



## Red neuronal convolucional para estimar humedad gravimétrica del suelo con bandas multiespectrales UAV

### Convolutional neural network for estimating soil gravimetric moisture using UAV multispectral bands

**Jesús Bojórquez Delgado**

Tecnológico Nacional de México/Instituto Tecnológico Superior de Guasave, Guasave, México

jesus.bd@guasave.tecnm.mx

ORCID: 0009-0004-0648-9094

**Gilberto Bojórquez Delgado**

Tecnológico Nacional de México/Instituto Tecnológico Superior de Guasave, Guasave, México

gilberto.bd@guasave.tecnm.mx

ORCID: 0009-0000-7829-6540



<https://doi.org/10.36825/RITI.13.32.004>

Recibido: Junio 15, 2025

Aceptado: Octubre 08, 2025

**Resumen:** La estimación precisa de la humedad gravimétrica del suelo es esencial para la gestión eficiente de recursos hídricos en agricultura de precisión, especialmente en regiones semiáridas. Este estudio propone una red neuronal convolucional (CNN) para estimar la humedad gravimétrica del suelo utilizando datos multiespectrales adquiridos mediante vehículos aéreos no tripulados (UAV). La investigación se llevó a cabo en una parcela de suelo franco-arcilloso en Guasave, Sinaloa, México, durante diferentes fases de secado post-riego. Se empleó un dron DJI Mavic 3 Multispectral equipado con cámaras en las bandas *Green* (560 nm), *Red* (650 nm), *Red-Edge* (730 nm) y *NIR* (860 nm), obteniendo imágenes con resolución espacial aproximada de 4 cm/píxel. Se realizaron mediciones gravimétricas in situ para validar el desempeño del modelo CNN desarrollado. La arquitectura CNN propuesta constó de tres capas *Conv1D* con 32 filtros, una capa *MaxPooling*, una capa de aplanamiento y una capa densa, diseñada específicamente para explotar relaciones no lineales complejas entre las bandas espectrales y la humedad del suelo. Los resultados mostraron un desempeño excepcional del modelo con un error cuadrático medio (MSE) de 0.0058, un coeficiente de determinación ( $R^2$ ) de 0.91 y un error absoluto medio (MAE) de 0.046 en el conjunto de prueba. La correlación entre las predicciones y las mediciones reales fue alta ( $r = 0.92$ ,  $p < 0.001$ ). Los análisis estadísticos confirmaron la homocedasticidad y normalidad de los residuos, indicando robustez del modelo. Se destacó además la superioridad del enfoque CNN respecto a índices empíricos tradicionales, mostrando gran sensibilidad a microvariaciones intraparcelarias.

**Palabras clave:** *Redes Neuronales Convolucionales, UAV Multiespectral, Humedad Gravimétrica, Agricultura de Precisión, Gestión Hídrica.*

**Abstract:** Accurate estimation of soil gravimetric moisture is essential for the efficient management of water resources in precision agriculture, particularly in semi-arid regions. This study proposes a convolutional neural network (CNN) to estimate soil gravimetric moisture using multispectral data acquired by unmanned aerial vehicles (UAVs). The research was conducted on a clay-loam soil plot in Guasave, Sinaloa, Mexico, during

different post-irrigation drying phases. A DJI Mavic 3 Multispectral drone equipped with sensors in the *Green* (560 nm), *Red* (650 nm), *Red-Edge* (730 nm), and *NIR* (860 nm) bands was employed, capturing imagery with a spatial resolution of approximately 4 cm/pixel. In situ gravimetric measurements were collected to validate the performance of the developed CNN model. The proposed CNN architecture consisted of three Conv1D layers with 32 filters, one MaxPooling layer, a flattening layer, and a fully connected dense layer, specifically designed to capture complex nonlinear relationships between spectral bands and soil moisture. The model achieved outstanding performance, with a mean squared error (MSE) of 0.0058, a coefficient of determination ( $R^2$ ) of 0.91, and a mean absolute error (MAE) of 0.046 on the test dataset. Predictions were highly correlated with actual measurements ( $r = 0.92$ ,  $p < 0.001$ ). Statistical analyses confirmed homoscedasticity and residual normality, indicating model robustness. Furthermore, the CNN-based approach outperformed traditional empirical indices, demonstrating high sensitivity to within-field microvariability.

**Keywords:** *Convolutional Neural Networks, Multispectral UAV, Gravimetric Moisture, Precision Agriculture, Water Management.*

## 1. Introducción

El uso eficiente del agua en la agricultura es un reto crítico, especialmente en regiones semiáridas donde la disponibilidad hídrica es limitada y las variaciones climáticas intensifican la competencia por los recursos [1]. La sobreexplotación de acuíferos y la escasez de información precisa sobre la humedad del suelo pueden conducir a decisiones de riego subóptimas, afectando tanto la productividad agrícola como la sostenibilidad ambiental [2], [3].

Los métodos convencionales in situ, como sondas TDR o muestreos gravimétricos, proporcionan mediciones puntuales muy precisas, pero resultan costosos y logísticamente impracticables cuando se pretende caracterizar la heterogeneidad espacial de parcelas extensas [4], [5].

Por su parte, la teledetección satelital (por ejemplo, Sentinel-2) ofrece cobertura amplia y alta frecuencia temporal, pero los índices empíricos convencionales (NDWI, NDMI) no están calibrados para suelos desnudos y dependen de condiciones atmosféricas y del tipo de suelo, lo que limita su precisión en la estimación directa de la humedad edáfica [6], [7]. Además, la resolución espacial de 10 m/píxel impide detectar microvariaciones intraparcclarias (<10m), las cuales son críticas en estrategias de riego de precisión [8].

Los UAV multispectrales han emergido como una alternativa prometedora al combinar alta resolución espacial y flexibilidad operativa en campo. En particular, el DJI Mavic 3 Multispectral integra cámaras monocromáticas centradas en 560 nm (Green), 650 nm (Red), 730 nm (Red-Edge) y 860 nm (NIR), todas con FWHM  $\approx 20$  nm y obturador global de 12 bits, así como un sensor de irradiancia descendente que permite la corrección radiométrica en tiempo real [9]. Estas características facilitan la adquisición de reflectancias superficiales con resolución de centímetros y georreferenciación centimétrica mediante GNSS-RTK. Sin embargo, a la fecha no existe un índice espectral validado específicamente para las bandas Green, Red, Red-Edge y NIR de este UAV que permita estimar cuantitativamente la humedad gravimétrica del suelo en condiciones reales de campo.

La relación entre reflectancia multispectral y contenido hídrico del suelo es altamente no lineal, influenciada por variables edáficas como textura, contenido de materia orgánica y características superficiales [10], [11].

En este contexto, las redes neuronales convolucionales (CNN) han demostrado su capacidad para capturar patrones espectrales complejos en datos hiperespectrales y multispectrales satelitales [11], [12], pero su aplicación a datos multispectrales UAV limitados a cuatro bandas y su validación con mediciones in situ de campo aún requiere investigación.

De acuerdo con lo anterior, este estudio tiene como objetivo principal desarrollar y validar un índice espectral de humedad del suelo, basado en una CNN entrenada con reflectancias multispectrales UAV (bandas Green, Red, Red-Edge, NIR) y mediciones gravimétricas obtenidas en campo. En particular, se pretende demostrar que este enfoque puede superar la precisión de los índices tradicionales (NDWI, NDMI) al capturar microvariaciones intraparcclarias en un ambiente semiárido. Este trabajo abarca los siguientes aspectos: identificación de vacíos en índices convencionales, justificación del uso de UAV multispectrales para monitoreo de alta resolución, diseño de la arquitectura CNN adaptada a cuatro bandas y validación mediante datos in situ.

## 2. Materiales y métodos

Esta sección detalla los materiales y procedimientos utilizados en la investigación.

### 2.1. Área de estudio y muestreo *in situ*

La investigación se llevó a cabo en una parcela de 8.01 ha ubicada en el ejido El Tajito, Guasave, Sinaloa (25;39;18 N, 108;38;14 W), caracterizada por un clima semiárido cálido con temperatura promedio anual de 23 °C y precipitación de 450 mm/año. El suelo es franco-arcilloso, sin cobertura vegetal durante las mediciones, lo que permitió aislar la firma espectral del suelo y evitar interferencias de clorofila.

Dentro del contorno de la parcela se establecieron siete nodos interiores (etiquetados 1–7), ubicados de forma equidistante para capturar gradientes horizontales generados por microtopografía y variabilidad textural, sin prolongar excesivamente el tiempo de muestreo (25 min), factor crucial para mantener una ventana atmosférica constante (irradiancia, temperatura y viento). La distribución de estos nodos se muestra en la Figura 1.



**Figura 1.** Distribución de los siete nodos *in situ* sobre suelo desnudo.

Se planificaron cuatro campañas pos-riego en 2025 para cubrir las fases de secado del perfil hídrico:

- 6 h pos-riego (Saturación): El perfil se mantiene próximo a saturación, con la mayor parte del poro ocupado por agua.
- 48 h pos-riego (Fin de drenaje gravitacional): El flujo libre cesa y la humedad queda gobernada por retención capilar.
- 120 h pos-riego (Capacidad de campo): Se alcanza el equilibrio hídrico suelo–gravedad; humedad óptima para la mayoría de los cultivos.
- 192 h pos-riego (Secado evaporativo): La pérdida de agua está dominada por evaporación y difusión de vapor.

Estas etapas se fundamentan en estudios lisimétricos y experimentos en suelos franco-arcillosos [13], [14], [15], garantizando que las mediciones reflejen las transiciones críticas de la curva de secado.

### 2.2. Mediciones *in situ* de humedad

Para garantizar la calidad y representatividad de los datos de humedad empleados en el entrenamiento y validación de la CNN, se aplicó el siguiente protocolo en cada nodo y campaña de campo. En primer lugar, se utilizó la sonda Misopily SA04-528B037 como se muestra en la Figura 2, un dispositivo capacitivo–resistivo de acero inoxidable con dos pines separados 38 mm y longitud activa de 60 mm, adecuado para lecturas en el rango de 0–10 cm del perfil del suelo. Esta sonda, con rango 0–100 % VWC, precisión  $\pm 2$  % y resolución 0.1 %, cuantifica de forma no destructiva el contenido volumétrico de agua en el suelo. En cada nodo se realizaron tres lecturas consecutivas, separadas por 10 s, y se calculó el promedio aritmético para obtener el valor final de humedad volumétrica  $\theta_{vwc}$ .



**Figura 2.** Sonda Misopily SA04-528B037.

Para comparar con la salida de la CNN (que estima humedad gravimétrica) cada  $\theta_{vwc}$  se transformó a humedad gravimétrica  $\theta_{grav}$  según la Ecuación 1, donde se asumen  $\rho_{water} = 1 \text{ g/cm}^3$  y  $\rho_b = 1.45 \text{ g/cm}^3$ , valor medido en muestras representativas del suelo.

$$\theta_{grav} = \frac{\theta_{vwc} \rho_{water}}{\rho_b}, \quad \rho_{water} = 1 \text{ g/cm}^3, \quad \rho_b = 1.45 \text{ g/cm}^3. \quad (1)$$

Por último, para asegurar la precisión geoespacial de cada medición, se empleó la estación base DJI D-RTK 2, receptor GNSS multiconstelación de doble frecuencia (GPS, GLONASS, Galileo, BeiDou) con precisión RTK de  $\pm(10 \text{ mm} + 1 \text{ ppm})$  en horizontal y  $\pm(20 \text{ mm} + 1 \text{ ppm})$  en vertical. Durante cada campaña, esta estación transmitió correcciones diferenciales a 10 Hz al controlador de campo y al UAV, obteniéndose solución RTK fija ( $< 2 \text{ cm}$ ). Así se registraron las coordenadas WGS-84 de cada nodo de muestreo con exactitud centimétrica, requisito fundamental para extraer posteriormente los valores promedio de reflectancia de las imágenes multispectrales como puede observarse en la Figura 3.



**Figura 3.** Estación base DJI D-RTK 2.

### 2.3. Captura y procesamiento de imágenes UAV

Para capturar datos multispectrales con la precisión requerida, se utilizó un DJI Mavic 3 Multispectral, un UAV de 920 g con autonomía aproximada de 38 min. Bajo su domo metálico, dispone de cuatro cámaras monocromáticas centradas en las bandas Green (560 nm), Red (650 nm), Red-Edge (730 nm) y NIR (860 nm), cada una con FWHM  $\approx 20 \text{ nm}$ , obturador global y conversión A/D de 12 bits. Esta configuración discrimina cambios en la reflectancia asociados a variaciones en el contenido hídrico del suelo. Asimismo, el dron incluye

una cámara RGB 4/3" CMOS (20 MP) para ortofotos de referencia, y un sensor de irradiancia descendente que mide la radiación solar incidente en tiempo real, esencial para la corrección radiométrica. El módulo RTK integrado recibe correcciones de la estación DJI D-RTK 2 vía OcuSync 3.0, logrando precisión posicional  $\leq 2$  cm, lo que garantiza georreferenciación exacta de cada imagen como se muestra en la Figura 4.



**Figura 4.** DJI Mavic 3 Multispectral.

Con la plataforma definida, la misión se planificó en DJI Pilot 2 con los siguientes parámetros: vuelo a 70 m AGL, GSD  $\approx 4$  cm/píxel; superposición del 80 % longitudinal y 70 % lateral en patrón *double-grid* para cubrir uniformemente la parcela; horario de 09:30 h (UTC-7) en días despejados con ángulo solar  $< 5^\circ$  para reducir sombras; y salida de datos en GeoTIFF de 16 bits por banda, geoetiquetados y corregidos por irradiancia descendente.

Para consolidar los datos capturados, los archivos RAW se procesaron en DJI Terra v5.2 generando mosaicos multispectrales nivel 2A. El flujo incluyó: corrección radiométrica basada en el sensor de irradiancia para convertir valores digitales en reflectancia de superficie  $\rho(\lambda)$ ; corrección atmosférica con Sen2Cor adaptado a UAV (modelo 6S) para eliminar dispersión y absorción atmosférica; estabilización georreferencial mediante coordenadas RTK (ver Figura 3), alineando cada banda y minimizando distorsiones geométricas; y exportación final de GeoTIFF con las bandas  $\rho_{green}$ ,  $\rho_{red}$ ,  $\rho_{re}$  y  $\rho_{nir}$ , cada una acompañada de metadatos como fecha, hora, ángulo solar y coordenadas RTK.

De esta manera, cada píxel en los mosaicos multispectrales quedó asociado a una medición gravimétrica de humedad y una posición centimétrica, conformando el conjunto MS-4 para el entrenamiento de la CNN.

#### 2.4. Construcción y preprocesamiento del dataset in situ

A partir de la información adquirida en el muestreo, se generó un archivo que agrupa las parejas reflectancia-humedad gravimétrica para cada nodo y campaña de muestreo. Este conjunto de datos, denominado DataSetMuestreoInSitu.csv, quedó compuesto de la siguiente manera:

##### 2.4.1. Registros

Se incluyeron 28 filas, una por cada combinación de nodo (1-7) y campaña pos-riego (6, 48, 120, 192 horas). Cada registro contiene:

- *node\_id*: identificador del nodo (1-7).
- *timestamp*: fecha y hora (UTC-7) de la lectura in situ.
- *lon, lat*: coordenadas RTK WGS-84 del nodo (exactitud 2cm).
- *rho\_green, rho\_red, rho\_re, rho\_nir*: reflectancias medias extraídas de la ventana  $3 \times 3$ px alrededor de las coordenadas del nodo, en bandas Green (560nm), Red (650nm), Red-Edge (730nm) y NIR (860nm), todas normalizadas en  $[0, 1]$ .
- *soil\_moisture*: humedad gravimétrica promedio obtenida de las tres lecturas in situ, transformada según la Ecuación 1 y normalizada en  $[0, 1]$ .

##### 2.4.2. Estructura de columnas

La Tabla 1 muestra la definición de cada columna en DataSetMuestreoInSitu.csv.

**Tabla 1.** Estructura de DataSetMuestreoInSitu.csv.

| Columna       | Descripción                      | Unidad   |
|---------------|----------------------------------|----------|
| node_id       | Identificador del nodo (1–7)     | –        |
| timestamp     | Fecha y hora (UTC–7)             | ISO 8601 |
| lon, lat      | Coordenadas WGS-84               | grados   |
| rho_green     | Reflectancia 560 nm              | 0–1      |
| rho_red       | Reflectancia 650 nm              | 0–1      |
| rho_re        | Reflectancia 730 nm              | 0–1      |
| rho_nir       | Reflectancia 858 nm              | 0–1      |
| soil_moisture | Humedad gravimétrica normalizada | 0–1      |

Fuente: Elaboración propia.

Este *dataset* se desarrolló exclusivamente para la validación del modelo propuesto, sin aplicar ningún otro preprocesamiento adicional.

### 2.5. Construcción y preprocesamiento del dataset multiespectral de entrenamiento

Para contar con suficientes datos de entrenamiento se generó el *dataset* multiespectral MS-4, sintetizado a partir del conjunto hiperespectral KarLy. Este enfoque aprovecha la alta resolución espectral de KarLy para emular un sensor multiespectral de 4 bandas mediante técnicas de reducción y selección espectral.

A continuación, se describen las principales características de KarLy y el flujo aplicado para su transformación en MS-4, el cual incluyó la normalización de los datos, la selección de bandas representativas y la validación de la coherencia radiométrica del nuevo conjunto. Asimismo, se establecieron criterios de calidad que garantizan la utilidad del *dataset* en tareas de entrenamiento supervisado.

#### 2.5.1. Descripción del dataset KarLy

El *KarLy Hyperspectral Benchmark Dataset on Soil Moisture* fue desarrollado por Riese y Keller (KIT, Alemania) y está disponible en Zenodo bajo licencia CC BY 4.0 [16]. KarLy contiene mediciones hiperespectrales VNIR (454 – 950 nm, resolución 4 nm, 101 bandas útiles tras preprocesado) de un núcleo intacto de suelo franco en condiciones de laboratorio controladas ( $20 \pm 1$  °C, HR  $50 \pm 3$  %), calibradas mediante panel Spectralon® 99 %. Cada cubo hiperespectral ( $50 \times 50$  px  $\times$  125 bandas iniciales) se asoció a una lectura volumétrica continua de humedad gravimétrica (% p/p) obtenida con sonda TRIME PICO TDR (2 cm de profundidad), sincronizada (<10 s) con la adquisición espectral.

El archivo original soilmoisture\_dataset.csv incluye 1 029 registros (tomados cada 30 min), con las siguientes columnas:

- *datetime*: fecha y hora (CEST, formato ISO 8601).
- *soil\_moisture*: humedad gravimétrica del suelo (% p/p).
- *soil\_temperature*: temperatura del suelo (°C).
- 101 columnas espectrales:  $\rho(\lambda)$  en reflectancia ( $[0, 1]$ ), correspondientes a bandas VNIR de 454 a 950 nm con incrementos de 4 nm.

Tras aplicar correcciones radiométricas, eliminación de bandas oscuras y alineamiento geométrico, se depuraron duplicados (18 registros) y valores nulos, obteniéndose 1 011 muestras finales. Todos los valores de *soil\_moisture* se normalizaron al intervalo  $[0, 1]$  mediante transformación Min–Max.

#### 2.5.2. Selección de bandas para MS-4

Para simular las cuatro bandas del dron multiespectral, se extrajeron del cubo KarLy las bandas más cercanas a las longitudes centrales del Mavic 3 Multispectral (560 nm, 650 nm, 730 nm, 858 nm). La correspondencia quedó registrada en la Tabla 2.

**Tabla 1.** Correspondencia entre KarLy VNIR y bandas MS-4.

| Banda Mavic | $\lambda_{\text{Mavic}}$ [nm] | $\lambda_{\text{KarLy}}$ [nm] | Nombre final |
|-------------|-------------------------------|-------------------------------|--------------|
| Green       | 560                           | 562                           | rho_green    |
| Red         | 650                           | 650                           | rho_red      |
| Red-Edge    | 730                           | 730                           | rho_re       |
| NIR         | 860                           | 860                           | rho_nir      |

Fuente: Elaboración propia

De este modo, cada registro KarLy de 101 bandas se redujo a un vector  $[\rho_{562}, \rho_{650}, \rho_{730}, \rho_{858}]$ , renombrado como  $[\rho_{\text{green}}, \rho_{\text{red}}, \rho_{\text{re}}, \rho_{\text{nir}}]$ .

### 2.5.2. Emparejamiento con $\theta_{\text{grav}}$

KarLy proporciona *soil\_moisture* en % p/p. Dado que en MS-4 la variable objetivo se define como humedad gravimétrica normalizada en  $[0, 1]$ , se aplicó la misma normalización Min–Max (Ecuación 2).

$$\tilde{\theta}_{\text{grav}} = \frac{\theta_{\text{grav}} - \min(\theta_{\text{grav}})}{\max(\theta_{\text{grav}}) - \min(\theta_{\text{grav}})} \quad (2)$$

quedando  $\tilde{\theta}_{\text{grav}} \in [0, 1]$ . Las cuatro bandas extraídas ya se encontraban escaladas en  $[0, 1]$  tras el preprocesado original de KarLy.

### 2.5.2. Composición final del *dataset* MS-4

El *dataset* MS-4 resultante agrupa únicamente las 1 011 muestras hiperespectrales de KarLy reducidas a  $\{\rho_{\text{green}}, \rho_{\text{red}}, \rho_{\text{re}}, \rho_{\text{nir}}, \tilde{\theta}_{\text{grav}}\}$ . Las 28 muestras in situ se reservaron exclusivamente para validar la CNN y no formaron parte del entrenamiento.

### 2.5.3. Partición estratificada

Antes de entrenar el modelo se dividió en:

- Conjunto de entrenamiento: 70 % (708 muestras).
- Conjunto de validación: 15 % (152 muestras).
- Conjunto de prueba: 15 % (151 muestras).

Esta partición se realizó mediante estratificación en cuartiles de  $\tilde{\theta}_{\text{grav}}$ , para asegurar que cada subconjunto mantuviera la misma distribución de humedad en todo el rango. De esta forma, MS-4 quedó listo para alimentar el entrenamiento de la CNN con 4 entradas espectrales y 1 objetivo continuo.

## 2.6. Diseño del Modelo

Para abordar la estimación de humedad gravimétrica a partir de datos multiespectrales UAV, se diseñó una red neuronal convolucional (CNN) que toma como entrada las cuatro bandas espectrales *Green*, *Red*, *Red-Edge* y *NIR* y produce una predicción continua de  $\theta_{\text{grav}}$ . A continuación, se describe con detalle la arquitectura seleccionada, junto con la justificación teórica de cada componente y el protocolo de entrenamiento empleado.

### 2.6.1. Arquitectura

La CNN procesa vectores  $\mathbf{x} = [\rho_{\text{green}}, \rho_{\text{red}}, \rho_{\text{re}}, \rho_{\text{nir}}]^T \in \mathbb{R}^{4 \times 1}$  y consta de las siguientes etapas:

- Capa de entrada: Un tensor de dimensiones (4, 1), donde cada una de las cuatro posiciones corresponde a la reflectancia normalizada  $\rho$  de una banda específica.
- Bloque convolucional (Conv1D\_1–Conv1D\_3): Se aplican tres capas Conv1D sucesivas, cada una con 32 filtros y tamaño de *kernel* igual a 3 (*stride* = 1, *padding* = *same*), activación ReLU.
- Capa MaxPooling1D: Con un *pool size* de 2, reduce la dimensión espacial de 4 a 2, reteniendo los valores máximos de cada par de posiciones. Esta operación no solo disminuye la cantidad de parámetros, sino que aporta invarianza a pequeñas traslaciones en la firma espectral, mitigando el ruido resultado de fluctuaciones atmosféricas residuales.
- Capa Flatten: Aplana la salida del *MaxPooling*, de tamaño (2, 32), a un vector unidimensional de 64 elementos, preparado para su conexión a la etapa densa.
- Capa de salida lineal: Una única neurona sin función de activación (lineal), que calcula mediante la Ecuación 3.

$$\hat{\theta}_{\text{grav}} = \sum_{i=1}^{64} W_i^{(2)} z_i + b^{(2)} \quad (3)$$

donde  $z_i$  son las salidas de la capa oculta y  $W^{(2)}, b^{(2)}$  sus pesos y sesgo. Este diseño asegura que la predicción continúe en  $\mathbb{R}$  y pueda ajustarse directamente a los valores gravimétricos reales.

La selección de cada componente responde a principios de aprendizaje profundo y características físicas de la reflectancia del suelo:

- Tres capas Conv1D con 32 filtros cada una: Este número de filtros ha demostrado capturar eficientemente patrones locales en secuencias cortas (4 bandas) sin incurrir en sobreajuste [11]. El *kernel* de tamaño 3 permite modelar interacciones entre bandas contiguas, fundamentales para detectar cambios en absorciones de agua y materia mineral.
- MaxPooling1D (*pool size* = 2): Reducir la dimensión de 4 a 2 mediante agrupamiento máximo introduce invarianza a pequeñas variaciones espectrales generadas por ruido atmosférico residual y errores de registro georreferenciado. Además, disminuye la complejidad computacional de las etapas posteriores, acelerando la convergencia.
- Capa Dense con 64 unidades: Dado que las capas convolucionales extraen mapas de características locales, la capa densa sirve para combinar y abstraer esas características en un espacio de mayor dimensión, donde la relación espectral–humedad puede modelarse de forma óptima. El tamaño 64 equilibra expresividad y control de la complejidad.
- Ausencia de *Dropout*: En ensayos previos se comprobó que añadir *Dropout* inducía varianza innecesaria en los pesos cuando las entradas constan de solo cuatro canales normalizados, sin mejorar significativamente el desempeño en validación. La normalización Min–Max de entradas y la estructura compacta de la red garantizan buena generalización sin requerir regularización adicional [17].

## 2.7. Entrenamiento y validación

Para entrenar la CNN se definieron los siguientes hiperparámetros y estrategias de optimización:

- Optimizador: Adam con tasa de aprendizaje inicial  $\alpha = 3 \times 10^{-4}$ ,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ . Adam ajusta dinámicamente la tasa de cada parámetro según momentos acumulados, lo que favorece la convergencia en espacios de pérdida no convexos [18].
- Función de pérdida: Error cuadrático medio (MSE), adecuada para problemas de regresión continua e intensamente documentada en la literatura como función diferenciable que penaliza los errores de gran magnitud [19].
- Métricas de evaluación:
  - $R^2$  (coeficiente de determinación): Evalúa la proporción de varianza de la variable objetivo explicada por el modelo.
  - MSE en validación: Permite monitorear la evolución del error durante el entrenamiento.
- *Callbacks*:

- *EarlyStopping* (monitor = *val\_loss*, *patience* = 30, *min\_delta* =  $1 \times 10^{-4}$ ): Detiene el entrenamiento si no se observa mejora en la pérdida de validación tras 30 épocas consecutivas, evitando sobreajuste.
- *ReduceLROnPlateau* (monitor = *val\_loss*, *patience* = 30, *min\_delta* =  $1 \times 10^{-4}$ ): Reduce la tasa de aprendizaje a la mitad si no hay mejora en la pérdida de validación durante 10 épocas, permitiendo un afinamiento fino en regiones de baja pendiente.
- *Batch size*: 32, seleccionado para equilibrar la estabilidad de gradientes y eficiencia computacional.
- Épocas máximas: Se seleccionaron 500 épocas. Para el entrenamiento se secciono 500 épocas mediante *EarlyStopping*.

El protocolo de entrenamiento siguió estos pasos:

1. Inicialización de pesos: Se empleó inicialización de Glorot uniforme para todas las capas Conv1D y Dense, con el fin de preservar la varianza de activaciones y gradientes en las primeras etapas.
2. Verificación de distribuciones: Antes de entrenar, se comprobó que los subconjuntos de entrenamiento y validación presentaban distribuciones similares en todas las bandas  $\rho$  y en  $\theta$  mediante histograma y prueba de Kolmogorov–Smirnov ( $p > 0.05$ ), garantizando homogeneidad estadística.
3. Ciclo de entrenamiento: En cada época, Adam actualizó los pesos minimizando la MSE sobre el conjunto de entrenamiento, mientras se calculaba la MSE y  $R^2$  en validación.
4. Selección del modelo final: Se eligió el punto en el que la pérdida de validación fue mínima, y esos pesos se conservaron para la evaluación final en el conjunto de prueba.


La combinación de capas Conv1D para extracción jerárquica de características espectrales, *MaxPooling* para reducción de dimensionalidad y estructura Dense para predicción continua, junto con estrategias de optimización basadas en Adam y mecanismos de parada temprana, proporcionan una arquitectura CNN tanto precisa como robusta, capaz de modelar la compleja relación espectral–humedad en datos multiespectrales UAV.

### 3. Resultados

En esta sección se presenta un análisis exhaustivo del desempeño de la modelo propuesta basado en la CNN MS-4 sobre el conjunto de prueba multiespectral, enfatizando su convergencia durante el entrenamiento, las métricas cuantitativas finales y la evaluación detallada de errores y residuos. Asimismo, se contrastan los hallazgos con los enfoques empíricos tradicionales para valorar la mejora obtenida.

#### 3.1. Convergencia durante el entrenamiento

Para evaluar la dinámica de aprendizaje, se monitoreó la evolución del error cuadrático medio (MSE) tanto en el conjunto de entrenamiento como en el de validación a lo largo de 87 épocas, período en el cual actuaron los mecanismos de *ReduceLROnPlateau* y *EarlyStopping*. En la Figura 5 se observa que, durante las primeras 20 épocas, el MSE en entrenamiento desciende con gran rapidez, pasando de aproximadamente 0.08 a 0.01. Paralelamente, el MSE de validación sigue una trayectoria similar, alcanzando un valor cercano a 0.007 alrededor de la época 20.



**Figura 5.** Evolución del ECM durante el entrenamiento del modelo.

A partir de la época 30, la brecha entre las curvas de entrenamiento y validación se estabiliza en menos de 0.002, lo cual indica que la red aprendió patrones espectrales relevantes sin incurrir en un sobreajuste significativo.

El comportamiento de estas curvas evidencia, por un lado, la capacidad de la arquitectura para modelar relaciones espectrales no lineales en un espacio de baja dimensionalidad (solo cuatro bandas); y por otro, la efectividad de los *callbacks* en regular el proceso. Finalmente, la época 57 corresponde al punto en que la pérdida de validación alcanza su mínimo absoluto ( $MSE_{val}=0.0054$ ), criterio que se utilizó para almacenar los pesos definitivos del modelo.

### 3.2. Métricas finales en conjunto de prueba


Con los pesos obtenidos en el entrenamiento, el modelo se evaluó sobre las 152 muestras del subconjunto de prueba. Las principales métricas resultaron:  $MSE_{test} = 0.0058$ ,  $R2_{test} = 0.91$  y  $MAE_{test} = 0.046$ .

Estos indicadores reflejan un desempeño sobresaliente: un coeficiente de determinación de 0.91 sugiere que la CNN MS-4 explica más del 90 % de la variabilidad de la humedad gravimétrica en datos no vistos. A su vez, el error absoluto medio (MAE) de 0.046 cm<sup>3</sup>/cm<sup>3</sup> implica que, en promedio, las predicciones se ubican dentro de  $\pm 4,6$  % de la humedad real, valores compatibles con los márgenes de decisión en riego de precisión.

### 3.3. Correlación entre valores predichos y reales

Para visualizar la correspondencia entre estimaciones  $\hat{\theta}$  y valores reales  $\theta$ , en la Figura 6 se presenta un diagrama de dispersión en el que cada punto representa una muestra de prueba. La línea de identidad (línea negra) sirve como referencia de ajuste perfecto. Más del 85 % de las predicciones se concentran dentro de un margen de  $\pm 0,05$  respecto a dicha línea, lo que evidencia una alta precisión tanto en la zona media como en los extremos del rango de humedad.

Sin embargo, se advierte que los errores mayores ( $|\hat{\theta} - \theta| > 0.10$ ) se producen principalmente en valores de  $\theta < 0.10$  y  $\theta > 0.90$ . Estos rangos coinciden con menor densidad de muestras en el conjunto de prueba y con regiones espectrales donde la reflectancia del suelo tiende a saturarse, ya sea porque el poro está casi completamente lleno de agua o extremadamente seco, perdiendo la diferenciación espectral [20]. Estas observaciones son consistentes con estudios previos que reportan una mayor dificultad para discriminar humedad en condiciones de saturación extrema o sequía absoluta.




**Figura 6.** Dispersión entre estimaciones  $\hat{\theta}$  y valores reales  $\theta$ .

### 3.4. Análisis de residuos


Un análisis detallado de residuos permite verificar supuestos estadísticos y descartar sesgos sistemáticos. Se definieron los residuos  $d_i = \hat{\theta}_i - \theta_i$  y se evaluaron a través de varios gráficos y pruebas paramétricas.

La Figura 7 muestra los residuos en función de  $\theta_i$ . La nube de puntos exhibe simetría alrededor de cero, sin trazas de dispersión creciente o decreciente en los extremos. Este patrón sugiere homocedasticidad, es decir, la varianza del error se mantiene relativamente constante, lo cual es esencial para la validez de intervalos de confianza y pruebas de hipótesis basadas en la distribución normal de errores.



**Figura 7.** Residuos  $d_i = \hat{\theta}_i - \theta_i$  en función de  $\theta_i$ .

La Figura 8 presenta la distribución de los residuos en forma de histograma. La forma aproximada de campana, centrada en cero, indica que la mayoría de los errores se concentra en torno a la media nula. La media de los residuos se calculó como  $\bar{d} = -0.001$ , prácticamente cero, y la desviación estándar resultó  $\sigma_d = 0.035$ . En este contexto, el 68 % de las diferencias cae dentro de  $\pm 0.035$ . Sólo alrededor del 2–3 % de los residuos supera  $\pm 2\sigma$ , reflejando la presencia de unos pocos valores atípicos, esperables dado el muestreo en condiciones reales de campo.



**Figura 8.** Histograma de residuos.

Para verificar la normalidad de los residuos, se construyó un gráfico Q–Q (Figura 9) donde los cuantiles empíricos se comparan con los cuantiles teóricos de una distribución normal. La alineación cercana a la diagonal en los cuantiles centrales y ligeras desviaciones en las colas inferior y superior muestran que la mayor parte de los residuos se ajusta a la normalidad, con desvíos menores atribuibles a los pocos *outliers* ya identificados. La prueba de Shapiro–Wilk ( $W = 0.98$ ,  $p = 0.12$ ) no rechaza la hipótesis de normalidad al nivel  $\alpha=0.05$ , lo que valida el uso de métodos paramétricos para evaluar la precisión del modelo.




Figura 9. Gráfico Q-Q de residuos  $d_i$ .

El diagrama de Bland–Altman (Figura 10) permite evaluar la concordancia numérica entre las estimaciones y las mediciones reales. Cada punto representa la diferencia  $d_i$  frente al promedio  $m_i = (\hat{\theta}_i + \theta_i)/2$ . La banda de límites de acuerdo, definida como  $\bar{d} \pm 1.96 \sigma_d$ , abarca aproximadamente el 95 % de las diferencias. En este caso,  $\bar{d} = -0.001$  y  $1.96 \sigma_d \approx 0.0686$ , resultando en límites de  $[-0.0696, 0.0676]$ . La uniformidad de esta banda a lo largo de los valores medios indica que la precisión del modelo es consistente en todo el rango de humedad, lo que refuerza la validez de la homocedasticidad observada previamente.




Figura 10. Diagrama de Bland–Altman

### 3.5. Correlación entre estimaciones del Modelo basado en CNN y datos in situ

El coeficiente de correlación de Pearson entre las predicciones  $\{\hat{\theta}_i\}$  y los valores reales  $\{\theta_i\}$  en el conjunto de prueba resultó ser:  $r = 0.92$ ,  $p < 0.001$ .

Este alto valor de  $r$ , estadísticamente significativo, confirma que más del 85 % de la variación observada en la humedad gravimétrica se explica linealmente por la salida del modelo CNN. La concordancia con la línea de identidad en la Figura 6 refuerza que la red captura adecuadamente las relaciones espectrales-hídricas en el suelo desnudo.

## 4. Discusión

Los resultados presentados evidencian que la CNN MS-4 alcanza un desempeño notablemente superior al de índices empíricos clásicos en suelos desnudos, tales como NDWI y NDMI, los cuales no están calibrados para las bandas específicas del Mavic 3 Multispectral y muestran baja precisión cuando se emplean sin ajustes locales [7]. A continuación, se discuten los hallazgos más relevantes:

- Modelado de patrones no lineales: La arquitectura Conv1D de tres capas con 32 filtros logra capturar interacciones locales entre bandas contiguas (*Green-Red*, *Red-Red-Edge*, *Red-Edge-NIR*),

esenciales para reflejar las absorbancias del agua en el VNIR. El rápido descenso del MSE durante las primeras 20 épocas y el ascenso simultáneo de  $R^2$  hasta 0.90 indican que estas capas son efectivas para extraer características espectrales relevantes [11].

- **Robustez estadística:** El análisis de residuos demuestra homocedasticidad y normalidad en la mayoría de los casos, validando los supuestos de los métodos paramétricos. El diagrama de Bland-Altman muestra un sesgo medio prácticamente nulo ( $\bar{d} = -0.001$ ) y límites de acuerdo estrechos ( $\pm 0.0686$ ), lo cual respalda la estabilidad del índice en todo el rango de humedad.
- **Precisión en el rango medio:** Más del 85 % de las predicciones se encuentran dentro de  $\pm 0.05$  de la línea de identidad, lo que confirma la utilidad práctica del modelo para rangos de humedad intermedios (0.10–0.90). En este dominio, la firma espectral del suelo es más diferenciable y la densidad de muestras es mayor, lo cual favorece un ajuste más fino.
- **Desempeño en extremos:** Los errores más pronunciados ( $> 0.10$ ) se observan en  $\theta < 0.10$  y  $\theta > 0.90$ , debido a la menor densidad de muestras y a la disminución de la variabilidad espectral en condiciones de saturación o sequía extrema. Este fenómeno coincide con reportes previos que indican que, en suelos casi secos o casi saturados, la reflectancia se vuelve menos sensible a variaciones adicionales de humedad [11].
- **Ventaja sobre índices empíricos:** A diferencia de NDWI o NDMI, que se basan en relaciones lineales entre dos bandas y no capturan interacciones espectrales complejas, la CNN MS-4 integra múltiples bandas simultáneamente y aprende pesos que optimizan la predicción. Esto resulta en una correlación de  $r = 0.92$ , muy superior a la obtenida por índices empíricos sin calibración específica [8].
- **Relevancia operativa:** La precisión obtenida ( $MAE \approx 0.046$ ) es adecuada para implementar sistemas de monitoreo en tiempo real con UAV multiespectrales. La resolución espacial de  $\approx 4$  cm/píxel combinada con la capacidad predictiva de la CNN permite detectar microvariaciones intraparcelarias, lo cual es crítico para prácticas de riego de precisión en suelos desnudos [21].

#### Limitaciones identificadas:

- El conjunto de entrenamiento se basa exclusivamente en un suelo franco-arcilloso homogéneo, lo cual podría afectar la generalización a suelos de diferente textura u orgánicos.
- Las mediciones in situ cubren un rango limitado de humedad en condiciones de campo; sería recomendable incorporar más muestras en extremos para robustecer el ajuste en colas.
- Los vuelos se realizaron siempre en cielo despejado; la robustez ante condiciones atmosféricas variables (p. ej., nubes delgadas) no se evaluó en este experimento.

En conjunto, estos resultados demuestran que la CNN MS-4 constituye un índice operativo y fiable para estimar la humedad gravimétrica del suelo a partir de datos UAV multiespectrales, superando ampliamente las limitaciones de los índices empíricos tradicionales cuando se aplican sin calibración específica.

## 5. Conclusiones

El presente estudio demuestra que una red neuronal convolucional (CNN) de diseño compacto, compuesta por tres capas Conv1D con 32 filtros y tamaño de *kernel* igual a 3, seguida de un bloque de MaxPooling1D, una capa de aplanamiento (*Flatten*) y una capa densa de 64 unidades, es capaz de estimar con elevada precisión la humedad gravimétrica del suelo utilizando únicamente las bandas espectrales *Green* (560 nm), *Red* (650 nm), *Red-Edge* (730 nm) y *NIR* (860 nm) suministradas por un dron multiespectral. Esta arquitectura supera claramente la precisión de los índices empíricos convencionales (por ejemplo, NDWI o NDMI) cuando estos no se calibran para las bandas específicas del DJI Mavic 3 Multispectral.

Al evaluar el desempeño de la CNN sobre el conjunto de prueba MS-4, compuesto por 152 muestras independientes, se obtuvo un error cuadrático medio (MSE) de 0.0058, un coeficiente de determinación  $R^2$  de 0.91 y un error absoluto medio (MAE) de 0.046. Estos valores se acompañan de un coeficiente de correlación de Pearson  $r = 0.92$  entre las estimaciones  $\hat{\theta}$  de la CNN y las mediciones in situ  $\theta$ , lo cual confirma que la red captura de manera eficiente las relaciones espectrales no lineales que caracterizan la variabilidad de humedad en suelos desnudos.

El análisis detallado de los residuos corrobora la validez estadística del modelo: los residuos se distribuyen de forma homocedástica, sin tendencia sistemática a lo largo del rango de humedad, y aproximan una distribución normal (prueba de Shapiro–Wilk,  $p = 0.12$ ). Asimismo, el sesgo medio de los residuos fue prácticamente nulo ( $-0.001$ ), lo que indica ausencia de desviaciones sistemáticas tanto hacia la sobreestimación como hacia la subestimación de la humedad. Estos resultados garantizan que las inferencias y los intervalos de confianza derivados del modelo son robustos y fiables.

Otro hallazgo relevante es que la alta resolución espacial del UAV ( $\approx 4$  cm/píxel) combinada con la sensibilidad espectral de la CNN permite identificar microvariaciones intraparcclarias, por ejemplo, los gradientes radiales de riego, los patrones en surcos y las cabeceras de los círculos de irrigación, con un nivel de detalle que resulta crítico para la toma de decisiones en agricultura de precisión. Gracias a esta resolución, es posible detectar zonas puntuales de estrés hídrico en tiempo real y optimizar la aplicación de recursos hídricos a escala local, reduciendo desperdicios y mejorando la eficiencia de riego en suelos semiáridos.

No obstante, se identificaron ciertas limitaciones en los extremos del rango de humedad ( $\theta < 0.1$  y  $\theta > 0.9$ ), donde los errores de predicción tienden a aumentar debido a la menor densidad de muestras y a la menor diferenciación espectral en condiciones de saturación extrema o sequía casi total. Estas observaciones sugieren la necesidad de ampliar el dataset con mediciones en condiciones de humedad extremas y de incorporar suelos de distinta textura, por ejemplo, suelos arenosos, limosos o con mayores contenidos orgánicos, para mejorar la generalización del índice propuesto.

El índice espectral basado en CNN aquí desarrollado constituye un avance significativo en la estimación de humedad del suelo mediante datos UAV multispectrales. Su alta precisión, validada estadísticamente, y la capacidad de detectar microvariaciones intraparcclarias lo posicionan como una herramienta operativa con amplio potencial de adopción en sistemas de riego inteligente y monitoreo ambiental.

## 6. Referencias

- [1] Rosegrant, M. W., Ringler, C., Zhu, T. (2009). Water for Agriculture: Maintaining Food Security under Growing Scarcity. *Annual Review of Environment and Resources*, 34 (1), 205–222. <https://doi.org/10.1146/annurev.environ.030308.090351>
- [2] Qian, Y., Zhu, Y., Ye, M., Huang, J., Wu, J. (2021). Experiment and numerical simulation for designing layout parameters of subsurface drainage pipes in arid agricultural areas. *Agricultural Water Management*, 243. <https://doi.org/10.1016/j.agwat.2020.106455>
- [3] Wisser, D., Frolking, S., Douglas, E. M., Fekete, B. M., Vörösmarty, C. J., Schumann, A. H. (2008). Global irrigation water demand: Variability and uncertainties arising from agricultural and climate data sets. *Geophysical Research Letters*, 35 (24), 1–5. <https://doi.org/10.1029/2008GL035296>
- [4] Dorigo, W., Himmelbauer, I., Aberer, D., Schremmer, L., Petrakovic, I., Zappa, L., Preimesberger, W., Xaver, A., Annor, F., Ardö, J., Baldocchi, D., Bitelli, M., Blöschl, G., Boga, H., Brocca, L., Calvet, J.-C., Camarero, J. J., Capello, G., Choi, M., ... Sabia, R. (2021). The International Soil Moisture Network: serving Earth system science for over a decade. *Hydrology and Earth System Sciences*, 25 (11), 5749–5804. <https://doi.org/10.5194/hess-25-5749-2021>
- [5] Katz, B. S., Stotler, R. L., Hirmas, D., Ludvigson, G., Smith, J. J., Whittemore, D. O. (2016). Geochemical Recharge Estimation and the Effects of a Declining Water Table. *Vadose Zone Journal*, 15 (10), 1–13. <https://doi.org/10.2136/vzj2016.04.0031>
- [6] Beck, H. E., Pan, M., Miralles, D. G., Reichle, R. H., Dorigo, W. A., Hahn, S., Sheffield, J., Karthikeyan, L., Balsamo, G., Parinussa, R. M., Van Dijk, A. I. J. M., Du, J., Kimball, J. S., Vergopolan, N., Wood, E. F. (2021). Evaluation of 18 satellite- and model-based soil moisture products using in situ measurements from 826 sensors. *Hydrology and Earth System Sciences*, 25 (1), 17–40. <https://doi.org/10.5194/hess-25-17-2021>
- [7] Harpold, A. A., Kaplan, M. L., Klos, P. Z., Link, T., McNamara, J. P., Rajagopal, S., Schumer, R., Steele, C. M. (2017). Rain or snow: hydrologic processes, observations, prediction, and research needs. *Hydrology and Earth System Sciences*, 21 (1), 1–22. <https://doi.org/10.5194/hess-21-1-2017>
- [8] Kerr, Y. H., Al-Yaari, A., Rodriguez-Fernandez, N., Parrens, M., Molero, B., Leroux, D., Bircher, S., Mahmoodi, A., Mialon, A., Richaume, P., Delwart, S., Al Bitar, A., Pellarin, T., Bindlish, R., Jackson, T. J., Rüdiger, C., Waldteufel, P., Mecklenburg, S., Wigneron, J.-P. (2016). Overview of SMOS performance in

- terms of global soil moisture monitoring after six years in operation. *Remote Sensing of Environment*, 180, 40–63. <https://doi.org/10.1016/j.rse.2016.02.042>
- [9] Rand, C. F., Khan, A. L. (2024). Applicability of Relatively Low-Cost Multispectral Uncrewed Aerial Systems for Surface Characterization of the Cryosphere. *Remote Sensing*, 16 (19), 1-17. <https://doi.org/10.3390/rs16193662>
- [10] Shi, P., Li, P., Li, Z., Sun, J., Wang, D., Min, Z. (2022). Effects of grass vegetation coverage and position on runoff and sediment yields on the slope of Loess Plateau, China. *Agricultural Water Management*, 259. <https://doi.org/10.1016/j.agwat.2021.107231>
- [11] Shokati, H., Mashal, M., Noroozi, A., Abkar, A. A., Mirzaei, S., Mohammadi-Doqozloo, Z., Taghizadeh-Mehrjardi, R., Khosravani, P., Nabiollahi, K., Scholten, T. (2024). Random Forest-Based Soil Moisture Estimation Using Sentinel-2, Landsat-8/9, and UAV-Based Hyperspectral Data. *Remote Sensing*, 16 (11), 1-17. <https://doi.org/10.3390/rs16111962>
- [12] Hegazi, E. H., Samak, A. A., Yang, L., Huang, R., Huang, J. (2023). Prediction of Soil Moisture Content from Sentinel-2 Images Using Convolutional Neural Network (CNN). *Agronomy*, 13 (3), 1-18. <https://doi.org/10.3390/agronomy13030656>
- [13] Brutsaert, W., Chen, D. (1995). Desorption and the two Stages of Drying of Natural Tallgrass Prairie. *Water Resources Research*, 31 (5), 1305–1313. <https://doi.org/10.1029/95WR00323>
- [14] Idso, S. B., Reginato, R. J., Jackson, R. D., Kimball, B. A., Nakayama, F. S. (1974). The Three Stages of Drying of a Field Soil. *Soil Science Society of America Journal*, 38 (5), 831–837. <https://doi.org/10.2136/sssaj1974.03615995003800050037x>
- [15] Seneviratne, S. I., Corti, T., Davin, E. L., Hirschi, M., Jaeger, E. B., Lehner, I., Orlowsky, B., Teuling, A. J. (2010). Investigating soil moisture–climate interactions in a changing climate: A review. *Earth-Science Reviews*, 99 (3–4), 125–161. <https://doi.org/10.1016/j.earscirev.2010.02.004>
- [16] Riese, F. M., Keller, S. (2019). *felixriese/hyperspectral-soilmoisture-dataset: Dataset with universal DOI* (Versión v1.0.3) [Software]. Zenodo. <https://doi.org/10.5281/ZENODO.1227836>
- [17] LeCun, Y., Bottou, L., Orr, G. B., Müller, K.-R. (1998). Efficient BackProp. En G. B. Orr, K.-R. Müller (Eds.), *Neural Networks: Tricks of the Trade* (pp. 9–50). Springer Berlin Heidelberg. [https://doi.org/10.1007/3-540-49430-8\\_2](https://doi.org/10.1007/3-540-49430-8_2)
- [18] Hochreiter, S., Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9 (8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [19] Chai, T., Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7 (3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- [20] Shokati, H., Mashal, M., Noroozi, A., Abkar, A. A., Mirzaei, S., Mohammadi-Doqozloo, Z., Taghizadeh-Mehrjardi, R., Khosravani, P., Nabiollahi, K., Scholten, T. (2024). Random Forest-Based Soil Moisture Estimation Using Sentinel-2, Landsat-8/9, and UAV-Based Hyperspectral Data. *Remote Sensing*, 16 (11), 1962. <https://doi.org/10.3390/rs16111962>
- [21] Neely, W. R., Borsa, A. A., Burney, J. A., Levy, M. C., Silverii, F., Sneed, M. (2021). Characterization of Groundwater Recharge and Flow in California’s San Joaquin Valley From InSAR-Observed Surface Deformation. *Water Resources Research*, 57 (4), 1-20. <https://doi.org/10.1029/2020WR028451>