

ESTIMACIÓN DE LA TEXTURA DE SUELOS MEDIANTE ALGORITMOS DE
INTELIGENCIA ARTIFICIAL APLICADOS A FIRMAS ESPECTRALES NIR

Fabio Andres Corzo Arguello

Trabajo de Grado para optar al título de Ingeniero Electrónico

Director

Hans Yecid Garcia Arenas

Doctor en Ingeniería

Universidad Industrial de Santander

Facultad de Ingenierías Fisico-Mecanicas

Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones

Bucaramanga

2026

Dedicatoria

Dedicado a mi hermosa madre Luz Marina y a mis hermanos Jayder y Angie. Ustedes han sido mi inspiración durante este largo camino.

También a ese niño que desde muy pequeño tuvo que enfrentar situaciones no acordes a su edad para sostener este sueño.

Todo ha valido la pena.

Agradecimientos

Agradezco a mi familia, en especial a mi tío Henry, quién siempre estuvo ahí ayudándome para sacar adelante mi carrera y creyó en mí.

A mi tía Rocio, quién me ayudo bastante en mis inicios de carrera, fue la persona que me guió en la parte mas difícil que es llegar nuevo a la universidad.

A Valeria Aceros, mi compañera de vida, quién me motivó a tomar caminos diferentes y siempre confió en mí. Con su apoyo incondicional me ha hecho creer en que puedo con todo. Te amo y este logro es para los dos, no sabes lo agradecido que estoy de haberte conocido.

A Perse: mi hermoso gatico, quién me acompañó en pandemia pero no está aquí para celebrar este gran logro. Él no sabe que fue lo mas importante de mi vida y que con sus bigotes hizo que pudiera atravesar esos dos años tan difíciles. A pesar de que no estés, siempre te llevaré en mi corazón.

A mi director Hans, quién me ayudo en un momento muy crítico y gracias a su orientación puedo celebrar este logro.

A Sebastian Y Andrey, quienes han sido unos grandes amigos y han hecho que estos últimos años, que son los mas difíciles, sean llevaderos. Gracias por esas largas noches de juego, llenas de risa, siempre las atesoraré.

Y a todas las personas que conocí durante este largo camino y me ayudaron sin esperar nada a cambio. Gracias por hacer de este mundo algo mejor.

Tabla de Contenido

Introducción	12
1 Objetivos	15
1.1 Objetivo general	15
1.2 Objetivos específicos	15
2 Marco Teórico	16
2.1 La Textura del Suelo: Variable Crítica y su Problemática de Medición	16
2.2 La Espectroscopia NIR: De la Física a la “Huella Digital” del Suelo	17
2.2.1 El Fundamento Físico: Sensibilidad a los Componentes del Suelo	17
2.2.2 Acondicionamiento de la Muestra: Aislando la Señal Textural	17
2.2.3 De la Interacción Física a la Señal Digital	19
2.2.4 La “Huella Digital” Espectral como Señal Compuesta y Multivariada	19
2.3 Aprendizaje Automático: Del Modelado Lineal a la Arquitectura Profunda	20
2.3.1 Mínimos Cuadrados Parciales (PLS):	20
2.3.2 Random Forest (RF):	21
2.3.3 Redes Neuronales Convolucionales (CNN):	22
2.3.3.1 Justificación Estructural: El Espectro como Señal 1D	22
2.3.3.2 Mecanismo de Aprendizaje Jerárquico de Características	22
2.3.3.3 Ventaja Decisiva	23

3 Desarrollo de la Solución	24
3.1 Adquisición y Estructuración de Datos Crudos	24
3.1.1 Procesamiento de los Datos Espectrales (Archivos .mat)	24
3.1.2 Integración con los Resultados de Laboratorio	25
3.2 Limpieza y Control de Calidad de los Datos	25
3.3 Preprocesamiento Espectral	26
3.3.1 Normalización con SNV (Variación Normal Estándar)	26
3.3.2 Suavizado y Derivación con el Filtro Savitzky-Golay	27
3.4 Arquitectura del Modelo	27
3.4.1 Resumen General de la Arquitectura	27
3.4.2 Descripción de la Arquitectura del Modelo	28
3.4.3 Estrategia de Partición de Datos	29
3.4.4 Configuración de Hiperparámetros	29
3.4.5 Control del Entrenamiento (Callbacks)	30
3.5 Resultados y Discusión de la Solución	30
3.5.1 Evaluación del Desempeño Predictivo	30
3.5.2 Verificación de la Suma Composicional	31
3.5.3 Evaluación del Proceso de Aprendizaje	32
3.5.4 Análisis de la Complejidad del Dominio	33
3.5.5 Análisis Comparativo con Modelos de Referencia	33
3.5.6 Valor real vs Valor predicho	34

4 Conclusiones	37
4.1 Cumplimiento de los Objetivos Específicos	37
4.2 Aportes y Hallazgos Relevantes	38
4.3 Limitaciones y Trabajo Futuro	38
4.4 Impacto y Aplicaciones	39
4.5 Impacto y Proyección	39
5 Recomendaciones	40
5.1 Expansión y Diversificación del Conjunto de Datos	40
5.2 Innovación en Arquitecturas de Aprendizaje Profundo	40
Referencias Bibliográficas	41
Apéndices	45

Lista de Figuras

Figura 1	Comparación gráfica de firmas espectrales NIR	20
Figura 2	Gráfica de las curvas del MSE de los datos de entrenamiento y validación.	32
Figura 3	Comparación de espectros similares con diferente contenido de arcilla.	34
Figura 4	Gráfico de dispersión entre valores reales y predichos para la fracción de arena utilizando CNN, PLS y RF.	36
Figura 5	Gráfico de dispersión entre valores reales y predichos para la fracción de limo utilizando CNN, PLS y RF.	45
Figura 6	Gráfico de dispersión entre valores reales y predichos para la fracción de arcilla utilizando CNN, PLS y RF.	46

Lista de Tablas

Tabla 1	Resumen general de la arquitectura CNN-1D propuesta.	28
Tabla 2	Resultados del modelo CNN en el conjunto de prueba (test set).	31
Tabla 3	Comparativa del coeficiente de determinación R^2 frente a modelos tradicionales.	35
Tabla 4	Configuración consolidada de hiperparámetros de entrenamiento.	47

Lista de Apéndices

	pág.
Apéndice A Comparaciones adicionales entre modelos	45
Apéndice B Configuración detallada de hiperparámetros	46

Resumen

Título: Estimación de la textura de suelos mediante algoritmos de inteligencia artificial aplicados a firmas espectrales NIR*

Autor: Fabio Andres Corzo Arguello**

Palabras Clave: Aprendizaje profundo, Textura del suelo, Espectroscopía NIR, Redes neuronales convolucionales, Firmas espectrales, Santander.

Descripción:

El presente trabajo tiene como objetivo desarrollar una herramienta precisa y eficiente para la predicción de textura del suelo a partir de firmas espectrales en rango cercano al infrarrojo (NIR) con base en muestras recolectadas en la región de Santander, Colombia. Para esto, se implementó un modelo de red neuronal convolucional (CNN) capaz de estimar los porcentajes de arena, limo y arcilla a partir de la información espectral. Mediante técnicas de preprocesamiento de datos, prueba de varios modelos y optimización de parámetros de la CNN, se alcanzó un coeficiente de determinación R^2 promedio de 0.56. Lo anterior, demuestra la relación que existe entre las firmas espectrales y la textura del suelo. De esta forma, damos paso a la consideración de los modelos de aprendizaje profundo como herramientas confiables para la caracterización de suelos, lo que ofrecerá alternativas más ágiles y económicas si se compara con los métodos tradicionales. Este estudio contribuye al desarrollo de soluciones tecnológicas para el monitoreo y la gestión de suelos, ayudando al fortalecimiento de prácticas sostenibles en el mundo agrícola y ambiental de la región.

* Trabajo de grado

** Facultad de Ingenierías Fisicomecánicas, Escuela de Eléctrica, Electrónica y Telecomunicaciones. Director: Ph.D. Hans Yecid García Arenas.

Abstract

Title: Estimation of soil texture using artificial intelligence algorithms applied to NIR spectral signatures*

Author: Fabio Andres Corzo Arguello**

Key Words: Deep learning, Soil texture, NIR spectroscopy, Convolutional neural networks, Spectral signatures, Santander.

Description:

The objective of this study is to develop an accurate and efficient tool for predicting soil texture based on spectral signatures in the near-infrared (NIR) range, using samples collected in the Santander region of Colombia. To this end, a convolutional neural network (CNN) model was implemented that is capable of accurately estimating the percentages of sand, silt, and clay from spectral information. Through data preprocessing techniques, testing of various models, and optimization of CNN parameters, an average coefficient of determination (R^2) of 0.56 was achieved. This demonstrates the relationship between spectral signatures and soil texture. This paves the way for deep learning models to be considered reliable tools for soil characterization, offering more agile and economical alternatives compared to traditional methods. This study contributes to the development of technological solutions for soil monitoring and management, helping to strengthen sustainable practices in the region's agricultural and environmental sectors.

* Bachelor Thesis

** Facultad de Ingenierías Fisicomecánicas, Escuela de Eléctrica, Electrónica y Telecomunicaciones. Director: Ph.D. Hans Yecid García Arenas.

Introducción

La textura del suelo, definida como la proporción de arena, limo y arcilla, determina propiedades hidráulicas críticas como la infiltración y la retención de agua, siendo esencial para la agricultura de precisión en Santander. Sin embargo, en regiones con desafíos logísticos como esta, la ejecución de este proceso se enfrenta a obstáculos considerables: la dificultad para acceder a laboratorios especializados, los costos elevados que implica el transporte y tratamiento de las muestras y, sobre todo, los prolongados tiempos de análisis.

Históricamente, la determinación de la textura del suelo ha estado reservada a los análisis fisicoquímicos convencionales. A pesar de que estos métodos son precisos, exigen infraestructura compleja, personal especializado y largos periodos de espera, lo que limita su aplicación generalizada, especialmente en regiones con recursos restringidos. Esta realidad ha impulsado la búsqueda de alternativas más ágiles y accesibles que permitan estimar las propiedades del suelo de manera rápida y económica.

En este contexto, la espectroscopía de reflectancia en el infrarrojo cercano (NIR) ha emergido como una técnica prometedora. Diversas investigaciones han demostrado la potente correlación entre las firmas espectrales en este rango y la composición del suelo, incluyendo propiedades como el contenido de carbono, la capacidad de intercambio catiónico y, crucialmente, la textura (Perret y cols. (2020)). La interacción de la luz con las moléculas de la muestra genera un espectro característico “Huella Digital” que codifica información detallada sobre su composición química y

física.

Para el caso particular de los suelos tropicales, esta técnica reviste especial interés. Estudios recientes en contextos similares al nuestro —como los desarrollados en Costa Rica por Ortiz, de Dios Herrero, y Kloster (2024)— han demostrado que la espectroscopía Vis-NIR combinada con modelos de aprendizaje automático permite estimar con precisión diversas propiedades edáficas, alcanzando coeficientes de determinación superiores a 0.8 para nutrientes como Ca, Mg y Fe. En Argentina, investigaciones del INTA han confirmado la capacidad de esta tecnología para predecir el contenido de arcilla más limo, carbono orgánico y pH en muestras de suelo, destacando su potencial como herramienta de análisis rápido y ambientalmente amigable (Perret y cols. (2020)). Estos antecedentes, provenientes de contextos edafoclimáticos análogos al nuestro, refuerzan la pertinencia de explorar estas técnicas en la región de Santander.

No obstante, el camino desde la medición espectral hasta la estimación confiable de propiedades del suelo no es trivial. La señal NIR es intrínsecamente compleja, con múltiples superposiciones de características espectrales y fuerte colinealidad entre las longitudes de onda. Tradicionalmente, el análisis quimiométrico de estos datos ha recurrido a métodos como la regresión por mínimos cuadrados parciales (PLS), que ofrece robustez en sistemas lineales y constituye el punto de partida estándar en la disciplina. Sin embargo, estos enfoques lineales encuentran limitaciones cuando se enfrentan a las relaciones no lineales y las interacciones complejas que caracterizan la respuesta espectral del suelo.

Es aquí donde las técnicas de aprendizaje profundo (deep learning) ofrecen una ventaja determinante. A diferencia de los métodos convencionales, las redes neuronales profundas pue-

den modelar dependencias no lineales complejas y extraer características jerárquicas de los datos, aprendiendo representaciones cada vez más abstractas a través de sus múltiples capas. Esta capacidad las hace particularmente adecuadas para decodificar la información sutil contenida en las series espectrales del suelo, especialmente en fracciones como la arcilla, cuyas bandas de absorción diagnósticas pueden verse afectadas por interacciones con la matriz del suelo.

A pesar de los avances reportados en la literatura, persiste una brecha importante: la mayoría de los modelos desarrollados se han entrenado y validado con bases de datos espectrales globales o de regiones templadas, existiendo escasa evidencia sobre su desempeño en suelos tropicales con mineralogías específicas, como los presentes en Santander. Esta limitación es crítica, pues las propiedades espectrales del suelo dependen fuertemente de su composición mineralógica, la cual puede variar drásticamente entre regiones.

El presente estudio propone abordar esta brecha mediante el diseño y entrenamiento de una Red Neuronal Convolutiva (CNN) unidimensional, específicamente desarrollada para estimar los porcentajes de arena, limo y arcilla a partir de espectros NIR recolectados en la región de Santander. La arquitectura propuesta, incorpora mecanismos de regularización intensiva y funciones de activación ELU para maximizar su capacidad de generalización. Los resultados sugieren la viabilidad técnica de esta aproximación, alcanzando coeficientes de determinación en el orden de $R^2 \approx 0,56$, lo que posiciona al modelo como una alternativa prometedora frente a los métodos tradicionales.

1. Objetivos

1.1. Objetivo general

Desarrollar e implementar un modelo de inteligencia artificial para estimar los porcentajes de arena, limo y arcilla en suelos agrícolas a partir de firmas espectrales NIR, con el fin de validar su precisión y aplicabilidad en la caracterización de suelos.

1.2. Objetivos específicos

1. Preparar las firmas espectrales NIR de suelos agrícolas disponibles en el grupo HDSP como insumo para el entrenamiento de los algoritmos.
2. Desarrollar e implementar un modelo de inteligencia artificial para la estimación de la textura en suelos agrícolas mediante los porcentajes de arena, limo y arcilla.
3. Optimizar los parámetros de entrenamiento de los modelos a fin de mejorar la precisión de las predicciones.
4. Validar el desempeño de los modelos utilizando métricas estadísticas como el coeficiente de determinación (R^2).

2. Marco Teórico

2.1. La Textura del Suelo: Variable Crítica y su Problemática de Medición

Para contextualizar el desarrollo de este trabajo, es fundamental partir de la relevancia ingenieril y ambiental de la textura del suelo. Más allá de su definición composicional (la proporción de arena, limo y arcilla), la textura es un atributo maestro que determina propiedades hidráulicas y mecánicas decisivas. Controla, por ejemplo, la tasa de infiltración, la capacidad de retención de agua útil y la susceptibilidad a la erosión. Por tanto, su cuantificación precisa es una necesidad transversal en la agricultura de precisión, la gestión de recursos hídricos y la ingeniería geotécnica.

El método convencional para su determinación —ya sea el del hidrómetro, la pipeta o el método táctil—, si bien es preciso, introduce una serie de limitaciones operativas que restringen su aplicabilidad a gran escala. Estas técnicas demandan un tiempo de procesamiento considerable (días) y requieren de infraestructura de laboratorio y personal especializado (Beretta y cols., 2014). Como consecuencia, la caracterización textural se convierte en un proceso costoso y de baja densidad espacial, donde el número de muestras analizadas es una fracción mínima del área de interés. Esta limitación es particularmente crítica en regiones como el departamento de Santander, Colombia, donde la diversidad edáfica y la accesibilidad pueden complicar los muestreos intensivos (Instituto Geográfico Agustín Codazzi - IGAC, 2003).

Esta disyuntiva —entre la necesidad de datos precisos y lo poco práctico de los métodos tradicionales para obtenerlos de manera ágil y extensiva— constituye la motivación central de

esta investigación. La búsqueda de un método alternativo, rápido, no destructivo y potencialmente portable, que permita inferir la textura a partir de una medición indirecta, se presenta como una solución de alto valor. La espectroscopia NIR emerge como una candidata idónea para este fin, al capturar la “huella digital” óptica del suelo, la cual contiene información inherente sobre su composición mineral y orgánica.

2.2. La Espectroscopia NIR: De la Física a la “Huella Digital” del Suelo

Para comprender la implementación tecnológica y el análisis de datos presentados en este informe, es fundamental establecer los principios físicos que rigen la interacción entre la luz NIR y los componentes mineralógicos del suelo. Esta sección aborda cómo, bajo condiciones controladas de preparación de la muestra, esta interacción genera una firma espectral única que codifica información sobre la distribución de tamaños de partícula (textura).

2.2.1. El Fundamento Físico: Sensibilidad a los Componentes del Suelo

La radiación en el Infrarrojo Cercano (NIR, aproximadamente 780-2500 nm) es absorbida por los materiales debido a las vibraciones de sus enlaces moleculares. En esta región espectral, predominan las absorciones correspondientes a sobretonos y bandas de combinación de enlaces específicos. Para suelos secos, los enlaces más relevantes son los O-H estructurales presentes en los minerales arcillosos, los cuales generan bandas de absorción características (Stenberg, Viscarra Rossel, Mouazen, y Wetterlind, 2010).

2.2.2. Acondicionamiento de la Muestra: Aislado la Señal Textural

La relación entre la señal espectral y la textura puede verse afectada por factores de interferencia. Para aislar la señal, se aplicaron los siguientes pasos:

1. **Tamizado:** Este proceso busca homogeneizar el tamaño de partícula para eliminar la variabilidad espectral debida a la estructura y rugosidad, estandarizando el efecto de dispersión de la luz. De acuerdo con Stenberg y cols. (2010), esto permite que las variaciones en la reflectancia se atribuyan principalmente a la composición mineralógica y no a la disposición física de la muestra.
2. **Secado:** La eliminación del agua constituye un paso crítico para estabilizar la respuesta espectral. Según Stenberg y cols. (2010)), la presencia de humedad genera dos efectos principales que degradan la calidad de la señal. En primer lugar, provoca un oscurecimiento general de la reflectancia debido al cambio en el índice de refracción del medio. Más importante aún, el agua introduce bandas de absorción intensas en la región del infrarrojo cercano (> 1000 nm), las cuales pueden solaparse e interferir con las firmas espectrales de los componentes edáficos de interés. Se ha documentado, por ejemplo, que el incremento en el contenido de humedad reduce sustancialmente la profundidad de la banda diagnóstica de los minerales arcillosos ubicada cerca de los 2200 nm; en niveles altos de saturación hídrica, esta banda puede incluso llegar a desaparecer por completo. En consecuencia, el trabajo con muestras secas (humedad post-secado ($< 1\%$)) garantiza que las señales sutiles de los minerales arcillosos y otros componentes sean plenamente detectables, evitando que queden enmascaradas por el ruido espectral dominante del agua.

2.2.3. De la Interacción Física a la Señal Digital

La captura de la firma espectral se realizó con un espectrómetro NIRQuest (Ocean Optics). Este instrumento descompone la luz reflejada por la muestra en sus longitudes de onda constituyentes, generando un vector digital de reflectancia. Cada valor en este vector representa la intensidad de la luz reflejada en una banda espectral estrecha, creando una curva continua: la firma espectral.

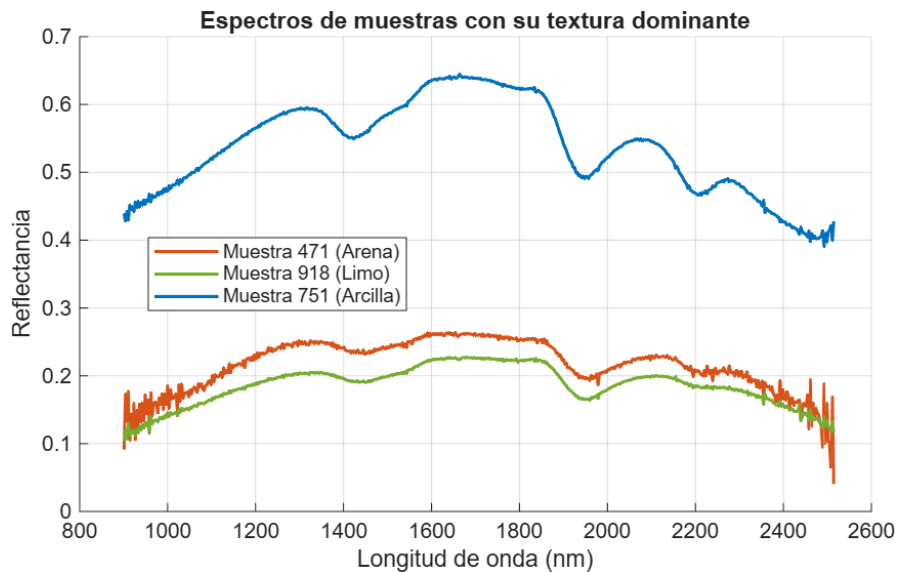
2.2.4. La “Huella Digital” Espectral como Señal Compuesta y Multivariada

El espectro NIR resultante actúa como una “huella digital” óptica del suelo. Sin embargo, es crucial entender su naturaleza:

- 1. Es una señal compuesta de múltiples contribuciones.** El espectro no corresponde a la suma lineal de firmas puras de arena, limo y arcilla. En su lugar, refleja la interacción conjunta de sus componentes: las arcillas dejan huellas de absorción más profundas por sus grupos funcionales activos; la arena, dominada por cuarzo, tiende a elevar la reflectancia de fondo por su carácter espectralmente inerte; y el limo modula la curva de manera intermedia. (Shepherd y Walsh, 2002).
- 2. La información está distribuida en todo el espectro.** No existe una única longitud de onda que permita identificar directamente el contenido de arena, limo o arcilla. Las propiedades texturales están codificadas en la forma de la curva: en la profundidad de las bandas de absorción, en la forma de los valles, en las zonas de transición y en la reflectancia general del continuo. La Figura 1 ilustra cómo la forma global del espectro cambia sistemáticamente dependiendo de la fracción dominante en la muestra.

Figura 1

Comparación gráfica de firmas espectrales NIR



Nota. Comparación de tres firmas espectrales NIR correspondientes a muestras con mayor contenido de arena, limo y arcilla.

2.3. Aprendizaje Automático: Del Modelado Lineal a la Arquitectura Profunda

Las firmas espectrales NIR presentan alta dimensionalidad (512 variables), requiriendo modelos multivariados capaces de extraer patrones no-lineales. En esta sección se describen los diferentes métodos usados hacia las arquitecturas de aprendizaje profundo, basando la adopción final de una CNN como la solución para el problema expuesto en este trabajo.

2.3.1. Mínimos Cuadrados Parciales (PLS):

En la quimiometría, el algoritmo PLS se considera el punto de partida estándar para el análisis de datos espectrales debido a su robustez en sistemas lineales. Este método fue diseñado

específicamente para escenarios donde el número de variables predictoras (X) supera significativamente al número de muestras disponibles, una condición común en la espectroscopia NIR. La estrategia del algoritmo consiste en proyectar las variables de entrada y salida en un nuevo espacio de variables que maximicen la covarianza entre ambos conjuntos, asegurando estabilidad matemática ante la colinealidad de las longitudes de onda (Wold, Sjöström, y Eriksson (2001)). Su principal virtud radica en su utilidad para modelar tendencias lineales con una carga computacional mínima.

Pese a ello, la aplicación de PLS en este trabajo se ve restringida por una limitación estructural: su necesidad de linealidad. Dado que la relación entre la reflectancia en el NIR y la composición textural del suelo está mediada por interacciones físicas y químicas no lineales, PLS resulta incapaz de modelar adecuadamente cómo se combinan e interactúan las señales individuales de la arcilla, el limo y la arena en el espectro (Stenberg y cols., 2010). Por lo tanto, esta incapacidad para aprender patrones complejos lo convierte en un modelo subóptimo para el problema presente.

2.3.2. *Random Forest (RF):*

Random Forest nace del problema que existe con las restricciones lineales del PLS. Se trata de un método que construye varios árboles de decisión basados en submuestras aleatorias de los datos y de las variables, agregando sus predicciones para mejorar la robustez. (Breiman, 2001)

RF ha demostrado más eficiencia en la predicción de las propiedades edáficas a partir de espectros, superando en gran mayoría a PLS. Sin embargo, su arquitectura presenta una desventaja para el procesamiento de las señales espectrales: RF detecta cada longitud de onda como una característica independiente.

Esto significa que ignora por completo la estructura secuencial y la correlación del espectro, donde cada valor en una longitud de onda está ligado a sus adyacentes. Debido a esto, se pierde bastante información, tales como la posición y la anchura de los picos de absorción presentes en la firma espectral.

2.3.3. Redes Neuronales Convolucionales (CNN):

2.3.3.1. Justificación Estructural: El Espectro como Señal 1D. Una firma espectral NIR puede conceptualizarse como una “imagen” unidimensional, donde el eje horizontal es la longitud de onda y el “color” de cada “píxel” es su valor de reflectancia. Así como los píxeles en una imagen 2D están correlacionados espacialmente, los puntos en un espectro 1D están correlacionados espectralmente (Yu, Jia, y Xu, 2017). En la teoría de predicción de suelos, se ha validado que las CNN-1D están optimizadas para preservar la integridad de esta estructura interna al recibir los datos como vectores de alta dimensionalidad (Cao y cols., 2024).

2.3.3.2. Mecanismo de Aprendizaje Jerárquico de Características . El núcleo de una CNN son sus capas convolucionales, que aplican filtros aprendibles que se deslizan a lo largo del espectro:

- **Primeras Capas (Bajo Nivel):** Las primeras capas aprenden a detectar características locales simples, como bordes (transiciones bruscas de reflectancia), picos (valles de absorción) o pendientes, que son manifestaciones directas de la presencia y concentración de componentes específicos. (Mishra y cols., 2022)
- **Capas Posteriores (Alto Nivel):** Estas capas combinan estas características simples para for-

mar representaciones abstractas y compuestas de la forma espectral global (Debus, Parastar, Harrington, y Kirsanov, 2021). Esto permite que la red aprenda a discriminar y cuantificar la contribución simultánea de arena, limo y arcilla a partir de la morfología compleja de la curva.

2.3.3.3. Ventaja Decisiva. La ventaja fundamental de la CNN sobre PLS y RF es su capacidad de aprendizaje de características de extremo a extremo. (Debus y cols., 2021). Mientras que PLS y RF operan sobre representaciones fijas de los datos, la CNN aprende automáticamente la transformación no lineal desde el espectro crudo (o ligeramente preprocesado) hasta las variables objetivo. Debido a esta ventaja, la CNN es la opción ideal para descifrar la información textural que esta codificada de manera distribuida a lo largo de la “Huella Digital” Omondiagbe, Roudier, Lilburne, Ma, y McNeill (2024).

1. Detección de patrones locales: El filtro actúa como un detector que, al deslizarse, aprende un patrón específico (una configuración de picos o valles). En este contexto, el filtro permite que la red identifique la forma y la ubicación de las bandas de absorción molecular y mapee su intensidad a través de la secuencia.
2. Invarianza de traslación: Dado que el mismo filtro se aplica en toda la secuencia, la red puede reconocer un patrón específico independientemente de su ubicación exacta en el espectro. Debido a esto el modelo es más tolerante al ruido y a las variaciones instrumentales. Por ejemplo, si un pico de absorción se desplaza ligeramente de posición entre muestras, la CNN lo sigue identificando como el mismo patrón.

3. Desarrollo de la Solución

3.1. Adquisición y Estructuración de Datos Crudos

Los datos utilizados en esta investigación provienen del proyecto institucional titulado “*Desarrollo de un sistema óptico computacional para estimar el contenido de carbono orgánico de suelos agrícolas a través de imágenes espectrales e inteligencia artificial en cultivos de cítricos de Santander*”, desarrollado por el Grupo de Investigación HDSP de la Universidad Industrial de Santander (Comunicaciones UIS (2024)).

3.1.1. Procesamiento de los Datos Espectrales (Archivos .mat)

La información espectral se obtuvo a partir de archivos en formato MATLAB (.mat), suministrados por el equipo de investigación del proyecto mencionado bajo protocolos de acceso restringido para fines académicos. Para poder leer estos archivos en un entorno de programación Python, se utilizó la biblioteca h5py. Cada archivo correspondía a una muestra de suelo y almacenaba una matriz con todos sus escaneos espectrales.

A cada muestra física se le realizó la captura de 114 espectros, totalizando aproximadamente 112,000 espectros individuales de 512 longitudes de onda cada uno. Este número de réplicas por muestra permite capturar la variabilidad natural del material y la posible influencia del propio sensor, generando así un conjunto de datos más robusto.

A diferencia de otros enfoques que descartan las longitudes de onda en los extremos del espectro, en este estudio se decidió trabajar con la señal completa de 512 puntos. La razón es

darle libertad al modelo para que, por sí mismo, identifique y aprenda de los patrones presentes incluso en las zonas de transición espectral. Estas regiones son particularmente relevantes, ya que contienen información sobre transiciones mineralógicas y cambios en la estructura cristalina de los componentes del suelo (Stenberg y cols., 2010).

3.1.2. Integración con los Resultados de Laboratorio

Para que el modelo pudiera aprender de manera supervisada, fue necesario asignar a cada espectro su valor real de composición (los porcentajes de arena, limo y arcilla obtenidos en el laboratorio). Esta vinculación se realizó de forma automatizada mediante un algoritmo que, usando un identificador único por muestra, asignó correctamente los valores de laboratorio a cada uno de sus 114 espectros asociados.

3.2. Limpieza y Control de Calidad de los Datos

La medición con sensores portátiles sobre muestras heterogéneas como el suelo puede introducir ruido o errores. Por ello, se implementó un protocolo de limpieza automática para garantizar la calidad de los datos antes del entrenamiento:

- **Gestión de datos incompletos:** Se eliminaron todos los registros que tuvieran valores nulos (NaN) en las etiquetas de laboratorio, ya que habrían impedido el cálculo correcto de la función de error del modelo.
- **Detección de lecturas erróneas:** Se filtraron y descartaron aquellos espectros cuya desviación estándar fuera exactamente cero. Esto indica que no hubo variación en la señal capturada, lo que suele ser síntoma de un error en la medición (por ejemplo, un archivo corrupto o

una lectura fallida), y por tanto, no aportan información útil para el aprendizaje.

Como resultado de este protocolo, se eliminaron 114 registros (0.1 %) por presencia de valores nulos en las etiquetas de laboratorio y 1,971 espectros (1.8 %) por desviación estándar nula, reteniendo un total de 110,091 espectros válidos para las fases subsiguientes de entrenamiento y evaluación del modelo. En conjunto, el proceso de limpieza eliminó el 1.9 % de las muestras originales (2,085 registros), conservando el 98.1 % del dataset inicial.

3.3. Preprocesamiento Espectral

El preprocesamiento de las firmas espectrales es una etapa crítica para reducir la variabilidad física no deseada y resaltar la información química relevante, mejorando así la capacidad de aprendizaje del modelo. La selección de técnicas se basó en el marco teórico establecido por Rinnan, van den Berg, y Engelsen (2009), que define los estándares para la corrección de señales en espectroscopía NIR. Los parámetros específicos, por su parte, se adoptaron siguiendo la implementación reportada por Omondiagbe, Lilburne, Licorish, y MacDonell (2023) para la predicción de propiedades del suelo mediante CNN.

3.3.1. Normalización con SNV (Variación Normal Estándar)

Como primer paso, se aplicó la normalización SNV (Standard Normal Variate). Esta técnica, recomendada por Rinnan y cols. (2009), corrige eficazmente los efectos de dispersión de la luz (scattering) y las variaciones en la trayectoria óptica, interferencias físicas que no guardan relación con la composición química de la muestra. Su implementación inicial, alineada con la metodología de Omondiagbe y cols. (2023), permite normalizar la intensidad de todos los espectros, estableciendo una base común antes de su ingreso a la red neuronal.

3.3.2. Suavizado y Derivación con el Filtro Savitzky-Golay

A continuación, se procesó la señal con el filtro Savitzky-Golay, configurado para realizar simultáneamente un suavizado y el cálculo de la primera derivada. Los parámetros empleados fueron una ventana de 11 puntos y un polinomio de segundo orden, seleccionados específicamente por su efectividad en datos de suelos, según la optimización realizada por Omondiagbe y cols. (2023).

La aplicación de la primera derivada se justifica porque, como señala Rinnan y cols. (2009), es altamente efectiva para eliminar desplazamientos de la línea base (baseline offsets). Paralelamente, el suavizado previene la amplificación indeseada del ruido instrumental inherente al sensor. Esta combinación transforma la señal, permitiendo que la CNN se enfoque directamente en los picos de absorción y en las tasas de cambio espectral que están más correlacionadas con la composición del suelo.

3.4. Arquitectura del Modelo

3.4.1. Resumen General de la Arquitectura

Antes de detallar cada uno de los componentes del modelo propuesto, se presenta en la Tabla 1 un resumen general de la arquitectura de la red neuronal convolucional unidimensional (1D-CNN). Esta representación permite visualizar de forma clara la estructura del modelo y la distribución de sus principales bloques.

Tabla 1

Resumen general de la arquitectura CNN-1D propuesta.

Bloque	Capas	Filtros	Kernel	Dropout
Bloque 1	Conv1D + BN + ELU	32	4	0.4
Bloque 2	Conv1D + BN + ELU	64	4	0.4
Bloque 3	Conv1D + BN + ELU	128	4	0.4
Denso	Dense + Dropout	128 → 64 → 3	-	0.7

Nota. BN: Batch Normalization; ELU: Exponential Linear Unit.

3.4.2. Descripción de la Arquitectura del Modelo

Se diseñó una red neuronal convolucional unidimensional (1D-CNN) inspirada en Omondigbe y cols. (2023), adaptada para mitigar el sobreajuste debido al tamaño limitado del conjunto de datos.

El modelo está compuesto por tres bloques convolucionales encargados de extraer características jerárquicas del espectro. Cada bloque utiliza capas Conv1D (kernel = 4), Batch Normalization ajustada (momentum = 0.014, $\epsilon = 0,00099$), activación ELU y SpatialDropout1D (0.4), favoreciendo la estabilidad del entrenamiento y la robustez de las representaciones.

Posteriormente, las características extraídas son procesadas por capas densas con regularización L2 y L1/L2, junto con Dropout (0.7), lo que permite controlar la complejidad del modelo y

mejorar su capacidad de generalización.

El modelo cuenta con tres salidas independientes (arena, limo y arcilla) y se entrena utilizando el optimizador Adam y la función de pérdida MSE.

3.4.3. Estrategia de Partición de Datos

Para evitar fuga de información, se implementó una partición basada en grupos utilizando el identificador de cada muestra de suelo, garantizando que todas sus réplicas se asignaran a un único conjunto.

El proceso se realizó en dos etapas: una división externa (80 % entrenamiento+validación, 20 % prueba) y una interna (85 % entrenamiento, 15 % validación). Esto resultó en una distribución final de 68 % entrenamiento (668 muestras), 12 % validación (118) y 20 % prueba (197).

Esta estrategia asegura una evaluación realista del modelo, reflejando su capacidad de generalización a muestras no vistas.

3.4.4. Configuración de Hiperparámetros

La selección de los hiperparámetros del modelo se realizó considerando la naturaleza del problema, caracterizado por un número limitado de muestras y una alta dimensionalidad espectral. En este contexto, se priorizó una configuración orientada a mejorar la estabilidad del entrenamiento y la capacidad de generalización del modelo.

Se empleó el optimizador Adam debido a su capacidad para adaptar dinámicamente la tasa de aprendizaje durante el entrenamiento. La tasa de aprendizaje inicial se fijó en 1×10^{-3} , complementada con un esquema de reducción dinámica mediante el callback `ReduceLROnPlateau`.

El entrenamiento se realizó con un tamaño de lote de 128 muestras y un máximo de 1000

épocas, incorporando parada temprana (Early Stopping) para evitar el sobreajuste.

Adicionalmente, se aplicaron estrategias de regularización como L1/L2, Dropout (70%) y Spatial Dropout (40%), con el fin de mejorar la robustez del modelo.

La configuración completa de hiperparámetros se presenta en el Apéndice 2.

3.4.5. Control del Entrenamiento (Callbacks)

Para mejorar la estabilidad del entrenamiento y la convergencia del modelo, se implementaron dos callbacks principales:

- **Reducción Dinámica de la Tasa de Aprendizaje (ReduceLRonPlateau):** Ajusta dinámicamente la tasa de aprendizaje cuando la pérdida de validación deja de mejorar, permitiendo una convergencia más fina y estable.
- **Parada Temprana (EarlyStopping):** Detiene el entrenamiento cuando no hay mejora en la validación, evitando el sobreajuste y restaurando los mejores pesos obtenidos.

3.5. Resultados y Discusión de la Solución

En esta sección se exponen los hallazgos obtenidos tras la fase de experimentación y validación de la CNN. Los resultados se presentan de manera cuantitativa y comparativa para demostrar el cumplimiento de los objetivos establecidos al inicio del proyecto.

3.5.1. Evaluación del Desempeño Predictivo

El desempeño del modelo fue evaluado en el conjunto de datos de prueba (Test set), el cual está compuesto por muestras no utilizadas durante el entrenamiento ni la validación, permitiendo así medir la capacidad de generalización del modelo.

La métrica principal empleada fue el coeficiente de determinación (R^2), el cual cuantifica la proporción de la varianza de los datos reales que es explicada por el modelo. Los valores reportados corresponden a la evaluación final del modelo entrenado sobre el conjunto de prueba.

Tabla 2

Resultados del modelo CNN en el conjunto de prueba (test set).

Propiedad	R^2 (Test)
Arena	0.6046
Limo	0.4754
Arcilla	0.5846
Promedio Global	0.5549

Nota. Coeficientes de determinación (R^2) obtenidos en el conjunto de prueba. El promedio global corresponde al promedio aritmético de los valores de arena, limo y arcilla. Los resultados reflejan la capacidad del modelo para generalizar a muestras no vistas.

Como se observa en la Tabla 2, la fracción de arena presenta el mayor desempeño predictivo ($R^2 = 0,6046$), seguida por la arcilla ($R^2 = 0,5846$), mientras que el limo muestra el menor nivel de ajuste ($R^2 = 0,4754$). Esta tendencia es consistente con la literatura, donde el limo suele presentar mayor dificultad de modelado debido a la ausencia de características espectrales distintivas y al solapamiento con otras fracciones granulométricas.

3.5.2. Verificación de la Suma Composicional

La validez de un modelo de textura de suelo depende de que se respete la restricción física de que la suma de sus componentes (Arena + Limo + Arcilla) sea igual al 100%.

Las predicciones del modelo presentaron una suma promedio de **99.97 %**, con un error

marginal de apenas **0.03 %**.

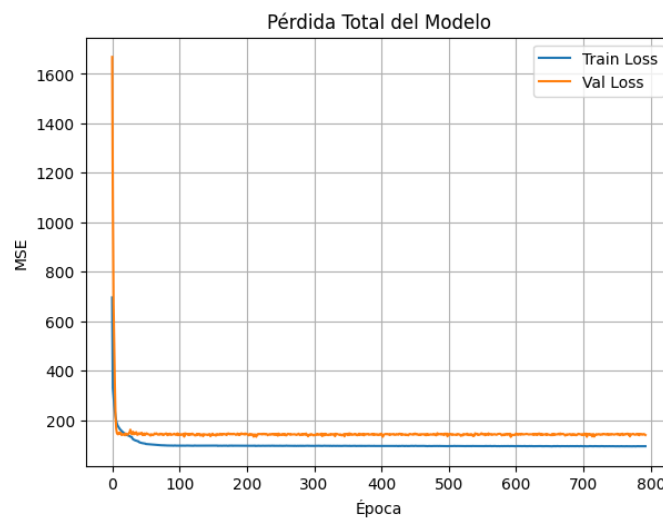
3.5.3. Evaluación del Proceso de Aprendizaje

En la Figura 2 se presentan las curvas de función de pérdida (Loss) para el conjunto de entrenamiento como para el de validación.

Se observa que ambas curvas descienden de manera asintótica y luego se estabilizan. El hecho de que la curva de validación siga de cerca a la de entrenamiento confirma que la estrategia de regularización (Dropout al 70% y Batch Normalization) fue efectiva para evitar el sobreajuste.

Figura 2

Gráfica de las curvas del MSE de los datos de entrenamiento y validación.



Nota. Curvas de aprendizaje del modelo expresadas mediante el Error Cuadrático Medio (MSE). La rápida convergencia de la pérdida de entrenamiento (*Train Loss*) y validación (*Val Loss*) durante las primeras 100 épocas evidencia la eficiencia del proceso de optimización realizado.

3.5.4. Análisis de la Complejidad del Dominio

Un aspecto fundamental para la evaluación de este proyecto es comprender que la textura del suelo no posee una firma espectral directa y específica, lo que impone un techo “técnico” a la precisión estadística (R^2).

El hecho de alcanzar un coeficiente de determinación de 0.60 para arena y 0.58 para arcilla debe interpretarse bajo el contexto de lo ambiguo que es el espectro. Tal como se visualiza en la Figura 3, el modelo se enfrenta a escenarios donde la física del problema contradice la lógica lineal. En dicha figura se observa que dos muestras con espectros visualmente idénticos (Muestras 570 y 369) presentan, no obstante, una diferencia real del 18% en su contenido de arcilla (16% vs. 34%).

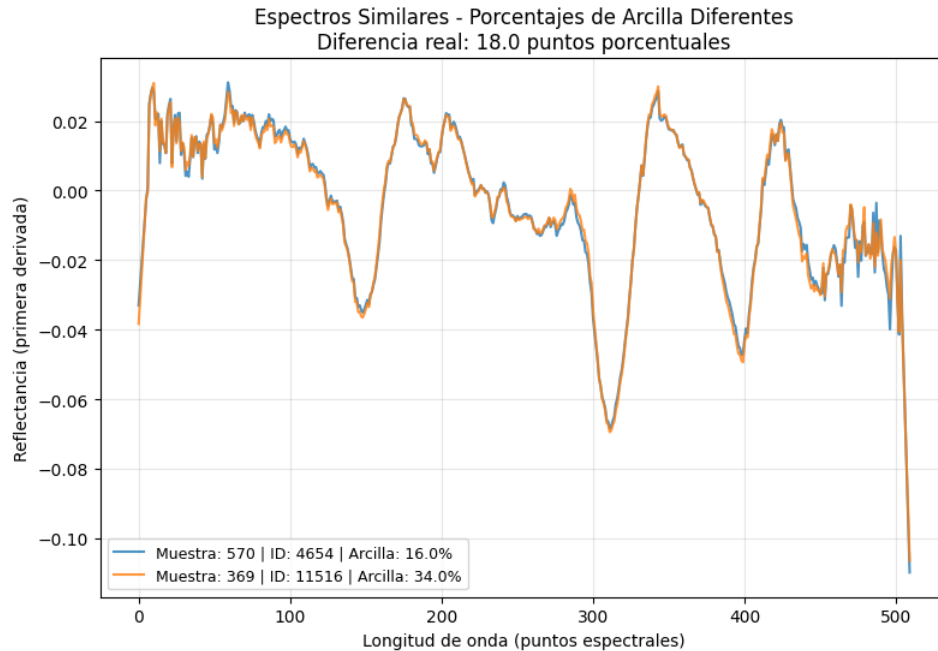
Bajo estas restricciones, la superioridad de la CNN no radica en “forzar” un R^2 artificialmente alto, sino en su capacidad para extraer rasgos sutiles que logran atravesar esa ambigüedad espectral mejor que cualquier método tradicional.

3.5.5. Análisis Comparativo con Modelos de Referencia

Para contextualizar el desempeño de la red neuronal y validar sus resultados de manera rigurosa, se implementaron y evaluaron dos modelos de referencia ampliamente utilizados en espectroscopía de suelos, tal como se establece en metodologías de referencia como la de Chagas, de Carvalho Junior, Bhering, y Calderano Filho (2016), la Regresión de Mínimos Cuadrados Parciales (PLS) y el Bosque Aleatorio (Random Forest, RF). Estos modelos sirven como una línea base robusta para comparar la capacidad predictiva de la arquitectura profunda propuesta.

Figura 3

Comparación de espectros similares con diferente contenido de arcilla.



Nota. Las muestras 570 (16% de arcilla) y 369 (34% de arcilla) presentan espectros visualmente similares, lo que evidencia la ambigüedad inherente al problema y la existencia de un límite superior en el desempeño predictivo del modelo ($R^2 < 0,8$).

Los resultados cuantitativos de esta comparación se presentan de manera resumida en la tabla 3, donde se contrastan las métricas clave de los tres modelos para cada fracción granulométrica.

3.5.6. Valor real vs Valor predicho

Para evaluar la precisión de los modelos, se analizaron diagramas de dispersión entre valores reales y predichos. En la Figura 4 se presenta la comparación entre la CNN propuesta, PLS y Random Forest para la fracción de arena, como caso representativo del comportamiento general de los modelos.

Tabla 3

Comparativa del coeficiente de determinación R^2 frente a modelos tradicionales.

Modelo	Arena (R^2)	Limo (R^2)	Arcilla (R^2)	Promedio (R^2)
PLS (15 componentes)	0.3681	0.2047	0.4882	0.3537
Random Forest (100 estimadores)	0.4563	0.3761	0.4798	0.4374
CNN (Propuesta)	0.6046	0.4754	0.5846	0.5549

Nota. El modelo PLS se configuró con 15 componentes principales y el modelo Random Forest con 100 estimadores. Los valores en negrita indican el mejor desempeño para cada categoría, evidenciando que la CNN propuesta presenta la mayor capacidad predictiva y de generalización para la base de datos analizada.

Los resultados muestran que la CNN presenta una mayor concentración de puntos alrededor de la línea ideal ($y = x$), indicando una mejor capacidad predictiva. En contraste, PLS y Random Forest evidencian una mayor dispersión, especialmente en el caso de PLS.


Las gráficas correspondientes a las fracciones de limo y arcilla se presentan en el Anexo 1.

El análisis por fracción confirma que la Arena (R^2 : 0.60) y la Arcilla (R^2 : 0.58) presentan una tendencia lineal definida, lo que indica que el modelo captura adecuadamente sus patrones espectrales.

En contraste, el Limo (R^2 : 0.47) muestra mayor dispersión y ausencia de una tendencia clara, confirmando que es la fracción más difícil de predecir.

Figura 4

Gráfico de dispersión entre valores reales y predichos para la fracción de arena utilizando CNN, PLS y RF.



Nota. Comparación del desempeño predictivo de los modelos CNN, PLS y RF para la estimación de la fracción de arena mediante gráficos de dispersión entre valores reales y predichos.

4. Conclusiones

De acuerdo con el desarrollo experimental y el análisis de resultados del presente trabajo de investigación, se presentan las siguientes conclusiones en estricta correspondencia con los objetivos planteados:

4.1. Cumplimiento de los Objetivos Específicos

- **Objetivo 1: Preparar las firmas espectrales NIR de suelos agrícolas.**

Se estructuró y preprocesó el conjunto de datos espectrales HDSP aplicando filtrado Savitzky–Golay y estandarización, transformando los datos crudos en representaciones robustas del comportamiento espectral del suelo.

- **Objetivo 2: Desarrollar e implementar un modelo de IA para la estimación de la textura del suelo.**

Se diseñó e implementó una arquitectura 1D-CNN que predice simultáneamente arena, limo y arcilla, demostrando capacidad para capturar patrones no lineales en los datos espectrales.

- **Objetivo 3: Optimizar los parámetros de entrenamiento para mejorar la precisión del modelo.**

Mediante ajuste de hiperparámetros y estrategias de regularización (ELU, Dropout, L1/L2), se redujo el sobreajuste y se superó el desempeño de métodos tradicionales como PLS y Random Forest.

- **Objetivo 4: Validar el desempeño del modelo utilizando métricas estadísticas.**

El modelo fue evaluado rigurosamente mediante el coeficiente de determinación (R^2) para cada una de las tres fracciones granulométricas (arena, limo y arcilla) en los conjuntos de entrenamiento, validación y prueba. El desempeño promedio de las tres fracciones arrojó los siguientes valores: $\overline{R^2} \approx 0,75$ en entrenamiento, $\overline{R^2} \approx 0,52$ en validación y $\overline{R^2} \approx 0,55$ en prueba. Estos resultados evidencian una adecuada capacidad de generalización. Adicionalmente, se identificó que la fracción de limo presenta la mayor dificultad de predicción ($R^2 \approx 0,47$), lo cual es consistente con su comportamiento espectral menos distintivo en la región del infrarrojo cercano.

4.2. Aportes y Hallazgos Relevantes

El modelo desarrollado no solo logró estimar con precisión moderada-alta las fracciones granulométricas del suelo, sino que también demostró la capacidad de aprender de forma implícita la restricción física de suma composicional, alcanzando valores cercanos al 100% en la suma de arena, limo y arcilla sin necesidad de imponer restricciones explícitas en la arquitectura.

Asimismo, se evidenció que la principal limitación del problema no radica en el modelo, sino en la ambigüedad intrínseca del dominio espectral, donde diferentes composiciones del suelo pueden generar firmas espectrales altamente similares. Este fenómeno impone un límite práctico en la precisión alcanzable por cualquier modelo predictivo.

4.3. Limitaciones y Trabajo Futuro

Como limitación principal, el modelo fue entrenado con un conjunto de datos específico del grupo de investigación HDSP, lo que podría restringir su capacidad de generalización a otras

regiones con características edafológicas distintas. Futuras investigaciones deberían considerar la incorporación de datos más diversos para mejorar la robustez del modelo.

4.4. Impacto y Aplicaciones

El presente trabajo aporta una solución eficiente para la estimación rápida de la textura del suelo, reduciendo significativamente los tiempos y costos asociados a métodos tradicionales de laboratorio. Esta herramienta tiene el potencial de apoyar procesos de agricultura de precisión, facilitando la toma de decisiones informadas en campo y contribuyendo al uso sostenible de los recursos agrícolas.

4.5. Impacto y Proyección

Este trabajo representa un avance hacia la agricultura de precisión al desarrollar una herramienta que reduce el tiempo de análisis de textura del suelo de semanas a segundos, superando en más del 90% la eficiencia de los métodos tradicionales.

El enfoque basado en espectroscopía NIR y aprendizaje profundo elimina el uso de reactivos químicos y disminuye significativamente los costos operativos, facilitando el acceso a análisis de suelos sin requerir infraestructura especializada.

Esta solución resulta especialmente relevante para pequeños y medianos productores, al permitir una toma de decisiones más rápida y eficiente, contribuyendo al uso sostenible de los recursos agrícolas y al fortalecimiento de la seguridad alimentaria en contextos regionales como Santander.

5. Recomendaciones

A partir de los hallazgos y limitaciones identificadas en el desarrollo y validación de la arquitectura realizada, se proponen las siguientes líneas de investigación y desarrollo para expandir la precisión, robustez y aplicabilidad de la espectroscopía NIR en la caracterización de suelos.

5.1. Expansión y Diversificación del Conjunto de Datos

- **Integración de Bibliotecas Espectrales Globales:** Para evaluar y mejorar la capacidad de generalización del modelo, se recomienda enriquecer el conjunto de datos con muestras de diversas regiones. Esto permitiría entrenar modelos más universales y evaluar su transferibilidad a suelos con mineralogías y propiedades distintas a las del contexto local.
- **Balanceo de la Distribución Textural:** Dada la tendencia observada en los resultados, se sugiere una recolección estratégica de muestras en los extremos de la clasificación textural (por ejemplo, suelos franco-arcillosos extremos o arenosos puros). Esto compensaría la concentración en valores centrales del dataset actual y mejoraría la capacidad predictiva del modelo en todo el rango de variabilidad.

5.2. Innovación en Arquitecturas de Aprendizaje Profundo

Se propone investigar el uso de modelos pre-entrenados en vastas bibliotecas espectrales públicas como punto de partida. Un posterior ajuste fino (fine-tuning) con datos específicos de sensores portátiles de bajo costo podría acelerar el entrenamiento y mejorar el desempeño.

Referencias

- Beretta, A. N., Silbermann, A. V., Paladino, L., Torres, D., Bassahun, D., Musselli, R., y García-Lamohte, A. (2014). Soil texture analyses using a hydrometer: Modification of the bouyoucos method. *Ciencia e Investigación Agraria*, 41(2), 263–271. Descargado de <http://dx.doi.org/10.4067/S0718-16202014000200013>
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5–32. Descargado de <https://doi.org/10.1023/A:1010933404324> doi: <https://doi.org/10.1023/A:1010933404324>
- Cao, L., Sun, M., Yang, Z., Jiang, D., Yin, D., y Duan, Y. (2024). A novel transformer-cnn approach for predicting soil properties from lucas vis-nir spectral data. *Agronomy*, 14(9). Descargado de <https://www.mdpi.com/2073-4395/14/9/1998> doi: 10.3390/agronomy14091998
- Chagas, C. D. S., de Carvalho Junior, W., Bhering, S. B., y Calderano Filho, B. (2016). Spatial prediction of soil surface texture in a semiarid region using random forest and multiple linear regressions. *CATENA*, 139, 232-240. Descargado de <https://doi.org/10.1016/j.catena.2016.01.001>
- Comunicaciones UIS. (2024). *Investigadores UIS crean un sistema con inteligencia artificial que revoluciona el análisis de suelos agrícolas en minutos*. Descargado de <https://comunicaciones.uis.edu.co/investigadores-uis-crean-un-sistema-con-inteligencia-artificial-que-revoluciona-el-analisis-de-suelos-agricolas-en-minutos/> (Accedido: 15-03-2026)

- Debus, B., Parastar, H., Harrington, P., y Kirsanov, D. (2021). Deep learning in analytical chemistry. *TrAC Trends in Analytical Chemistry*, 145, 116459. Descargado de <https://www.sciencedirect.com/science/article/pii/S016599362100282X> doi: <https://doi.org/10.1016/j.trac.2021.116459>
- FAO. (2009). *Guía para la descripción de suelos* (4.^a ed.). Roma: Organización de las Naciones Unidas para la Agricultura y la Alimentación. (Traducido y adaptado al castellano por R. Vargas Rojas)
- Instituto Geográfico Agustín Codazzi - IGAC. (2003). *Estudio general de suelos y zonificación de tierras. departamento de santander. escala 1:100.000*. Bogotá, Colombia: IGAC. (Primera Edición)
- Mishra, P., Passos, D., Marini, F., Xu, J., Amigo, J. M., Gowen, A. A., ... Nordon, A. (2022). Deep learning for near-infrared spectral data modelling: Hypes and benefits. *TrAC Trends in Analytical Chemistry*, 157, 116804. Descargado de <https://doi.org/10.1016/j.trac.2022.116804>
- Mohamed, E., Saleh, A., Belal, A., y Gad, A. (2018). Application of near-infrared reflectance for quantitative assessment of soil properties. *The Egyptian Journal of Remote Sensing and Space Science*, 21(1), 1-14. Descargado de <https://www.sciencedirect.com/science/article/pii/S1110982317300327> doi: <https://doi.org/10.1016/j.ejrs.2017.02.001>
- Omondiagbe, O. P., Lilburne, L., Licorish, S. A., y MacDonell, S. G. (2023). Soil texture prediction with automated deep convolutional neural networks and population-based learning. *Geoderma*, 436, 116521. Descargado de <https://doi.org/10.1016/j.geoderma.2023>

.116521

- Omondiagbe, O. P., Roudier, P., Lilburne, L., Ma, Y., y McNeill, S. (2024). Quantifying uncertainty in the prediction of soil properties using mid-infrared spectra. *Geoderma*, 448, 116954. Descargado de <https://www.sciencedirect.com/science/article/pii/S0016706124001836> doi: <https://doi.org/10.1016/j.geoderma.2024.116954>
- Ortiz, D., de Dios Herrero, J. M., y Kloster, N. (2024, jul.). Uso de la espectroscopia visible e infrarrojo cercano para estimar propiedades de suelo en argentina. *Ciencia del Suelo*, 42(1), 1–13. Descargado de <https://ojs.suelos.org.ar/index.php/cds/article/view/820>
- Perret, J., Villalobos-Leandro, J. E., Abdalla-Bolaños, K., Fuentes-Fallas, C. L., Cuarezma-Espinoza, K. M., Macas-Amaya, E. N., ... Drewry, D. (2020). Desarrollo de métodos de análisis de espectroscopia y algoritmos de aprendizaje automático para la evaluación de algunas propiedades del suelo en costa rica. *Agronomía Costarricense*, 44(2), 139–154. doi: <https://doi.org/10.15517/rac.v44i2.43108>
- Rinnan, A., van den Berg, F., y Engelsen, S. B. (2009). Review of the most common pre-processing techniques for near-infrared spectra. *TrAC Trends in Analytical Chemistry*, 28(10), 1201-1222. Descargado de <https://www.sciencedirect.com/science/article/pii/S0165993609001629> doi: <https://doi.org/10.1016/j.trac.2009.07.007>
- Shepherd, K., y Walsh, M. (2002, 05). Development of reflectance spectral libraries for characterization of soil properties. *Soil Science Society of America Journal*, 66, 988-998. doi: <https://doi.org/10.2136/sssaj2002.9880>

- Stenberg, B., Viscarra Rossel, R. A., Mouazen, A. M., y Wetterlind, J. (2010). Chapter five - visible and near infrared spectroscopy in soil science. En D. L. Sparks (Ed.), (Vol. 107, p. 163-215). Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/S0065211310070057> doi: [https://doi.org/10.1016/S0065-2113\(10\)07005-7](https://doi.org/10.1016/S0065-2113(10)07005-7)
- Wold, S., Sjöström, M., y Eriksson, L. (2001). Pls-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*, 58(2), 109-130. Descargado de <https://www.sciencedirect.com/science/article/pii/S0169743901001551> doi: [https://doi.org/10.1016/S0169-7439\(01\)00155-1](https://doi.org/10.1016/S0169-7439(01)00155-1)
- Yu, S., Jia, S., y Xu, C. (2017). Convolutional neural networks for hyperspectral image classification. *Neurocomputing*, 219, 88-98. doi: <https://doi.org/10.1016/j.neucom.2016.09.010>
- Zhao, B., Lu, H., Chen, S., Liu, J., y Wu, D. (2017). Convolutional neural networks for time series classification. *Journal of Systems Engineering and Electronics*, 28(1), 162-169. doi: <http://doi.org/10.21629/JSEE.2017.01.18>


Apéndices

Apéndice A. Comparaciones adicionales entre modelos

En este anexo se presentan las gráficas adicionales de comparación entre los modelos para las fracciones de limo y arcilla.

Figura 5


Gráfico de dispersión entre valores reales y predichos para la fracción de limo utilizando CNN, PLS y RF.



Nota. Comparación del desempeño predictivo de los modelos CNN, PLS y RF para la estimación de la fracción de limo mediante gráficos de dispersión entre valores reales y predichos.

Figura 6

Gráfico de dispersión entre valores reales y predichos para la fracción de arcilla utilizando CNN, PLS y RF.



Nota. Comparación del desempeño predictivo de los modelos CNN, PLS y RF para la estimación de la fracción de arcilla mediante gráficos de dispersión entre valores reales y predichos.

Apéndice B. Configuración detallada de hiperparámetros

En este apéndice se presenta la configuración completa de los hiperparámetros utilizados en el entrenamiento del modelo CNN.

Tabla 4

Configuración consolidada de hiperparámetros de entrenamiento.

Parámetro	Valor	Descripción
Optimizador	Adam	Optimización adaptativa
Tasa de aprendizaje	1×10^{-3}	Con reducción dinámica
Batch size	128	Tamaño del lote
Épocas máximas	1000	Límite de entrenamiento
Early Stopping	200	Detención por no mejora
Función de pérdida	MSE	Error cuadrático medio
Regularización L2	0.005	Primera capa densa
Regularización L1/L2	0.001 / 0.001	Segunda capa densa
Dropout	0.7	Capas densas
Spatial Dropout	0.4	Capas convolucionales

Nota. Configuración utilizada para garantizar estabilidad durante el entrenamiento y reducir el sobreajuste del modelo. Elaboración propia.