

## APPLICATION OF MACHINE LEARNING ALGORITHMS IN GEOSCIENCE: COMPREHENSIVE REVIEW AND FUTURE CHALLENGE

## APLICACIÓN DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO EN GEOCIENCIA: REVISIÓN INTEGRAL Y DESAFÍO FUTURO

*Cantillo, J. R.<sup>1</sup>; Estrada, J. J.<sup>2</sup>; Henríquez, C.<sup>3</sup>*

<sup>1</sup> Geólogo Es. Janer Rafael Cantillo Romero.

email: [jrcantillo93@gmail.com](mailto:jrcantillo93@gmail.com)

ORCID <https://orcid.org/0000-0001-6925-447X>

<sup>2</sup>Ingeniero geólogo Javier Javier Estrada Romero.

email: [ingenierogeologojavier@gmail.com](mailto:ingenierogeologojavier@gmail.com)

ORCID <https://orcid.org/0009-0008-6493-5231>

<sup>3</sup>PhD. Carlos Henríquez Miranda. Docente Programa de Ingeniería de Sistemas.  
Universidad de Magdalena.

email: [Chenriquezm@unimagdalena.edu.co](mailto:Chenriquezm@unimagdalena.edu.co)

ORCID: <https://orcid.org/0000-0001-8252-1413>

**Recibido: 16/07/2023 / Aceptado: 30/11/2023**

### Resumen

Este artículo aborda la aplicación de técnicas de Aprendizaje Automático o Machine Learning en la geoingeniería y geociencia, destacando su relevancia en la predicción y comprensión de fenómenos naturales. A pesar de prescindir de leyes físicas explícitas, los modelos de ML ofrecen flexibilidad para adaptarse y descubrir patrones complejos. En particular, se resalta la capacidad del aprendizaje automático para mejorar la precisión y eficiencia en la predicción de la susceptibilidad a deslizamientos de tierra, con enfoques como el aprendizaje supervisado y no supervisado. Se menciona la importancia de comprender por qué un modelo clasifica ciertas clases, ofreciendo herramientas explicables que permitan alinear resultados con la comprensión física de los procesos geológicos. Además, se exploran aplicaciones cruciales de ML en la ingeniería geotécnica, con modelos basados en algoritmos como máquinas de vectores de soporte, redes neuronales artificiales y clasificadores de Bayes. Se destaca la necesidad de investigar el acoplamiento de modelos basados en la física y en datos de IA para una comprensión más completa y predicciones confiables. La integración de técnicas de ML en la geoingeniería emerge como una estrategia clave para abordar los desafíos climáticos y antropogénicos actuales, ofreciendo nuevas perspectivas en la investigación de deslizamientos de tierra y otros riesgos geológicos. Este artículo forma parte de la investigación realizada en el marco de la Maestría en Ingeniería Ambiental, donde se busca explorar el potencial del Aprendizaje Automático para la gestión de riesgos geológicos.

**Palabras clave:** Aplicación, Machine Learning, Geociencia, fenómenos naturales.

### Abstract

This article addresses the application of Machine Learning (ML) techniques in geoenvironmental and geoscience, highlighting its relevance in the prediction and understanding of natural phenomena. Despite the absence of specific physical laws, ML models offer flexibility to adapt and discover complex patterns. In particular, the ability of ML to improve the accuracy and efficiency in predicting susceptibility to land gradients is highlighted, with approaches such as supervised and unsupervised learning. The importance of understanding why a model classifies certain classes is mentioned, offering explainable tools that allow results that are aligned with the physical understanding of geological processes. Additionally, crucial applications of ML in geotechnical engineering are explored, with models based on algorithms such as support vector machines, artificial neural networks, and Bayes classifiers. The need to investigate the compatibility of physics-based models and AI data is highlighted for a more complete understanding and reliable predictions. The integration of ML techniques in geoenvironmental engineering emerges as a key strategy to address current climate and anthropogenic challenges, offering new perspectives in the investigation of land sectors and other geological hazards. This article is part of the research carried out within the framework of the Master's Degree in Environmental Engineering, which seeks to explore the potential of Machine Learning for the management of geological risks.

**Keywords:** Application, Machine Learning, Geoscience, natural phenomena.

## 1. INTRODUCCIÓN

La ciencia ha sido testigo de momentos históricos en los cuales los descubrimientos y/o avances tecnológicos han creado oportunidades inimaginables como la constante evolución de la tecnología a tal manera que analiza fenómenos complejos respondiendo así a la creciente necesidad de implementar técnicas que procesen datos de manera oportuna y precisa, abriendo paso a las tecnologías de inteligencia artificial (IA).

Estas tecnologías de IA se caracterizan de forma determinísticas y apoyadas en el método científico, con la idoneidad de emular el pensamiento humano mediante el cómputo iterativo de algoritmos matemáticos (Özdemir & Hekim, 2018; Rouhiainen, 2018), debido a la capacidad de programar el aprendizaje automatizado a partir de datos enfocados a la toma de decisiones bajo un complejo proceso de

razonamiento (tal y como lo haría el ser humano, sumado al hecho de una gran capacidad de procesamiento las máquinas en ciertos aspectos pueden superar al ser humano en tareas muy específicas), con la ventaja que los dispositivos no necesitan descansar y pueden analizar grandes volúmenes de información, sumado a que la cantidad de errores tiende a ser menor (Rouhiainen, 2018).

En este sentido y aplicada a las Ciencias de la Tierra, la IA se enfoca principalmente en sistemas de minería de datos (Data Mining) (Götz *et al.*, 2015), y en modelos predictivos a partir de Aprendizaje Automatizado (ML) (Thessen, 2016). La minería de datos cobra sentido al tener la capacidad de gestionar bases de datos y con un periodo de tiempo de actualización muy corto (Morales, 2021).

El ML reside en la capacidad de generar modelos predictivos a través de algoritmos informáticos mejorando automáticamente la experiencia para generar resultado, predictivos de forma masiva (Mitchell, 1997); sin embargo la utilización de algoritmos matemáticos en la ciencias de la tierra es algo complejo, ya que existe un sin número de variables de déficit predicción y monitoreo. Estos algoritmos, diseñados para ajustarse a los datos recopilados, se enfrentan a la tarea de analizar procesos en sistemas terrestres que exhiben patrones similares a lo largo del tiempo, es decir se puede realizar asociación del comportamiento cíclico en los datos conforme pasa el tiempo, bajo cierto estado e interacción de los elementos y situaciones que conforman el ambiente (variables) (Morales, 2021).

La capacidad del Aprendizaje automático (ML) para analizar, procesar y modelar grandes conjuntos de datos, descubriendo patrones no evidentes mediante algoritmos complejos, ofrece una perspectiva innovadora en la investigación de deslizamientos de tierra esto se debe a la convergencia de factores que han fortalecido la minería de datos y el análisis Bayesiano. La disponibilidad creciente de datos, junto con el acceso más asequible y al procesamiento computacional, permite la rápida generación de modelos automáticos. Esto facilita un análisis eficiente de datos topográficos, climáticos y geológicos, mejorando la capacidad para predecir y prevenir deslizamientos de tierra proporcionando a las comunidades una mejor oportunidad de comprender y gestionar eficazmente estos fenómenos naturales. Esta investigación tiene como objetivo aplicar los algoritmos de

aprendizaje automático en la geociencia: revisión integral y desafío futuro.

## 2. METODOLOGÍA

El presente artículo está basado en la búsqueda, recopilación y examinación exhaustiva de publicaciones realizadas a nivel nacional e internacional, relacionadas con estudios a fenómenos naturales, donde se emplearon portales de búsqueda como: Google, Google Académico, Scielo, Researchgate, Science Direct, Springer-Link, Academia.edu y Scopus, bibliotecas institucionales de la Universidad Nacional de Colombia, Universidad Industrial de Santander, Universidad EAFIT, Universidad Pedagógica y Tecnológica de Colombia, Universidad de Caldas, Pontificia Universidad Javeriana, Universidad Francisco de Paula Santander, Luis Ángel Arango, Humboldt y el Servicio Geológico Colombiano.

A través de esta revisión exhaustiva, se busca aplicar los algoritmos de aprendizaje automático en la geociencia: revisión integral y desafío futuro.

## 3. ANÁLISIS Y DISCUSIÓN DE RESULTADOS

### 3.1 Aprendizaje Automático

Por definición de IBM (International Business Machines), ML es una rama de la IA y la informática que se centra en el uso de datos y algoritmos inspirándose en la forma en que el cerebro humano procesa la información LeCun *et al.*, (2015) mejorando gradualmente su precisión. El aprendizaje automático se divide en tres categorías principales: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje semisupervisado (Hinestroza & Cárdenas, 2018). El aprendizaje profundo se puede

aplicar a las tres categorías principales y se refiere al amplio subconjunto de modelos de aprendizaje automático que utilizan capas de redes neuronales y técnicas similares (Zhang *et al.*, 2022). El aprendizaje supervisado entrena con datos etiquetados con pares de entrada y salida y, en última instancia, aprenden a asignar entradas a salidas minimizando la diferencia entre predicciones y verdades fundamentales hasta que el modelo se haya ajustado adecuadamente (Hinestroza & Cárdenas, 2018), superando las deficiencias de los métodos estadísticos y de base física produciendo resultados más confiables a partir de los datos (Pham *et al.*, 2017; Zhou *et al.*, 2018).

Por otro lado, el aprendizaje no supervisado utiliza algoritmos de aprendizaje automático para analizar y agrupar conjuntos de datos sin etiquetar (Hinestroza & Cárdenas, 2018). Estos algoritmos descubren patrones ocultos o agrupaciones de datos minimizando la discrepancia entre verdades fundamentales y predicciones. La habilidad de estos algoritmos para descubrir similitudes y diferencias en la información los convierte en la elección ideal para diversas aplicaciones, como análisis exploratorio de datos, reconocimiento de imágenes y patrones (Zhang *et al.*, 2022). Además, el aprendizaje no supervisado se emplea para reducir la cantidad de características en un modelo mediante el proceso de reducción de dimensionalidad y el aprendizaje refuerzo utiliza los datos del sistema no etiquetados, pero después realizar varias acciones y de cierto periodo, el sistema será retroalimentado mediante actualizaciones (Hinestroza & Cárdenas, 2018). En general, el aprendizaje

automático es el método más efectivo a la hora de predecir (Goetz *et al.*, 2015; Zhou *et al.*, 2018).

Pourghasemi y Rahmati realizaron un estudio comparativo de los 10 modelos de aprendizaje automático más avanzados (Pourghasemi & Rahmati, 2018). Se puede ver claramente en la revisión de la literatura que estudios comparativos adicionales de distintos se requieren modelos de aprendizaje automático para un mejor análisis de problemas, evaluando la efectividad de modelos y para ayudar a mejorar la predicción de la susceptibilidad a deslizamientos de tierra (Goetz *et al.*, 2015; Pourghasemi & Rahmati, 2018; A. M. Youssef *et al.*, 2016). Desde entonces se han publicado multitud de contribuciones científicas, explorando la susceptibilidad a deslizamientos de tierra, desde el Aprendizaje automático (Melchiorre *et al.*, 2008).

### 3.2 Aplicaciones Cruciales de Aprendizaje Automático en la geociencia

Actualmente, se ha centrado cada vez más atención en los riesgos geológicos o la estimación de la seguridad de las estructuras geotécnicas porque los riesgos geológicos o la falla de una estructura representarían una gran amenaza para las vidas y propiedades de los humanos (Ortiz *et al.*, 2022), como la erupción del volcán el Nevado del Ruiz (López-Cotuá, 2017), deslizamiento de Quebrada Blanca (Mendoza *et al.*, 2016), deslizamiento de Villatina (Tamayo, 2017). Para prevenir o mitigar los desastres y garantizar que las estructuras geotécnicas tengan suficiente seguridad (Ou *et al.*, 2022), se necesitan con urgencia predicciones precisas de la aparición de riesgos geotécnicos y análisis

de confiabilidad de las estructuras geotécnicas.

Los avances en la precisión de la probabilidad de ocurrencia a deslizamientos de tierra han llevado a la exploración de diversos métodos para mitigar la subjetividad con suficiente precisión y eficiencia (Luo *et al.*, 2019; Mohammadi *et al.*, 2015; Shi *et al.*, 2019; Zhan *et al.*, 2021). Entre estos métodos se encuentran la introducción de herramientas de aprendizaje automático en los modelos basados en predicción esto ha dado lugar recientemente al trabajo fundamental de Lundberg & Lee, (2017). Específicamente, los autores han creado el primer método que permite consultar los modelos elemento espacial por elemento espacial, así como predictor por predictor es decir, su método se puede analizar al nivel de cada componente sobre el que se ha construido y los resultados se pueden examinar hasta el punto de comprender por qué el algoritmo convergió para asignar una etiqueta específica a una unidad específica (Zhang *et al.*, 2022), Ampliando el campo de aplicaciones completamente nuevo en cualquier campo científico importante.

En el contexto de la predicción de deslizamientos de tierra, este tipo de herramienta de aprendizaje automático puede ayudar a comprender por qué un modelo clasifica una clases como susceptible o no. Esta es una oportunidad no solo para hacer predicciones confiables sino también para comprender por qué dicho modelo produce tales predicciones (K. Youssef *et al.*, 2022). La relevancia de dicha extensión del modelo radica en la capacidad de alinear los resultados de los modelos con la comprensión física de los procesos responsables de la génesis del

fallo. A diferencia de otras tareas, como el procesamiento del lenguaje natural, donde el desempeño del modelo puede ser más crítico que la comprensión fundamental del fenómeno, en las aplicaciones geocientíficas. Por esta razón, el uso de soluciones explicables de ML ofrece a los científicos la oportunidad de evitar el compromiso entre rendimiento y comprensión.

### 3.3 Descubrimientos Destacados en las Aplicaciones de Aprendizaje Automático en Ciencias de la Tierra

El uso de técnicas de IA más avanzadas, incluida ML ha mejorado la precisión y eficiencia de la predicción del mapeo a la susceptibilidad por deslizamiento de tierra (Zhang *et al.*, 2022). De las secciones anteriores, se pudo descubrir que es más probable que las técnicas de algoritmos de IA se adopten en la predicción de zona con ocurrencia a deslizamiento de tierra. Además, según la revisión documental, los modelos basados en algoritmos únicos se utilizan ampliamente en la ingeniería geotécnica, como, máquinas de vectores de soporte (SVM) (Lin *et al.*, 2017), redes neuronales artificiales (RNA) (Can *et al.*, 2019; Huang *et al.*, 2017), bosque aleatorio (Akinci & Zeybek, 2021; Huang *et al.*, 2022), clasificadores ingenuos de Bayes (NB) (Pham *et al.*, 2017) y otros aprendizajes automáticos son modelos que se utilizan ampliamente en el mapeo de susceptibilidad por deslizamiento de tierra. Los modelos tradicionales de base física se construyen basándose en la relación mecánica entre las respuestas de las estructuras geotécnicas y factores de vital influencia; mientras que los modelos basados en IA establecen un mapeo directo entre entradas y salidas sin

ninguna consideración de los significados físicos subyacentes. Por lo tanto, se debe prestar más atención a la investigación sobre el acoplamiento/uso combinado de modelos basados en la física y basados en datos de IA para una mejor comprensión del mecanismo físico y predicciones más confiables en aplicaciones geotécnicas (Zhang *et al.*, 2022).

Se han realizado trabajos considerables de monitoreo utilizando los satélites SAR, INSAR y LiDAR para la prevención y reducción de riesgos geológicos. Sería beneficioso para las comunidades y los gobiernos seguir utilizando IA de manera consistente, confiable e inteligente para detectar posibles deslizamientos de tierra (Zhang *et al.*, 2022). Por ejemplo, Can *et al.*, (2019) indica que ML es capaz de identificar señales influyentes asociadas con peligros geológicos basándose en algunos conjuntos de datos disponibles. Además de eso, las técnicas de inteligencia artificial más avanzadas para evaluar la posibilidad de que ocurran desastres naturales son muy demandadas para la estrategia de prevención de riesgos geológicos.

### 3.4 Avances ML en Geoingeniería y Geociencia

Los modelos de aprendizaje automático (ML), al fundamentarse en datos, prescinden de la incorporación de leyes físicas por diseño, centrándose exclusivamente en los patrones presentes en los datos de entrenamiento. Aunque los enfoques físicos son interpretativos y permiten la extrapolación más allá de las condiciones observadas, los métodos basados en datos poseen flexibilidad para adaptarse y descubrir patrones

inesperados (Zhang *et al.*, 2022). En el ámbito de la geoingeniería y geociencia, el desafío principal para los profesionales radica en extraer la máxima información útil y obtener nuevos conocimientos, destacando la importancia de la investigación en modelos conscientes del dominio y el uso de técnicas como el aprendizaje por refuerzo (Zhang y Phoon, 2022).

El principio fundamental de "basura entra, basura sale" en el aprendizaje automático refleja la influencia directa de la selección de observaciones de entrenamiento en el éxito o fracaso de las predicciones (Buranyi, 2017). En estos campos, las técnicas de aprendizaje automático (ML) enfrentan notables deficiencias, siendo la escasez de muestras de entrenamiento un problema común y obstáculo clave para avanzar en estas aplicaciones. La limitada cantidad de datos afecta negativamente la capacidad del modelo para incorporar funciones relevantes, resultando en una precisión predictiva menos satisfactoria (Samodra *et al.*, 2017). Además, el sesgo en las observaciones, con diferencias significativas en la cantidad de etiquetas en el conjunto de entrenamiento, presenta otro desafío. Para superar estas limitaciones, se sugiere desarrollar y compartir conjuntos de datos de entrenamiento de referencia, así como investigar e invertir en técnicas que requieran menos datos, como el aprendizaje semisupervisado y el aprendizaje activo (Zhang *et al.*, 2022).

En el ámbito de la geoingeniería, las predicciones suelen abordar cuestiones como la capacidad portante o la deformación, consideradas como estimaciones numéricas (Zhang *et al.*,

2022). Por otro lado, en problemas relacionados con las geociencias, se centran en aspectos como la evaluación de la susceptibilidad o vulnerabilidad a riesgos geológicos como lo ejemplifica (Zhao & Chen, 2020), así como la clasificación de tipos de suelo o roca, que poseen una naturaleza más categórica. Sin embargo, la cuantificación de la rigidez y resistencia, dada la variabilidad espacial y las características anisotrópicas de los geomateriales, presenta una considerable incertidumbre, lo que implica que los resultados obtenidos a través de técnicas de aprendizaje automático (ML) pueden no ser deterministas.

El cambio climático y las crecientes actividades antropogénicas han intensificado los desafíos en la predicción de fenómenos naturales y la evaluación de respuestas en geingeniería. Frente a esta complejidad, los métodos de aprendizaje automático emergen como soluciones que permiten predicciones más extensibles, mantenibles y escalables (Melchiorre *et al.*, 2008). Los terremotos, erupciones volcánicas, tsunamis y deslizamientos de tierra representan amenazas significativas para miles de millones de personas en todo el mundo (Wang *et al.*, 2019). La minimización de sus efectos requiere un mayor entendimiento de los procesos físicos subyacentes. Además, el cambio climático y las crecientes actividades antropogénicas han intensificado los desafíos en la predicción de fenómenos naturales y la evaluación de respuestas en geingeniería. Para lograrlo, es esencial avanzar en dos frentes: desarrollar la próxima generación de sistemas de observación de la Tierra y establecer sistemas innovadores de modelización e interpretación confiable de los grandes

conjuntos de datos obtenidos. En este sentido, la tendencia de desarrollo apunta hacia la incorporación de nuevas cantidades de observación, técnicas de seguimiento avanzadas y la integración de estos análisis con métodos de aprendizaje automático (ML) consideradas como estimaciones numéricas (Zhang *et al.*, 2022). Además, para abordar las diversas escalas temporales de los eventos geológicos, desde segundos hasta minutos (como alarmas para deslizamientos de tierra y terremotos), días a semanas (predicciones inmediatas como erupciones volcánicas) y años (predicciones a largo plazo como hundimientos o levantamientos del terreno), los enfoques desarrollados deben ser capaces de considerar estas diferentes temporalidades de manera efectiva.

#### 4. CONCLUSIONES

La aplicación de técnicas de Aprendizaje Automático (ML) en la geingeniería y geociencia representa una innovación significativa en la predicción y comprensión de fenómenos naturales. A pesar de la falta de incorporación explícita de leyes físicas en los modelos de ML, la flexibilidad de estos métodos para adaptarse y descubrir patrones complejos brinda una perspectiva única. El desafío radica en extraer información valiosa y avanzar en modelos conscientes del dominio, reconociendo la importancia de la investigación y el uso de técnicas especializadas como el aprendizaje por refuerzo.

El principio de "basura entra, basura sale" destaca un desafío fundamental en la aplicación de ML a la geingeniería. La escasez de muestras de entrenamiento y

el desequilibrio en las observaciones son obstáculos notables que afectan la precisión predictiva. Para superar estas limitaciones, se sugiere el desarrollo y compartición de conjuntos de datos de referencia, así como la exploración de técnicas que requieran menos datos, como el aprendizaje semisupervisado y activo.

Por otro lado, gracias a los aportes de la inteligencia artificial y la capacidad del Aprendizaje Automático para analizar, procesar y modelar grandes conjuntos de datos ofrece una perspectiva innovadora en la investigación de deslizamientos de tierra. La convergencia de la minería de datos, y el acceso a datos extensos permite una rápida generación de modelos automáticos. Esto mejora la capacidad de prever y prevenir deslizamientos de tierra, ofreciendo a las comunidades una herramienta eficaz para comprender y gestionar estos fenómenos naturales. La integración de técnicas de ML en la geoingeniería emerge como una estrategia clave para abordar los desafíos climáticos y antropogénicos actuales.

## 5. REFERENCIAS BIBLIOGRÁFICAS

- Akinci, H., & Zeybek, M. (2021). Comparing classical statistic and machine learning models in landslide susceptibility mapping in Ardanuc (Artvin), Turkey. *Natural Hazards*, 108(2).  
<https://doi.org/10.1007/s11069-021-04743-4>
- Buranyi, S. (2017). Rise of the racist robots - how AI is learning all our worst impulses. *The Guardian*, August 8.
- Can, A., Dagdelenler, G., Ercanoglu, M., & Sonmez, H. (2019). Landslide susceptibility mapping at Ovacik-Karabük (Turkey) using different artificial neural network models: comparison of training algorithms. *Bulletin of Engineering Geology and the Environment*, 78(1), 89–102.  
<https://doi.org/10.1007/s10064-017-1034-3>
- Goetz, J. N., Brenning, A., Petschko, H., & Leopold, P. (2015). Evaluating machine learning and statistical prediction techniques for landslide susceptibility modeling. *Computers and Geosciences*, 81.  
<https://doi.org/10.1016/j.cageo.2015.04.007>
- Götz, M., Richerzhagen, M., Bodenstern, C., Cavallaro, G., Glock, P., Riedel, M., & Benediktsson, J. A. (2015). On scalable data mining techniques for earth science. *Procedia Computer Science*, 51(1).  
<https://doi.org/10.1016/j.procs.2015.05.494>
- Hinestroza, D., & Cárdenas, J. (2018). *El Machine Learning a través de los tiempos, y los aportes a la humanidad*.
- Huang, F., Yan, J., Fan, X., Yao, C., Huang, J., Chen, W., & Hong, H. (2022). Uncertainty pattern in landslide susceptibility prediction modelling: Effects of different landslide boundaries and spatial shape expressions. *Geoscience Frontiers*, 13(2).  
<https://doi.org/10.1016/j.gsf.2021.101317>
- Huang, F., Yin, K., Huang, J., Gui, L., & Wang, P. (2017). Landslide susceptibility mapping based on self-organizing-map network and extreme learning machine. *Engineering Geology*, 223.  
<https://doi.org/10.1016/j.enggeo.2017.04.013>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.  
<https://doi.org/10.1038/nature14539>
- Lin, G. F., Chang, M. J., Huang, Y. C., &



- Ho, J. Y. (2017). Assessment of susceptibility to rainfall-induced landslides using improved self-organizing linear output map, support vector machine, and logistic regression. *Engineering Geology*, 224, 62–74. <https://doi.org/10.1016/j.enggeo.2017.05.009>
- López-Cotuá, A. (2017). Armero, Una Historia Hecha Ceniza: Preguntas Que Quedaron En El Olvido. *Revista Saber, Ciencia y Libertad*, 18–21.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 2017-December.
- Luo, H. Y., Shen, P., & Zhang, L. M. (2019). How does a cluster of buildings affect landslide mobility: a case study of the Shenzhen landslide. *Landslides*, 16(12). <https://doi.org/10.1007/s10346-019-01239-y>
- Melchiorre, C., Matteucci, M., Azzoni, A., & Zanchi, A. (2008). Artificial neural networks and cluster analysis in landslide susceptibility zonation. *Geomorphology*, 94(3–4), 379–400. <https://doi.org/10.1016/J.GEOMORP.2006.10.035>
- Mendoza, W., Taborda, G., & Villagrán, J. (2016). *Investigación documental sobre la tragedia de Quebradablanca en la vía Bogotá – Villavicencio, en el año 1974 “Quebradablanca, el olvido de una tragedia”*.
- Mitchell, T. M. (1997). Machine Learning. In *Natural Computing Series*. [https://doi.org/10.1007/978-3-031-17922-8\\_9](https://doi.org/10.1007/978-3-031-17922-8_9)
- Mohammadi, S. D., Naseri, F., & Alipoor, S. (2015). Development of artificial neural networks and multiple regression models for the NATM tunnelling-induced settlement in Niayesh subway tunnel, Tehran. *Bulletin of Engineering Geology and the Environment*, 74(3). <https://doi.org/10.1007/s10064-014-0660-2>
- Morales, D. (2021, January 26). *Inteligencia artificial y Ciencias de la Tierra*. <https://revistacienciasdelatierra.com/geoingenieria-y-tecnologia/inteligencia-artificial-y-ciencias-de-la-tierra/8376/>
- Ortiz, V., Polo, C., Giraes, D., & Manco-Jaraba, D. (2022). Análisis de susceptibilidad por movimientos en masa implementando el método Mora-Vahrson modificado para el corregimiento de Chemesquemena (Cesar, Colombia). *Tecnura*, 27(77), 1–21. <https://doi.org/https://doi.org/10.14483/22487638.19951>
- Ou, Q., Zhang, L., Ding, X., & Wang, C. (2022). Response of Inclined Loaded Pile in Layered Foundation Based on Principle of Minimum Potential Energy. *International Journal of Geomechanics*, 22(7). [https://doi.org/10.1061/\(asce\)gm.1943-5622.0002400](https://doi.org/10.1061/(asce)gm.1943-5622.0002400)
- Özdemir, V., & Hekim, N. (2018). Birth of Industry 5.0: Making Sense of Big Data with Artificial Intelligence, “the Internet of Things” and Next-Generation Technology Policy. *OMICS A Journal of Integrative Biology*, 22(1), 65–76. <https://doi.org/10.1089/omi.2017.0194>
- Pham, B. T., Bui, D. T., Dholakia, M. B., Prakash, I., Pham, H. V., Mehmood, K., & Le, H. Q. (2017). A novel ensemble classifier of rotation forest and Naïve Bayer for landslide susceptibility assessment at the Luc Yen district, Yen Bai Province (Viet Nam) using GIS. *Geomatics, Natural Hazards and Risk*, 8(2). <https://doi.org/10.1080/19475705.2016.1255667>
- Pourghasemi, H. R., & Rahmati, O. (2018). Prediction of the landslide susceptibility: Which algorithm, which precision? *Catena*, 162. <https://doi.org/10.1016/j.catena.2017.05.009>

- 11.022
- Rouhiainen, L. (2018). Inteligencia artificial 101 cosas que debes saber hoy sobre nuestro futuro. *Alienta Editorial*, 22.  
[https://planetadelibrosar0.cdnstatics.com/libros\\_contenido\\_extra/40/39307\\_Inteligencia\\_artificial.pdf](https://planetadelibrosar0.cdnstatics.com/libros_contenido_extra/40/39307_Inteligencia_artificial.pdf)
- Samodra, G., Chen, G., Sartohadi, J., & Kasama, K. (2017). Comparing data-driven landslide susceptibility models based on participatory landslide inventory mapping in Purwosari area, Yogyakarta, Java. *Environmental Earth Sciences*, 76(4), 1–19.  
<https://doi.org/10.1007/s12665-017-6475-2>
- Shi, S., Zhao, R., Li, S., Xie, X., Li, L., Zhou, Z., & Liu, H. (2019). Intelligent prediction of surrounding rock deformation of shallow buried highway tunnel and its engineering application. *Tunnelling and Underground Space Technology*, 90.  
<https://doi.org/10.1016/j.tust.2019.04.013>
- Tamayo, H. (2017, September 27). 30 años del deslizamiento en Villatina, una tragedia que no se olvida. *EL TIEMPO*.  
<https://www.eltiempo.com/colombia/medellin/30-anos-del-deslizamiento-en-villatina-una-tragedia-que-no-se-olvida-135132>
- Thessen, A. E. (2016). Adoption of machine learning techniques in ecology and earth science. *One Ecosystem*, 1.  
<https://doi.org/10.3897/oneeco.1.e8621>
- Wang, Y., Fang, Z., & Hong, H. (2019). Comparison of convolutional neural networks for landslide susceptibility mapping in Yanshan County, China. *Science of the Total Environment*, 666.  
<https://doi.org/10.1016/j.scitotenv.2019.02.263>
- Youssef, A. M., Pourghasemi, H. R., Pourtaghi, Z. S., & Al-Katheeri, M. M. (2016). 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*, 13(5).  
<https://doi.org/10.1007/s10346-015-0614-1>
- Youssef, K., Shao, K., Moon, S., & Bouchard, L.-S. (2022). XAI model for accurate and interpretable landslide susceptibility. *ArXiv Preprint ArXiv:2201.06837*.
- Zhan, L. tong, Guo, X. gang, Sun, Q. qian, Chen, Y. min, & Chen, Z. yu. (2021). The 2015 Shenzhen catastrophic landslide in a construction waste dump: analyses of undrained strength and slope stability. *Acta Geotechnica*, 16(4). <https://doi.org/10.1007/s11440-020-01083-8>
- Zhang, W., Gu, X., Tang, L., Yin, Y., Liu, D., & Zhang, Y. (2022). Application of machine learning, deep learning and optimization algorithms in geoenvironment and geoscience: Comprehensive review and future challenge. In *Gondwana Research* (Vol. 109).  
<https://doi.org/10.1016/j.gr.2022.03.015>
- Zhao, X., & Chen, W. (2020). Optimization of computational intelligence models for landslide susceptibility evaluation. *Remote Sensing*, 12(14).  
<https://doi.org/10.3390/rs12142180>
- Zhou, C., Yin, K., Cao, Y., Ahmed, B., Li, Y., Catani, F., & Pourghasemi, H. R. (2018). Landslide susceptibility modeling applying machine learning methods: A case study from Longju in the Three Gorges Reservoir area, China. *Computers and Geosciences*, 112.  
<https://doi.org/10.1016/j.cageo.2017.11.019>