

# Técnicas para la predicción espacial de zonas susceptibles a deslizamientos

## Spatial prediction Techniques for landslide-prone areas

Andrés Camilo Florez García<sup>1</sup>, José Nelson Pérez Castillo<sup>2</sup>

<sup>1</sup> <https://orcid.org/0000-0002-1919-1965>, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia, [acflorezg@correo.udistrital.edu.co](mailto:acflorezg@correo.udistrital.edu.co)

<sup>2</sup> <https://orcid.org/0000-0001-8153-3113>, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia, [jnperezc@correo.udistrital.edu.co](mailto:jnperezc@correo.udistrital.edu.co)

Fecha de recepción: 13/05/2019 Fecha de aceptación del artículo: 16/08/2019



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No comercial-SinObraDerivada 4.0 internacional.

DOI: [doi.org/10.18041/1794-4953/avances.15188](https://doi.org/10.18041/1794-4953/avances.15188)

Como citar: Florez García, A., & Pérez Castillo, J. N. (2019). Técnicas para la predicción espacial de zonas susceptibles a deslizamientos. Avances: Investigación En Ingeniería, 16(1). <https://doi.org/10.18041/1794-4953/avances.15188>

## Resumen

Si bien las técnicas implementadas para predecir zonas susceptibles a procesos de remoción en masa han logrado modelar con cierto grado de precisión casos de deslizamientos, no logran modelar eventos complejos, donde la relación entre los deslizamientos y sus factores desencadenantes no presentan un comportamiento lineal. Lo anterior se debe a ausencia de estructuras de dependencia espacio-temporal que permitan evaluar efectos espaciales (autocorrelación y heterogeneidad); por lo tanto, la interpretación de los resultados suele ser errada y lleva a una menor confiabilidad. Dado lo anterior, el objetivo del artículo es brindar un documento sólido que ofrezca una perspectiva general y detallada de las técnicas de predicción espacial; al tiempo que se propone una metodología innovadora que permita utilizar las bondades del aprendizaje automático y la estadística espacial, con el propósito de mejorar el desempeño predictivo de zonas susceptibles a deslizamientos.

**Palabras clave:** deslizamientos, algoritmos de predicción, máquina de aprendizaje, SIG, análisis geoespacial.

## Abstract

The implemented techniques for the prediction of landslide-prone areas have been effective at a certain degree. However, many approaches tend to face difficulties to determine non-linear landslides triggering factors, due to the absence of Spatio-temporal dependency structures that evaluate spatial effects as autocorrelation and heterogeneity when describing complex problems. Therefore, results understanding may not be precise and lead to a less reliability condition. The main objective of this article is to provide a solid document that offers both, a general and a detailed perspective about Spatial Prediction Techniques. Finally, we propose an innovative methodology that allows us to use automatic learning and spatial statistics to improve the predictive performance of landslide-prone areas.

**Keywords:** Landslide, Prediction algorithms, Machine Learning, GIS, Geospatial analysis

## Introducción

De acuerdo con las estadísticas presentadas por el Centro de Investigación sobre la Epidemiología de los Desastres, en los últimos decenios se han presentado, en promedio, 380 desastres de origen natural alrededor del mundo. Del total de desastres, el 53% son eventos de origen hidrometeorológico de los cuales las inundaciones corresponden al 82,8%, y los movimientos en masa detonados por lluvias, al 17,2%, que han afectado a más de 196 millones de personas y dejado pérdidas económicas superiores a los 406.300 millones de dólares [1]. Del total de eventos, los movimientos en masa representan el 17,2% [2].

En años recientes, la predicción de procesos de remoción en masa ha tomado mayor importancia, entre geocientíficos, profesionales de ingeniería y, en general, en la comunidad mundial [3]. La principal razón se debe a un aumento significativo de deslizamientos como consecuencia de cambios en los regímenes de precipitación [4] y [5], asentamientos en zonas de alta pendiente, actividad antrópica [6] y sísmica, erosión [7], deforestación [8], entre otras.

Como consecuencia, desde los años setenta los esfuerzos se han enfocado en predecir zonas susceptibles a movimientos en masa, con el fin de mitigar impactos sobre la población y el ambiente. Además, tales esfuerzos han aumentado en popularidad con el desarrollo de los sistemas de información geográfica (SIG) y las tecnologías de computación [9]. Lo anterior ha dado como resultado una serie de técnicas que han buscado optimizar y mejorar la precisión en la predicción de zonas susceptibles a deslizamientos alrededor del mundo.

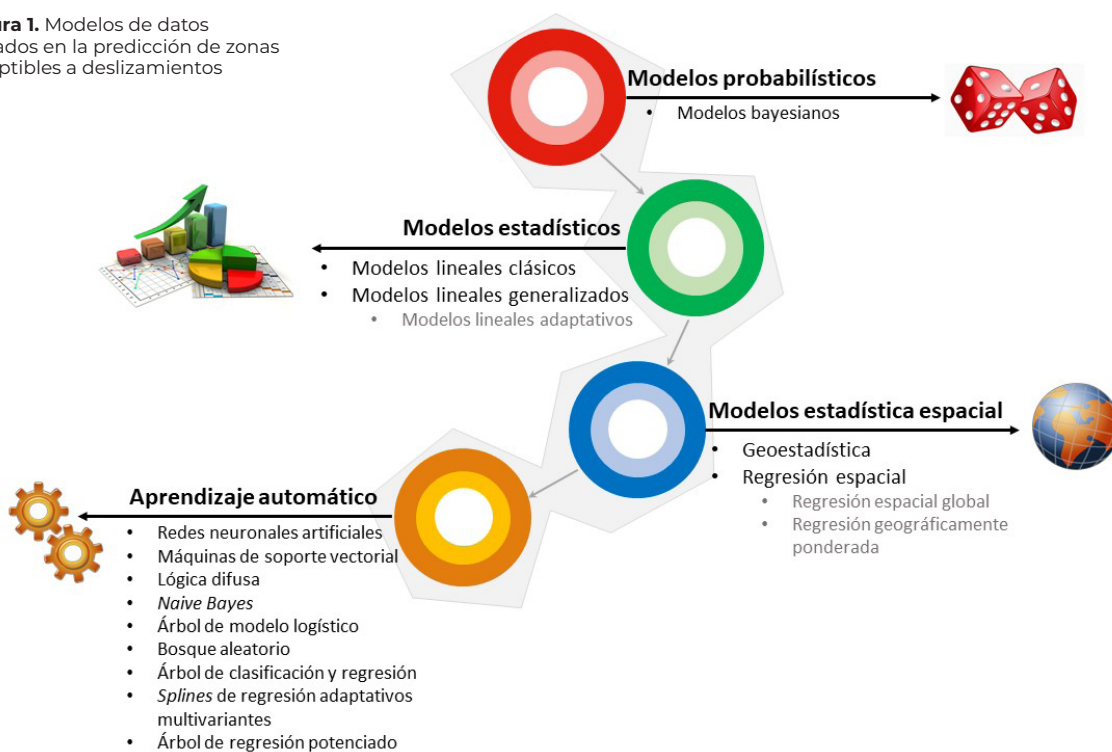
Desde este escenario, el objetivo del presente artículo es brindar un documento sólido que ofrezca una perspectiva general de las técnicas de predicción de movimientos en masa, para, finalmente, proponer una metodología innovadora que permita utilizar las bondades del aprendizaje automático y la estadística espacial, con el propósito de mejorar el desempeño predictivo de zonas susceptibles a procesos de remoción en masa.

## Antecedentes

Las técnicas para predecir procesos de remoción en masa pueden dividirse en dos grupos: métodos cualitativos y métodos cuantitativos. Los primeros se basan en el conocimiento e incorporan la experticia específica de quien determina el grado y susceptibilidad a la presencia de movimientos en masa, combinando mapas, capas u otra información que sea clave para la caracterización del deslizamiento [10]-[15], como son procesos de jerarquía analítica y análisis heurístico (análisis geomorfológico y combinación cuantitativa de mapas). Entre tanto, los métodos cuantitativos incorporan el análisis estadístico y probabilístico o siguen enfoques deterministas [16] y [17] (figura 1).

Ambos enfoques resultan de especial interés en la predicción de deslizamientos; sin embargo, este artículo abarca los métodos cuantitativos, los cuales se pueden agrupar en modelos probabilísticos basados en teoría bayesiana, modelos estadísticos basados en análisis de correlación y en estadística espacial, y modelos de aprendizaje automático los cuales en los últimos años han tomado mayor relevancia [18].

**Figura 1.** Modelos de datos implementados en la predicción de zonas susceptibles a deslizamientos



## 1.1. Modelos probabilísticos

Los métodos bayesianos se introdujeron por primera vez en el análisis de toma de decisiones bajo incertidumbre por [19]; 20 años más adelante [20] sugirió que los modelos de inferencia bayesiana podrían ser aplicados para la predicción estocástica de problemas empíricos en geomorfología. De allí y con la aparición de los SIG se masificó su práctica y ello dio lugar a las primeras metodologías que permitieran establecer áreas susceptibles a movimientos en masa.

En este campo, [21], [22] y [23] usaron un grupo de datos espaciales en un SIG para crear mapas de riesgo por deslizamiento, a partir de la superposición de variables o factores desencadenantes y el cálculo de las probabilidades condicionales resultado de la intersección de las variables superpuestas y, de esta manera, estimar la susceptibilidad a la presencia de procesos de remoción en masa.

Se han implementado técnicas más complejas que permiten optimizar y enriquecer los modelos de probabilidad bayesiana, los modelos de regresión lineal multivariados [24], las técnicas refinadas para el cálculo de probabilidades condicionales y la correlación entre procesos de ladera y factores detonantes [25], [26] e índices de entropía [27].

## 1.2. Modelos estadísticos

Entre los métodos estadísticos, los que despertaron mayor interés en la literatura sobre el tema están los modelos bivariados, los modelos lineales generalizados (GLM) y los modelos lineales adaptativos (GAM). Los cuales se describirán a continuación.

## 1.2.1. Modelos lineales clásicos

La atribución arbitraria de valores ponderados sobre cada factor que incide en la presencia de movimientos en masa, el juicio del especialista que realiza la evaluación de susceptibilidad y la reproducibilidad de resultados representan las principales limitaciones en los modelos bayesianos descritos anteriormente [28]. La solución a este problema dio como resultado la adopción de un enfoque estadístico que compare la distribución espacial de los movimientos en masa con los parámetros que se están considerando. Es posible aplicar los resultados en áreas actualmente libres de deslizamientos, donde pueden existir condiciones de susceptibilidad ante una futura inestabilidad.

**Modelos bivariados.** El análisis estadístico bivariado es el modelo matemático más simple para el mapeo de susceptibilidad al deslizamiento. Se asume que cada una de las variables independientes condicionantes de la susceptibilidad a movimientos en masa no se relaciona internamente [29]. Cada clase de variable se combina con la distribución de los movimientos en masa, y los pesos se calculan de acuerdo con la cantidad de deslizamientos contenidos por cada clase de variable.

Siendo este un criterio subjetivo de quien realiza la selección, los principales estudios se han concentrado en la correcta selección de variables y en el cálculo de los pesos por cada clase de variable. En este sentido, se han propuesto técnicas que estandaricen el proceso de selección de variables y pesos por cada clase de variable, comparando y evaluando los resultados obtenidos de aplicar cada una de ellas [9], [30]-[38].

De las principales técnicas: frecuencia de radio (FR), peso de evidencia, índice estadístico y proceso analítico de jerarquía, se ha encontrado en la técnica de FR los mejores resultados en términos de confiabilidad y precisión, hasta con un 10% de mejora en relación con las demás técnicas [39]-[41].

A continuación, se presenta una serie mínima de pasos que se deben implementar para la predicción de movimientos en masa aplicando modelos bivariados:

1. Identificación de variables independientes incidentes en la aparición de movimientos en masa.
2. Definición de clases o subcategorías para cada una de las variables incidentes.
3. Cálculo de la frecuencia de deslizamientos por cada clase o subcategoría definida por variable.
4. De acuerdo con la distribución en la frecuencia de deslizamiento por cada clase o subcategoría, se reclasifican en un rango de valores numéricos definidos por el investigador. Este rango debe estar parametrizado para todas las clases o subcategorías por variable.
5. Superposición de variables reclasificadas y cálculo del índice de susceptibilidad por cada unidad espacial defendida (píxel).

Si bien el análisis estadístico bivariado se considera un enfoque cuantitativo, aún sigue siendo rudimentario, debido a que existe un alto grado de subjetividad en la escogencia de las variables independientes, generación de clases o subcategorías por variable y en la reclasificación de

las clases por variable [42], lo cual se ve reflejado en factores irrelevantes que son considerados en el análisis de los modelos [43]. Para reducir este problema, se propusieron modelos lineales generalizados. A continuación, se explica en mayor detalle su funcionamiento.

### 1.2.2. Modelo lineal generalizado

El GLM es una extensión del modelo lineal clásico y que se ha convertido en una solución adecuada para modelos de dependencia con datos no métricos [44], un desarrollo más profundo se puede encontrar en [45].

A través de los años, los GLM se han aplicado en diferentes áreas de la geología, como es el caso de la industria petrolera. Sin embargo, el desarrollo de esta técnica en el marco de la predicción de deslizamientos fue abordado por [46], con el desarrollo del primer GLM a partir de la recolección de un grupo de variables geológicas y geomorfológicas incidentes en la ocurrencia de movimientos en masa. Como resultado, [46] logró identificar que las variables con mayor poder discriminante son: la pendiente, la densidad de los drenajes, el gradiente y la rugosidad de la superficie, pues representan cerca de un 50% de la variabilidad en áreas afectadas por movimientos en masa en Calabria, al sur de Italia.

Si bien existen diferentes tipos de GLM, en la predicción de procesos de remoción en masa la regresión logística (LR) ha sido el principal GLM aplicado. El resultado del modelo arroja un valor entre 0 (falso) y 1 (verdadero), el cual mide si el evento o la variable explicada (deslizamiento) ocurre (verdadero) o no (falso). La idea de la LR es aproximar la probabilidad de obtener 0 o 1 de acuerdo con el valor de las variables explicativas. En los trabajos de [47] y [48] se presenta un desarrollo más robusto de las LR.

Varios autores han aplicado los modelos de LR en la evaluación de la susceptibilidad a procesos de remoción en masa [49]-[53]. En general, los resultados permiten observar que los modelos de LR resaltan la interrelación existente entre movimientos en masa y los factores incidentes, con un porcentaje de acierto entre el 70% y el 80%, dependiendo del área de estudio y la escala de trabajo.

El procedimiento general implica varios pasos preliminares que se deben llevar a cabo sobre el área de estudio, bajo el principio de “el presente y el pasado son clave para el futuro” [51]. En este sentido, el principio fundamental es utilizar características de movimientos en masa existentes para evaluar las posibles áreas susceptibles de presentar deslizamientos. Los pasos por seguir se pueden enumerar en:

1. Inventario de procesos de remoción en masa: este paso implica recopilar un histórico de procesos de remoción en masa que hayan ocurrido sobre el área de estudio usando imágenes de sensores remotos, como fotografías aéreas, imágenes de drones o imágenes satelitales de alta resolución [54], [55].
2. Identificación y preparación de factores significantes: este paso implica un cierto grado de conocimiento y experticia del investigador para identificar las variables que inciden en la presencia de movimientos en masa; también puede basarse en estudios previos para la escogencia de las variables. Sin embargo, no hay criterios universales; el consenso general, de acuerdo con [55], es que cualquier variable independiente debe ser operativa (tener un cierto grado de afinidad con la variable dependiente), completa (está representada

justamente en toda el área de estudio), no uniforme (varía espacialmente), medible (puede expresarse mediante cualquiera de los diferentes tipos de escalas de medición) y no redundante.

La preparación de las variables elegidas puede realizarse haciendo uso de un SIG para el tratamiento de la información ráster [49] o vector, y de esta manera procesar información de imágenes satelitales, modelos de elevación digital o cualquier otra fuente de información [56].

3. Modelo de LR: el objetivo del modelo de LR es encontrar el modelo más adecuado para describir la relación entre la presencia o ausencia de deslizamientos (variable dependiente) y un conjunto de parámetros independientes [57]. Hay que tener en cuenta que la variable dependiente debe ser una variable dicotómica [58] y las variables independientes deben tener una misma escala de medición, por lo que [55] recomienda crear capas de valores binarios para cada clase por variable independiente. Esto funciona cuando la cantidad de parámetros es pequeña. Si, al contrario, son muchos los parámetros, se podrían presentar problemas asociados a multicolinealidad y modelos complejos de interpretación que deben evaluarse. En dado caso, se recomienda aplicar el Índice de Tolerancia y el factor de inflación de varianza [59].
4. Análisis estadístico: el último paso se centra en el análisis estadístico del modelo de regresión logístico. Básicamente se evalúa: la significancia de cada una de las variables independientes en la presencia de movimientos en masa [56], el coeficiente de determinación como proporción de la varianza total de la variable explicada en relación con las variables explicativas y el índice de característica relativa de funcionamiento (ROC) [60].

Si bien el GLM descrito hasta este punto ha permitido abordar el modelamiento de los movimientos en masa con cierto grado de precisión, este enfoque presenta dos problemas: el primero se debe a su incapacidad de modelar casos complejos de deslizamiento, debido a que la relación entre problemas basados en fenómenos naturales y sus factores desencadenantes no siempre presentan un comportamiento lineal [61], [62]. Adicional, carecen de un análisis espacial exhaustivo que permita evaluar la presencia de dependencia espacial o autocorrelación entre deslizamientos de manera global o local sobre el área de estudio [63], [64].

Por esta razón, la predicción de procesos de ladera aplicando GLM presenta errores en áreas de la región de estudio en las que la relación construida puede no ser fuerte debido a variaciones locales, lo que conduce a una menor confiabilidad en los resultados [65]. En este punto aparecen los GAM como una extensión semiparamétrica del GLM, logrando combinar relaciones lineales y no lineales entre los factores desencadenantes de procesos de remoción en masa y la ocurrencia del evento [66]. De esta manera, se aborda uno de los principales problemas que han presentado los GLM.

### 1.2.3. Modelo lineal adaptativo

El GAM, originalmente desarrollado por [66], se conoce como complemento del GLM semiparamétrico. Dado que el modelo GAM estima las curvas de respuesta parcial del predictor con una función de suavizado no paramétrico en lugar de una función paramétrica, lo que permite el desarrollo de relaciones estadísticas entre la ocurrencia de movimientos en masa y factores desencadenantes, lo que proporciona descripciones de patrones geoambientales [67].



[67] encontró relaciones no lineales entre variables topográficas y la presencia de movimientos en masa, por lo que GAM permitió capturar procesos geomorfológicos complejos, como la erosión ligada a la agricultura en zonas de ladera o a grandes incendios que son difíciles de representar de forma lineal. Ello proporciona resultados fácilmente interpretables que pueden arrojar luz sobre los factores desencadenantes de movimientos en masa y facilita la identificación de posibles interacciones causales [68].

Sin embargo, de acuerdo con [69], los GAM presentan problemas con valores atípicos, el número o el orden de los predictores y los valores de predicción ausentes, además la inclusión de términos no lineales (transformados) o términos lineales (no transformados) proporciona una mejora marginal en la predicción de movimientos en masa [67]. Este problema condujo al desarrollo de modelos de Machine Learning (ML) que permitieran mejorar de manera significativa la precisión en la predicción de procesos de ladera. Por otra parte, algunos autores se centraron en el desarrollo de técnicas estadísticas y estadística espacial que permitieran modelar variaciones globales y locales que afecten la calidad predictiva.

Por lo anterior, en este punto las técnicas aplicadas para la predicción de procesos de remoción en masa toman dos enfoques: el primero basado en estadística espacial, y el segundo, en técnicas de aprendizaje automático.

### 1.3. Estadística espacial

A principios de los años noventa aparece la estadística espacial como una disciplina que permite el análisis descriptivo e inferencial de datos espaciales por medio de un conjunto de metodologías apropiadas [70]. De acuerdo con [70], hay dos tipos de datos espaciales: datos de área o puntuales, como muestras de distribuciones discretas desarrollado por [71] y discutido ampliamente por [70], y datos geoestadísticos basados en distribuciones continuas producto de los trabajos de [72] y [73].

Debido a la naturaleza de los eventos de deslizamiento, la geoestadística se ha enfocado en predecir el comportamiento espacial de algunas variables detonantes, con el fin de establecer umbrales que puedan desencadenar un nuevo evento. Por otra parte, las distribuciones discretas se han aplicado para construir modelos de regresión espacial que permitan establecer la susceptibilidad del terreno a presentar movimientos en masa como producto de una serie de variables desencadenantes.

#### 1.3.1. Geoestadística

De acuerdo con [74], las principales variables detonantes de procesos de ladera son: la precipitación, la actividad sísmica y la erosión del suelo como producto de propiedades físicas. Estas variables presentan la característica de ser continuas en el espacio, por lo que resulta óptimo aplicar técnicas geoestadísticas para predecir sus valores en zonas no muestreadas.

[75] calcularon los umbrales de lluvia en una determinada región para la predicción espacial de lluvias prolongadas, los cuales causaron deslizamientos en función de su intensidad durante un cierto periodo denominado umbral intensidad-duración. El interpolador de Kriging, de tipo ordinario, se utilizó para predecir los umbrales y su validación se hizo en tres periodos, donde el coeficiente de determinación  $R^2$  estuvo por encima del 65%.

Si bien los resultados fueron consistentes, algunos elementos de análisis importantes, como la anisotropía, no se tuvieron en cuenta en este estudio, porque la variabilidad del umbral en el espacio se ve afectada principalmente por la composición geológica y los gradientes de inclinación del terreno. Además, los periodos de análisis no cubrieron en su totalidad el rango de tiempo cuando se presentan mayores afectados por lluvias prolongadas, los cuales pueden llegar en promedio hacer de 1 a 24 horas [76] o bien pueden ocurrir después de que se presenta el pico más alto de lluvias [77]. Por lo tanto, los antecedentes como las precipitaciones máximas desempeñan un papel importante en la activación de los deslizamientos [78].

Otro aporte significativo fue el obtenido por [79], cuyo objetivo consistió en evaluar la relación entre las propiedades físicas del suelo (como conductividad hidráulica, densidad de partícula y porosidad total) y el relieve en áreas que son susceptibles a deslizamientos en la subcuenca del Córrego do Yung. El análisis geoestadístico mostró que el rango de valores para las propiedades de macroporosidad, microporosidad y limo fue el más bajo en las capas más profundas, lo que indicó una baja continuidad estructural en áreas potencialmente erosionables que pueden generar zonas de deslizamiento.

Algunos movimientos en masa también son inducidos por actividad sísmica, [80] aplicaron un modelo geoestadístico que incluye un efecto espacial latente, con el fin de probar si este es capaz de capturar el patrón de los movimientos sísmicos en los lugares donde se presentaron deslizamientos inducidos por terremotos sin tener conocimiento previo sobre el terremoto en el modelo estadístico. Según los resultados, el efecto espacial latente es capaz de capturar la distribución espacial de los movimientos sísmicos provocados por un terremoto y su relación con la intensidad de los procesos de remoción en masa.

Como se evidencia en los trabajos discutidos, la geoestadística ha permitido predecir el comportamiento de variables detonantes de movimientos en masa de manera eficiente, y aunque es una técnica válida, no es la más recomendable cuando se desea analizar la naturaleza propiamente del evento. Si bien las variables detonantes son la mayor causa de deslizamientos, este enfoque deja de lado otras variables como la geología, la geomorfología, la cobertura de la tierra, el uso del suelo, la cercanía a vías y las fallas que inciden en la presencia de procesos de remoción en masa, además de la naturaleza propia del fenómeno.

### 1.3.2. Modelos de regresión espacial

Los movimientos en masa son eventos espaciales discretos y temporalmente dinámicos, considerados distribuciones discretas [81], lo cual sugiere la necesidad de abordar su análisis por medio de técnicas que modelen no solo su dinámica temporal, sino su naturaleza discreta. En este sentido, con los modelos de regresión espacial se obtienen representaciones más reales para predecir nuevos movimientos en masa, al permitir analizar la variabilidad espacial presente entre los parámetros incidentes y los eventos históricos donde se han presentado deslizamientos [65].

La predicción de procesos de remoción en masa por medio de este tipo de modelos ha abordado dos elementos fundamentales de análisis: 1) la autocorrelación espacial global, por medio de los modelos de regresión espacial global (SR), y 2) la autocorrelación local, a través de los modelos geográficamente ponderados (GWR). Los principales trabajos han estado a cargo de [65], [82], [83] y [84].



### 1.3.2.1. Regresión espacial global

El modelo de SR es una técnica en la cual la autocorrelación espacial entre los parámetros que inciden en los procesos de remoción en masa se tiene en cuenta por medio de la construcción de un modelo de interacción espacial [56]. Existen tres tipos de modelos de interacción espacial: regresión automática simultánea, promedio móvil y regresión espacial condicional. El desarrollo teórico se puede abordar en los trabajos realizados por [85], [86], [87], [88], [89], [90] y [91].

[58] aplicaron una regresión automática simultánea para predecir movimientos en masa en la región de More y Romsdal, en Noruega. Los resultados permitieron validar que el modelo de SR tiene mayor rendimiento predictivo, en comparación con el modelo de LR, debido a que este último sobreestima la influencia del parámetro de la pendiente en una región de 5 km<sup>2</sup> y subestima la influencia del parámetro de la precipitación en una región cercana a los 7 km<sup>2</sup>.

Resultados similares se obtuvieron en la región occidental del Marco Negro, en Turquía, donde [82] evidenciaron que el modelo de SR proporciona un mejor rendimiento predictivo en 0,898 unidades de pendiente, en comparación con el modelo de LR, en 0,820 unidades de pendiente. La principal razón para la mejora en el rendimiento del modelo de SR se debe a que las correlaciones espaciales entre las unidades de mapeo se incorporan en el modelo; mientras que este hecho no se considera en el modelo LR.

### 1.3.2.2. Regresión geográficamente ponderada

El modelo de GWR, propuesto por [92], tiene la capacidad de capturar la estacionalidad espacial, es decir, las variaciones espaciales, al permitir que los parámetros de la regresión varíen con la ubicación. Para lograrlo en el modelo de regresión geográficamente ponderada se incorporan coordenadas espaciales [93].

En la literatura, varios estudios han comparado los modelos GWR, LR y aprendizaje automático (ML). Los resultados se han evaluado usando parámetros estadísticos. [94] concluyó al respecto que el GWR logra un mejor rendimiento de generalización ( $R^2 = 0,30$ ), en comparación con el modelo de regresión logístico ( $R^2 = 0,17$ ). [93] sugirieron que el modelo GWR destaca las relaciones locales presentes en el área de estudio, las cuales no son perceptibles en el modelo LR. De esta manera, el modelo GWR proporciona información significativa para el mapeo de la susceptibilidad a procesos de remoción en masa. Los últimos trabajos han comparado en su mayor parte técnicas ML. [84] encontraron en el modelo GWR un mayor rendimiento al analizar el área bajo la curva (AUC = 0,87) en comparación con la técnica de soporte vectorial (AUC = 0,80). Para [95] la capacidad de predicción fue superior hasta en un 19%.

En conclusión, el modelo de SR tiene mayor rendimiento predictivo, en comparación con LR; sin embargo, cuando se investiga la estructura de correlación espacial local de los parámetros de GWR y se incorpora en el mapeo de susceptibilidad, aumenta el poder explicativo del modelo. Por lo tanto, en el mapeo de susceptibilidad de deslizamiento la contribución de cada deslizamiento y sus parámetros desencadenantes varían significativamente.

Sin embargo, [96] encontraron que en ocasiones el modelo GWR presenta algunas desventajas. Por ejemplo, la falta de independencia entre las estimaciones locales puede llevar a la falla en las inferencias válidas para las estimaciones locales. En este contexto, [84] sugieren investigar

métodos de optimización, como pueden ser técnicas de ML, que permitan reducir la cantidad de factores mientras se preserva la precisión de predicción del modelo, lo que disminuye el problema de multicolinealidad y la sensibilidad del modelo al sobreajuste, especialmente en entornos con escasez de datos. Además, son capaces de modelar de manera eficiente relaciones no lineales, las cuales en el ámbito de la evaluación de deslizamientos suelen ser recurrentes, debido a la complejidad del entorno geológico, como a los factores relacionados con el propio desencadenamiento (tormentas, terremotos, erosión, influencia humana, etc.) [97]. En este sentido, los próximos trabajos se han enfocado en reducir los problemas descritos aplicando técnicas de ML.

## 1.4. Aprendizaje automático

El ML, de acuerdo con [98], es el campo emergente de la informática que estudia los algoritmos capaces de aprender a partir de los datos disponibles en un proceso iterativo y de refinamiento gradual. Ello permite encontrar asociaciones que los métodos estadísticos no detectan fácilmente para realizar tareas de procesamiento, como clasificación, predicción o agrupación [99]. En el campo de la predicción de procesos de remoción en masa se han implementado varias técnicas. A continuación, se discuten sus principales aportes.

### 1.4.1. Redes neuronales artificiales

Las ANN son dispositivos de procesamiento implementados como un algoritmo y reaccionan a la entrada de datos de entrenamiento, de tal manera que alteran su estado inicial [28]. Un desarrollo profundo de las ANN se puede abordar en el trabajo realizado por [100]. En el campo de la predicción de movimientos en masa, los datos o las capas de entrada son factores condicionantes de deslizamientos; entonces, el procedimiento continúa asignando pesos a las conexiones entre las capas de entrada de forma aleatoria y eligiendo la cantidad de capas ocultas. El resultado calculado se compara con el esperado y se determina el error; el procedimiento se repite de manera iterativa hasta que se alcanza la convergencia del producto calculado con el esperado.

La red neuronal perceptrón multicapa (MLP), entrenada con el algoritmo Back Propagation, se ha implementado ampliamente en la predicción de procesos de remoción en masa. [101] y [102] encontraron en las ANN un mayor rendimiento en comparación con LR, modelos bivariados, FR y proceso analítico de jerarquía. [103] y [104] compararon el rendimiento de varios tipos de ANN, y sus resultados indicaron que al ingresar más factores en una ANN no necesariamente se produce un mejor resultado, debido a la redundancia y multicolinealidad entre los factores. El resultado con mayor rendimiento predictivo se obtuvo con una red entrenada por 7 capas de entrada, 23 neuronas ocultas y 2 capas de salida.

Trabajos más recientes han confrontado diferentes técnicas de ANN, por ejemplo, [105] evaluaron el rendimiento de dos redes neuronales: MLP y función de base radial (RBF). Los resultados mostraron un mayor rendimiento en la red neuronal MLP (AUC = 88,1%) en comparación con RBF (AUC = 87,24%). Por otra parte, [106] y [107] implementaron redes neuronales recurrentes (RNN) para la predicción de deslizamientos, y los resultados evidenciaron mayor rendimiento en la RNN (83,33%) en comparación con la MLP (78,38%). La principal razón se debe a que las RNN son más apropiadas para modelar sistemas dinámicos no lineales y procesar características más relevantes en los parámetros desencadenantes.

### 1.4.2. Máquinas de soporte vectorial

Las máquinas de soporte vectorial (SVM), propuestas por [108], son un método de clasificación supervisado basado en la minimización del riesgo estructural, usada para clasificación o predicción [109] en modelos no lineales o problemas linealmente separables [110].

En la predicción de procesos de remoción en masa se destacan los trabajos realizados por [111], [112] y [113], de donde sobresalen los aportes obtenidos en la selección del Kernel, siendo la RBF la que ha presentado mejor rendimiento en la predicción de deslizamientos. Algunas de las principales ventajas en la implementación de SVM son su fácil proceso de entrenamiento y su capacidad de encontrar el mejor equilibrio entre la complejidad (generalización) y el error (sobreajuste) [114]. Sin embargo, las SVM no son capaces de atrapar variaciones locales en comparación con las ANN; además, para lograr una buena precisión en la predicción se requiere un mayor tiempo de aprendizaje durante el periodo de calibración del modelo [115].

### 1.4.3. Lógica difusa

Lógica difusa es el resultado del trabajo realizado por [116], y es una de las principales herramientas para manejar problemas complejos, aplicada en un gran número de disciplinas.

En la predicción de zonas susceptibles a procesos de remoción en masa, [117] consideró como miembros de un grupo a los objetos espaciales en un mapa, donde un grupo era cada grado de susceptibilidad al deslizamiento. Estos grupos son el resultado de la combinación de las variables desencadenantes de procesos de remoción en masa (pendiente, curvatura, aspecto, geología, uso del suelo, cobertura de la tierra, etc.) y los valores de pertenencia difusa son cada categoría por variable desencadenante que permiten reflejar el grado de pertenencia a un grupo; de esta manera, teniendo entonces 2 o más grupos con funciones de pertenencia difusa, para el mismo conjunto se puede emplear una variedad de operadores que combinen los valores de pertenencia. De los diferentes operadores aplicados, el operador gamma mostró los mejores resultados (84,68%); por otra parte, el operador lógico (66,50%) evidenció el rendimiento más bajo.

Un importante aporte al uso de la lógica difusa para la predicción de zonas susceptibles a procesos de remoción en masa fue el realizado por [118], al fusionar esta técnica con una ANN, denominada sistema adaptativo de inferencia neurodifusa. En esencia, la ANN es equivalente al sistema de inferencia difusa y su ventaja radica en la posibilidad de optimizar las funciones de pertenencia de tal manera que se minimice la tasa de error de salida, por lo que el sistema neurodifuso puede aprender el comportamiento del fenómeno a partir de un gran conjunto de datos y generar automáticamente reglas difusas a un nivel de precisión preestablecido [119] y [120].

Los resultados del trabajo de [118] permiten concluir que la técnica sistema adaptativo de inferencia neurodifusa muestra un rendimiento bastante razonable con respecto a estudios similares de otros investigadores que utilizan la técnica neurodifusa [121], [122], lógica difusa [117], la técnica de ANN con el algoritmo de aprendizaje backpropagation [123], [124].

Hasta este punto, las técnicas de ML descritas han sido las que más se han aplicado en la predicción de deslizamientos de tierra y otros fenómenos naturales; sin embargo, en la actualidad existen 4 técnicas de ML que poco se han empleado para la predicción de procesos de remoción

en masa, pero que han presentando resultados novedosos en otras disciplinas: modelo logístico de árbol (LMT), bosques aleatorios (RF), clasificación y regresión de árboles (CART), Naive Bayes (NB) y la regresión multivariada adaptativa de splines (MARS) [125].

#### 1.4.4. Naive Bayes

NB es un algoritmo de aprendizaje automático basado en un proceso que estima la probabilidad de una nueva observación perteneciente a una categoría predefinida, utilizando un modelo de probabilidad definido según la teoría de Bayes. La técnica evalúa la probabilidad previa de cada categoría basada en un conjunto de datos de entrenamiento, que se describe por una serie de variables, y asume que esa clasificación podría estimarse calculando la función de densidad de probabilidad condicional y la probabilidad posterior [126].

La técnica de NB usa el teorema de Bayes, que se puede construir para predecir deslizamientos a partir de los siguientes pasos, de acuerdo con [127]:

1. Recopilar un histórico de movimientos en masa sobre el área de estudio.
2. Estimar la probabilidad previa de cada categoría.
3. Estimar la media de cada categoría.
4. Construir matrices de covarianza, encontrar la matriz inversa y el determinante de cada categoría.
5. Construir la función discriminante de cada categoría.

La principal ventaja de la técnica NB es su facilidad de modelar sin necesidad de complicados esquemas iterativos de estimación de parámetros [128]; además, de acuerdo con [129], requiere un pequeño conjunto de datos de entrenamiento para estimar los parámetros de clasificación y, aun así, tener un buen desempeño predictivo [127]. Sin embargo, el clasificador NB no puede aprender de las interacciones entre las características de acondicionamiento, y su rendimiento depende de la ausencia de multicolinealidad entre las variables explicativas, y también carece de una interpretación probabilística.

#### 1.4.5. Modelo logístico de árbol

El LMT es un modelo de clasificación que combina los métodos RF y LR [130]. Su principal ventaja es su capacidad de descomponer problemas complejos, como lo hace RF, en cuestiones más simples con reglas de decisiones, reemplazando los nodos de las hojas de un valor constante en un plano de regresión [131].

[132] presentan una explicación matemática clara sobre el funcionamiento del LMT para predecir procesos de remoción en masa. Adicionalmente, el resultado de su trabajo refleja en el LMT una capacidad de predicción del 86,1% y un valor predictivo positivo del 80%, lo cual permite considerarlo una técnica prometedora para el mapeo de susceptibilidad al deslizamiento. En el caso de [125], el LMT y la RBF lograron obtener valores de AUC más altos para los conjuntos de datos de entrenamiento y validación ( $AUC > 0,8$ ); pero difirieron significativamente para las medidas estadísticas, siendo el LMT la que presentó un mejor rendimiento predictivo ( $AUC = 0,812$ ).

### 1.4.6. Bosques aleatorios

Los RF constituyen un método de aprendizaje propuesto por [132], que utiliza varios árboles de clasificación (bosques) para solucionar problemas de clasificación, regresión y aprendizaje no supervisado [133]. El proceso de predicción de deslizamientos consiste en construir múltiples muestras de entrada, que se conocen como conjuntos de entrenamiento, y en definir una regla de clasificación para cada árbol. La decisión del árbol se basa en predictores seleccionados al azar y la predicción de la clase asignada está determinada por la selección mayoritaria entre todos los árboles. La proporción de árboles en el conjunto que predice la presencia de procesos de ladera se puede utilizar como un índice de susceptibilidad al deslizamiento [134]. Durante este proceso, algunas observaciones que no se utilizan durante la construcción del árbol se omiten del conjunto de entrenamiento. Tales observaciones omitidas crean un conjunto de pruebas, llamadas muestras de out of bag (OOB), que se aplican para evaluar el error de clasificación errónea y para estimar la precisión predictiva esperada [115].

Si bien los resultados obtenidos en la predicción de movimientos en masa por medio de la técnica de LMT han ilustrado que este es capaz de representar adecuadamente la relación cuantitativa entre la ocurrencia de deslizamientos y los diferentes factores detonantes a escala regional [135]. [136] han indicado que la unidad espacial de análisis y el proceso de entrenamiento influyen de manera significativa en la exactitud predictiva de LMT.

### 1.4.7. Clasificación y regresión de árboles

CART es una técnica con enfoque estadístico que utiliza datos históricos para construir árboles de clasificación o de regresión y, de esta manera, clasificar o predecir nuevos valores [137]. El análisis de CART se puede llevar a cabo a partir de 1) construcción de árboles, 2) detección de árboles, 3) poda de árboles y 4) selección óptima de árboles. Un desarrollo profundo se encuentra en el trabajo de [138].

En el trabajo realizado por [130] y [139] se evidenció que la CART tiene una menor calidad predictiva, en comparación con técnicas como RF y LMT, donde el índice AUC dio como resultados valores del 98,5% y del 94,5%, en relación con lo obtenido por la CART (93,3%). Resultados similares se obtuvieron por [137], donde la técnica regresión logística de Kernel presentó un mejor rendimiento predictivo con un valor de AUC de 0,894. Para la técnica CART el resultado fue de 0,842 [115].

### 1.4.8. Regresión multivariada adaptativa de splines

La MARS es un procedimiento de aprendizaje automático relativamente nuevo [115] que combina la regresión lineal clásica, la construcción matemática de splines y la partición recursiva binaria para producir un modelo local en el que las relaciones entre la variable respuesta y los predictores son no lineales o lineales [140]. Un desarrollo matemático profundo se puede encontrar en el trabajo realizado por [141].

Los resultados obtenidos para predecir deslizamientos aplicando MARS han evidenciado algunas mejoras en el rendimiento predictivo, en comparación con técnicas como GLM, GAM y CART [115]. Esto puede deberse, de acuerdo con [142], a problemas de los valores atípicos, el número o el orden de los predictores y los valores de predicción faltantes, razones por las cuales se evidencia

un menor valor de ROC en comparación con la MARS. Resultados similares fueron obtenidos por [141], al comparar la MARS con LR, donde el rendimiento predictivo fue más eficiente, con cerca un 3% de mejora.

Otros trabajos presentan disimilitudes. Para [143], GMA y GLM presentaron un rendimiento por encima del 90%, aplicando el estadístico ROC, en contraste con MARS. [140] evaluaron las técnicas CART y MARS usando el estadístico AUC. Los resultados mostraron que la técnica CART (0,77) posee una capacidad predictiva más alta que MARS (0,76). En conclusión, los resultados obtenidos hasta este punto no han permitido establecer las razones por las cuales MARS evidencia mejores resultados en comparación con otras técnicas, lo que sugiere la necesidad de rastrear nuevos trabajos que permitan determinar los pros y los contras de este método.

### 1.4.9. Árbol de regresión ponderado

El BRT es una combinación de técnicas estadísticas y de ML [115]. Ajusta complejas relaciones no lineales entre variables dependientes e independientes, al combinar una serie de modelos individuales que mejoran el rendimiento del modelo global y árboles de regresión que relacionan una respuesta a sus predictores por divisiones binarias recursivas. En comparación con la técnica de SR, la cual genera un único modelo predictivo, BRT adapta múltiples regresiones, combinándolas para obtener una predicción espacial y, de esta manera, mejorar el rendimiento predictivo de zonas susceptibles a deslizamientos.

Algunos estudios previos han mostrado semejanzas en el rendimiento predictivo entre las técnicas RF y BRT [136]; además, la mayoría de los trabajos califican los resultados de la técnica BRT como satisfactorios. Por ejemplo, [144] indica que entre las técnicas estadísticas comparadas con el BRT y la RF, se obtuvieron rendimientos predictivos excelentes ( $AUC > 0,9$ ).

## 1.5. Modelos híbridos o ensamblados

El modelo híbrido o ensamblado es una de las técnicas que se ha venido implementando con mayor frecuencia en los últimos años para predecir zonas susceptibles a movimientos en masa [145]. Su importancia radica en aprovechar las bondades de las técnicas de aprendizaje automático y la estadística para la correcta selección de variables detonantes de deslizamientos, lo que reduce los tiempos de procesamiento en la predicción de zonas susceptibles [146]; además, ha mostrado una mayor precisión para reconocer áreas de derrumbes, lo que ha permitido evidenciar una mayor eficiencia, en comparación con las metodologías propuestas hasta ahora [147].

En la actualidad, hay una gran cantidad de modelos híbridos propuestos para optimizar el proceso de predicción. Los resultados sugieren la importancia de considerar más de una sola técnica o criterio en el proceso predictivo [144].

La tabla 1 compara las técnicas analizadas. Las primeras 11 columnas responden a las preguntas de sí/no (el símbolo ♦ se usa para indicar la presencia de una característica y un símbolo -- se usa para indicar su ausencia). La tabla evidencia la enorme variedad de técnicas existentes para predecir zonas susceptibles a deslizamientos; además, no hay una técnica que abarque todas las características que permitan establecerla como la idónea para ser implementada en este tipo de fenómenos.



Tabla 1. Técnicas para la predicción de deslizamientos

Técnica	Ponderación variables independientes	Relaciones no lineales	Dependencia espacial	Dependencia temporal	Dependencia espacio-temporal	Variaciones locales	Heterogeneidad	Heterogeneidad espacial	Multilinealidad	Permite variables de diferente naturaleza	Afectado ante presencia de outliers
Modelos bayesianos [20]	♦	--	--	--	--	--	--	--	--	--	♦
Modelos bivariados [29]	♦	--	--	--	--	--	--	--	--	--	
Modelos lineales generalizados (GLM) [46]	--	--	--	--	--	--	♦	--	♦	--	♦
Modelos lineales adaptativos (GAM) [66]	--	♦	--	--	--	--	♦	--	♦	--	♦
Geoestadística [74]	--	--	♦	--	--	♦	♦	♦	♦	--	♦
Regresión espacial global (SR) [63]	--	♦	♦	--	--	--	♦	♦	♦	--	♦
Regresión geográficamente ponderada (GWR) [92]	--	♦	♦	--	--	♦	♦	♦	♦	--	♦
Redes neuronales artificiales (ANN) [100]	--	♦	--	♦	--	♦	♦	--	♦	♦	--
Máquinas de soporte vectorial (SVM) [108]	--	♦	--	--	--	--	♦	--	♦	♦	--
Lógica difusa [116]	♦	♦	--	--	--	--	--	--	--	♦	--
Naive Bayes (NB) [119]	--	--	--	--	--	--	♦	--	--	--	--
Modelo logístico de árbol (LMT) [130]	--	♦	--	--	--	--	♦	--	--	♦	--
Bosques aleatorios (RF) [132]	--	♦	--	--	--	--	♦	--	--	♦	--
Clasificación y regresión de árboles (CART) [138]	--	♦	--	--	--	--	♦	--	--	♦	--
Regresión multivariada adaptativa de splines (MARS) [141]	--	♦	--	--	--	--	♦	--	--	♦	--
Árboles de regresión ponderados (BRT) [115]	--	♦	♦	--	--	♦	♦	--	♦	♦	--
Modelos híbridos o ensamblados [147]	--	♦	♦	--	--	♦	♦	♦	♦	♦	--

Si bien la estrategia híbrida ha intentado incorporar de manera conjunta elementos de la estadística y el aprendizaje automático (denominados modelos híbridos o ensamblados) que permitan abordar la problemática presente por relaciones no lineales entre factores

desencadenantes y movimientos en masa, y el modelamiento de estructuras de dependencia espacial que permitan evaluar la correlación espacial entre los eventos históricos a escala local sobre el área de estudio [152], [153] y [63], estos elementos no se han logrado incorporar. Por lo anterior, la interpretación de los resultados suele ser errada y la predicción de zonas susceptibles a movimientos en masa presenta errores en áreas de la región de estudio en las que la relación construida puede no ser fuerte, debido a variaciones locales, lo que conduce a una menor confiabilidad en los resultados [64].

Otro factor que puede alterar el rendimiento predictivo de los procesos de remoción en masa es la alta correlación temporal presente en la ocurrencia de procesos de remoción en masa, como resultado de la intensidad, la duración de lluvias y otra serie de variables climatológicas [154]; por lo tanto, resulta necesario construir estructuras de dependencia espacio-temporal [155] y [156] que permitan evaluar la presencia de autocorrelación y heterogeneidad espacio-temporal entre los eventos históricos de movimientos en masa analizando el espacio-tiempo en una única instancia.

## 2. Trabajos futuros

En este sentido, en otras disciplinas se han implementado técnicas estadísticas; pero siguen presentando las mismas limitaciones que las técnicas aplicadas hasta este punto en la predicción de deslizamientos, por su falta de capacidad para atrapar relaciones no lineales y la heterogeneidad en los datos (tabla 2). Adicional a los métodos estadísticos, en los últimos años las técnicas de ML (tabla 3) han recibido mayor atención.

De acuerdo con [157], la ventaja comparativa en las técnicas de ML radica en su capacidad de modelar relaciones complejas no lineales para la predicción de fenómenos espacio-temporales. En estos métodos, todas las observaciones históricas de todas las ubicaciones espaciales se usan para predecir una observación en una ubicación  $i$  en un tiempo  $t$ . Sin embargo, cada observación se ve afectada principalmente por sus vecinos dependientes del espacio-tiempo.

No obstante, [158] establece que dichas dependencias espacio-temporales no están bien consideradas en las técnicas de ML para predecir fenómenos espaciales. Además, debido a la heterogeneidad, un modelo global construido con los métodos existentes no logra manejar bien las variaciones en la relación entre variables dependientes e independientes en diferentes regiones del espacio. Estas limitaciones hacen que el entrenamiento de las técnicas de ML sea arbitrario y afecte el rendimiento predictivo [159], [160].

**Tabla 2.** Métodos estadísticos de predicción espacio-temporal.

Método	Expresión	Capacidad		
		Relaciones no lineales	Dependencia espacio temporal	Heterogeneidad
STARIMA	$\text{STARMA}(p, q): \sum_{k=1}^p \sum_{h=0}^{m_k} \varphi_{kh} L^{(h)} Z_i(t-k) + \varepsilon_i(t) - \sum_{l=1}^q \sum_{h=0}^{n_l} \theta_{lh} L^{(h)} \varepsilon_i(t-l)$	Relaciones no lineales	Dependencia espacio temporal	Heterogeneidad
	$\text{STAR}(p): Z_i(t) = \sum_{k=1}^p \sum_{h=0}^{m_k} \varphi_{kh} L^{(h)} Z_i(t-k)$	No	Si	No
	$\text{STMA}(q): z_i(t) = \varepsilon_i(t) - \sum_{l=1}^q \sum_{h=0}^{n_l} \theta_{lh} L^{(h)} \varepsilon_i(t-l)$	No	Si	No

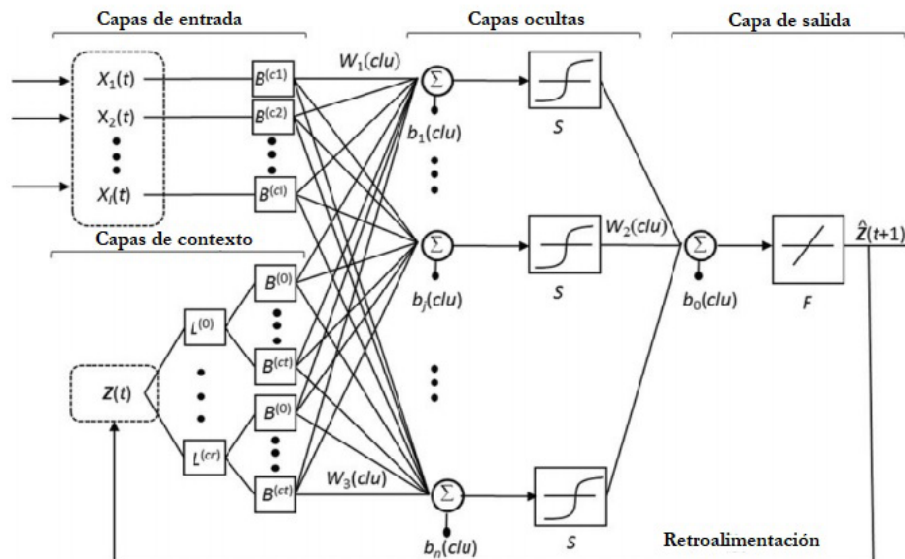
Método	Expresión	Capacidad		
		Relaciones no lineales	Dependencia espacio temporal	Heterogeneidad
GTWR	$z_i(t) = \beta_0(x_i, y_i, t_i) + \sum_{l=1}^k \beta_l(x_i, y_i, t_i) x_{il}(t) + \varepsilon_i(t)$	No	No	Si
Geoestadística espacio temporal	Semivariograma $\gamma(h_s, h_t) = 1/2 COV(z_i(t) - z_{i+h_s}(t + h_t))$	No	Si	No
	Separado $\gamma(h_s, h_t) = \gamma_s(h_s) \odot \gamma_t(h_t)$	No	Si	No
	No separado $\gamma(h_s, h_t) = (k_1 C_s(0) + k_2) \gamma_s(h_s) + (k_1 C_s(0) + k_3) \gamma_t(h_t) - k_1 \gamma_s(h_s) \gamma_t(h_t)$	No	Si	No

**Tabla 3.** Clasificación taxonómica de las ANN para el análisis y modelación de datos espaciales

Topología de conexión	Entrenamiento	Técnica	Estudios previos
Feedforward	Supervisado	Back Propagation	[101], [102] y [104]
		Radial basis function	[161] y [107]
	No Supervisado	No hay ejemplos	
Feedback	Supervisado	Fuzzy ARTMAP	[162] y [163]
		Back Propagation Real Time	[158] y [164]
		Self-Organizing map	[165] y [166]
	No Supervisado	ART-1	[167]
		ART-2	[168]

Para superar estas limitaciones, algunos autores sugieren incorporar estructuras de dependencia espacio-temporal en la topología de conexión de las ANN [156]. De esta manera, se logran abordar los elementos que hasta este momento han presentado un vacío conceptual al momento de predecir zonas susceptibles a procesos de remoción en masa. Esta técnica se ha aplicado con éxito en otros campos de investigación; por lo tanto, resulta de especial interés investigar su aplicabilidad en eventos naturales.

Dada la inexistencia de estas aplicaciones en la literatura especializada, se hará una aproximación conceptual de la aplicabilidad de una ANN con estructuras de dependencia espacio-tiempo (HSTANN) en la predicción de zonas susceptibles a movimientos en masa. La estructura de ANN propuesta por [156] se puede observar en la figura 2, donde se tienen dos tipos de capas de entrada. Para el caso de la predicción de deslizamientos, estas serían variables detonantes (geología, geomorfología, pendiente, TWI, distancia a vías, distancia a fallas, MDT, aspecto, etc.). Como segundo elemento de entrada se tienen las capas de contexto, las cuales consisten en un grupo de clústeres resultado del análisis de dependencia espacial de variables derivadas de lluvias como: lluvias diarias, precipitación media anual, precipitación diaria normalizada, número promedio de días con lluvia y lluvias antecedentes; todas estas variables asociadas al lugar donde ha ocurrido el movimiento en masa. Finalmente, el proceso de aprendizaje de la ANN propuesta utiliza el registro histórico de eventos como método de aprendizaje para predecir nuevas zonas susceptibles a movimientos en masa.



**Figura 2.** Red neuronal artificial con estructuras de dependencia espacio-tiempo  
Fuente: tomado de [156].

La construcción de los clústeres espaciales se desarrolla como parte del análisis exploratorio de datos espaciales. Desde esta perspectiva, Geo-SOM proporciona un conjunto de herramientas exploratorias de análisis de datos espaciales que combina técnicas visuales interactivas que respaldan ambas perspectivas analíticas [172]. Para realizar el análisis de dependencia de datos espaciales, [165] mencionan dos métodos: los space-time, que intentan analizar los cambios de la situación espacial a lo largo del tiempo, y los time-space, diseñados para analizar la distribución de las variaciones temporales locales sobre el espacio. Para la predicción de procesos de remoción en masa se recomienda el método time-space, el cual permite tener en cuenta la proximidad espacial y la similitud de los eventos en el tiempo. A continuación, se describe las fases propuestas para la implementación del modelo HSTANN en la predicción de zonas susceptibles a deslizamientos (figura 3).

## 2.1. Fase 1: adquisición y preparación de la información

La primera fase se centra en la recopilación y procesamiento de información, con el fin de obtener como producto un conjunto de variables detonantes de deslizamientos y un registro histórico organizado y depurado de las zonas del área de estudio donde se han presentado este tipo de eventos.

En la preparación de las variables detonantes de procesos de ladera se debe vectorizar la cartografía y obtener del MDT el ángulo y aspecto de la pendiente; también la curvatura, el plano de curvatura y el perfil de curvatura. Adicional se calculan el TWI y las áreas de influencia para la infraestructura vial, hidrografía y fallas presentes en el área de estudio. Estos insumos, junto con la ubicación geográfica de los registros históricos de movimientos en masa, son procesados y almacenados en un SIG.

Luego de contar con la información procesada, se realiza un análisis exploratorio de datos espaciales entre las variables independientes producto de la actividad anterior y los registros históricos de procesos de remoción en masa, con el fin de identificar correlaciones sobre el conjunto de datos e identificar problemas de multicolinealidad.

## 2.2. Fase 2: implementación de estructuras de dependencia espacio-tiempo en una red neural artificial parcialmente recurrente

La segunda fase se centra en la integración de estructuras de dependencia espacio-tiempo de los registros históricos de deslizamientos en la topología de conexión de una red neural artificial parcialmente recurrente, junto con las variables detonantes producto de la fase 1.

La asociación de series espacio-temporales para los registros históricos de movimientos en masa es la primera actividad. El objetivo es emplear el método de agrupación por clúster para modelar las características espaciales de los registros históricos, teniendo en cuenta tanto la proximidad espacial como la similitud de la serie de tiempo. El mapa de autoorganización (SOM), “que pertenece a los métodos basados en modelos”, proporciona las capacidades para mejorar la calidad general del análisis de datos geospaciales multidimensionales [165], [166]. Para considerar tanto la proximidad espacial como la similitud de series de tiempo, se utiliza una extensión de SOM (Geo-SOM) [167].

En el proceso de generar los clústeres se debe, inicialmente, segmentar el conjunto de datos de espacio-tiempo en una serie de clústeres usando Geo-SOM y los índices de validez de agrupamiento. Después, para cada clúster se define la matriz de ponderación espacial basada en diagramas de Voronoi y se identifican los retardos de espacio y tiempo utilizando ST-ACF y ST-PACF. Finalmente, se adaptan las estructuras de dependencia espacio-tiempo en una red neuronal artificial parcialmente recurrente. En esta actividad se selecciona la red Jordan, una red neural parcialmente recurrente que permite la entrada de variables independientes (obtenidas en la fase 1) y estructuras de dependencia espacio-tiempo. Como algoritmo de aprendizaje se usan back propagation real time y la función de activación sigmoide.

## 2.3. Fase 3: predicción y validación

La fase final corresponde a la predicción de procesos de remoción en masa. Para ello se toma el 30% del total de los datos reportados a la fecha. En este paso es importante utilizar algunos estadísticos matemáticos implementados ampliamente para la validación de modelos predictivos (ROC, AUC y RMSE).

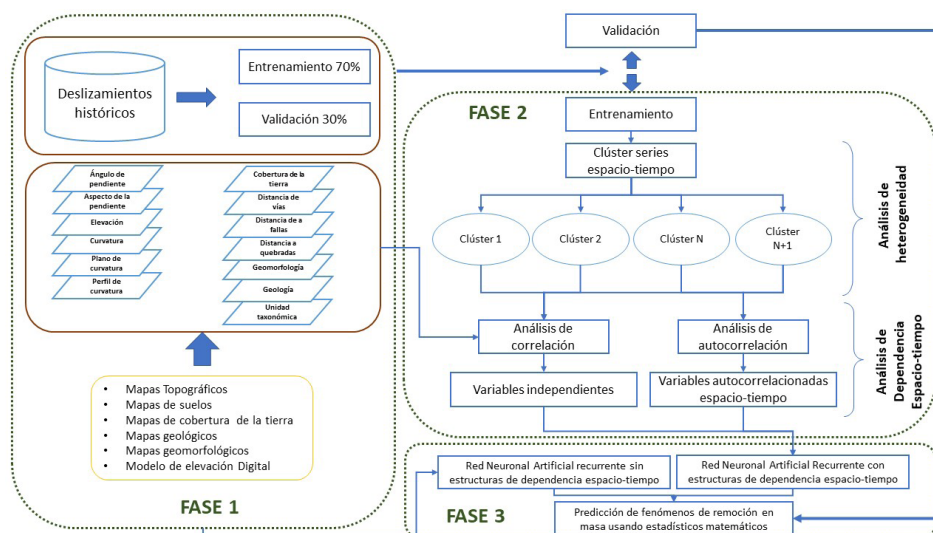


Figura 3. Metodología para la predicción de zonas susceptibles a deslizamientos con estructuras de dependencia espacio-tiempo

## Conclusiones

Las técnicas híbridas propuestas en los últimos años, si bien han mejorado el rendimiento predictivo en comparación con modelos heurísticos y estadísticos, han ido reduciendo su margen de mejora, lo que lleva a que hoy en día aún se debata cuál es la manera más adecuada para modelar los procesos de ladera y predecir nuevas zonas susceptibles. Esto se debe a que no solo es cuestión de la técnica que se implementa, sino que se han encontrado que elementos como la escala a la cual son capturadas las variables detonantes y las condiciones geoambientales del área de estudio pueden afectar en diferente grado las técnicas predictivas. Por lo tanto, resulta importante la comprensión y el conocimiento de estas diferencias para aplicar un modelo adecuado en un área de estudio determinada [176].

Si bien algunos elementos de la estadística consumen tiempo en los procesos de entrada, salida y análisis, estos permiten mejorar el rendimiento predictivo cuando se combinan con técnicas de ML, así estas sean capaces de identificar automáticamente las interacciones entre variables dependientes e independientes [124]. Por lo tanto, el implementar elementos de la estadística evita el enfoque de caja negra en el análisis espacial, predicción e interpretación de los resultados.

Uno de los principales elementos que ha sido descuidado en la predicción de deslizamientos es el componente espacio-temporal. Las actuales técnicas propuestas no están construidas para modelar de manera adecuada la heterogeneidad espacio-temporal, por lo que sin la consideración de la dependencia espacio-tiempo el método de entrenamiento resulta arbitrario, lo que hace más difícil interpretar los resultados. Por lo tanto, si la heterogeneidad espacio-tiempo no se modela de modo adecuado, el modelo predictivo construido podría ser inválido en regiones locales sobre el área de estudio. Por ello, se sugiere sondear en la implementación de asociaciones espacio-temporales dentro de la arquitectura de aprendizaje de las técnicas de ML y la estadística espacial con el uso de herramientas como GeoSOM.

De los métodos de validación aplicados, los estadísticos AUC y ROC —los que más se han utilizado para validar el rendimiento predictivo— no son la mejor alternativa, debido a que, en algunos casos, un AUC o ROC alto no son garantía de una alta precisión en predicciones espaciales; por esta razón, se recomienda validar los resultados comparando con otros estadísticos (como el error medio cuadrático) o implementar una validación espacial cruzada, dividiendo el área de estudio en zonas de interés y en cada una de ellas evaluar el rendimiento predictivo del modelo propuesto.

## Referencias

- [1] E. Aristizábal, T. González, J. D. Montoya, J. I. Vélez, H. Martínez y A. Guerra, “Análisis de umbrales empíricos de lluvia”, EIA, pp. 95-111, 2011.
- [2] G.-S. Debarati, P. Hoyois y R. Below, Annual Disaster Statistical Review 2009. The numbers and trends, Bruselas: Centre for Research on the Epidemiology of Disasters, 2015.
- [3] K. Sassa y Ž. Arbanas, “Landslides: Journal of the International Consortium on Landslides”, Advancing Culture of Living with Landslides, pp. 257-267, 2017.
- [4] L. G. Stefano y F. Guzzetti, “Landslides in a changing climate”, Earth Sci. Rev., pp. 2-42, 2016.



- [5] D. Salciarini, E. Volpe, S. A. Kelley, L. Brocca, S. Camici, G. Fanelli y C. Tamagnini, "Modeling the effects induced by the expected climatic trends on landslide activity at large scale", *Proc. Eng.*, pp. 541-545, 2016.
- [6] H. Shahabi, S. Khezri, B. Ahmad y M. Hashim, "Landslide susceptibility mapping at central Zab basin, Iran: a comparison between analytical hierarchy process, frequency ratio and logistic regression models", *Catena*, pp. 55-70, 2014.
- [7] L. Montanarella, "The EU thematic strategy on soil protection. In land degradation in Central and Eastern Europe", Office for Official Publications of the European Communities, Luxembourg, 2003.
- [8] D. Alexander, "On the causes of landslides: Human activities, Perception, and Natural Processes", *Environ. Geol. Water*, pp. 165-179, 1992.
- [9] S.-B. Bai, J. Wang, G.-N. Lü, P.-G. Zhou, S.-S. Hou y S.-N. Xu, "GIS-based and data-driven bivariate landslide-susceptibility mapping in the Three Gorges Area, China", *Pedosphere*, pp. 14-20, 2009.
- [10] R. Anbalagan, "Landslide hazard evaluation and zonation mapping in mountainous terrain.", *Eng. Geol.*, pp. 269-277, 1992.
- [11] A. Pachauri y M. Pant, "Landslide hazard mapping based on geological attributes", *Eng. Geol.*, pp. 81-100, 1992.
- [12] E. A. Castellanos Abella y V. W. Cees J., "Qualitative landslide susceptibility assessment by multicriteria analysis: A case study from San Antonio del Sur, Guantánamo, Cuba", *Geomorphology*, pp. 453-466, 2008.
- [13] A. Quesada Román y G. Barrantes Castillo, "Modelo morfométrico para determinar áreas susceptibles a procesos de ladera", *Invest. Geog.*, vol. 2017, pp. 37-48, 2017.
- [14] F. Aceves Quesada, G. Legorreta Paulín y Y. Álvarez Ruiz, "Cartografía geomorfológica para el inventario de procesos gravitacionales", *Bol. Soc. Geol. Mex.*, vol. 66, n.º 2, pp. 329-342, 2014.
- [15] A. Quesada Román y G. Barrantes Castillo, "Procesos de ladera cosísmicos del terremoto de Cinchona (Costa Rica) del 8 de enero de 2009 (Ms= 6,2)", *Cuad. Geog.*, vol. 25, n.º 1, pp. 217-232, 2016.
- [16] H. Pourghasemi, M. Mohammady y B. Pradhan, "Landslide susceptibility mapping using index of entropy and conditional probability models in GIS: Safarood Basin", *CATENA*, pp. 71-84, 2012.
- [17] B. Pham, B. Pradhan, D. Tien Bui, I. Prakash y M. Dholaki, "A comparative study of different machine learning methods for landslide susceptibility assessment: a case study of Uttarakhand area", *Environ. Model Softw.*, pp. 240-250, 2016.
- [18] B. T. Pham, D. Tien Bui, I. Prakash y M. Dholakia, "Hybrid integration of Multilayer Perceptron Neural Networks and machine learning ensembles for landslide susceptibility assessment at Himalayan area (India) using GIS", *Catena*, vol. 149, pp. 52-63, 2017.
- [19] H. Raiffa y R. Schlaifer, *Applied statistical decision theory*, Boston: Harvard University Press, p. 356, 1961.
- [20] G. A. Griffiths, "stochastic prediction in geomorphology using bayesian inference models", *Math. Geol.*, pp. 66-74, 1982.
- [21] S.-Q. Wang y D. J. Unwin, "Modelling landslide distribution on loess soils in China: an investigation", *Int. J. Geograph. Inform. Syst.*, pp. 391-405, 1992.
- [22] A. Carrara, M. Cardinali y F. Guzzetti, "Uncertainty in assessing landslide hazard and risk", *ITC J.*, pp. 172-183, 1992.
- [23] C.-J. F. Chung y A. G. Fabbri, "The representation of geoscience information for data integration", *Nonrenewable Resources*, pp. 122-139, 1993.
- [24] C.-J. F. Chung y A. G. Fabbri, "Probabilistic prediction models for landslide hazard mapping", *Photogramm. Eng. Rem. S.*, pp. 1389-1399, 1999.

- [25] S. Lee, J. Choi y K. Min, "Landslide susceptibility analysis and verification using the Bayesian probability model", *Environ. Geol.*, pp. 120-131, 2002.
- [26] B. Neuhäuser y B. Terhorst, "Landslide susceptibility assessment using "weights-of-evidence" applied to a study area at the Jurassic escarpment (SW-Germany)", *Geomorphology*, pp. 12-24, 2007.
- [27] H.R. Pourghasemi, M. Mohammady y B. Pradhan, "Landslide susceptibility mapping using index of entropy and conditional probability models in GIS: Safarood Basin, Iran", *Catena*, pp. 71-84, 2012.
- [28] P. Aleotti y R. Chowdhury, "Landslide hazard assessment: summary review and new perspectives", *Bulletin of Eng. Geol. and the Environment*, pp. 21-44, 1999.
- [29] A. Nandi y A. Shakoor, "A GIS-based landslide susceptibility evaluation using bivariate and multivariate statistical analyses", *Eng. Geol.*, pp. 11-20, 2010.
- [30] C. van Westen, *Statistical landslide hazard analysis*, ITC Publication, 1997.
- [31] P. Rautela y R. Lakhera, "Landslide risk analysis between Giri and Ton Rivers in Himalaya (India)", *Int. J. Appl. Earth Obs.*, pp. 153-160, 2000.
- [32] A. Lulseged, Y. Hiromitsu y U. Norimitsu, "Landslide susceptibility mapping using GIS-based weighted linear combination, the case in Tsugawa area of Agano River, Niigata Prefecture, Japan", *Landslides*, pp. 73-81, 2004.
- [33] L. S. Mehmet y Vedat Doyuran, "Data driven bivariate landslide susceptibility assessment using geographical information systems: a method and application to Asarsuyu catchment, Turkey", *Eng. Geol.*, pp. 303-321, 2004.
- [34] L. S. Mehmet y V. Doyuran, "A comparison of the GIS based landslide susceptibility assessment methods: multivariate versus bivariate", *Environ. Geol.*, pp. 665-679, 2004.
- [35] T. Kavzoglu, K. Emrehan y C. Ismail, "An assessment of multivariate and bivariate approaches in landslide susceptibility mapping: a case study of Duzkoy district", *Nat. Hazards*, pp. 471-496, 2015.
- [36] D. Kubwimana, L. Ait Brahim, M. Bousta, O. Dewitte, A. Abdelouafi y T. Bahaj, "Landslides susceptibility assessment using AHP method in Kanyosha watershed (Bujumbura-Burundi): Urbanisation and management impacts", de MATEC Web of Conferences, Rabat, 2018.
- [37] A. Quesada Román y S. Feoli-Boraschi, "Comparación de la metodología Mora-Vahrson y el método morfométrico para determinar áreas susceptibles a deslizamientos en la microcuenca del río Macho, Costa Rica", *Rev. Geog. Am. Centr.*, vol. 61, pp. 17-45, 2018.
- [38] A. Quesada-Román y J. J. Zamorano Orozco, "Peligros geomorfológicos en Costa Rica: Cuenca Alta del Río General", *Anu. Instit. Geociênc.*, vol. 41, n.º 3, pp. 239-251, 2018.
- [39] A. Yalcin, "GIS-based landslide susceptibility mapping using analytical hierarchy process and bivariate statistics in Ardesen (Turkey): Comparisons of results and confirmations", *CATENA*, pp. 1-12, 2008.
- [40] G. Demir, A. Mustafa y A. Aykut, "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", *Nat. Hazards*, pp. 1481-1506, 2013.
- [41] S. Nader, A. Kassim y L. Min Lee, "Susceptibility assessment of shallow landslides in Hulu Kelang area, Kuala Lumpur, Malaysia using analytical hierarchy process and frequency ratio", *Geotech. Eng. Geol.*, pp. 43-57, 2015.
- [42] A. Nandi y A. Shakoor, "A GIS-based landslide susceptibility evaluation using bivariate and multivariate statistical analyses", *Eng. Geol.*, pp. 11-20, 2009.
- [43] C. Yilmaz, T. Topal y S. Mehmet, "GIS-based landslide susceptibility mapping using bivariate statistical analysis in Devrek (Zonguldak-Turkey)", *Environ. Earth Sci.*, pp. 2161-2178, 2012.

- [44] E. López González y M. Ruiz Soler, "Análisis de datos con el Modelo Lineal Generalizado. Una aplicación con R", *Rev. Esp. Pedagog.*, pp. 59-80, 2011.
- [45] M. Ato García, *Modelo lineal generalizado*, Documenta Universitaria, 2005.
- [46] A. Carrara, "Multivariate models for landslide hazard evaluation", *Math.Geol.*, pp. 403-426, 1983.
- [47] D. W. Hosmer y S. Lemeshow, *Applied Logistic Regression*, Ohio: John Wiley & Sons, 2000.
- [48] K. Lange, *Mathematical and Statistical Methods for Genetic Analysis*, Los Ángeles: Springer, 2002.
- [49] B. Pradhan, "Landslide susceptibility mapping of a catchment area using frequency ratio, fuzzy logic and multivariate logistic regression approaches", *J. Indian Soc. Remote*, pp. 301-320, 2010.
- [50] B. Pradhan, "Remote sensing and GIS-based landslide hazard analysis and cross-validation using multivariate logistic regression model on three test areas in Malaysia", *Adv. Space Res.*, pp. 1244-1256, 2010.
- [51] S. Bai, G. Lü, W. Jian, Z. Pinggen y D. Liang, "GIS-based rare events logistic regression for landslide-susceptibility mapping of Lianyungang, China", *Environ. Earth Sci.*, pp. 139-149, 2011.
- [52] O. F. Althuwaynee, B. Pradhan, P. Hyuck-Jin y H. L. Jung, "A novel ensemble bivariate statistical evidential belief function with knowledge-based analytical hierarchy process and multivariate statistical logistic regression for landslide susceptibility mapping", *Catena*, pp. 21-36, 2014.
- [53] H. Hasali, R. Rangali, N. L. Deshapriya y L. Samarakoon, "Landslide susceptibility mapping using logistic regression model (a case study in Badulla District, Sri Lanka)", *Procedia Eng.*, pp. 1046-1053, 2018.
- [54] S. Lee, "Application of Likelihood Ratio and Logistic Regression Models to Landslide Susceptibility Mapping Using GIS", *Environ. Manage.*, pp. 223-232, 2004.
- [55] L. Ayalew y H. Yamagishi, "The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan", *Geomorphology*, pp. 12-31, 2005.
- [56] J. Mathew, V. K. Jha y G. S. Rawat, "Landslide susceptibility zonation mapping and its validation in part of Garhwal Lesser Himalaya, India, using binary logistic regression analysis and receiver operating characteristic curve method", *Landslides*, pp. 17-26, 2009.
- [57] S. Lee, "Application of logistic regression model and its validation for landslide susceptibility mapping using GIS and remote sensing data", *Int. J. Remote. Sens.*, pp. 1477-1491, 2005.
- [58] O. Adnan y A. Tolga, "A comparative study of frequency ratio, weights of evidence and logistic regression methods for landslide susceptibility mapping: Sultan Mountains, SW Turkey", *J. Asian Earth Sci.*, pp. 1-18, 2013.
- [59] D. Tien Bui, O. Lofman, R. Inge y O. Dick, "Landslide susceptibility analysis in the Hoa Binh province of Vietnam using statistical index and logistic regression", *Nat. Hazards*, pp. 1413-1444, 2011.
- [60] J. Hanley y B. McNeil, "The meaning and use of the area under a receiver operating characteristic (ROC) curve", *Radiology*, pp. 29-36, 1982.
- [61] E. Yesilnacar y T. Topal, "Landslide susceptibility mapping: A comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey)", *Eng. Geol.*, pp. 251-266, 2005.
- [62] H. R. Pourghasemi y N. Kerle, "Random forests and evidential belief function-based landslide susceptibility assessment in Western Mazandaran Province, Iran", *Environ. Earth Sci.*, pp. 75-185, 2016.

- [63] H. Düzgün y S. Kemeç, "Spatial regression and geographically weighted regression for spatial prediction", en *The Encyclopedia of Geographical Information*, s. d., 2008.
- [64] A. Erener, H. Sebnemy B. Düzgün, "Improvement of statistical landslide susceptibility mapping by using spatial and global regression methods in the case of More and Romsdal (Norway)", *Landslides*, pp. 55-68, 2010.
- [65] A. Erener, H. Sebnemy B. Düzgün, "Improvement of statistical landslide susceptibility mapping by using spatial and global regression methods in the case of More and Romsdal (Norway)", *Landslides*, pp. 7-55, 2010.
- [66] T. Hastie y R. Tibshirani, *Generalized additive models*, Chapman, 1990.
- [67] J. N. Goetz, R. H. Guthrie y A. Brenning, "Integrating physical and empirical landslide susceptibility models using generalized additive models", *Geomorphology*, pp. 376-386, 2011.
- [68] N. R. Regmi, G. R. John y J. D. Vitek, "Modeling susceptibility to landslides using the weight of evidence approach: Western Colorado, USA", *Geomorphology*, pp. 172-187, 2010.
- [69] S. Abeare, Comparisons of boosted regression tree, GLM, and GAM performance in the standardization of yellowfin tuna catchrate data from the Gulf of Mexico longline fishery, 2009.
- [70] N. Cressie, *Statistics for Spatial Data*, Revised Edition, New York: John Wiley & Sons, 1991.
- [71] B. D. Ripley, "Modelling spatial patterns", *J. Royal Stat. Soc. Series B (Methodological)*, vol. 39, n.º 2, pp. 172-212, 1977.
- [72] D. G. Krige, "A Statistical Approaches to Some Basic Mine Valuation Problems on the Witwatersrand", *J. Chem., Metall. Min. Soc. South Afr.*, pp. 119-139, 1951.
- [73] G. Matheron, "Traité de géostatistique appliquée", de Tome I: Mémoires du Bureau de Recherches Géologiques et Minières, Paris: Editions, 1962, p. 333.
- [74] J. Chacón, C. Irigaray, T. Fernández y R. El Hamdouni, "Engineering geology maps: landslides and geographical information systems", *Bull. Eng. Geol. Environ.*, pp. 341-411, 2006.
- [75] E. Canli y T. Glade, "Spatially Distributed Rainfall Prediction Based on Automated Kriging for Landslide Early Warning Systems", *World Academy of Science, Engineering and Technology International Journal of Mathematical and Computational Sciences*, 2017.
- [76] M. Tuhua, L. Changjiang, L. Zhiming y B. Qiyun, "Rainfall intensity-duration thresholds for the initiation of landslides in Zhejiang Province, China", *Geomorphology*, pp. 193-206, 2015.
- [77] C.-W. Chen, H. Saito y T. Oguchi, "Rainfall intensity-duration conditions for mass movements in Taiwan", *Prog. Earth Planet. Sci.*, pp. 2-14, 2015.
- [78] A. M. Ramos-Cañón, M. G. Trujillo-Vela, L. F. Prada-Sarmiento, "Niveles umbrales de lluvia que generan deslizamientos: una revisión crítica". *Cienc. Ing. Neogranad.*, 61-80, 2015.
- [79] L. D. Miguel Fonseca, L. João Luiz, F. F. Elpídio Inácio, R. D. S. Gerson, M. F. Williams Pinto, T. S. Adriana Maria Rocha, "Variability in soil physical properties in landslide-prone areas", *Acta Scientiarum. Agronomy*, pp. 109-118, 2017.
- [80] L. Lombardo, H. Bakka, H. Tanyas, C. van Westen, M. Mai y H. Raphael, "Geostatistical modeling to capture seismic-shaking patterns from earthquake-induced landslides", de *AMCS/STAT Graduate Seminar*, New York, 2018.
- [81] C. D. Iswar, *Spatial Statistical modelling for assesing landslide hazard and vulnerability*, Twente: University of Twente, 2011.
- [82] A. Erener, H. S. B. Düzgün, "Landslide susceptibility assessment: what are the effects of mapping unit and mapping method?", *Environ. Earth Sci.*, pp. 859-877, 2012.
- [83] S. Park, J. Kim, "A comparative analysis of landslide susceptibility assessment by using global and spatial regression methods in Inje Area, Korea", *J. Korean Soc. Surv., Geode., Photogramm. Cartogr.*, pp. 579-587, 2015.

- [84] H. Hong, B. Pradhan, M. I. Sameen, C. Wei, C. Xu, "Spatial prediction of rotational landslide using geographically weighted regression, logistic regression, and support vector machine models in Xing Guo area (China)", *Geomat. Nat. Haz. Risk*, pp. 1997-2022, 2017.
- [85] L. Anselin, *Spatial Econometrics: Methods and Models*, Dordrecht: Kluwer, 1988, pp. 32-33.
- [86] R. Dubin, "Estimation of regression coefficients in the presence of spatially autocorrelated error terms", *Rev. Econ. Statist.*, pp. 466-474, 1988.
- [87] R. Dubin, "Spatial autocorrelation and neighborhood quality", *Reg. Sci. Urban Econ.*, pp. 433-452, 1992.
- [88] L. Anselin, "Local indicators of spatial association—LISA", *Geogr. Anal.*, pp. 93-115, 1995.
- [89] A. Fotheringham, "Trends in quantitative methods I: stressing the local", *Progr. Hum. Geogr.*, pp. 261-272, 1997.
- [90] R. K. Pace, "Performing large spatial regressions and autoregressions", *Econ. Letters*, pp. 283-291, 1997.
- [91] C. Brunsdon, A. Fotheringham y M. Charlton, "Spatial nonstationarity and autoregressive models.", *Environ. Plann.*, pp. 957-973, 1998.
- [92] C. Brunsdon, A. Fotheringham y M. Charlton, "Geographically weighted regression: A method for exploring spatial nonstationarity", *Geogr. Anal.*, pp. 281-298, 1996.
- [93] T. Feuillet, J. Coquin, D. Mercier, E. Cossart, A. Decaulne, H. Páll Jónsson y S. Þorsteinn, "Focusing on the spatial non-stationarity of landslide predisposing factors in northern Iceland: Do paraglacial factors vary over space?", *Prog. Phys. Geogr. Earth Environ.*, pp. 354-377, 2014.
- [94] S. Park y J. Kim, "A comparative analysis of landslide susceptibility assessment by using global and spatial regression methods in Inje Area, Korea", *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, pp. 579-587, 2015.
- [95] Y. Xianyu, W. Yi, N. Ruiqing y H. Youjian, "A combination of geographically weighted regression, particle swarm optimization and support vector machine for landslide susceptibility mapping: a case study at Wanzhou in the Three Gorges Area, China", *Int. J. Environ. Res. Public Health*, p. 487, 2016.
- [96] S. Sua, X. Rui y Z. Yuan, "Multi-scale analysis of spatially varying relationships between agricultural landscape patterns and urbanization using geographically weighted regression", *App. Geogr.*, pp. 360-375, 2012.
- [97] M. Marjanović, K. Miloš, B. Bajat y V. Voženilek, "Landslide susceptibility assessment using SVM machine learning algorithm", *Eng. Geol.*, pp. 225-234, 2011.
- [98] T. M. Mitchell, *Machine Learning*, New York: McGraw Hill, 1997.
- [99] O. Korup y A. Stolle, "Nat. Hazards explained. Landslide prediction from machine learning", *Geology Today*, pp. 26-33, 2014.
- [100] I. Basheer y M. Hajmeer, "Artificial neural networks: fundamentals, computing, design, and application", *J. Microbiol. Methods*, pp. 3-31, 2000.
- [101] B. Pradhan y S. Lee, "Landslide susceptibility assessment and factor affect analysis: back-propagation artificial neural networks and their comparison with frequency ratio and bivariate logistic regression modelling.", *Environ. Model. Softw.*, pp. 747-759, 2010.
- [102] S. Park, C. Chuluong y K. Byungwoo, "Landslide susceptibility mapping using frequency ratio, analytic hierarchy process, logistic regression, and artificial neural network methods at the Inje area, Korea", *Environ. Earth Sci.*, pp. 1443-1464, 2013.
- [103] V. Nourani, B. Pradhan y H. Ghaffari, "Landslide susceptibility mapping at Zonouz Plain, Iran using genetic programming and comparison with frequency ratio, logistic regression, and artificial neural network models", *Nat. Hazards*, pp. 523-547, 2014.



- [104] D. Jie, H. Yamagishi, H. R. Pourg, A. P. Yunus, S. Xuan, Y. Xu y Z. Zhongfan, "An integrated artificial neural network model for the landslide susceptibility assessment of Osado Island, Japan", *Nat. Hazards*, p. 1749-1776, 2015.
- [105] M. Zare, H. R. Pourghasemi, M. Vafakhah y B. Pradhan, "Landslide susceptibility mapping at Vaz Watershed (Iran) using an artificial neural network model: A comparison between multilayer perceptron (MLP) and radial basic function (RBF) algorithms", *Arab. J. Geosci.*, pp. 1-16, 2012.
- [106] H. Chen, Z. Zeng y H. Tang, "Landslide deformation prediction based on recurrent neural network", *Neural Process. Lett.*, pp. 169-178, 2015.
- [107] M. R. Mezaal, B. Pradhan, M. I. Sameen, H. Z. Mohd Shafri y Z. Md Yusoff, "Optimized Neural Architecture for Automatic Landslide Detection from High-Resolution Airborne Laser Scanning Data", *App. Sci.*, pp. 2-20, 2017.
- [108] V. Vapnik, *The Nature of Statistical Learning Theory*, New York: Springer-Verlag, 1995.
- [109] V. Vapnik, *The Nature of Statistical Learning*, New York: Springer, 2000.
- [110] J. Broséus, M. Vallat y P. Esseiva, "Multi-class differentiation of cannabis seedlings in a forensic context", *Chemom. Intell. Lab. Syst.*, p. 343-350, 2011.
- [111] M. Marjanović, M. Kovačević, B. Bajat y V. Voženílek, "Landslide susceptibility assessment using SVM machine learning algorithm", *Eng. Geol.*, pp. 225-234, 2011.
- [112] H. Hong, B. Pradhan, D. T. Bui, C. Xu, A. M. Youssef y W. Chen, "Comparison of four kernel functions used in support vector machines for landslide susceptibility mapping: a case study at Suichuan area (China)", *J. Geom., Nat. Hazards Risk*, pp. 1-26, 2017.
- [113] B. Pradhan y M. I. Sameen, "Manifestation of SVM-Based Rectified Linear Unit (ReLU) Kernel Function in Landslide Modelling", *Space Sci. Commun. Sustainability*, pp. 185-195, 2018.
- [114] W. Chen, H. R. Pourghasemi, A. Kornejadyc y N. Zhanga, "Landslide spatial modeling: Introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques", *Geoderma*, pp. 314-327, 2017.
- [115] H. R. Pourghasemia y O. Rahmat, "Prediction of the landslide susceptibility: Which algorithm, which precision?", *Catena*, pp. 177-192, 2018.
- [116] L. Zadeh, "Fuzzy sets", *IEEE Inf. Control*, pp. 338-353, 1965.
- [117] S. Lee, "Application and verification of fuzzy algebraic operators to landslide susceptibility mapping", *Environ. Geol.*, pp. 615-623, 2007.
- [118] H.-J. Oh y B. Pradhan, "Application of a neuro-fuzzy model to landslide-susceptibility mapping for shallow landslides in a tropical hilly area", *Comput. Geosci.*, pp. 1264-1276, 2011.
- [119] B. Dixon, "Applicability of neuro-fuzzy techniques in predicting ground-water vulnerability: a GIS-based sensitivity analysis", *J. Hydrol.*, pp. 17-38, 2005.
- [120] K. Polat y S. Günes, "A hybrid medical decision making system based on principles component analysis, k-NN based weighted pre-processing and adaptive neuro-fuzzy inference system", *Digital Signal Process.*, pp. 913-921, 2006.
- [121] S. Lee, J. Choi y H. Oh, "Landslide susceptibility mapping using a neuro-fuzzy", de *American Geophysical Union, Fall Meeting, Daejeon*, 2009.
- [122] M. H. Vahidnia, A. A. Alesheikh, A. Abbas y F. Hosseinali, "A GIS-based neuro-fuzzy procedure for integrating knowledge and data in landslide susceptibility mapping", *Comput. Geosci.*, vol. 36, n.º 9, pp. 1101-1114, 2010.
- [123] D. P. Kanungo, M. K. Arora, S. S y R. P. Guptac, "A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas", *Eng. Geol.*, vol. 85, pp. 347-366, 2006.
- [124] I. Yilmaz, "Comparison of landslide susceptibility mapping methodologies for Koyulhisar, Turkey: conditional probability,



- logistic regression, artificial neural networks, and support vector machine”, *Environ. Earth Sci.*, vol. 61, pp. 821-836, 2010.
- [125] W. Chen, J. Peng, H. Hong, H. Shahabi, B. Pradhan, J. Liu, A.-X. Zhu, X. Pei y Z. Duan, “Landslide susceptibility modelling using GIS-based machine learning techniques for Chongren County, Jiangxi Province, China”, *Scie. Total Environ.*, pp. 112-1135, 2018.
- [126] J. Soni, U. Ansari, D. Sharma y S. Soni, “Predictive data mining for medical diagnosis: an overview of heart disease prediction”, *Int. J. Comput. Appl.*, pp. 43-48, 2011.
- [127] P. Bhargavi y S. Jyothi, “Applying naive Bayes data mining technique for classification of agricultural land soils”, *Int. J. Comput. Sci. Network Security*, pp. 117-122, 2009.
- [128] X. Wu, V. Kumar, R. J. Quinlan, J. Ghosh, Q. Yang, H. Motoda, G. J. McLachlan, A. Ng, B. Liu, P. S. Yu, Z.-H. Zhou, M. Steinbach, D. J. Hand y D. Steinberg, “Top 10 algorithms in data mining”, *Knowl. Inf. Syst.*, pp. 1-37, 2008.
- [129] P. Tsangaratos y I. Llia, “Comparison of a logistic regression and Naïve Bayes classifier in landslide susceptibility assessments: The influence of models complexity and training dataset size”, *Catena*, pp. 164-179, 2016.
- [130] W. Chen, X. Xie, J. Wang, B. Pradhan, H. Hong, D. Tien Bui, Z. Duan y J. Ma, “A comparative study of logistic model tree, random forest, and classification and regression tree models for spatial prediction of landslide susceptibility”, *Catena*, pp. 147-160, 2017.
- [131] I. H. Witten, E. Frank y M. A. Hall, *Data Mining: Practical Machine Learning Tools and Techniques (The Morgan Kaufmann Series in Data Management Systems)*, Burlington: Morgan Kaufmann, 2011.
- [132] D. T. Bui, T. A. Tuan, H. Klempe, B. Pradhan y I. Revhaug, “Spatial prediction models for shallow landslide hazards: a comparative assessment of the efficacy of support vector machines, artificial neural networks, kernel logistic regression, and logistic model tree”, *Landslides*, pp. 117-136, 2016.
- [133] L. Breiman, “Random Forests”, *Mach. Learn.*, pp. 5-32, 2001.
- [134] R. Genuer, J.-M. Poggi y C. Tuleau-Malot, “Variable selection using random forests”, *Pattern Recognit. Lett.*, pp. 2225-2236, 2010.
- [135] J. N. Goetz, A. Brenning, H. Petschko y P. Leopold, “Evaluating machine learning and statistical prediction techniques for landslide susceptibility modeling”, *Comput. Geosci.*, pp. 1-11, 2015.
- [136] K. Zhang, X. Wu, R. Niu, K. Yang y Z. Lingran, “The assessment of landslide susceptibility mapping using random forest and decision tree methods in the Three Gorges Reservoir area, China”, *Environ. Earth Sci.*, pp. 1-20, 2017.
- [137] A. M. Youssef, H. R. Pourghasemi, Z. S. Pourtaghi y M. M. Al-Katheeri, “Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tayyah Basin, Asir Region, Saudi Arabia”, *Landslides*, pp. 1-25, 2015.
- [138] B. Thai Pham y I. Prakash, “Machine Learning Methods of Kernel Logistic Regression and Classification and Regression Trees for Landslide Susceptibility Assessment at Part of Himalayan Area, India”, *Indian J. Sci. Tech.*, pp. 1-10, 2018.
- [139] J. F. Díaz Sepúlveda, «Comparación entre árboles de regresión CART y regresión lineal» M.Sc. tesis, Universidad Nacional de Colombia, Bogotá, 2012.
- [140] B. Pham Thai, K. Khosravi y I. Prakash, “Application and comparison of decision Tree-Based Machine Learning methods in Landslide susceptibility assessment at Pauri Garhwal area, Uttarakhand, India”, *Environ. Sci. Processes Impacts*, pp. 1-34, 2017.
- [141] Á. Felicísimo, A. Cuartero, J. Remondo y E. Quirós, “Mapping landslide susceptibility with logistic regression, multiple adaptive regression splines, classification and regression trees, and maximum entropy methods: a comparative study”, *Landslides*, pp. 175-189, 2012.

- [142] L.-J. Wang, M. Guo, K. Sawada, J. Lin y J. Zhang, "Landslide susceptibility mapping in Mizunami City, Japan: A comparison between logistic regression, bivariate statistical analysis and multivariate adaptive regression spline models", *Catena*, pp. 271-282, 2015.
- [143] S. Abeare, *Comparisons of Boosted Regression Tree, GLM, and GAM performance in the Standardization of Yellowfin Tuna Catch-Rate Data from the Gulf of Mexico Lonline Fishery, Louisiana: Louisiana State University*, 2009.
- [144] H. R. Pourghasemi y M. Rossi, "Landslide susceptibility modeling in a landslide prone area in Mazandarn Province, north of Iran: a comparison between GLM, GAM, MARS, and M-AHP methods", *Theor. Appl. Climatol.*, pp. 1-25, 2016.
- [145] P. Vorpahl, H. Elsenbeer, M. Mär y B. Schröder, "How can statistical models help to determine driving factors of landslides?", *Ecol. Model.*, pp. 27-39, 2012.
- [146] H. R. Pourghasemi, Z. T. Yansari, P. Panagos y B. Pradhan, "Analysis and evaluation of landslide susceptibility: a review on articles published during 2005–2016 (periods of 2005–2012 and 2013–2016)", *Arab. J. Geosci.*, pp. 2-12, 2018.
- [147] W. Chen, H. Shahabi, A. Shirzadi, T. Li, C. Guo, H. Hong, W. Li, D. Pan, J. Hu, M. Ma, M. Xi y B. B. Ahmad, "A novel ensemble approach of bivariate statistical based logistic model tree classifier for landslide susceptibility assessment", *Geocarto International*, pp. 1-32, 2018.
- [148] L. Peng, R. Niu, B. Huang, X. Wu, Y. Zhao y R. Ye, "Landslide susceptibility mapping based on rough set theory and support vector machines: A case of the Three Gorges area, China", *Geomorphology*, pp. 287-301, 2014.
- [149] D. Tien Bui, B. Pradhan, I. Revhaug, D. B. Nguyen, H. V. Pham y B. Quy Ngoc, "A novel hybrid evidential belief function-based fuzzy logic model in spatial prediction of rainfall-induced shallow landslides in the Lang Son city area (Vietnam)", *Geomat. Nat. Hazards Risk*, pp. 13-36, 2013.
- [150] O. F. Althuwaynee, B. Pradhan, H.-J. Park y J. H. Lee, "A novel ensemble bivariate statistical evidential belief function with knowledge-based analytical hierarchy process and multivariate statistical logistic regression for landslide susceptibility mapping", *Catena*, pp. 21-36, 2014.
- [151] O. F. Althuwaynee, B. Pradhan, H.-J. Park y J. H. Lee, "A novel ensemble decision tree-based CHi-squared automatic Interaction Detection (CHAID) and multivariate logistic regression models in landslide susceptibility mapping", *Landslides*, pp. 1063-1078, 2014.
- [152] A. M. Youssef, P. Biswajeet, M. N. Jebur y H. M. El-Harbi, "Landslide susceptibility mapping using ensemble bivariate and multivariate statistical models in Fayfa area, Saudi Arabia", *Environ. Earth Sci.*, pp. 1-17, 2014.
- [153] W. Black, "Spatial interaction modeling using artificial neural networks", *J. Transp. Geogr.*, vol. 3, n.º 3, pp. 159-166, 1995.
- [154] M. M. Fischer, "Methodological challenges in Neural spatial interaction modelling: The issue of model selection", *Spat. Econ. Sci.*, pp. 89-101, 2000.
- [155] M. Hong, J. Kim y S. Jeong, "Rainfall intensity-duration thresholds for landslide prediction in South Korea by considering the effects of antecedent rainfall", *Landslides*, pp. 523-534, 2017.
- [156] T. Cheng y J. Wang, "Accommodating spatial associations in DRNN for space-time analysis", *Comput. Environ. Urban Syst.*, pp. 409-418, 2009.
- [157] M. Deng, W. Yang, Q. Liu, R. Jin, F. Xu y Y. Zhang, "Heterogeneous space - time artificial neural network for space - time series prediction", *Transact. GIS*, pp. 1-19, 2017.
- [158] T. Cheng, J. Haworth, B. Anbaroglu, T. Garavig y J. Wang, *Spatiotemporal Data Mining*, Berlin: Springer, 2014, pp. 1173-1193.
- [159] T. Cheng y J. Wang, "Accommodating spatial associations in DRNN for space-time analysis.", *Comput. Environ. Urban Syst.*, pp. 409-418, 2009.
- [160] M. M. Fischer y M. Reismann, "A Methodology for Neural Spatial Interaction Modeling.", *Geogr. Anal.*, pp. 207-228, 2002.

- [161] S. Openshaw, "Modelling spatial interaction using a neural net", en *Geographic information systems, spatial modelling, and policy evaluation*, Berlin: Springer-Verlag, 1993, pp. 147-164.
- [162] Y. Zheng, X. Yi, M. Li, R. Li, Z. Shan, E. Chang y T. Li, "Forecasting fine-grained air quality based on big data", en *Proceedings of the 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Chicago, 2015.
- [163] S. Gopal, W. Liu y C. Woodcock, "Visualization based on the fuzzy artmap neural network for mining remotely sensed data", en *Geographic Data Mining and Knowledge Discovery*, Bristol: Taylor and Francis, pp. 315-336, 2001.
- [164] Aravind y Koufakou, "Cross-validation in fuzzy ARTMAP for large databases", *Neural Network*, pp. 1279-1291, 2011.
- [165] M. Deng, W. Yang, Q. Liu, R. Jin, F. Xu y Y. Zhang, "Heterogeneous Space-Time Artificial Neural Networks for space - time series prediction", *Transact. GIS*, pp. 1-19, 2017.
- [166] W. Lin, "Earthquake-induced landslide hazard monitoring and assessment using SOM and PROMETHEE techniques: A case study at the Chiufenershan area in Central Taiwan", *Int. J. Geogr. Inform. Sci.*, pp. 995-1012, 2008.
- [167] M. J. Friedel, "Modeling hydrologic and geomorphic hazards across post-fire landscapes using a self-organizing map approach", *Environ. Model. Softw.*, pp. 1660-1674, 2011.
- [168] G. A. Carpenter, "Distributed Learning, Recognition, and Prediction by ART and ARTMAP Neural Networks", *Neural Networks*, pp. 1473-1494, 1997.
- [169] C.-H. Chen, K. Li Pheng y W. Yan, "A strategy for acquiring customer requirement patterns using laddering technique and ART2 neural network", *Adv. Eng. Inform.*, pp. 229-240, 2002.
- [170] C.J. Van Westen, E. Castellanos y S. L. Kuriakose, "Spatial data for landslide susceptibility, hazard and vulnerability assessment: an overview", *Eng. Geol.*, pp. 112-131, 2008.
- [171] A. M. Ramos Cañón, L. F. Prada Sarmiento, M. G. Trujillo Vela, J. P. Macías y A. C. Santos, "Linear discriminant analysis to describe the relationship between rainfall and landslides in Bogotá, Colombia", *Landslides*, pp. 671-681, 2015.
- [172] R. Henriques, F. Bacao y V. Lobo, "Exploratory geospatial data analysis using the Geo-SOM suite", *Comput. Environ. Urban Syst.*, 2012.
- [173] G. Andrienko, N. Andrienko, S. Bremm, T. Schreck, T. von Landesberger, P. Bak y D. Keim, "Space-in-Time and Time-in-Space Self-Organizing Maps for Exploring Spatiotemporal Patterns", *Comput. Graph. Forum*, vol. 3, pp. 913-922, 2010.
- [174] F. Baçãoa, V. Lobo y M. Painhoa, "The self-organizing map, the Geo-SOM, and relevant variants for geosciences", *Comput. Geosci.*, vol. 31, n.º 2, pp. 155-163, 2005.
- [175] R. Henriques, B. Fernando y L. Victor, "Exploratory geospatial data analysis using the GeoSOM suite", *Comput. Environ. Urban Syst.*, vol. 36, n.º 3, pp. 218-232, 2012.
- [176] A. Brenning, *Statistical geocomputing combining R and SAGA: the example of landslide susceptibility analysis with generalized additive models*, Hamburger: Beiträge zur Physischen Geographie und Landschaftsökologie, 2008.
- [177] A. Brenning, "Spatial prediction models for landslide hazards: review, comparison and evaluation", *Nat. Hazards Earth Syst. Sci.*, pp. 853-862, 2005.
- [178] S. Keesstra, G. Mol, A. Zaal y J. Wallinga, "Soil science in a changing world", de Wageningen soil conference, 2015.
- [179] M. Ruff y K. Czurda, "Landslide susceptibility analysis with a heuristic approach in the Eastern Alps (Vorarlberg, Austria)", *Geomorphology*, pp. 314-324, 2008.
- [180] A. Ozdemir, "Landslide susceptibility mapping using Bayesian approach in the Sultan Mountains (Aks\_ehir, Turkey)", *Nat. Hazards*, pp. 1573-1607, 2011.