

TRABAJO DE GRADO
Opción Investigación o Proyecto de Grado

Título del trabajo

Clasificación de Suelos con Capacitancia Dieléctrica y Machine Learning

Corporación Universitaria Remington.

Nombre de la facultad.

Facultad de Ingeniería

Nombre del programa académico.

Ingeniería Civil

Nombres de los estudiantes autores del trabajo de grado.

Alex Pino Mosquera

Nombre del Tutor del trabajo de grado.

Juan Esteban Velez Alvarez

Opción en la que realizó su trabajo de grado (Investigación o Proyecto de grado).

Proyecto de grado

Año de presentación del trabajo de grado.

2026

Agradecimientos

Expreso mi más sincero agradecimiento al profesor **Juan Esteban Vélez Álvarez**, quien ha sido una figura fundamental en mi formación académica y profesional. Desde el cuarto semestre, ha contribuido significativamente a mi proceso de formación, apoyándome en el mejoramiento académico, motivándome a ser mejor estudiante e inculcando el interés por la investigación y el desarrollo de nuevos proyectos orientados al beneficio de la sociedad. Su dedicación, paciencia y disposición para compartir su experiencia han sido determinantes en el desarrollo de este proyecto y en mi crecimiento como futuro ingeniero.

Asimismo, agradecemos a la **Corporación Universitaria Remington** por brindarme un entorno académico de calidad, el cual ha contribuido de manera significativa a la formación integral. Esta institución ha sido clave en el fortalecimiento de nuestras competencias profesionales e individual, promoviendo el pensamiento crítico, la investigación y la excelencia académica.

De manera especial, **Alex Pino Mosquera** expresa su más profundo agradecimiento a sus padres, **Jesús Efrén Pino Lozano** y **Rubiela Mosquera Castro**, por su apoyo incondicional, esfuerzo constante y confianza a lo largo de su proceso formativo. Su respaldo ha sido fundamental para superar cada desafío y avanzar con determinación hacia el cumplimiento de sus metas académicas y profesionales.

Finalmente, expreso mi agradecimiento a todas aquellas personas que, de una u otra forma, contribuyeron al desarrollo de este trabajo de grado y a mi formación como futuro profesional en Ingeniería Civil. De igual manera, valoro profundamente a quienes, a través de sus palabras de apoyo y motivación, me impulsaron a seguir creciendo y a proyectarme como un profesional íntegro y comprometido con la sociedad.

Contenido

RESUMEN	4
Palabras clave.....	4
Introducción	4
Marco Teórico o de Referencia.....	6
2.1 Fundamentos y métodos de medición para la caracterización dieléctrica del suelo	6
2.2 Clasificación general de los suelos	6
2.2.2 Suelos finos.....	6
2.2.3 Suelos orgánicos	7
2.3 Propiedades eléctricas del suelo.....	7
2.3.1 Comportamiento eléctrico según el tipo de suelo	8
2.4 Métodos de medición dieléctrica del suelo	8
Planteamiento del problema.....	10
Objetivos	11
Objetivo General	11
Objetivos específicos	11
Metodología	12
Recolección de datos:	13
FIGURA 1 MONTAJE PARA LA CLASIFICACIÓN DE SUELO MEDIANTE MACHINE LEARNING	14
Resultados y Discusión	15
FIGURA 2 DISTRIBUCIÓN DE CAPACITANCIA	16
Análisis de la distribución de la capacitancia (Histograma)	16
FIGURA 3 COMPARACION DE CAPACITANCIA	17
Comparación estadística (Diagrama de cajas)	17
FIGURA 4 MATRIZ DE CLASIFICACION.....	18
Evaluación del modelo (Matriz de confusión)	18
Conclusiones	20
Referencias.....	21

RESUMEN

Este estudio explora cómo el machine learning puede clasificar tipos de suelos usando datos de sensores de capacitancia dieléctrica. Esto combina tecnologías modernas con la geotecnia tradicional, buscando una forma más eficiente de caracterizar suelos, algo crucial para el diseño de cimentaciones, estructuras y taludes. Los métodos actuales son caros, lentos y requieren expertos.

Por eso, la investigación propone usar sensores que miden la capacitancia dieléctrica del suelo, que se relaciona con su humedad, densidad y textura. Con estos datos, se entrenaron modelos de machine learning para predecir el tipo de suelo de forma estandarizada. Esta alternativa es más económica y rápida, ideal para estudios geotécnicos iniciales, sobre todo en áreas remotas. Representa un gran paso hacia la automatización y la inteligencia artificial en la ingeniería civil, agilizando diagnósticos y mejorando decisiones en proyectos de infraestructura.

Palabras clave

Clasificación de suelos, Capacitancia dieléctrica, Humedad del suelo, Machine Learning, Geotecnia.

Introducción

Este proyecto busca a implementar un modelo de machine learning para la clasificación de suelos con la recolección de muestras ya que, la clasificación del suelo permite anticipar comportamientos frente a las cargas, variaciones de humedad, estabilidad y capacidad de soporte [1]. Los tipos de suelo más comunes están compuestos por arcilla, arena, limo y grava, cada uno con propiedades físicas y químicas particulares, como plasticidad, permeabilidad, densidad y compresibilidad [2]. La capacitancia del suelo, relacionada con su capacidad para almacenar carga eléctrica en presencia de un campo eléctrico, está directamente influenciada por factores como la textura, contenido de humedad, salinidad y estructura del suelo [3]; [4]. Los sensores capacitivos han sido empleados para estimar el contenido volumétrico de agua y, en consecuencia, como variable indirecta para clasificar tipos de suelos [5].

Los modelos de machine learning ofrecen una forma precisa, automatizada y económica de análisis, útil cuando se dispone de múltiples datos físicos y eléctricos del subsuelo [6]. Esto representa una ventaja significativa en zonas donde el acceso al suelo es limitado o los ensayos convencionales son costosos. Asimismo, las bases de datos creadas con estos métodos permiten el entrenamiento de algoritmos con potencial de mejora continua mediante aprendizaje supervisado y validación cruzada [7].

Estudios recientes han documentado el uso de un analizador de redes vectoriales para medir la constante dieléctrica real e imaginaria del suelo en el rango de 700 MHz a 7 GHz, evidenciando que la humedad y la textura son los principales determinantes de la respuesta eléctrica, alcanzando ajustes estadísticos con R^2 cercanos a 0.95–0.99 [11]. Asimismo, ensayos comparativos utilizando coaxial VNA han demostrado que la salinidad y el contenido orgánico alteran la respuesta dieléctrica, con mayor precisión a frecuencias por encima de 250 MHz [12].

Marco Teórico o de Referencia

2.1 Fundamentos y métodos de medición para la caracterización dieléctrica del suelo

El objetivo del proyecto es mejorar el estudio de la clasificación de suelos a través del uso de machine learning, ya que los métodos tradicionales de laboratorio pueden tardar varias semanas en generar resultados confiables. En este contexto, se busca desarrollar una alternativa más rápida y eficiente mediante la medición de la capacitancia en suelos y la construcción de una base de datos adecuada que permita su clasificación automatizada, apoyándose en técnicas modernas utilizadas en la ingeniería y la ciencia de datos [6]; [7].

2.2 Clasificación general de los suelos

En ingeniería y ciencias del suelo, los materiales se clasifican principalmente según su tamaño de partícula, comportamiento mecánico y composición mineralógica. Uno de los sistemas más utilizados es el Sistema Unificado de Clasificación de Suelos (USCS), ampliamente adoptado en geotecnia [1]; [2]).

2.2.1 Suelos gruesos o granulares

Incluyen las gravas (partículas mayores a 4.75 mm) y las arenas (partículas entre 0.075 mm y 4.75 mm).

Características principales:

- Alta permeabilidad

- Baja compresibilidad

- Comportamiento dominado por la fricción entre partículas [1]; [2])

2.2.2 Suelos finos

Incluyen los limos y las arcillas.

Características principales:

Alta plasticidad (especialmente en arcillas)

Sensibilidad a la humedad

Baja permeabilidad

Comportamiento influenciado por fuerzas electroquímicas

[1];[2]; [15])

2.2.3 Suelos orgánicos

Son aquellos que contienen una cantidad significativa de materia orgánica.

Características principales:

Alta compresibilidad

Baja capacidad portante

Alta deformabilidad [1]

2.3 Propiedades eléctricas del suelo

Desde el punto de vista de esta investigación, es fundamental entender que las propiedades eléctricas del suelo dependen de factores como el contenido de humedad, la porosidad, la composición mineralógica y la presencia de sales disueltas [12].

2.3.1 Comportamiento eléctrico según el tipo de suelo

Arcillas: presentan alta capacitancia y baja resistividad debido a su alta capacidad de retención de agua.

Arenas: presentan baja capacitancia y mayor resistividad debido a su rápido drenaje.

Gravas: presentan muy baja capacitancia debido al reducido contacto entre partículas.

[3]; [4]; [11])

2.4 Métodos de medición dieléctrica del suelo

Algunos de los métodos más utilizados para la medición de propiedades eléctricas del suelo incluyen:

Sensores de capacitancia dieléctrica, como los modelos Decagon 5TE y ECH2O, que permiten medir el contenido de humedad y la permitividad dieléctrica del suelo in situ. Estos sensores permiten asociar rangos de valores eléctricos con tipos específicos de suelo [3]; [8]; [5]).

Time Domain Reflectometry (TDR), La técnica Time Domain Reflectometry (TDR) consiste en un método de medición ampliamente utilizado para determinar con alta precisión la humedad volumétrica y la constante dieléctrica del suelo, mediante el análisis del tiempo que tarda una señal electromagnética en propagarse y reflejarse a través de una sonda insertada en el material [4]. Su aplicación es fundamental en estudios geotécnicos, ya que permite obtener información confiable sobre las propiedades dieléctricas del suelo, las cuales están directamente relacionadas con su composición y contenido de agua. [4].

Métodos electromagnéticos y geofísicos, que permiten obtener información del contenido de agua y la distribución del suelo sin necesidad de excavación [10].

2.5 Integración de machine learning en la caracterización geotécnica

El ensayo de penetración con cono (CPT) equipado con sensores eléctricos se ha convertido en una herramienta útil para generar datos de entrenamiento para modelos de aprendizaje automático, permitiendo la clasificación continua del suelo [9].

Asimismo, el uso de propiedades dieléctricas como variables de entrada ha demostrado ser efectivo para la clasificación de suelos mediante algoritmos de machine learning [7]; [14].

La clasificación del suelo sigue siendo fundamental en el diseño geotécnico, ya que permite determinar sus propiedades físicas y mecánicas mediante ensayos como el análisis granulométrico y los límites de Atterberg [1]; [2]; [15];[16]).

Finalmente, los modelos de aprendizaje automático pueden implementarse en entornos de programación como Python, facilitando el procesamiento de datos y la generación de modelos predictivos robustos [17]; [6].

Planteamiento del problema.

Desde el campo de la ingeniería civil y geotécnica se sabe que el tipo de suelo es clave para iniciar a construir. De esto dependen decisiones importantes sobre el diseño, materiales y métodos de construcción, influyendo directamente en la seguridad y estabilidad de la obra. Sin embargo, los métodos tradicionales de análisis de suelos, aunque exactos como las pruebas de laboratorio y de campo, son caros, lentos, requieren expertos y equipos complejos que son difíciles de usar en lugares remotos. Esto dificulta tener diagnósticos rápidos, para superar estas limitaciones, se buscan alternativas más rápidas y eficientes. Es por eso que se busca a implementar las nuevas tecnologías como los sensores de capacitancia dieléctrica combinados con el machine learning ya que ofrecen una solución prometedora para automatizar la identificación de suelos en el sitio. Sin embargo, este estudio se enfoca en validar qué tan efectivos son estos nuevos métodos en situaciones reales y compararlos con las técnicas convencionales.

Objetivos

Objetivo General

Determinar la capacitancia de suelos como arcilla, arena y grava con el fin de desarrollar un modelo de machine learning que permita predecir el tipo de suelo.

Objetivos específicos

- Registrar la capacitancia de distintas muestras de terreno (limo, arena y piedra suelta) en condiciones definidas (humedad relativa, temperatura, etc).
- Construir un dispositivo para medición de capacitancia en suelos.
- Desarrollar un modelo de machine learning para predicción del tipo de suelo en función de la capacitancia medida.

Metodología

El procedimiento se divide en varias fases: La presente investigación adopta un enfoque experimental y aplicado, orientado al desarrollo de modelos predictivos mediante técnicas de machine learning para la clasificación de tipos de suelos a partir de datos obtenidos mediante sensores de capacitancia se construyó una protoboard con el objetivo de medir la capacitancia, el cual cuenta también con una caja con placas de cobre cubiertas con cinta para aislar el contacto directo con las placas, colocar las muestras de suelo y poder hacer la medición mediante la aplicación Thonny. Para el proceso de clasificación se implementó el algoritmo Random Forest, el cual consiste en un conjunto de árboles de decisión que trabajan de manera conjunta. Cada árbol se entrena con subconjuntos aleatorios de los datos y de las variables, lo que reduce el riesgo de sobreajuste y mejora la precisión del modelo. Este enfoque permite evaluar de forma robusta la relación entre los valores de capacitancia medidos y el tipo de suelo, generando predicciones más confiables y generalizables.

La fase de adquisición de datos constó de 60 muestras experimentales, divididas en grupos de 20 para tres tipos de suelo: arena, arcilla y grava. Con el fin de asegurar la uniformidad de las mediciones y mitigar el ruido ambiental sobre la capacitancia, los ensayos se realizaron en un laboratorio con temperatura controlada entre 25 °C y 28 °C. Asimismo, la humedad de las muestras se reguló estrictamente entre el 10 % y el 15 %, intervalo adecuado para el análisis dieléctrico. Los datos obtenidos fueron procesados para consolidar la base de datos de entrenamiento y validación del modelo de clasificación, permitiendo vincular las propiedades eléctricas medidas con su respectivo tipo de suelo.

Recolección de datos:

Se realizó la recolección de datos de las muestras obtenidas con el propósito de construir una base de información confiable que permitiera analizar las propiedades eléctricas y su relación con la clasificación de los suelos. Posteriormente, se llevó a cabo la eliminación de la información, eliminando valores nulos o inconsistentes, debido a que estos podían generar sesgos en el entrenamiento del modelo y afectar la precisión de los resultados.

Una vez garantizada la calidad de los datos, se evaluó la viabilidad del uso de la capacitancia como variable predictiva, ya que esta propiedad puede reflejar cambios asociados a la composición y características físicas del suelo, convirtiéndose en un parámetro relevante para su clasificación.

Seguidamente, se implementaron técnicas de machine learning aplicadas al campo de la geotecnia y el estudio de suelos, con el fin de explorar métodos alternativos que permitan optimizar los procesos tradicionales de caracterización, reduciendo tiempos de análisis y mejorando la capacidad predictiva. Dentro de estas técnicas, se empleó el algoritmo Random Forest, debido a su capacidad para procesar múltiples variables y generar predicciones robustas a partir de la construcción de varios árboles de decisión. Finalmente, se calculó el promedio de las predicciones generadas por todos los árboles del modelo, ya que este procedimiento permite disminuir el error individual de cada estimación y obtener un resultado final más preciso, estable y confiable para la clasificación del tipo de suelo.




FIGURA 1 MONTAJE PARA LA CLASIFICACIÓN DE SUELO MEDIANTE
MACHINE LEARNING

Resultados y Discusión

Los resultados obtenidos mediante el modelo de machine learning evidencian que la capacitancia es una variable importante para la clasificación de los tipos de suelo. La matriz de confusión muestra un buen desempeño general, con valores altos en la diagonal principal, lo que indica que la mayoría de las muestras fueron correctamente clasificadas, aunque existen algunas confusiones entre clases, especialmente en el suelo Arena Combinada–Revoque.

El análisis de la capacitancia revela diferencias entre los tipos de suelo. En particular, Arena Combinada–Revoque presenta mayor variabilidad y valores más altos, lo que facilita su identificación. Por otro lado, Arena 5/16 de P.B y Arena-Argos muestran distribuciones más compactas, aunque con ligera superposición, lo que puede generar errores en la clasificación.

Para mejorar la precisión del modelo, se recomienda aumentar el número de muestras a al menos 100 por tipo de suelo, permitiendo un entrenamiento más robusto. Además, la resistividad del suelo se identifica como un parámetro complementario clave, ya que se mide mediante métodos como el de cuatro electrodos y depende de factores como la humedad y la composición del suelo.

En conjunto, el uso de la capacitancia y la resistividad permite una clasificación más precisa, ya que ambas propiedades eléctricas aportan información complementaria sobre el comportamiento del suelo.




FIGURA 2 DISTRIBUCIÓN DE CAPACITANCIA

Análisis de la distribución de la capacitancia (Histograma)

El análisis gráfico que se obtuvo de la capacitancia que revela patrones distintivos que permiten diferenciar los materiales evaluados, aunque con grados variables de precisión:

Arena Combinada–Revoque: Se posiciona en el rango superior de la escala, con registros que oscilan entre 6000 y 10000 pF. La notable amplitud de su distribución sugiere una naturaleza heterogénea, factor que probablemente responde a la interacción entre la mezcla de componentes y sus niveles de humedad.

Arena-Argos: Exhibe una tendencia intermedia, concentrándose mayoritariamente entre los 900 y 1500 pF. A pesar de mostrar una mayor cohesión en los datos, se identifican algunos valores atípicos que se alejan del promedio del grupo.

Arena 5/16 de P.B: Registra la magnitud de capacitancia más baja de la muestra (500 a 1000 pF), caracterizándose por una dispersión mínima que indica una mayor homogeneidad en sus propiedades eléctricas.




FIGURA 3 COMPARACION DE CAPACITANCIA
Comparación estadística (Diagrama de cajas)

El análisis de cajas y bigotes ratifica las observaciones previas, permitiendo cuantificar la dispersión y la tendencia central de cada muestra:

Arena Combinada–Revoque: Este material se ratifica como el más diferenciable del conjunto. Su Rango Intercuartílico (IQR) es notablemente más extenso y sus valores máximos superan con creces a los demás. Esta elevada volatilidad en los datos eléctricos confirma que posee una firma distintiva, lo que simplifica su identificación automática.

Segmento de Baja Capacitancia (Arena-Argos y Arena 5/16 de P.B): Ambos suelos muestran una mayor consistencia interna, reflejada en cajas más compactas y una dispersión reducida.

Desde una perspectiva estadística, la proximidad en las métricas de tendencia central entre la Arena-Argos y la Arena 5/16 de P.B es el factor determinante de la ambigüedad. Mientras que la Arena Combinada-Revoque es un "conjunto" aislado y evidente, la similitud en el comportamiento dieléctrico.




FIGURA 4 MATRIZ DE CLASIFICACION

Evaluación del modelo (Matriz de confusión)

El desempeño del modelo de clasificación se valida a través de la métrica de aciertos y errores, revelando una eficacia general sólida, pero con puntos críticos de ambigüedad:

Tasa de Aciertos (Diagonal Principal)

La concentración de predicciones correctas en la diagonal principal de la matriz de confusion, con valores de 14, 11 y 13 unidades, confirma que el modelo posee una capacidad predictiva robusta y un desempeño global satisfactorio. Estos resultados corresponden a porcentajes de acierto de 70 % para-Arena 5/16 de P.B, 52,4 % para-Arena Combinada-Revoque y 65 % para-Arena-Argos, siendo la categoría de Arena Combinada-Revoque la que presentó el menor nivel de precisión entre las clases evaluadas.

La variación en estos porcentajes puede explicarse por las características físicas y dieléctricas propias de cada tipo de suelo. En materiales con una estructura más homogénea, las mediciones de capacitancia tienden a ser más estables debido a una

distribución más uniforme de la humedad y a una interacción electromagnética más consistente entre las partículas. Esta estabilidad facilita que el modelo identifique patrones repetitivos durante el entrenamiento y, por consiguiente, realice clasificaciones más precisas.

Por el contrario, en materiales con mayor proporción de partículas granulares, como ocurre en las mezclas de arena y particularmente en la combinación arena-revoque, la respuesta capacitiva presenta una mayor variabilidad. Esto se debe a que la movilidad relativa de las partículas, junto con la presencia de vacíos intergranulares y una distribución irregular del contenido de humedad, genera fluctuaciones en la constante dieléctrica del sistema. Como resultado, las mediciones presentan un comportamiento menos estable y más aleatorio, dificultando la identificación de patrones claros por parte del algoritmo.

En consecuencia, aunque el modelo presenta un desempeño satisfactorio en términos generales, los resultados evidencian que la precisión de clasificación está directamente relacionada con la estabilidad dieléctrica del material analizado, constituyendo un factor determinante en la confiabilidad de la clasificación automática de suelos mediante técnicas de machine learning.

Debilidades en la Clasificación:

Desviación en Arena Combinada–Revoque: A pesar de su perfil eléctrico alto, esta clase presenta el mayor índice de error, siendo etiquetada erróneamente como Arena-Argos o Arena 5/16. Esto sugiere que ciertos estados del material (posiblemente por variaciones de humedad) imitan los rangos de las arenas de menor capacitancia.

Intercambio entre Arenas de Baja Capacitancia: Se observa una confusión recíproca entre Arena-Argos y Arena 5/16 de P.B, lo cual es plenamente coherente con la proximidad estadística y el solapamiento de medianas analizados previamente.

Conclusiones

Cumpliendo el objetivo general al demostrar que la capacitancia es una variable adecuada para la clasificación de suelos, permitiendo desarrollar un modelo de machine learning con buen desempeño en la predicción del tipo de material. En cuanto a los objetivos específicos, se logró registrar la capacitancia de distintas muestras bajo condiciones controladas, evidenciando diferencias claras entre los suelos. La Arena Combinada–Revoque presentó los valores más altos y mayor variabilidad, lo que facilitó su identificación, mientras que la Arena-Argos y la Arena 5/16 de P.B mostraron comportamientos más similares, generando cierta dificultad en su diferenciación.

Asimismo, se construyó un dispositivo de medición funcional y se desarrolló un modelo de clasificación, cuyo desempeño fue validado mediante la matriz de confusión, mostrando una alta proporción de aciertos, aunque con algunas confusiones entre materiales de características cercanas. Desde una perspectiva técnica, estas limitaciones no representan una falla del modelo, sino una consecuencia directa de la similitud física y eléctrica entre los materiales analizados. Por lo tanto, se concluye que la capacitancia, aunque es un buen modelo predictivo, no es suficiente por sí sola para una clasificación completamente precisa en todos los casos.

En este sentido, se propone como mejora fundamental:

Incrementar el tamaño de la muestra experimental (mínimo 100 datos por tipo de suelo) para fortalecer el entrenamiento del modelo.

Incorporar la resistividad eléctrica como variable complementaria, ya que esta propiedad depende de factores como la humedad, la porosidad y la composición mineralógica, aportando información adicional que permite reducir la incertidumbre en la clasificación.

Referencias

- [1] Das, B. M. (2010). Principles of Geotechnical Engineering (7th ed.). Cengage Learning.
- [2] Coduto, D. P., Yeung, M. R., & Kitch, W. A. (2011). Geotechnical Engineering: Principles and Practices (2nd ed.). Pearson Education.
- [3] Topp, G. C., Davis, J. L., & Annan, A. P. (1980). Electromagnetic determination of soil water content: Measurements in coaxial transmission lines. *Water Resources Research*, 16(3), 574–582.
- [4] Robinson, D. A., Jones, S. B., Wraith, J. M., Or, D., & Friedman, S. P. (2003). A review of advances in dielectric and electrical conductivity measurement in soils using time domain reflectometry. *Vadose Zone Journal*, 2(4), 444–475.
- [5] Vaz, C. M. P., Jones, S. B., Meding, M., & Tuller, M. (2013). Evaluation of standard calibration functions for capacitance-based soil water sensors. *Vadose Zone Journal*, 12.
- [6] Abduljabbar, R., Omar, T., Sepasgozar, S. M. E., & Mohammed, B. (2020). Machine learning in construction: From shallow to deep learning. *Automation in Construction*, 113, 103180.
- [7] Zhou, Y., Wang, Y., & Ren, T. (2018). Soil texture classification based on dielectric permittivity measurements and machine learning algorithms. *Computers and Electronics in Agriculture*, 148, 63–70.
- [8] Bogaen, H. R., Huisman, J. A., Oberdörster, C., & Vereecken, H. (2007). Evaluation of a low-cost soil water content sensor for wireless network applications. *Journal of Hydrology*, 344(1–2), 32–42.
- [9] Fatehnia, M., Mahmoudabadi, V., & Amiri, S. (2024). Utilizing Machine Learning for Cone Penetration Test-Based Soil Classification. *Transportation Research Record*, 03611981241245679.
- [10] Jonard, F., Gonçalves, R., & Lambot, S. (2014). Quantitative electromagnetic imaging of soil water content using GPR and Bayesian inversion. *Geophysical Research Letters*, 41(14), 4973–4979.

- [11] Kabir, H., Khan, M. J., Brodie, G., et al. (2020). Measurement and modelling of soil dielectric properties... J. Microwave Power & Electromagnetic Energy, 54.
- [12] Bieganski, A., et al. (2019). Impact of soil salinity... Sci. Direct.
- [13] METER Group. (s. f.). Sensores de humedad del suelo: cómo funcionan. Por qué algunos no son aptos para la investigación.
- [14] Nguyen, MD; Costache, R.; Sy, AH; Ahmadzadeh, H.; Van Le, H.; Prakash, I.; Pham, BT. Enfoque novedoso para la clasificación de suelos mediante métodos de aprendizaje automático. Bull. Eng. Geol. Environ. 2022 , 81 , 468.
- [15] Atterberg, A. Die Plastizität der Tone. Int. Mitt. Bodenkd. 1911, 1, 10–43. (In German)
- [16] Das, B.M. Advanced Soil Mechanics; Taylor & Francis: London, UK, 2019.
- [17] Python Software Foundation. (2025). *Python*
- [18] Samouëlian, A., Cousin, I., Tabbagh, A., Bruand, A., & Richard, G. (2005). Electrical resistivity survey in soil science: A review. Earth-Science Reviews, 83(1–2), 173–193.