

Cobos-Mora, S.; Rodríguez-Galiano, V.; Guamán Aucapiña, J. Análisis de la incertidumbre espacial en modelos de susceptibilidad a movimientos en masa mediante Procesos Gaussianos

# Análisis de la incertidumbre espacial en modelos de susceptibilidad a movimientos en masa mediante Procesos Gaussianos

Cobos-Mora, Sandra <sup>1,2</sup> Rodríguez-Galiano, Víctor <sup>2</sup> Guamán Aucapiña, José <sup>1</sup>

<sup>1</sup> Universidad Católica de Cuenca, Ecuador

<sup>2</sup> Universidad de Sevilla, España

ORCID: Cobos-Mora 0000-0003-1091-0000 Rodríguez-Galiano 0000-0002-5422-8305 Guamán Aucapiña 0000-0002-4443-4375

Correspondencia: [zhandry\\_cobos@yahoo.com](mailto:zhandry_cobos@yahoo.com) [vrgaliano@us.es](mailto:vrgaliano@us.es) [jo\\_gu1994@hotmail.com](mailto:jo_gu1994@hotmail.com)

## RESUMEN

El modelado de susceptibilidad a movimientos en masa (MSMM) es una herramienta clave para la evaluación del riesgo geológico y la planificación territorial; sin embargo, la incertidumbre asociada a sus predicciones rara vez se cuantifica explícitamente, particularmente en regiones montañosas complejas como los Andes. La elevada heterogeneidad geomorfológica, climática y geológica, junto con la limitada disponibilidad de inventarios históricos, incrementa la variabilidad espacial de los factores condicionantes y reduce la confiabilidad de los modelos. Este estudio analiza la incertidumbre espacial de un MSMM mediante un enfoque probabilístico basado en Procesos Gaussianos (PG), utilizando variables geomorfológicas, geológicas y ambientales. La optimización del modelo se realizó mediante la Selección Secuencial hacia atrás de características (SBS). La incertidumbre se evaluó mediante la entropía de Shannon. Los resultados muestran que el modelo optimizado mejora el desempeño predictivo (AUC: 0,876–0,905) y reduce la incertidumbre (0,555–0,522). El análisis espacial evidencia mayores niveles de incertidumbre en rangos extremos de pendiente y distancia a vías principales, y mínimos en intervalos intermedios, donde el modelo presenta mayor estabilidad predictiva.

**Palabras clave:** modelo de susceptibilidad a movimientos en masa, optimización, procesos gaussianos, Entropía de Shannon, incertidumbre

Fecha de recepción: 17 febrero 2026 · Fecha de aceptación: 17 febrero 2026


# Análisis de la incertidumbre espacial en modelos de susceptibilidad a movimientos en masa mediante Procesos Gaussianos

Cobos-Mora, Sandra <sup>(1,2)</sup>, Rodríguez-Galiano, Víctor <sup>(2)</sup>, Guamán Aucapiña, José <sup>(1)</sup>

<sup>(1)</sup> Universidad Católica de Cuenca, Ecuador

 0000-0003-1091-0000, scobosm@ucacue.edu.ec ;  0000-0002-4443-4375, jrguamana01@est.ucacue.edu.ec.

<sup>(2)</sup> Universidad de Sevilla, España.

 0000-0002-5422-8305, vrgaliano@us.es.

**Resumen:** El modelado de susceptibilidad a movimientos en masa (MSMM) es una herramienta clave para la evaluación del riesgo geológico y la planificación territorial; sin embargo, la incertidumbre asociada a sus predicciones rara vez se cuantifica explícitamente, particularmente en regiones montañosas complejas como los Andes. La elevada heterogeneidad geomorfológica, climática y geológica, junto con la limitada disponibilidad de inventarios históricos, incrementa la variabilidad espacial de los factores condicionantes y reduce la confiabilidad de los modelos. Este estudio analiza la incertidumbre espacial de un MSMM mediante un enfoque probabilístico basado en Procesos Gaussianos (PG), utilizando variables geomorfológicas, geológicas y ambientales. La optimización del modelo se realizó mediante la Selección Secuencial hacia atrás de características (SBS). La incertidumbre se evaluó mediante la entropía de Shannon. Los resultados muestran que el modelo optimizado mejora el desempeño predictivo (AUC: 0,876–0,905) y reduce la incertidumbre (0,555–0,522). El análisis espacial evidencia mayores niveles de incertidumbre en rangos extremos de pendiente y distancia a vías principales, y mínimos en intervalos intermedios, donde el modelo presenta mayor estabilidad predictiva.

**Palabras clave:** modelo de susceptibilidad a movimientos en masa, optimización, procesos gaussianos, entropía de Shannon, incertidumbre

## ***Exploratory spatial analysis of uncertainty in Gaussian Process–based landslide susceptibility models***

**Abstract:** *Landslide susceptibility modeling (LSM) is a key tool for geological risk assessment and land-use planning; however, the uncertainty associated with its predictions is rarely quantified explicitly, particularly in complex mountainous regions such as the Andes. High geomorphological, climatic, and geological heterogeneity, combined with the limited availability of historical inventories, increases the spatial variability of conditioning factors and reduces model reliability. This study analyzes the spatial uncertainty of an LSM using a probabilistic framework based on Gaussian Processes (GP), incorporating geomorphological, geological, and environmental variables. Model optimization was performed using Sequential Backward Feature Selection (SBS). Uncertainty was quantified using Shannon entropy. Results show that the optimized model improves predictive performance (AUC: 0.876–0.905) and reduces uncertainty (0.555–0.522). Spatial analysis reveals higher uncertainty levels in extreme ranges of slope and distance to main roads, and lower values in intermediate ranges, where the model exhibits greater predictive stability.*

**Keywords:** *landslide susceptibility model, optimization, Gaussian Processes, Shannon entropy, uncertainty*

## **1. INTRODUCCIÓN**

La ausencia de un análisis explícito de la incertidumbre conduce a que muchos modelos de susceptibilidad a movimientos en masa (MSMM) se interpreten como predicciones determinísticas, cuando en realidad están condicionados por múltiples fuentes de variabilidad que se manifiestan como incertidumbre en las predicciones. Esta incertidumbre puede ser de dos tipos: aleatoria, asociada a la variabilidad inherente de los procesos

geomorfológicos, e incertidumbre epistémica, vinculada a limitaciones en los datos, el conocimiento del sistema y la estructura del modelo (Hüllermeier & Waegeman, 2021). En este contexto, factores como la calidad y representatividad de los inventarios de movimientos en masa (MM), la resolución y consistencia de las variables condicionantes, la dinámica espacio-temporal de los procesos y las restricciones de los algoritmos de modelado contribuyen conjuntamente a ambas formas de incertidumbre (Huang *et al.*, 2024).

En respuesta a esta problemática, la literatura ha propuesto avanzar en el análisis de la incertidumbre mediante enfoques como el remuestreo del inventario, el análisis de sensibilidad, los ensambles de modelos y los métodos bayesianos (Ferreira *et al.*, 2025). En este marco, los Procesos Gaussianos (PG) constituyen una alternativa metodológica robusta para el modelado probabilístico en MSMM, al permitir representar relaciones no lineales complejas y cuantificar explícitamente la incertidumbre a través de su estructura de covarianza (Rasmussen, 2004). Sin embargo, en problemas de clasificación, esta incertidumbre predictiva no siempre es directamente calculada en los entornos computacionales habituales, por lo que suele estimarse mediante métricas derivadas de las probabilidades, como la entropía de Shannon (Addis, 2023).

Estudios recientes en los Andes evidencian que los MSMM pueden alcanzar buenas exactitudes globales (Cobos-Mora *et al.*, 2023). Sin embargo, según los autores, no se han identificado estudios que cuantifiquen explícitamente la incertidumbre. Esta región presenta una elevada complejidad geoambiental, caracterizada por topografía abrupta, litologías heterogéneas, intensa actividad tectónica y alta variabilidad climática. Estas condiciones generan fuertes contrastes espaciales y relaciones no lineales que dificultan la interpretación local de los MSMM. Además, la limitada disponibilidad de información puede amplificar la incertidumbre predictiva

y reducir la robustez de los modelos en contextos montañosos complejos. Esta limitación configura un vacío de conocimiento. Por ello, el objetivo de esta investigación es analizar y cuantificar la incertidumbre espacial de los MSMM mediante la aplicación de técnicas basadas en PG y la entropía de Shannon, con el fin de mejorar la interpretación espacial de los MSMM y aportar información relevante para la gestión del riesgo y planificación territorial.

## 2. MATERIAL Y MÉTODOS

### 2.1. Área de estudio

La provincia de Azuay está ubicada en la región andina del sur del Ecuador y presenta una elevada complejidad geomorfológica caracterizada por pendientes pronunciadas (25–50 %) y una densa red de drenaje. A ello se suman precipitaciones intensas con marcada estacionalidad y la influencia de factores antrópicos, como el trazado vial, el riego y el cambio de uso del suelo que configuran un entorno altamente susceptible a MM.

### 2.2 Datos

La Tabla 1 presenta la descripción de las variables predictoras y variable objetivo empleadas para la generación de los MSMM.

**Tabla 1.** Variables predictoras y variable objetivo utilizadas en el MSMM.

Variable	Unidad	año	Fuente/Colección/Técnica	Resolución
Temperatura*	K	2017-2025	MODIS/061/MOD11A2 MODIS/061/MYD11A2	1000 m
Precipitación (media y máxima anual) *	mm/año	2017-2025	UCSB-CHG/CHIRPS/DAILY	5566 m
Almacenamiento agua subterránea*	mm	2017-2025	NASA/GLDAS/V022/CLSM/G025/DA1D	27830 m
Humedad del suelo*	Fracción de volumen	2017-2025	NASA/SMAP/SPL4SMGP/007	11000 m
NDVI*	no aplica	2017-2025	COPERNICUS/S2	30 m
Elevación (DEM)*	m	2020	NASA/NASADEM_HGT/001	30 m
Aspectos	grados		Procesamiento SIG	30 m
Curvatura plana	1/m			30 m
Curvatura de perfil	1/m			30 m
Pendientes	grados			30 m
Distancia a ríos	m	2019	Instituto Geográfico Militar (IGM)	1:5000
Distancia a vías principales, secundarias y locales	m			1:5000
Litología	no aplica	S/I	Secretaría Nacional de Gestión de riesgos (SGR)	1:100000
Distancia a fallas geológicas	m	S/I	Instituto de Investigación Geológico y Energético (IIGE)	1:100000
Inventario de presencia de movimientos en masa (1153 puntos)	no aplica	S/I	Prefectura del Azuay	S/I
		2016-2025	SNGR	
		S/I	IIGE	
Inventario de ausencia de movimientos en masa (1153 puntos)	No aplica	2025	Probability-proportional-to-size (PPS) sampling	S/I

\* variables obtenidas y procesadas a través de la plataforma en la nube Google Earth Engine.

### 2.3. Métodos

Esta investigación implementó PG como un método de clasificación supervisada probabilística en R (librería mlr) para la generación de los MSMM. El preprocesamiento incluyó la partición de datos en conjuntos de entrenamiento (70 %) y validación (30 %), la estandarización de variables numéricas y la codificación de variables categóricas. La calibración del modelo se realizó mediante validación cruzada espacial por bloques (10 particiones), garantizando independencia espacial entre subconjuntos (Dai *et al.*, 2023). La optimización de

hiperparámetros se abordó mediante un enfoque bayesiano, utilizando el área bajo la curva ROC (AUC) como función objetivo, y considerando un kernel gaussiano con ajuste del parámetro sigma ( $0.001 < \sigma < 0.5$ ). A partir de todas las variables se calculó el MSMM completo (MSMMC); del cual se aplicó una Selección Secuencial hacia atrás de Características (SBS) para identificar el conjunto óptimo de variables predictoras. De este último modelo se determinó la importancia relativa de las variables mediante el análisis de pérdida de AUC.

El desempeño de los modelos se evaluó con el conjunto de validación mediante métricas derivadas de la matriz de confusión: AUC, exactitud, Kappa, sensibilidad y especificidad. El umbral óptimo para la binarización de las probabilidades se determinó mediante el índice de Youden (Lim *et al.*, 2024). Finalmente, la incertidumbre se cuantificó mediante el índice de Brier y la entropía de Shannon, como medidas complementarias de la calidad probabilística y la dispersión de las predicciones (Felsberg *et al.*, 2022).

### 3. RESULTADOS Y DISCUSIÓN

A partir del conjunto total de variables consideradas en el modelado, el MSMM con SBS retiene únicamente ocho predictores: altitud, pendiente, distancia a fallas geológicas, distancia a vías principales, precipitación media, NDVI, almacenamiento de agua subterránea y humedad del suelo. Estas, definen el patrón espacial de la susceptibilidad de la Figura 1a. La incertidumbre asociada a estas predicciones presenta una distribución espacial heterogénea, con amplios sectores caracterizados por valores elevados de incertidumbre (Figura 1b).

El MSMM con SBS presentó una exactitud superior al MSMM completo (MSMMC), evidenciado por mejoras consistentes en sus métricas. En particular, el AUC aumentó de 0,876 a 0,905, la exactitud de 0,799 a 0,823 y el coeficiente Kappa de 0,5995 a 0,646. Asimismo, la sensibilidad se incrementó de 0,754 a 0,806, mientras que la especificidad se mantuvo constante en 0,84, lo que indicó una mejora en la detección de MM sin comprometer la identificación de zonas estables. En términos de incertidumbre global, el índice de Brier disminuyó de 0.147 en el MSMMC a 0.128 en el MSMM

con SBS, lo que indicó una mejora en la calidad probabilística de las predicciones. Por otro lado, los valores de entropía de Shannon, superiores a 0.5 en ambos MSMM, reflejaron una incertidumbre relativamente alta; no obstante, la reducción de 0.555 a 0.522 evidencia una disminución sistemática y una mayor certidumbre predictiva en el MSMM con SBS (Tabla 2).

El análisis de pérdida de AUC reveló que la pendiente y a la distancia a vías principales son las variables más importantes del modelo, dado que su exclusión generó la mayor reducción de la capacidad discriminativa, con pérdidas del 20.2% y 19.8% del AUC respectivamente (Figura 2a). La incertidumbre espacial presentó un comportamiento no lineal en función de ambas variables. En relación con la pendiente, la incertidumbre aumentó progresivamente desde valores cercanos a 0.45 hasta un primer máximo alrededor de 20.6°, seguido de una disminución que condujo a un mínimo relativo próximo a 39.5°, volviendo a incrementarse de forma sostenida hasta pendientes superiores a 70° (Figura 2b). De manera análoga, la incertidumbre en función de la distancia a vías principales exhibió un patrón curvilíneo, con un mínimo bien definido alrededor de 7.6 km y un aumento progresivo a mayores distancias (Figura 2c). En conjunto, estos resultados indicaron que la incertidumbre del modelo se concentró en rangos extremos de pendiente y en áreas alejadas de la red vial, mientras que disminuyó en intervalos intermedios donde el modelo presentó un comportamiento más estable y consistente, probablemente asociado a una mayor densidad de registros de MM en zonas próximas a las vías.

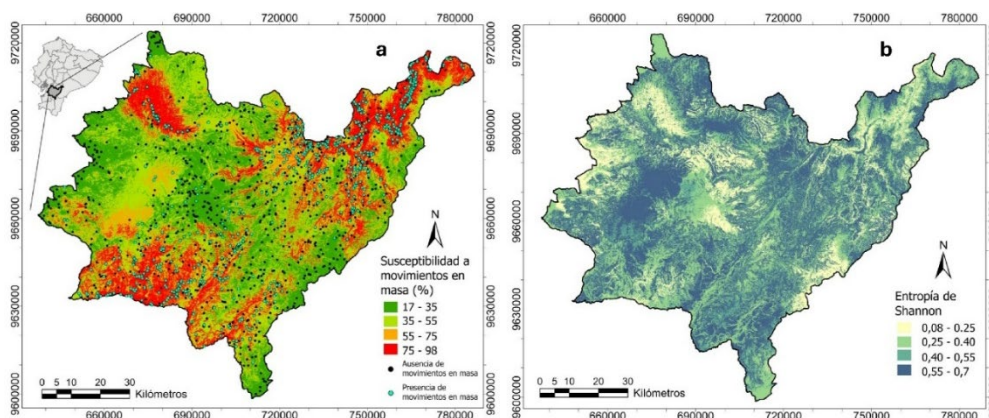
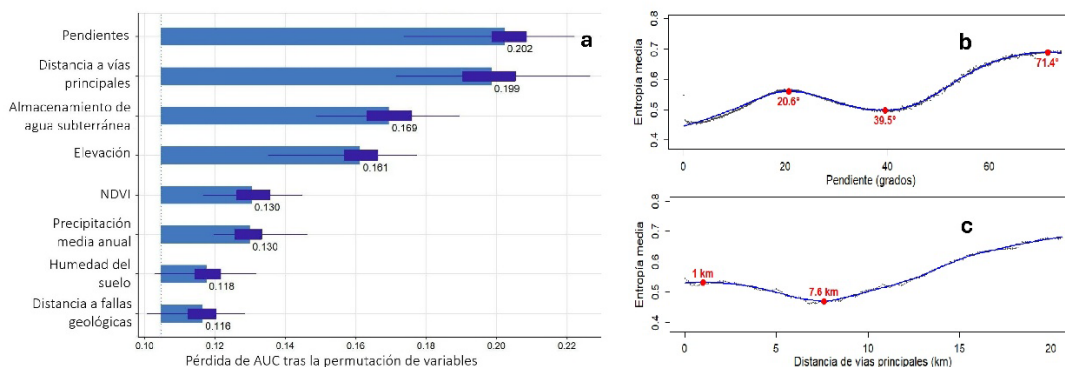


Figura 1. a) MSMM con SBS, b) incertidumbre espacial calculada mediante la entropía de Shannon.

Tabla 2. Métricas de exactitud e incertidumbre de los MSMM completo y con SBS.

	Índice Youden	auc <sup>1</sup>	Exactitud				Incertidumbre					
			exactitud	Kappa	sensibilidad	especificidad	tp <sup>2</sup>	tn <sup>3</sup>	fp <sup>4</sup>	fn <sup>5</sup>	Brier	Shannon
<b>MSMMC<sup>6</sup></b>	0.482	0,876	0,799	0,599	0,754	0,846	281	261	51	85	0,147	0,555
<b>MSMM con SBS<sup>7</sup></b>	0.485	0,905	0,823	0,646	0,806	0,840	279	279	53	67	0,128	0,522

<sup>1</sup> área bajo la curva, <sup>2</sup> verdaderos positivos, <sup>3</sup> verdaderos negativos, <sup>4</sup> falsos positivos, <sup>5</sup> falsos negativos, <sup>6</sup> MSMM completo, <sup>7</sup> MSMM con selección de características secuencial hacia atrás



**Figura 2.** a) Importancia de las variables predictoras en el MSMM con SBS en función del porcentaje de pérdida del AUC, b) análisis de incertidumbre en relación a pendientes; c) análisis de incertidumbre en relación a distancia a vías principales.

#### 4. CONCLUSIONES

En contextos geoambientales complejos como la región andina, caracterizados por alta heterogeneidad espacial y dinámicas no lineales, la incertidumbre no es un componente residual, sino una propiedad inherente del sistema, que condiciona la interpretación de los MSMM. En este sentido, la integración de PG con la entropía de Shannon permitió trascender el enfoque determinista convencional, incorporando una cuantificación de la incertidumbre en la predicción. Con este marco metodológico no solo se mejora la interpretabilidad de los resultados, sino que refuerza su pertinencia para la toma de decisiones en escenarios donde la información es incompleta y las condiciones son altamente variables.

#### 5. AGRADECIMIENTOS

Se agradece a la Universidad Católica de Cuenca a través del: proyecto de investigación PICTMS24-02 denominado “Optimización de Modelos de Susceptibilidad a Movimientos en Masa con IA y Teledetección y su Vinculación en las Políticas Públicas Territoriales”, Laboratorio SIGDATA y al grupo de Investigación *Urban and Earth Data Science*.

#### 6. REFERENCIAS

Addis, A. (2023). GIS-Based Landslide Susceptibility Mapping Using Frequency Ratio and Shannon Entropy Models in Dejen District, Northwestern Ethiopia. *Journal of Engineering*, 2023. <https://doi.org/10.1155/2023/1062388>

Bryce, E. et al. (2024). An updated landslide susceptibility model and a log-Gaussian Cox process extension for Scotland. *Landslides* 2024, 22(2), 517–535. <https://doi.org/10.1007/S10346-024-02368-9>

Cobos-Mora, S. et al.(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>

Dai, X. et al. (2023). Examining the Spatially Varying Relationships between Landslide Susceptibility and Conditioning Factors Using a Geographical Random Forest Approach: A Case Study in Liangshan, China.

*Remote Sensing* 2023, Vol. 15, 15(6). <https://doi.org/10.3390/rs15061513>

Felsberg, A. et al.(2022). Estimating global landslide susceptibility and its uncertainty through ensemble modeling. *Nat. Hazards and Earth Syst Sci*, 22(9), <https://doi.org/10.5194/NHESS-22-3063-2022>

Ferreira, Z. et al.(2025). Insights into landslide susceptibility: a comparative evaluation of multi-criteria analysis and machine learning techniques. *Geomatics, Nat. Hazards and Risk* , 16(1), 2471019. <https://doi.org/10.1080/19475705.2025.2471019>

Huang, F. et al. (2024). Uncertainties in landslide susceptibility prediction modeling: A review on the incompleteness of landslide inventory and its influence rules. *Geosci Front*, 15(6), 101886. <https://doi.org/10.1016/J.GSF.2024.101886>

Hüllermeier, E., et al.(2021). Aleatoric and epistemic uncertainty in machine learning: an introduction to concepts and methods. *Mach. Learn.* 2021, 110(3), 457-506. <https://doi.org/10.1007/s10994-021-05946-3>

Lim, J. et al.(2024). An ensemble neural network approach for space–time landslide predictive modelling. *Int. J. Appl. Earth Obs. Geoinf.*, 132(11), 104037. <https://doi.org/10.1016/j.jag.2024.104037>

Rasmussen, C. (2004). Gaussian Processes in Machine Learning. *Lect. Notes Comput. Sci.*, 3176, 63–71. [https://doi.org/10.1007/978-3-540-28650-9\\_4](https://doi.org/10.1007/978-3-540-28650-9_4)