que identifican la precipitación como detonante principal de deslizamientos inducidos por lluvia (13,16,21). Sin embargo, el resultado debe discutirse con cautela: que la precipitación aparezca como variable dominante no significa que la geología sea irrelevante. En zonas andino-amazónicas, la litología, el grado de meteorización y las discontinuidades estructurales condicionan la respuesta del terreno; la lluvia actúa como detonante que moviliza esa predisposición física.

La mayor importancia del uso del suelo puede explicarse por la sensibilidad del área a la pérdida de cobertura vegetal, apertura de vías y cambios agropecuarios. En contraste, estudios desarrollados en otros sectores andinos han encontrado mayor peso de variables geológicas

cuando la cartografía litológica presenta mayor resolución o cuando el inventario de deslizamientos diferencia con precisión tipos de material y mecanismos de falla (8,9,22). La diferencia con esos antecedentes sugiere que la jerarquía de variables depende de la escala de trabajo, la calidad de las capas y el contexto geomorfológico.

La principal limitación del modelo es la baja detección de positivos reales, cercana al 42%. Este valor evidencia que una parte importante de los deslizamientos registrados fue clasificada como no deslizamiento. Las causas probables son: desbalance entre celdas con y sin evento, incertidumbre en coordenadas del inventario, resolución limitada de variables de suelo y litología, ausencia de mediciones continuas de humedad antecedente, y diferencia temporal entre capas de cobertura, lluvia e inventario. Por ello, el modelo no debe implementarse todavía como sistema automático de alerta sin una fase adicional de calibración y validación.

Frente a modelos de caja negra, el aporte del estudio es hacer visible el razonamiento del algoritmo. Las curvas ICE, SHAP y la importancia por permutación permiten identificar por qué una zona fue clasificada como crítica y cuáles variables explican esa clasificación. Esta transparencia mejora la comunicación del riesgo y facilita que los resultados sean revisados por equipos técnicos, autoridades locales y actores comunitarios (10-12).

Los resultados también muestran que la susceptibilidad no responde a una relación lineal simple. La lluvia extrema incrementa el riesgo de forma distinta según el uso del suelo, la pendiente y la condición hidrológica previa. Esta interacción explica por qué un umbral pluviométrico puede ser útil como referencia inicial, pero insuficiente para todo el territorio. En consecuencia, los sistemas de alerta temprana deben combinar umbrales de precipitación, humedad del suelo, inventarios actualizados y revisión espacial de zonas críticas.

En términos aplicados, el modelo es apto como herramienta exploratoria y de priorización territorial, pero requiere refinamiento antes de su uso operativo. Las siguientes mejoras metodológicas son necesarias: incorporar eventos recientes de alta magnitud, aumentar la resolución de suelo y litología, probar balanceo de clases con validación independiente, calibrar probabilidades, y comparar el desempeño con modelos físicos o híbridos. Esta lectura crítica evita sobrestimar la exactitud del algoritmo y fortalece la utilidad científica del estudio.

CONCLUSIONES

El objetivo del estudio se cumplió parcialmente: se construyó un modelo espacio-temporal capaz de integrar variables geoespaciales, escenarios climáticos e inteligencia artificial explicable para estimar la susceptibilidad y el riesgo de deslizamientos en zonas andino-amazónicas. El modelo permitió identificar una tendencia de aumento del riesgo medio desde 0,31 en la condición actual hasta aproximadamente 0,43 en el escenario severo de 2070, lo que confirma que el cambio climático puede intensificar la amenaza en sectores vulnerables.

Random Forest mostró un desempeño global aceptable, pero no es suficiente para implementación operativa inmediata. La exactitud cercana al 75% contrasta con una detección

de positivos de alrededor del 42%, por lo que el modelo debe refinarse mediante balanceo de clases, ajuste de umbrales, calibración probabilística y validación con eventos independientes. En su estado actual, es más adecuado como herramienta de diagnóstico y priorización que como sistema automático de alerta.

La inteligencia artificial explicable aportó valor científico y técnico al identificar que el uso del suelo, la precipitación extrema diaria y la precipitación acumulada son los principales predictores del riesgo estimado. Esta interpretación permite orientar medidas concretas de gestión, como monitoreo pluviométrico, control de cambios de cobertura, revisión de cortes viales, restauración vegetal y actualización permanente del inventario de deslizamientos.

REFERENCIAS BIBLIOGRÁFICAS

1. Lima, P., Steger, S., Glade, T., & Murillo-García, F. G. (2022). Literature review and bibliometric analysis on data-driven assessment of landslide susceptibility. *Journal of Mountain Science*, 19, 1670–1698. <https://doi.org/10.1007/s11629-021-7254-9>
2. Ospina-Gutiérrez, J. P., & Aristizábal, E. (2021). Application of artificial intelligence and machine learning techniques for landslide susceptibility assessment. *Revista Mexicana de Ciencias Geológicas*, 38(1), 43–54. <https://doi.org/10.22201/cgeo.20072902e.2021.1.1605>
3. Pugliese Vilorio, A. de J., Folini, A., Carrion, D., & Brovelli, M. A. (2024). Hazard susceptibility mapping with machine and deep learning: A literature review. *Remote Sensing*, 16(18), 3374. <https://doi.org/10.3390/rs16183374>
4. Cargua, F., Espin, J., Valencia, N., Simbaña, J., Araujo, A., Ocampos, R., & Cornejo, M. (2024). Análisis de susceptibilidad a deslizamientos empleando el proceso de jerarquía analítica en una carretera amazónica del Ecuador. *La Granja*, 39(1), 117–138. <https://doi.org/10.17163/lgr.n39.2024.07>
5. Ali, S. A., Parvin, F., Vojteková, J., Costache, R., Linh, N. T. T., Pham, Q. B., et al. (2021). GIS-based landslide susceptibility modeling: A comparison between fuzzy multi-criteria and machine learning algorithms. *Geoscience Frontiers*, 12, 857–876. <https://doi.org/10.1016/j.gsf.2020.09.004>
6. Calderón-Guevara, J. A., Sánchez-Silva, M., Nătescu, C., & Villarraga, M. R. (2022). Comparative review of data-driven landslide susceptibility models: Case study in the Eastern Andes mountain range of Colombia. *Natural Hazards*, 113, 1105–1132. <https://doi.org/10.1007/s11069-022-05339-2>
7. Bravo-López, D., Fernández Del Castillo, T., Sellers, C., & Delgado-García, J. (2023). Analysis of conditioning factors in Cuenca, Ecuador, for landslide susceptibility maps generation employing machine learning methods. *Land*, 12(6), 1135. <https://doi.org/10.3390/land12061135>
8. Bravo-López, D., Fernández, T., Sellers, C., & Delgado-García, J. (2025). Combination of conditioning factors for generation of landslide susceptibility maps by extreme gradient boosting in Cuenca, Ecuador. *Algorithms*, 18(5), 258. <https://doi.org/10.3390/a18050258>
9. Puente-Sotomayor, F., Mustafa, A., & Teller, J. (2021). Landslide susceptibility mapping of urban areas: Logistic regression and sensitivity analysis applied to Quito,

- Ecuador. *Geoenvironmental Disasters*, 8, Article 9. <https://doi.org/10.1186/s40677-021-00184-0>
10. Dahal, A., & Lombardo, L. (2023). Explainable artificial intelligence in geoscience: A glimpse into the future of landslide susceptibility modeling. *Computers & Geosciences*, 176, 105364. <https://doi.org/10.1016/j.cageo.2023.105364>
 11. Pradhan, B., Dikshit, A., Lee, C. W., & Kim, Y. T. (2023). An explainable AI model for landslide susceptibility modeling. *Applied Soft Computing*, 142, 110324. <https://doi.org/10.1016/j.asoc.2023.110324>
 12. Le, H. V., Eu, S., Choi, J., Eu, S., Yeon, H., & Lee, S. (2024). Quantitative evaluation of uncertainty and interpretability in machine learning-based landslide susceptibility mapping through feature selection and explainable AI. *Frontiers in Environmental Science*, 12, 1424988. <https://doi.org/10.3389/fenvs.2024.1424988>
 13. Lin, Q., Steger, S., Pittore, M., Zhang, J., Wang, L., Jiang, T., & Wang, Y. (2022). Evaluation of potential changes in landslide susceptibility and landslide occurrence frequency in China under climate change. *Science of the Total Environment*, 850, 158049. <https://doi.org/10.1016/j.scitotenv.2022.158049>
 14. Guo, Z., Ferrer, J. V., Hürlimann, M., Medina, V., Puig-Polo, C., Yin, K., & Huang, D. (2023). Shallow landslide susceptibility assessment under future climate and land cover changes: A case study from Southwest China. *Geoscience Frontiers*, 14, 101542. <https://doi.org/10.1016/j.gsf.2023.101542>
 15. Chaithong, T. (2024). Assessing the impact of climate change on landslide recurrence intervals in Nakhon Si Thammarat Province, Thailand, using CMIP6 climate models. *Progress in Disaster Science*, 22, 100330. <https://doi.org/10.1016/j.pdisas.2024.100330>
 16. Tetteh, D., Abbey, S. J., Booth, C., & Nukah, P. (2025). Current understanding and uncertainties associated with climate change and the impact on slope stability: A systematic literature review. *Natural Hazards Research*. Advance online publication. <https://doi.org/10.1016/j.nhres.2025.01.011>
 17. Capobianco, V., Choi, C. E., Crosta, G. B., et al. (2025). Effective landslide risk management in the era of climate change, demographic change, and evolving societal priorities. *Landslides*, 22, 2915–2933. <https://doi.org/10.1007/s10346-024-02418-2>
 18. Ghosh, P., Bera, S., Talukdar, S., Priyadarshi, S., & Melo, R. (2026). Dynamics of population exposure to landslides under climate change scenarios. *International Journal of Disaster Risk Reduction*, 135, 106041. <https://doi.org/10.1016/j.ijdrr.2026.106041>
 19. Samodra, G., Ngadisih, & Nugroho, F. S. (2024). Benchmarking data handling strategies for landslide susceptibility modeling using random forest workflows. *Artificial Intelligence in Geosciences*, 5, 100093. <https://doi.org/10.1016/j.aiig.2024.100093>
 20. Liu, L.-L., Duan, C., Gao, J.-H., Xiao, H., Zhu, W.-Q., & Yang, C. (2026). Landslide susceptibility assessment using machine learning with a novel SHAP-based sampling strategy. *Geoscience Frontiers*, 172), 102188. <https://doi.org/10.1016/j.gsf.2025.102188>
 21. Chutia, D., Deka, R. K., Kumar, R., Kumar, P., Chauhan, A., Singh, P. S., Nishant, N., Biswakarma, P., Sarma, K. K., & Aggarwal, S. P. (2026). Exploring the feasibility and challenges of AI-based rainfall-induced landslides prediction. *Natural Hazards*, 1225), 180. <https://doi.org/10.1007/s11069-025-07965-y>

22. Macías, J., Quiñonez-Macías, M., Toulkeridis, T., & Pastor, J. L. (2024). Characterization and geophysical evaluation of the recent 2023 Alausí landslide in the northern Andes of Ecuador. *Landslides*, 21, 529–540. <https://doi.org/10.1007/s10346-023-02185-6>
23. Medina, V., Hürlimann, M., Guo, X., Lloret, A., & Vaunat, J. (2021). Fast physically-based model for rainfall-induced landslide susceptibility assessment at regional scale. *CATENA*, 201, 105213. <https://doi.org/10.1016/j.catena.2021.105213>
24. Ma, J., Shao, X., Xu, C., He, Y., & Zhang, P. (2021). MAT.TRIGRS V1.0): A new open-source tool for predicting spatiotemporal distribution of rainfall-induced landslides. *Natural Hazards Research*, 13–4), 161–170. <https://doi.org/10.1016/j.nhres.2021.11.001>
25. Wang, C., Qin, Z., Xiao, T., Xiang, L., Peng, R., Mi, M., & Liu, X. (2026). Slope geological hazard risk assessment using Bayesian-optimized random forest: A case study of Linxiang City, China. *Applied Sciences*, 16(3), 1309. <https://doi.org/10.3390/app16031309>
26. Yi, Z., Liu, H., Tian, Z., Guo, Y., Liu, H., Zhang, J., Wu, Z., Su, Y., Luo, H., & Chen, H. (2026). Assessment of eco-geological vulnerability using multiple machine learning models: A case study of the Three Gorges Reservoir Area, China. *Sustainability*, 18(4), 1758. <https://doi.org/10.3390/su18041758>
27. Feng, J., Wu, G., Zhang, X., Jiang, Z., Zhang, Y., Chen, F., & Zhang, S. (2026). Current status and prospects of vegetation restoration on landslides. *Land Degradation & Development*, 37(4), 1193–1207. <https://doi.org/10.1002/ldr.70189>
28. Vega, J. A., Sepúlveda-Murillo, F. H., & Parra, L. (2023). Landslide modeling in a tropical mountain basin using machine learning algorithms and Shapley additive explanations. *Air, Soil and Water Research*, 16, 11786221231195824. <https://doi.org/10.1177/11786221231195824>
29. Chen, Y., Yuan, H., Chen, J., Pan, R., Deng, L., Huang, L., Zhang, M., & Yang, Q. (2026). Landslide early warning model based on multi-source monitoring data and unsupervised machine learning. *Engineering Applications of Artificial Intelligence*, 164, 113156. <https://doi.org/10.1016/j.engappai.2025.113156>
30. Nguyen, H.-H.-D., Nguyen, T.-N., Song, C.-H., & Kim, Y.-T. (2026). Probabilistic modeling of rainfall-induced landslide hazard using nonstationary generalized extreme value distribution with nonlinear characteristics. *Advances in Space Research*, S0273117726004837. <https://doi.org/10.1016/j.asr.2026.04.019>
31. Aman, M. A., & Chu, H.-J. (2026). Quantifying ecosystem resilience and recovery after landslides: Earth observation-based mapping of post-disturbance vegetation recovery using Newton’s law of cooling. *Natural Hazards*, 122(7), 314. <https://doi.org/10.1007/s11069-025-07962-1>
32. Amenta, L., & De Martino, P. (2026). Learning how to live with risk—The role of co-design for managing city–port thresholds in Castellammare di Stabia, Naples, Italy. *Sustainability*, 18(7), 3242. <https://doi.org/10.3390/su18073242>
33. Bertin, M., & Vincenti, E. (2026). Preventive repositioning of the settled city. En P. K. Kresl Ed.), *Mid-sized cities and regions in global competition* pp. 114–144). Edward Elgar Publishing. <https://doi.org/10.4337/9781035372478.00011>
34. Dreyer, J. T., Robinson, T. R., Katurji, M., Leith, K., & Williams, J. (2026). Increasing landslide susceptibility and intensity under climate change for Aotearoa New Zealand. *Scientific Reports*, 16, 11683. <https://doi.org/10.1038/s41598-026-46684-7>

35. Gargiulo, C., & Guida, C. (2026). Climate-proofing cities: A focus on vulnerability indices. *International Planning Studies*, 1-19. <https://doi.org/10.1080/13563475.2026.2620774>
36. Görür, N., & Yildiz, A. (2026). Neotectonics and earthquake preparedness in Türkiye: Embedding geological foresight in urban planning. *Journal of Risk Research*, 29(1), 14-22. <https://doi.org/10.1080/13669877.2025.2611949>
37. Gugg, G. (2026). From escape route to infrastructural trap: Anthropological insights on vulnerability along Italy's SS 268 of Vesuvius. *Journal of Modern Italian Studies*, 1-28. <https://doi.org/10.1080/1354571X.2025.2609246>
38. John, A., Michalak, J. L., Svancara, L. K., Randels, C., & Lawler, J. J. (2026). Identifying climate-change refugia for species management and conservation in the Pacific Northwest. *Conservation Science and Practice*, 8(1), e70174. <https://doi.org/10.1111/csp2.70174>
39. Lam, K. S. P., Lam, C., Chan, E. Y. M., & Lui, B. L. S. (2026). Landslides in Hong Kong: Historical insights, contributory factors and lessons learnt. *Bulletin of Engineering Geology and the Environment*, 85(5), 298. <https://doi.org/10.1007/s10064-026-04983-3>
40. Mondragón-Rodríguez, A., & Quesada-Román, A. (2026). Integrating geomorphological and socio-spatial factors for landslide risk zonation in Atenas, Costa Rica. *Discover Hazards*, 21(8). <https://doi.org/10.1007/s44475-026-00012-9>
41. Morelli, T. L., Mozelewski, T., Cavalieri, C. N., Caven, A. J., Dreiss, L. M., Hovel, R. A., Hua, M., Jennings, M. K., John, A., Kehm, G., Keppel, G., Krawchuk, M. A., Langdon, S. F., Lawler, J. J., Lyon, L. M., Meigs, G. W., Mora-Gonzalez, M., Nadeau, C. P., Słowińska, S., ... Stralberg, D. (2026). Conserving climate-change refugia: Insights from research and practice. *Conservation Science and Practice*, 8(1), e70160. <https://doi.org/10.1111/csp2.70160>
42. Pei, J., Dai, C., & Cui, T. (2026). A directed weighted network approach for hazard chain risk assessment including heavy rainfall induced geological disasters and flooding. *Scientific Reports*, 16(1), 2866. <https://doi.org/10.1038/s41598-025-32694-4>
43. Pilatasig, L., et al. (2025). Casual-Nuevo Alausí landslide Ecuador, March 2023): A case study on the influence of the anthropogenic factors. *GeoHazards*, 62(28). <https://doi.org/10.3390/geohazards6020028>
44. Scapellato, G., Licciardello, G., Blanco, G. L. M., Campione, F., Carbone, M. L., Castorina, S., Londino, A. M., Riggio, M., Sapienza, G., Scrofana, G., Tomarchio, S., Scalia, S., & Neri, M. (2026). Digital governance and geohazard mitigation in post-earthquake reconstruction: The 2018 Etna case study. *GeoHazards*, 71(1), 16. <https://doi.org/10.3390/geohazards7010016>