

Artículo

Predicción de la humedad del suelo mediante aprendizaje por transferencia: Una aplicación en los Altos Andes Tropicales

Diego Escobar-González, Marcos Villacís, Sebastián Páez-Bimos, Gabriel Jácome, Juan González-Vergara, Claudia Encalada y Veerle Vanacker

Número especial

Dinámica del suelo y gestión de los recursos hídricos

Editado por

Prof. Dr. José Miguel Reichert



Artículo

Predicción de la humedad del suelo mediante aprendizaje por transferencia: Una aplicación en los Altos Andes Tropicales

Diego Escobar-González ^{*1,2, }, Marcos Villacís ^{3, }, Sebastián Páez-Bimos ^{3, }, Gabriel Jácome ^{4, },
Juan González-Vergara ^{5,6, }, Claudia Encalada ^{1, } y Veerle Vanacker ^{7, }

- ¹ Departamento de Gestión de Recursos Hídricos, Empresa Pública Metropolitana de Agua Potable y Saneamiento de Quito, EPMAPS Agua de Quito, Quito 170509, Ecuador; diego.escobar@aguaquito.gob.ec
- ² Facultad de Postgrado, Maestría en Ciencias de la Ingeniería para la Gestión de los Recursos Hídricos, Universidad Técnica del Norte (UTN), Av. 17 de Julio 5-21 y Gral. José María Córdova, Ibarra 100150, Ecuador
- ³ Departamento de Ingeniería Civil y Ambiental & Centro de Investigación y Estudios en Ingeniería de los Recursos Hídricos, Escuela Politécnica Nacional, Quito 170525, Ecuador; marcos.villacis@epn.edu.ec (M.V.); carlos.paezb@epn.edu.ec (S.P.-B.)
- ⁴ Laboratorio de Geociencias y Medio Ambiente (GEOMA), Carrera de Recursos Naturales Renovables, Facultad de Ingeniería en Ciencias Agropecuarias y Ambientales, Universidad Técnica del Norte (UTN), Av. 17 de Julio 5-21 y Gral. José María Córdova, Ibarra 100150, Ecuador. José María Córdova, Ibarra 100150, Ecuador; gajacomea@utn.edu.ec
- ⁵ Fondo Para la Protección del Agua (FONAG), Mariana de Jesús N32 y Martín de Utreras, Quito 170509, Ecuador; juan.gonzalez@fonag.org.ec
- ⁶ SDAS Researh Group, Ben Guerir 43150, Marruecos
- ⁷ Earth and Climate Research, Earth and Life Institute, UCLouvain, 1348 Louvain-la-Neuve, Bélgica; veerle.vanacker@uclouvain.be

*Correspondencia: diego.p.escobar.g@gmail.com

Resumen: La humedad del suelo es una variable crítica en el ciclo hidrológico y el sistema climático, impactando significativamente en los recursos hídricos, el funcionamiento de los ecosistemas y la ocurrencia de eventos extremos. Sin embargo, los datos de humedad del suelo son a menudo escasos, y la dinámica del agua del suelo no se entiende completamente en regiones montañosas como los Andes tropicales de Ecuador. Este estudio pretende modelar y predecir la dinámica de la humedad del suelo utilizando datos hidrometeorológicos recogidos in situ para el entrenamiento y técnicas de aprendizaje automático basadas en datos. Nuestros resultados destacan el papel fundamental de la vegetación en el control de la dinámica de la humedad del suelo y las diferencias significativas en el balance hídrico del suelo relacionadas con los tipos de vegetación y la topografía. Se desarrolló un modelo de referencia para predecir la dinámica de la humedad del suelo mediante técnicas de redes neuronales. Posteriormente, empleando técnicas de aprendizaje por transferencia, este modelo se aplicó eficazmente a diferentes horizontes y perfiles de suelo, demostrando su capacidad de generalización y adaptabilidad. El uso de esquemas de redes neuronales y técnicas de transferencia de conocimiento nos permitió desarrollar modelos predictivos de la humedad del suelo entrenados a partir de datos hidrometeorológicos recogidos in situ. La técnica de transferencia-aprendizaje, que aprovechó el conocimiento de un modelo pre-entrenado a un modelo con un dominio similar, arrojó resultados con errores del orden de $1 \times 10^{-6} < \epsilon < 1 \times 10^{-3}$.

Para los datos de entrenamiento, el pronóstico de la red base demostró excelentes resultados, con la métrica de error de menor magnitud RMSE igual a $4,77 \times 10^{-6}$, y NSE y KGE ambos iguales a 0,97. Estos modelos muestran un potencial prometedor para predecir con precisión la dinámica de la humedad del suelo a corto plazo, con aplicaciones potenciales para la vigilancia de riesgos naturales en regiones montañosas.

Palabras clave: humedad del suelo; redes neuronales; aprendizaje por transferencia; páramo; agua del suelo



Citación: Escobar-González, D.; Villacís, M.; Páez-Bimos, S.; Jácome, G.; González-Vergara, J.; Encalada, C.; Vanacker, V. Predicción de la humedad del suelo mediante aprendizaje por transferencia: An Application in the High Tropical Andes. *Water* **2024**, *16*, 832. <https://doi.org/10.3390/w16060832>

Editor académico: Jay Jabro

Recibido: 12 de enero de 2024
Revisado: 22 de febrero de 2024
Aceptada: 7 de marzo de 2024
Publicado: 13 marzo 2024



Copyright: © 2024 por los autores. Licenciatario MDPI, Basilea, Suiza.

Este artículo es un artículo de acceso abierto distribuido bajo los términos y condiciones de la licencia Creative Commons Attribution (CC BY) (<https://creativecommons.org/licenses/by/4.0/>).

1. Introducción

La humedad del suelo es una variable clave en el sistema climático, así como en los ciclos del agua, la energía y la biogeoquímica [1,2]. Una mejor cuantificación de la variabilidad espaciotemporal de la humedad del suelo contribuye a reducir la incertidumbre en la modelización del cambio climático, especialmente en lo que respecta a la aparición y frecuencia de fenómenos meteorológicos extremos como sequías o largos periodos continuos de lluvia [3]. Además, la dinámica de la humedad del suelo también desempeña un papel clave

en la predicción del impacto potencial de los fenómenos meteorológicos en, por ejemplo, incendios, inundaciones y corrimientos de tierras, y en la productividad del suelo y los ecosistemas, como se describe en [4]. A pesar de su importancia, la humedad del suelo es una de las variables menos comprendidas y más difíciles de medir en el campo de la hidrología del suelo [5]. Además, la vegetación juega un papel fundamental en la humedad del suelo a diferentes escalas espaciales y temporales, ya que las plantas extraen agua del suelo e influyen en las vías y flujos del agua [6,7].

El ecosistema de páramo andino se encuentra en los altos Andes tropicales y se caracteriza por una morfología esculpida glacialmente con presencia de pastos de tussock, plantas formadoras de cojines y parches de bosque de *Polylepis* [8]. La dinámica de la humedad del suelo en los ecosistemas de páramo es de gran interés para la planificación futura de los recursos hídricos en la región andina [9,10]. El ambiente de páramo se caracteriza por bajas tasas de erosión física [11] y aporte sostenido de lluvias durante todo el año [12], y los suelos formados por acumulación de cenizas volcánicas contienen alto contenido de materia orgánica (hasta más del 50%, [13]) y tienen alta capacidad de retención e infiltración de agua [14]. La dinámica de la humedad del suelo está controlada por el contenido de humedad previo y las condiciones atmosféricas, y afecta la conectividad hidrológica y el funcionamiento de las cuencas altoandinas [7,15]. La topografía, las propiedades fisicoquímicas del suelo y la cobertura vegetal controlan aún más la hidrología del páramo andino [16]. Los estudios previos sobre la hidrología del suelo en la región se han realizado predominantemente en áreas con suelos poco profundos que sobreyacen material parental volcánico o metasedimentario. Esto incluye trabajos de, por ejemplo, Iñiguez et al. [17] y Patiño et al. [9], sobre la respuesta hidrológica de los suelos de páramo a precipitaciones extremas y sequías. Los suelos volcánicos poligenéticos profundos han sido menos estudiados aunque son prevalentes en la parte norte y central de Ecuador [10].

La dinámica de la humedad del suelo controla la generación de la escorrentía superficial, pero las respuestas lluvia-escorrentía aún no se conocen completamente [18]. Pocos estudios empíricos han analizado la respuesta lluvia-escorrentía en los ecosistemas andinos. Los trabajos previos de, por ejemplo, Molina et al. [19], se centraron principalmente en los sistemas agroambientales de la región interandina y utilizaron experimentos de simulación de precipitaciones para examinar la respuesta hidrológica de diferentes tipos de suelo y cubiertas vegetales. Estos autores [20] demostraron que la respuesta hidrológica puede ser muy variable en el espacio y en el tiempo y está directamente relacionada con la dinámica de la humedad del suelo.

Dada la importancia de los altos Andes para proveer servicios hidrológicos a los centros urbanos en desarrollo en los valles interandinos, existe un creciente interés en modelar y pronosticar la dinámica de la humedad del suelo en base a variables hidrometeorológicas [15]. Los datos de humedad del suelo recolectados in situ están cada vez más disponibles para los sitios altoandinos [7,17,21], y sería de suma importancia incluir estas observaciones en un modelo basado en datos para el pronóstico de la humedad del suelo, lo que mejoraría el monitoreo ambiental y la gestión de los recursos hídricos durante eventos climáticos extremos [22]. Tales enfoques basados en datos complementan los enfoques basados físicamente y deterministas, que a menudo se ven limitados por el gran número de variables ambientales observadas que no siempre están disponibles, como muestran Prasad et al. [22].

La investigación sobre modelización agroambiental aplicada ha utilizado técnicas de aprendizaje automático para la predicción de la humedad del suelo, incluidos esquemas de redes neuronales, como la memoria profunda a corto plazo y las redes neuronales convolucionales [23,24]. Estas redes utilizan variables hidrometeorológicas como datos de entrada. En Suebsombut et al. [25], se empleó un enfoque similar para predecir la humedad del suelo a partir de parámetros ambientales recogidos de varios sensores inteligentes, con el objetivo de mejorar el riego de los cultivos. Otro trabajo de Sivasankaran et al. [26] desarrolló modelos predictivos para la humedad del suelo empleando una red generativa adversarial junto con un algoritmo de optimización Sailfis. En Liu et al. [27], se construyó una red neuronal artificial utilizando un método de optimización de retropropagación en combinación con un algoritmo genético para la predicción de las variaciones de humedad del suelo en terrenos en pendiente, y Zhang et al. [28] estimaron las variaciones de humedad del suelo utilizando una red neuronal de regresión generalizada mejorada para un sitio de alta montaña situado en la Región Autónoma del Tíbet.

La predicción de la humedad del suelo basada en técnicas de aprendizaje automático entrenadas a partir de datos de precipitaciones y variables hidrometeorológicas recogidos in situ [29] tiene un gran potencial para

predecir la dinámica del agua del suelo y también los efectos de fenómenos extremos como la sequía agrícola, la generación de escorrentía y las inundaciones pluviales. Además, puede facilitar la evaluación de los impactos sobre la calidad del agua durante las estaciones lluviosas prolongadas, principalmente como resultado de las precipitaciones precedentes [30]. En terrenos montañosos, una previsión precisa de la humedad del suelo puede mejorar la predicción de la susceptibilidad a los movimientos de masas, ya que la dinámica de la humedad del suelo desempeña un papel esencial en la estabilidad de las laderas [31]. Una previsión precisa de la humedad del suelo puede contribuir a mejorar la predicción y previsión de movimientos en masa e incendios, y pueden alimentar los sistemas de alerta temprana de riesgos naturales [32].

Este estudio aborda los patrones espacio-temporales de la dinámica de la humedad del suelo en los Andes tropicales y analiza cómo las técnicas de aprendizaje automático basadas en datos, como las redes neuronales, pueden utilizarse eficazmente para predecir la dinámica de la humedad del suelo utilizando variables hidrometeorológicas e hidrológicas del suelo registradas sobre el terreno. Además, explora cómo la transferencia de conocimiento desde modelos previamente entrenados puede mejorar la precisión de la predicción de la humedad del suelo en varios puntos de monitorización dentro de regiones de alta montaña. Este estudio se llevó a cabo en una cuenca andina de alta altitud, Jatunhuayco, caracterizada por la actividad volcánica del Holoceno y suelos volcánicos poligenéticos profundos. En estos ambientes, la precipitación es altamente heterogénea, incluso en distancias pequeñas, como se muestra en Ruiz et al. [12]. El área de estudio forma parte del Área de Conservación Hídrica del Antisana, que abastece de agua a Quito, la capital de Ecuador. Investigaciones previas mostraron que la dinámica de la humedad del suelo varía con las propiedades del suelo y la cobertura vegetal [7,33] y que las condiciones hidrológicas pueden variar a distancias cortas como resultado de la diversidad pedológica y litológica [34]. La aplicación de modelos avanzados para la predicción de la humedad del suelo en un entorno geográfico desafiante puede arrojar resultados que pueden ser informativos para la gestión de los recursos hídricos y la mitigación de los impactos de eventos climáticos extremos dentro de estas regiones.

2. Área de estudio

Los sitios estudiados se encuentran dentro de la subcuenca JTU_01, que abarca un área de 0,7 km², ubicada en la vertiente occidental del volcán Antisana en los Andes del Norte de Ecuador, dentro del Área de Conservación Hídrica Antisana. Su elevación oscila entre 4083 y 4279 msnm y las pendientes fluctúan entre 10 y 22% [7,33]. La subcuenca Figura 1a es ecológica e hidrológicamente bien monitoreada y forma parte del ecosistema de páramo dentro del sistema La Mica Quito Sur. Este sistema es una fuente crucial de agua para más de medio millón de habitantes del Distrito Metropolitano de Quito [35]. El área es administrada por el Fondo de Protección del Agua (FONAG) de la ciudad [36]. Desde 2011, se han prohibido las actividades antropogénicas y el pastoreo extensivo para preservar el ecosistema.

Para comprender mejor la hidrología del suelo en suelos jóvenes de ceniza volcánica, se implementaron y monitorearon dos laderas experimentales en JTU_01. JTU_01 se equipó en el marco del proyecto páramoSUS, un esfuerzo de colaboración conjunta entre instituciones académicas ecuatorianas y belgas, EPMAPS-Q y FONAG. Las laderas controladas difieren únicamente en su cubierta vegetal dominante. Una está dominada por gramíneas (*Calamagrostis intermedia*) y la otra por plantas en cojín (*Azorella pedunculata*). Cada ladera constaba de cuatro posiciones de muestreo de agua del suelo, superior (UP), réplica superior (UR), media (MI) e inferior (LO). Se excavó un total de ocho perfiles de suelo a lo largo de las dos toposecuencias. Se identificaron cuatro horizontes de suelo (A, 2A, 2BC y 3BC) en la parte superior de cada perfil. En este estudio se analizaron los horizontes superiores A y 2A. Las toposecuencias de los dos tipos de cubierta vegetal analizados, teniendo en cuenta las curvas de nivel, pueden verse en la Figura 1a y con más detalle en Páez-Bimos et al. [33].

En la estación meteorológica JTU_AWS (Figura 1a), se registraron variables meteorológicas entre el 16 de octubre de 2018 y el 7 de octubre de 2022. La precipitación media anual fue de 2,1 mmd⁻¹, la temperatura del aire fue de 4,12° C, la radiación solar entrante fue de 138,01 Wm⁻², y la humedad relativa era del 93,72%. La profundidad de enraizamiento

alcanzó los 70 cm en los perfiles TU-UP y los 30 cm en los CU-UR. Los suelos del metro superior son Andosoles vítricos poligenéticos desarrollados sobre depósitos volcánicos del Holoceno [37]. Estos suelos recubren una secuencia de paleosuelos y capas de tefra de aproximadamente 27 m de espesor, que se sitúan sobre estratos ricos en escoria y sedimentos glaciofluviales [38].

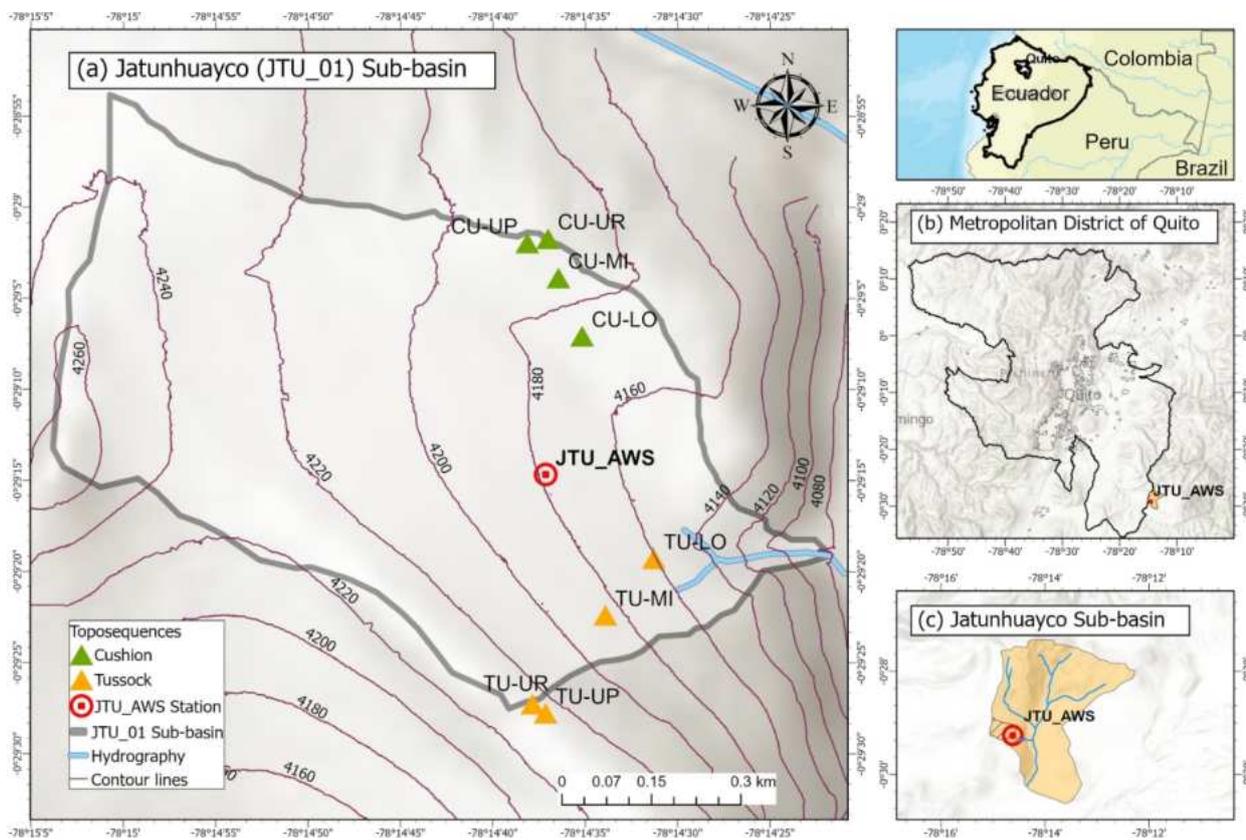


Figura 1. Localización del área de estudio en el norte de los Andes ecuatorianos. (a) Área de estudio con ubicación de los perfiles de suelo. (b) Ubicación del sitio de estudio en el Distrito Metropolitano de Quito. (c) Ubicación del área de estudio, JTU_01, dentro de la cuenca de Jatunhuayco.

3. Metodología

3.1. Recogida de datos

El cuadro 1 muestra la ubicación y descripción de los perfiles de suelo analizados dentro de la subcuenca Jatunhuayco, considerando las dos coberturas vegetales predominantes, *Azorella pedunculata* (CU-Cushion) y *Calamagrostis intermedia* (TU-Tussock). La tabla incluye la localización, altitud y pendiente del perfil del suelo; la cubierta vegetal dominante; y la profundidad de los dos horizontes superiores (A y 2A). En cada perfil de suelo se instalaron tres reflectómetros de dominio temporal (CS650, Campbell Scientific, Logan, UT, EE.UU.) para medir el contenido volumétrico de agua (θ) y la temperatura del suelo (T). Los reflectómetros se calibraron debidamente utilizando monolitos de suelo, y se establecieron las ecuaciones de calibración para los distintos horizontes. La precisión de las lecturas del contenido volumétrico de agua fue de $\pm 1\%$, debido a la calibración específica del suelo realizada en el laboratorio LEMSUR de la Escuela Politécnica Nacional [7].

La Tabla 2 resume las variables meteorológicas que se utilizaron en este estudio y proporciona información sobre los sensores ambientales utilizados para medir la precipitación, la temperatura del aire, la humedad relativa y la radiación solar en la estación meteorológica automática JTU_AWS. Las variables ambientales se registraron automáticamente con un intervalo de 5 min durante un periodo cercano a los 4 años, desde el 16 de octubre de 2018 hasta el 7 de octubre de 2022. La Tabla 2 menciona la precisión y el rango de medición de las variables. La información meteorológica fue validada siguiendo la metodología expuesta en [7].

Tabla 1. Localización de los perfiles de suelo, con descripción de las principales características del emplazamiento.

Perfil del suelo	Coordenadas	Altitud (m.a.s.l)	Pendiente (%)	Especies vegetales dominantes (%)	Horizonte Profundidad A (cm)	Horizonte Profundidad 2A (cm)
CU_UP	0°29'1.90" S / 78°14'38.15" W	4197	2.5	51.4 ± 23.6, <i>Azorella pedunculata</i>	8-30	30-60
CU_UR	0°29'1.69" S / 78°14'37.69" W	4196	2	78.4 ± 6.9, <i>Azorella pedunculata</i>	8-30	30-55
CU_MI	0°29'4.22" S / 78°14'36.51" W	4185	12	41.6 ± 34.8, <i>Azorella pedunculata</i>	8-32	32-70
CU_LO	0°29'6.89" S / 78°14'35.08" W	4174	10	54.2 ± 38.4, <i>Azorella pedunculata</i>	10-40	40-75
TU_UP	0°29'27.94" S / 78°14'37.07" W	4225	6.5	55.8 ± 21.6, <i>Calamagrostis intermedia</i>	5-30	30-60
TU_UR	0°29'26.99" S / 78°14'38.14" W	4227	10.5	15.3 ± 5.5, <i>Calamagrostis intermedia</i>	5-40	40-70
TU_MI	0°29'22.36" S / 78°14'34.01" W	4186	22	3.6 ± 9.9, <i>Calamagrostis intermedia</i>	5-27	27-70
TU_LO	0°29'19.08" S / 78°14'31.42" W	4161	20	83.9 ± 9.8, <i>Calamagrostis intermedia</i>	7-45	45-92

Nota 1: La especie de vegetación dominante se expresa con la media ± desviación estándar. Nota 2: Las coordenadas se dan en Datum WGS84.

Tabla 2. Información sobre las variables registradas en la estación JTU_AWS desde el 16 de octubre de 2018 hasta el 7 de octubre de 2022 con una frecuencia de registro de 5 min.

Sitio	Variable	Sensor	Precisión	Alcance
JTU_AWS	Precipitación	TE252MM	±1%	0 a 50 mmh ⁻¹
	Temperatura del aire	CS215	±0.9 °C	-40 a +70 °C
	Humedad relativa	CS215	±4%	0 a 100
	Radiación solar	CS300	±5 Wm ⁻²	0 a 2000 Wm ⁻²

Los datos hidrometeorológicos y ambientales auxiliares se utilizaron como datos de entrada para predecir la humedad del suelo. La figura 2 ilustra el marco metodológico general de la arquitectura de la red neuronal e incluye información sobre los conjuntos de datos de entrenamiento, validación y evaluación. Se implementaron técnicas de aprendizaje por transferencia para transferir conocimiento de un dominio específico a otro, de forma similar a como se hizo en Zhuang et al. [39]. De este modo, el conocimiento aprendido de la red base para, por ejemplo, pronosticar la humedad del suelo en la parte inferior del horizonte A (θ_{CU_LOA}) bajo vegetación de cojín, se aplicó después para pronosticar la humedad del suelo a otras profundidades y en otros sitios cubiertos por pastos tussock y vegetación de cojín con un dominio similar.

3.2. Análisis descriptivo de variables y preprocesamiento de datos

En esta fase se llevó a cabo un análisis detallado de las variables utilizadas en el estudio, junto con el preprocesamiento necesario para la posterior aplicación de redes neuronales. Se llevó a cabo un exhaustivo análisis descriptivo, que incluyó procedimientos de análisis visual y estadístico para comprender la naturaleza y distribución de los datos. Se generaron gráficos Violin plot para visualizar la distribución de las variables. Además, se calcularon estadísticas descriptivas como la media, la desviación estándar, los percentiles y otros indicadores relevantes para proporcionar una visión general de las características y variabilidades espaciotemporales presentes en los datos recogidos.

3.3. Modelos de redes neuronales artificiales

3.3.1. El perceptrón multicapa

El perceptrón multicapa, o red neuronal artificial, simula las neuronas biológicas como dispositivos computacionales [40]. Según Kelleher et al. [41], una neurona es la unidad más simple, y un grupo de neuronas alineadas forma una capa. Las neuronas y las capas se conectan -

asignándoles un peso w y una función de activación f , convirtiendo la red neuronal en una función de regresión lineal de múltiples entradas [41]. La red se representa analíticamente como el mapeo $\phi(X, \vartheta) \rightarrow y^{\wedge}$, donde ϑ representa hiperparámetros optimizados como el número de neuronas, capas ocultas, funciones de activación y pesos, con el objetivo de encontrar la representación más cercana de la variable objetivo $Y = y_0, \dots, y_j$ dado un conjunto de entradas $X = \{x_0, \dots, x_n\}$ [42]. Visualmente, esto se muestra en la Figura 3.

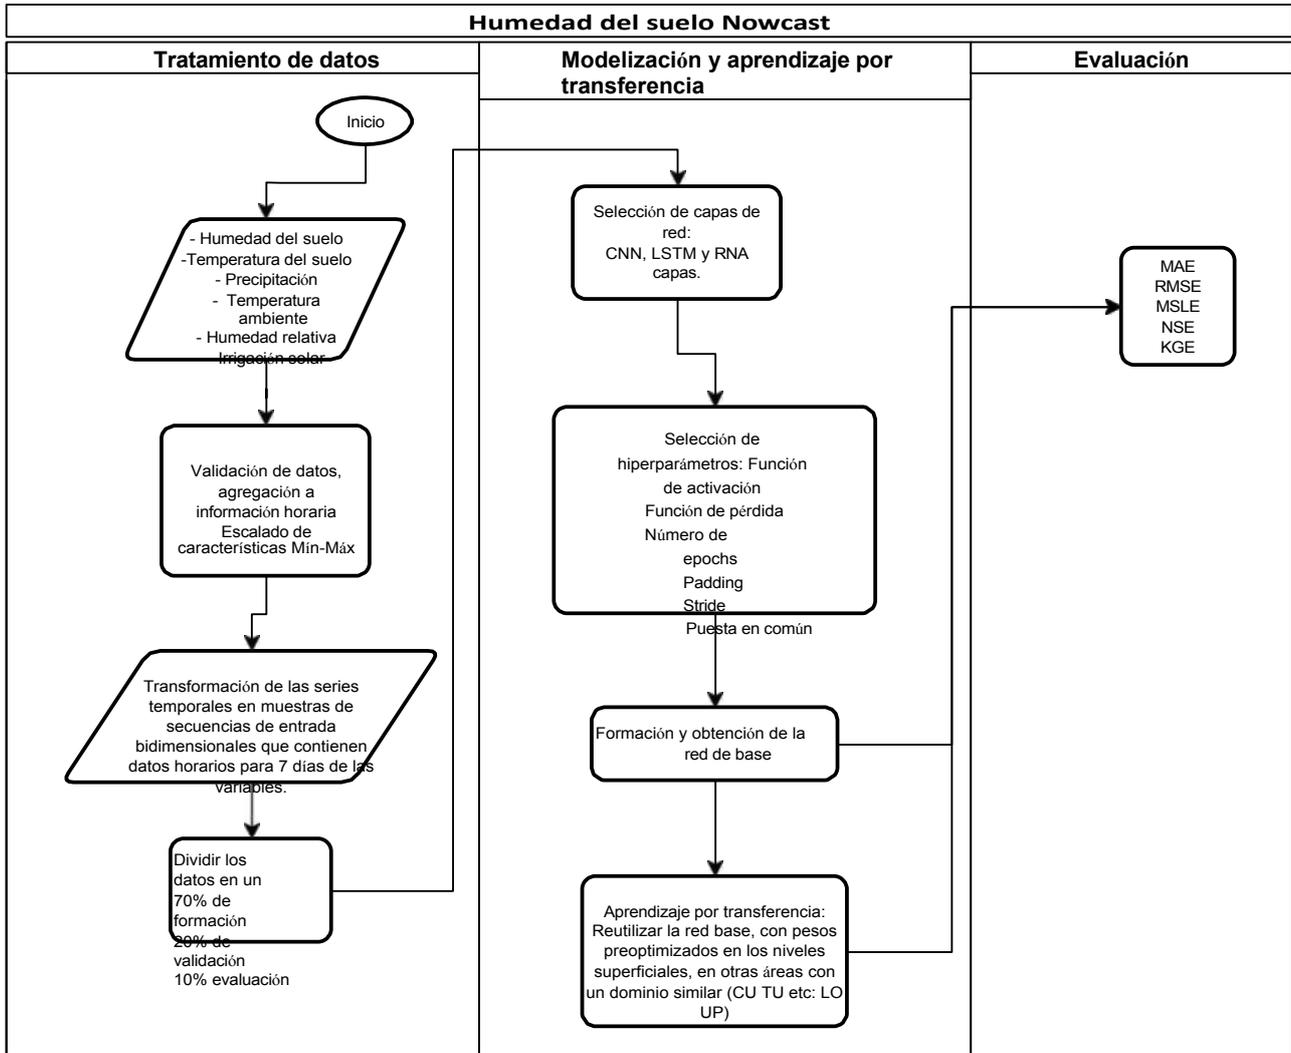


Figura 2. Diagrama de flujo para la predicción de la humedad del suelo mediante redes neuronales Diagrama de flujo de la predicción de la humedad del suelo mediante redes neuronales.

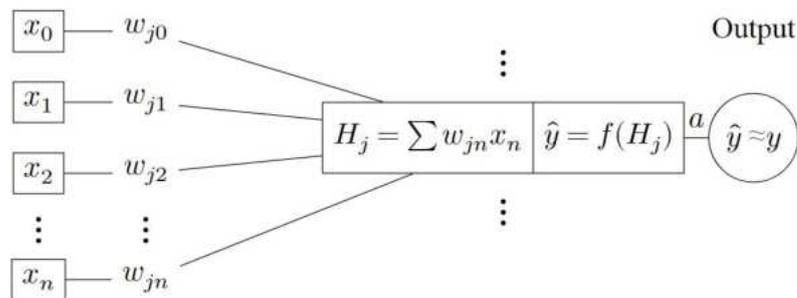


Figura 3. Representación básica de una red neuronal Representación básica de una red neuronal.

3.3.2. Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN) están especializadas en el procesamiento de datos con topología similar a la de una malla y se utilizan habitualmente en tareas de visión por ordenador como el reconocimiento de imágenes [42]. La operación de convolución se define como $s(t) = \sum_a I(a) * \kappa(t - a)$ para entradas 1-D y $s(t) = \sum_a \sum_b I(a, b) * \kappa(m - a, n - b)$ para entradas 2-D, donde $I(t)$ es la entrada, y $\kappa(a)$ es el núcleo. Las CNN utilizan un núcleo (filtro) que se desliza sobre los valores de entrada para realizar operaciones, produciendo un mapa de características [40]. Goodfellow et al. [42] mencionan que las CNN incluyen capas de agrupación o detección, que utilizan funciones estadísticas como la media, el máximo o el mínimo para las representaciones internas de entradas específicas, como se ilustra en la Figura 4.

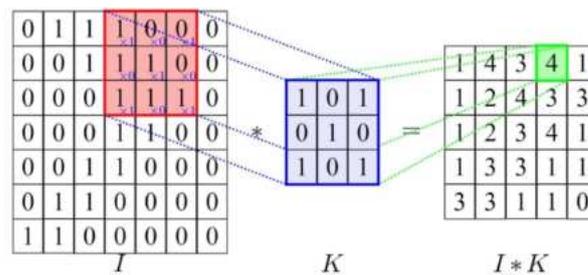


Figura 4. Representación bidimensional de una convolución. El deslizamiento o zancada K del kernel es un paso sobre la matriz de entrada I. El resultado I*K es el mapa de características, es decir, el producto elemento a elemento de los elementos.

3.3.3. Redes de memoria a largo plazo

Según Sit et al. [43], las redes de memoria a corto plazo (LSTM) abordan el problema del gradiente de fuga y constan de un estado c_t y tres "puertas": olvido, entrada y salida. Antes de pasar por las puertas, el valor de entrada x_t se combina con el valor de la neurona anterior h_{t-1} en un vector v . La puerta de olvido está formada por el vector v y una función sigmoide σ , lo que da como resultado f_t . La puerta de entrada está formada por el vector v , una función sigmoide σ y una función tangente hiperbólica \tanh , lo que da como resultado i_t . El estado c_t se obtiene utilizando C_{t-1} , f_t , i_t , y c_{t-1} , dando como resultado c_t . Finalmente, la puerta de salida se obtiene usando el vector v , o_t , y c_t , resultando en h_t , como se muestra en la Figura 5.

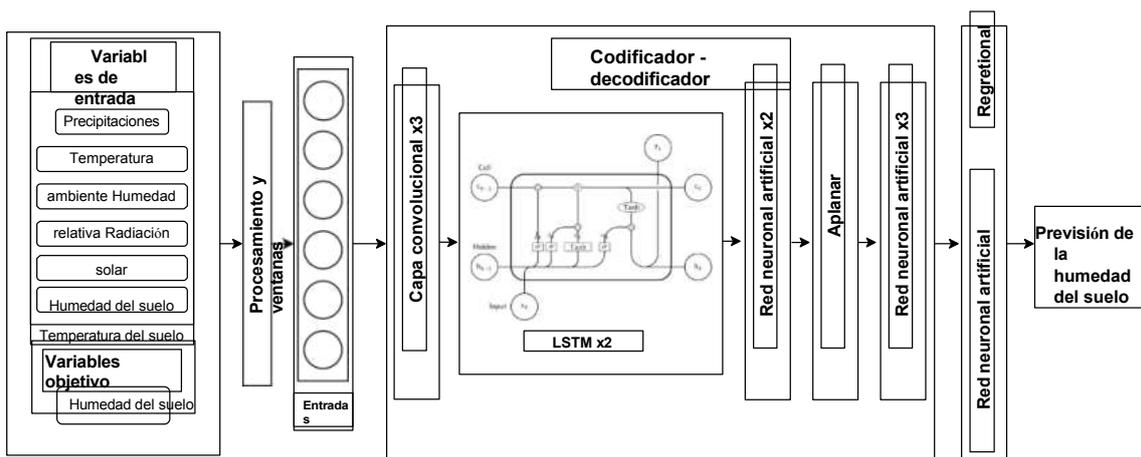


Figura 5. Arquitectura de la red neuronal: predicción de la humedad del suelo para las 48 h siguientes a partir de la información de los 7 días anteriores. Red base desarrollada para el perfil del suelo bajo plantas formadoras de cojines en la posición de la catena del suelo (*bcu_loa*).

3.3.4. Aprendizaje por transferencia

El aprendizaje por transferencia utiliza estructuras preentrenadas, lo que reduce los recursos y el tiempo necesarios para entrenar nuevos modelos. Su objetivo es mejorar la precisión aprovechando el conocimiento de dominios relacionados [39]. También evita problemas como el sobreajuste mediante la generalización de características útiles [44]. El aprendizaje profundo por transferencia explora el uso del conocimiento a través de redes neuronales y tiene cuatro vertientes

categorías: basado en instancias, basado en mapas, basado en redes y basado en adversarios [44]. Este trabajo empleó el aprendizaje por transferencia basado en redes, reutilizando redes neuronales preentrenadas en distintos dominios para mejorar el rendimiento.

3.4. Diseño y aplicación de la arquitectura de redes neuronales

3.4.1. Preprocesamiento de datos

Durante las etapas de preprocesamiento de datos, una de las técnicas más utilizadas es la normalización de datos, que se lleva a cabo mediante la siguiente ecuación:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

donde X es la variable original, X_{min} es el valor mínimo de X , y X_{max} es el valor máximo de X . Esta operación escala los valores de X en el rango entre 0 y 1. La red neuronal que se desarrolló para la previsión de la humedad del suelo (Figura 5) consiste en una arquitectura profunda que aprovecha las características de las redes neuronales convolucionales, las redes de memoria a largo plazo y las redes neuronales artificiales. La ventaja de combinar estas redes es la utilización de nuevas representaciones generadas por las capas convolucionales, el aprendizaje a partir de los patrones temporales captados por las capas de memoria a largo plazo y la aproximación de los valores de humedad del suelo mediante el mapeo generalizado de las capas de redes neuronales artificiales. Además, para realizar operaciones sólo dentro del segmento temporal de los datos y evitar interacciones aleatorias entre diferentes pasos temporales y canales, se utilizó una envoltura distribuida temporalmente. Esta envoltura se aplica sobre otra capa de la red neuronal, lo que permite compartir los parámetros de la capa de memoria a corto plazo a lo largo de todos los pasos temporales. Esto ayuda a la red neuronal a procesar secuencias de distintas longitudes de forma más eficiente y eficaz [43].

3.4.2. Configuración de la red neuronal base y el aprendizaje profundo por transferencia

Para el desarrollo de la red de base y su arquitectura, seleccionamos al azar uno de los sitios para los que se disponía de datos empíricos sobre la humedad del suelo, es decir, el perfil del suelo situado en la posición de pie de ladera en la catena del suelo bajo plantas formadoras de cojines ϑ_{CU_LOA} [33]. Como todos los sitios tenían una excelente cobertura de datos en el sitio experimental, cualquier sitio podría haber sido considerado para la construcción del modelo base. La red pronosticó la humedad del suelo para las siguientes 48 h basándose en los registros horarios de P , T , HR , RS y ϑ_{CU_LOA} , así como en los datos de humedad del suelo T_{CU_LOA} de los siete días anteriores; véase la Figura 5.

Una vez entrenado el modelo, se obtuvo la red base para pronosticar ϑ_{CU_LOA} . Posteriormente, se empleó el aprendizaje profundo por transferencia basado en la red, que consistió en reutilizar la red con pesos ya optimizados en los niveles superficiales para entrenarla con información de niveles más profundos; véase la Figura 6. Este proceso permitió predecir la humedad del suelo en horizontes más profundos (A y 2A) y en otras posiciones topográficas (LO, MI, UP, UPR) y coberturas vegetales (CU, TU). Por ejemplo, la red de base entrenada para la predicción de la humedad del suelo bajo plantas formadoras de cojines, ϑ_{CU_LOA} , se utilizó después para informar a la red de predicción de la humedad del suelo en el horizonte 2A de los suelos en la posición de la pendiente superior bajo pastos tussock, ϑ_{TU_UR2A} .

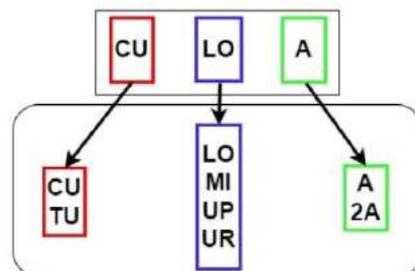


Figura 6. Aprendizaje de transferencia para dominios similares Aprendizaje de transferencia de conocimientos para la previsión de la humedad del suelo en 15 condiciones diferentes. Los códigos se refieren a distintos tipos de cubierta vegetal .

(CU = plantas formadoras de cojines; TU = hierbas de tussock), posición topográfica (LO = ladera al pie; MI = ladera media; UP = ladera superior; UPR = réplica en posición de ladera superior) y horizonte del suelo (A y 2A).

3.5. Entrenamiento de los hiperparámetros de la red

Durante el proceso de entrenamiento, se realizaron los siguientes ajustes en los hiperparámetros cruciales para garantizar un rendimiento óptimo de la red neuronal. En cuanto a las funciones de activación, se utilizaron la función unitaria lineal rectificadora, la tangente hiperbólica y las funciones sigmoidea o logística.

La función de unidad lineal rectificadora (ReLU)

$$f(x) = \max(x, 0)$$

se eligió por su capacidad para permitir la salida de valores positivos, mitigando eficazmente el problema del gradiente evanescente y facilitando una convergencia más rápida durante el entrenamiento. Para limitar la salida entre -1 y 1, se utilizó la función tangente hiperbólica (tanh), ya que la función tanh

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

ofrece gradientes suaves y ayuda a la convergencia, lo que resulta especialmente adecuado para las distribuciones de datos de nuestros datos hidrometeorológicos. La función sigmoidea o logística,

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

operar dentro de un rango de 0 a 1 se emplea habitualmente para tareas de clasificación binaria y nos permitió aplastar los valores de entrada a un rango probabilístico.

Para la función de pérdida y la evaluación del rendimiento del modelo, se empleó el error cuadrático medio (MSE). El MSE

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

cuantifica la diferencia cuadrática media entre los valores predichos (\hat{y}_i) y los observados (y_i) y proporciona una medida exhaustiva del rendimiento del modelo.

Se empleó el algoritmo de optimización de la tasa de aprendizaje adaptativo (ADAM) para optimizar los pesos de la red con los siguientes parámetros:

Tasa de aprendizaje = 0,005,

$$\begin{aligned} \beta_1 &= 0,9, \\ \beta_2 &= 0,999, \\ \epsilon &= 1 \times 10^{-7} \end{aligned} \tag{1}$$

donde β_1 y β_2 representan tasas de decaimiento exponencial para el primer y segundo momento estimados, y ϵ asegura la estabilidad numérica.

Además, el modelo aplicó un relleno uniforme alrededor de los datos de entrada para mantener las dimensiones espaciales de las capas convolucionales. Garantizar unas dimensiones de salida coherentes es especialmente importante para preservar el tamaño del mapa de características tras la convolución. El paso representa el movimiento de la ventana del filtro a través de los datos de entrada durante la convolución. En este caso se utilizó un intervalo de (3, 3) para permitir un movimiento horizontal y vertical de tres píxeles, lo que influye en las dimensiones de salida de las capas posteriores.

Para reducir la complejidad computacional y conservar al mismo tiempo la información esencial, se redujo el tamaño de los mapas de características mediante la técnica de pooling. En este caso, aplicamos un tamaño de pooling de (2, 2), lo que implica una reducción de la muestra mediante una ventana de 2×2 , seleccionando el valor máximo o medio para reducir las dimensiones espaciales pero conservando las características significativas.

3.6. Modelo de medidas de rendimiento

Para evaluar el rendimiento de los modelos de predicción de la humedad del suelo (ϑ), utilizamos cinco métricas de evaluación para conocer la precisión y fiabilidad de las predicciones de los modelos. A continuación, enumeramos cinco medidas de rendimiento ampliamente adoptadas con sus descripciones:

- Error absoluto medio (MAE): Mide la diferencia absoluta media entre los valores predichos ($\hat{\vartheta}_i$) y observados (ϑ_i).

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{\vartheta}_i - \vartheta_i| \tag{2}$$

- Error cuadrático medio (RMSE): Proporciona una estimación de la desviación estándar de los residuos, indicando la magnitud media del error.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{\vartheta}_i - \vartheta_i)^2} \tag{3}$$

- Error logarítmico cuadrático medio (MSLE): Similar al MSE, pero especialmente útil cuando las variables objetivo varían en varios órdenes de magnitud.

$$\text{MSLE} = \frac{1}{n} \sum_{i=1}^n \left(\log(\hat{\vartheta}_i + 1) - \log(\vartheta_i + 1) \right)^2 \tag{4}$$

- Eficacia de Nash-Sutcliffe (NSE): Mide el poder predictivo del modelo comparando las diferencias al cuadrado entre los valores observados y predichos con las diferencias al cuadrado entre los valores observados y medios.

$$\text{NSE} = 1 - \frac{\sum_{i=1}^n (\hat{\vartheta}_i - \vartheta_i)^2}{\sum_{i=1}^n (\vartheta_i - \bar{\vartheta})^2} \tag{5}$$

- Eficiencia de Kling-Gupta (KGE): Índice que combina correlación, ratio de sesgo y ratio de variabilidad para evaluar el rendimiento global del modelo.

$$\text{KGE} = 1 - \frac{q}{(r - 1)^2 + (s - 1)^2 + (b - 1)^2} \tag{6}$$

donde r es el coeficiente de correlación, s es la relación entre la desviación típica de los valores simulados y los observados, y b es la relación entre la media de los valores simulados y los observados.

Estas métricas y sus correspondientes ecuaciones ofrecían un medio completo de evaluar el rendimiento del modelo en la predicción de los niveles de humedad del suelo.

4. Resultados

4.1. Datos de observación sobre el tiempo, la temperatura y la humedad del suelo

4.1.1. Análisis descriptivo de datos meteorológicos

La estación meteorológica automática JTU_AWS (véase la Figura 1) lleva recopilando datos meteorológicos con una frecuencia de cinco minutos desde 2018 para las siguientes variables: precipitación, temperatura del aire, humedad relativa, radiación solar, presión barométrica, velocidad y dirección del viento. En la Figura 7, los gráficos de violín proporcionan una visión de la distribución de frecuencias de las variables analizadas.

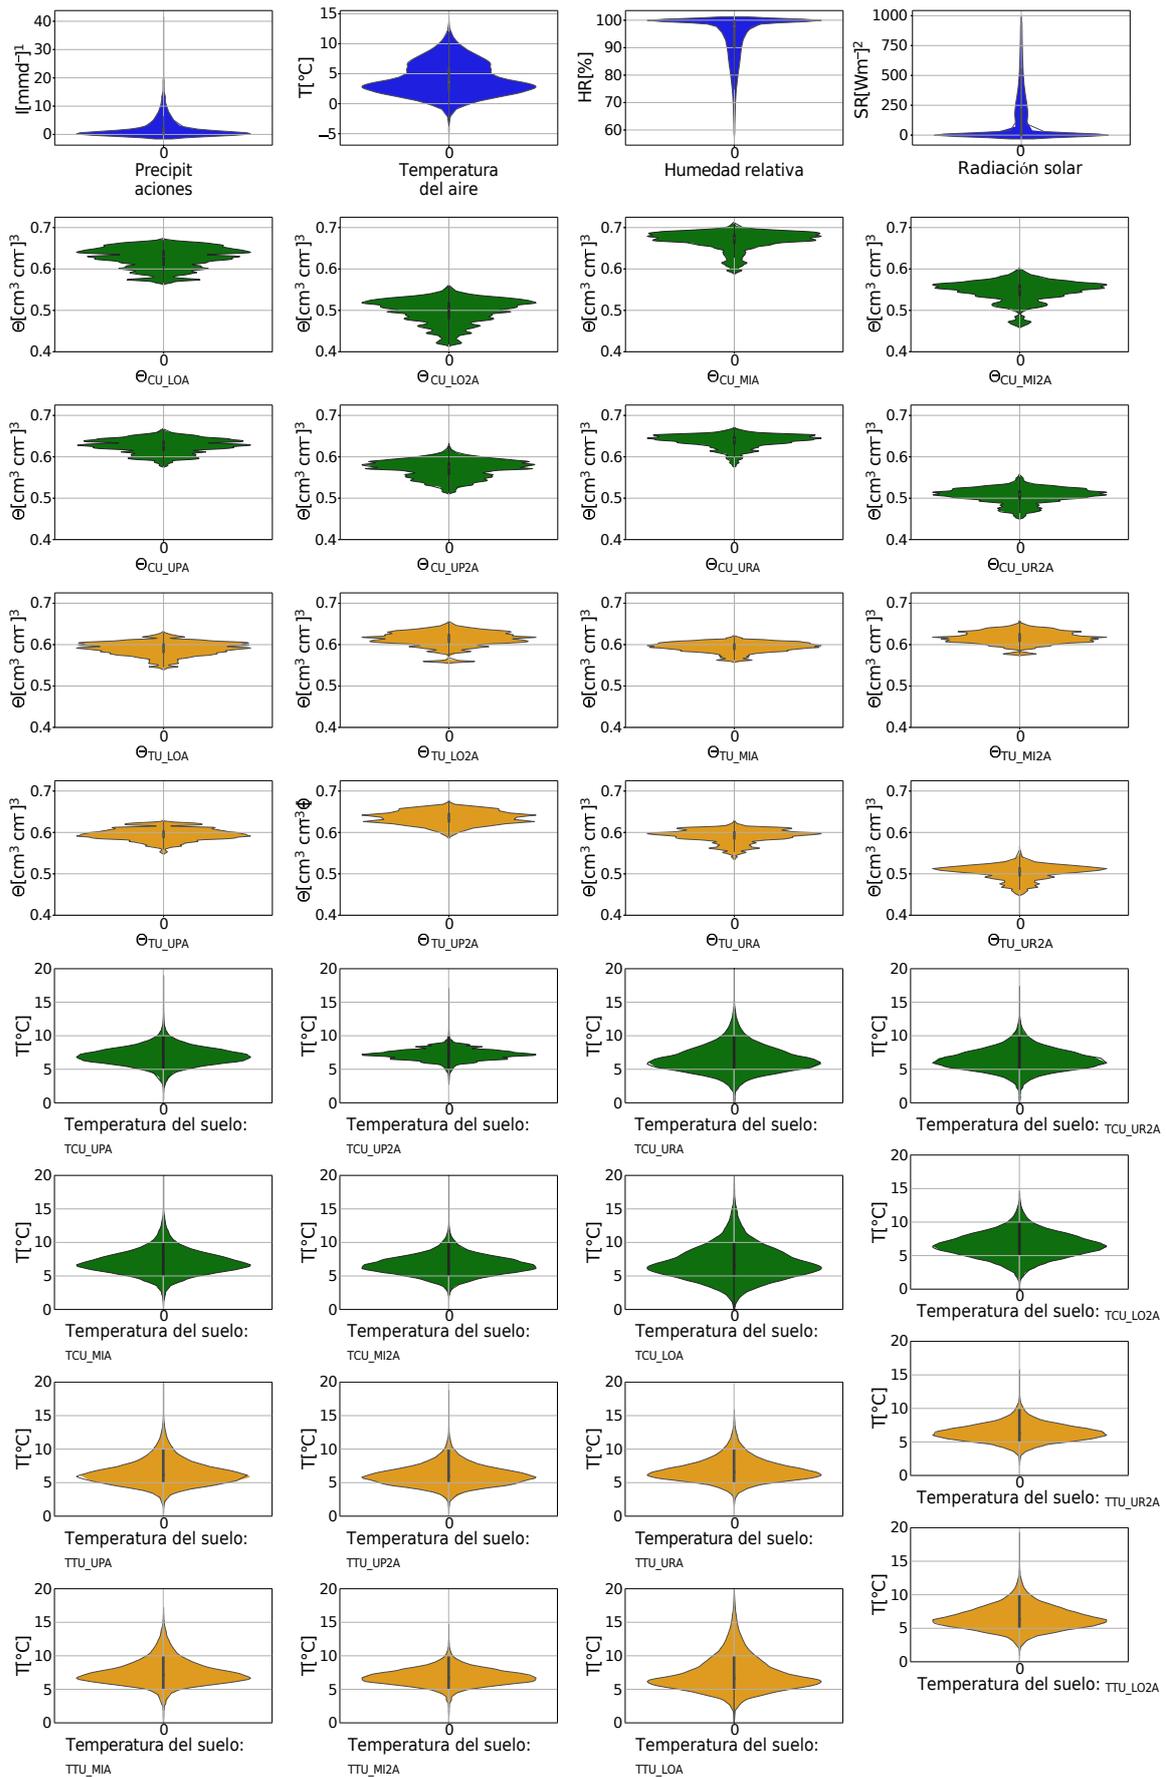


Figura 7. Gráficas de Violin de variables meteorológicas en la estación JTU_AWS y variables de suelo en Jatunhuayco JTU_01.

4.1.2. Análisis descriptivo de la temperatura del suelo

Para una breve descripción de la temperatura del suelo en los horizontes A y 2A de los dos tipos de suelo, *Azorella pedunculata* y *Calamagrostis intermedia*, en los perfiles analizados de UP, UR, MI y LOM se presentan las Tablas 3 y 4, junto con gráficas de violín en las filas 6 a 9 de la Figura 7, que ilustran el comportamiento de esta variable.

Tabla 3. Descripción estadística de la temperatura del suelo ($^{\circ}C$) en los perfiles A y 2A, para la vegetación en cojín.

	TCU_{UPA}	TCU_{UP2A}	TCU_{URA}	TCU_{UR2A}	TCU_{MIA}	TCU_{M2A}	TCU_{LOA}	TCU_{LO2A}
media	7	7.21	6.55	6.44	7.06	6.62	6.96	6.6
std	1.37	0.86	1.94	1.61	1.77	1.46	2.47	1.83
min	0.76	2.9	0	0.01	0.6	1.83	0.01	0.22
max	18.76	16.9	23.6	17.1	23.4	20.9	19.4	14.3
$d(P_{25}, P_{75})$	1.67	1.07	2.38	2.01	2.1	1.84	3.1	2.37

Nota. $d(P_{25}, P_{75})$ -diferencia entre los valores de temperatura del suelo en el percentil 25 y su correspondiente percentil 75.

Tabla 4. Descripción estadística de la temperatura del suelo ($^{\circ}C$) en los perfiles A y 2A, en vegetación de tussock.

	TCU_{UPA}	TCU_{UP2A}	TCU_{URA}	TCU_{UR2A}	TCU_{MIA}	TCU_{M2A}	TCU_{LOA}	TCU_{LO2A}
media	6.48	6.1	6.86	6.41	7.54	6.86	7.27	6.59
std	1.82	1.51	1.68	1.31	1.89	1.22	2.56	1.7
min	0.79	0.74	1.79	1.81	0.39	1.11	0.34	1.21
max	20.9	18.5	15.57	15.56	16.91	14.45	20.9	19
$d(P_{25}, P_{75})$	2.1	1.88	1.96	1.64	2.1	1.52	2.94	2.15

Nota. $d(P_{25}, P_{75})$ -diferencia entre los valores de temperatura del suelo en el percentil 25 y su correspondiente percentil 75.

Bajo vegetación formadora de cojines, la temperatura media del horizonte superior del suelo A tuvo un rango de $[6,55 < T_{CU_A} < 7,06]^{\circ}C$, mientras que para el horizonte subyacente 2A, tuvo un rango de $[6.44 < T_{CU_2A} < 7.21]^{\circ}C$. Bajo los pastos tussock, la temperatura media en el horizonte A fluctuó entre $[6.48 < T_{TU_A} < 7.54]^{\circ}C$, mientras que para el horizonte 2A, tuvo un rango de $[6.1 < T_{TU_2A} < 6.86]^{\circ}C$. Independientemente de la cubierta vegetal y de la posición topográfica, la temperatura media en el horizonte A fue superior a la del horizonte 2A, con la única excepción del horizonte A del suelo en la posición superior de la ladera bajo vegetación amortiguadora, donde la temperatura media en el horizonte A fue de $7^{\circ}C$, mientras que en el 2A alcanzó $7,21^{\circ}C$. Este resultado puede atribuirse a la exposición del lugar, dada su ubicación en una cumbre barrida por el viento, donde las velocidades del viento son elevadas.

En todos los perfiles, la diferencia entre los valores de temperatura en el percentil 25 y su correspondiente percentil 75, definida como $d(P_{25}, P_{75})$, fue mayor para el horizonte superior A que para el horizonte subyacente 2A. Por ejemplo, la diferencia para TCU_{UPA} fue de $1,67^{\circ}C$, y para el horizonte subyacente TCU_{UP2A} , fue de sólo $1,07^{\circ}C$. Esto indica que existe una mayor variación en los valores de temperatura en el horizonte superior del suelo A en comparación con el 2A, y este patrón se mantuvo en todos los casos. Esto confirma que, al aumentar la profundidad del suelo, éste es propenso a sufrir menos factores externos que influyan en la variación de la temperatura. Además, la desviación estándar (*std*) siguió un patrón similar, confirmando esta observación.

4.1.3. Análisis descriptivo de la humedad del suelo

Una descripción de la humedad del suelo puede observarse en las tablas 5 y 6 y en las parcelas de violín de las filas 2 a 5 de la figura 7. Los valores medios de humedad del suelo bajo la vegetación almohadillada en los horizontes superiores A fueron siempre superiores a los del horizonte subyacente 2A. Además, los primeros valores fueron superiores a los valores medios de humedad del suelo bajo la vegetación de tussock en ambos horizontes A y 2A. Bajo la vegetación de tussock, no se observó una tendencia general clara en la humedad del suelo con la profundidad, aunque los horizontes A eran más secos que los horizontes 2A en las posiciones de pendiente media y de pie de ladera, y se produjo el patrón opuesto en las posiciones de pendiente superior.

Tabla 5. Descripción estadística de la humedad del suelo (%) en los perfiles A y 2A, para la vegetación en cojín.

	θ_{CU_LOA}	θ_{CU_LO2A}	θ_{CU_M1A}	θ_{CU_M2A}	θ_{CU_UPA}	θ_{CU_UP2A}	θ_{CU_URA}	θ_{CU_UR2A}
media	0.63	0.5	0.67	0.55	0.63	0.57	0.64	0.51
std	0.03	0.03	0.02	0.03	0.02	0.02	0.02	0.02
min	0.57	0.42	0.59	0.46	0.58	0.51	0.58	0.45
max	0.67	0.56	0.71	0.6	0.67	0.63	0.67	0.56

Nota. $d(P_{25}, P_{75})$ -diferencia entre los valores de temperatura en el percentil 25 y su correspondiente percentil 75.

Tabla 6. Descripción estadística de la humedad del suelo (%) en los perfiles A y 2A, para la vegetación de tussock.

	θ_{CU_LOA}	θ_{CU_LO2A}	θ_{CU_M1A}	θ_{CU_M2A}	θ_{CU_UPA}	θ_{CU_UP2A}	θ_{CU_URA}	θ_{CU_UR2A}
media	0.59	0.61	0.59	0.62	0.6	0.64	0.59	0.5
std	0.02	0.02	0.01	0.01	0.01	0.02	0.02	0.02
min	0.54	0.56	0.56	0.57	0.55	0.16	0.54	0.16
max	0.63	0.66	0.62	0.66	0.63	0.68	0.63	0.56

Nota. $d(P_{25}, P_{75})$ -diferencia entre los valores de temperatura en el percentil 25 y su correspondiente percentil 75.

4.2. Predicción de la humedad del suelo con técnicas de redes neuronales

4.2.1. Desarrollo de la red neuronal de base

La técnica de aprendizaje por transferencia, que aprovechó los conocimientos de un modelo preentrenado para aplicarlo a otro con un dominio similar, arrojó resultados con errores del orden de $1 \times 10^{-6} < \epsilon < 1 \times 10^{-3}$. Para los datos de entrenamiento, la previsión de la red base demostró unos resultados excelentes, con la métrica de error de menor magnitud RMSE igual a $4,77 \times 10^{-6}$, y NSE y KGE iguales ambos a 0,97.

Durante el entrenamiento de la red neuronal base utilizada para pronosticar los valores de humedad del suelo para las siguientes 48 h basándose en la información de los siete días anteriores, la función de pérdida encontró un mínimo local entre las épocas 100 y 150, como se muestra en la Figura 8a. Sin embargo, al ser una red profunda, continuó optimizándose lentamente hasta la época 300, como se muestra en la Figura 8b.

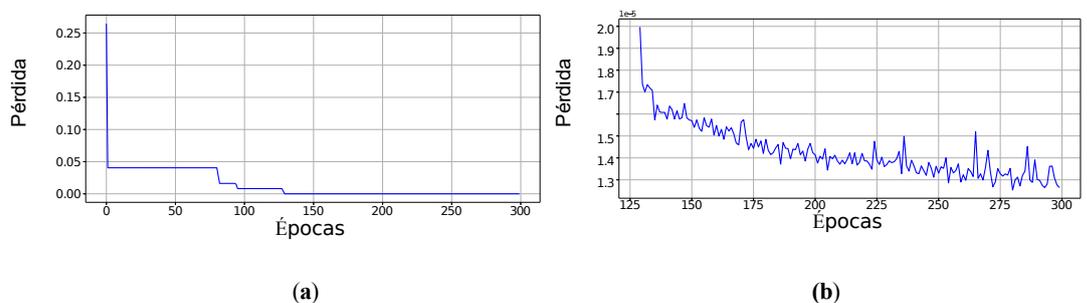
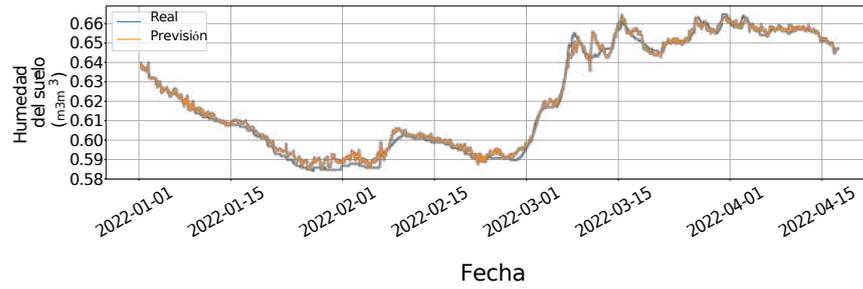


Figura 8. Función de pérdida de la red de previsión de 48 h de θ_{CULOA} dada la información horaria de P , T , HR , θ_{CULOA} y TCU_{LOA} durante siete días. (a) Valor de la función de pérdida durante el entrenamiento. (b) Zoom del valor de la función de pérdida después de 127 épocas.

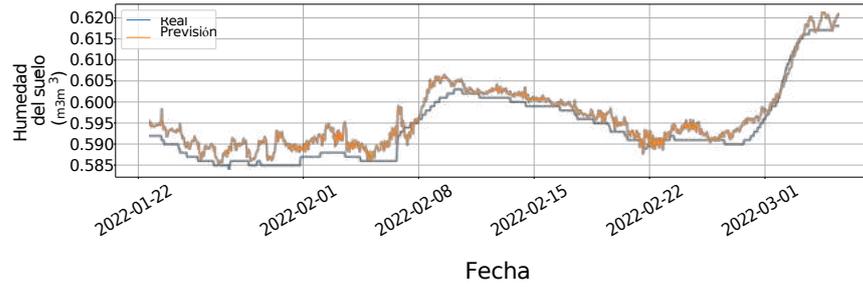
4.2.2. Red de Base para la Previsión de la Humedad del Suelo del Horizonte A en la Posición Topográfica del Pie de Talud

Presentamos aquí los resultados de la red de base que predijo la humedad del suelo del horizonte A en la zona inferior (LO) bajo plantas formadoras de cojines (θ_{CU_LOA}). Las variables de entrada para la predicción incluyeron datos horarios de precipitación, temperatura del aire, humedad relativa y radiación solar, junto con datos de humedad y temperatura del suelo del sitio de los 7 días anteriores. Además, proporcionamos una evaluación de la red base, considerando los conjuntos de datos de entrenamiento, validación y evaluación.

En la Figura 9a, se presenta la previsión de 48 h de θ_{CU_LOA} para la red que tomó como entrada siete días de variables ambientales horarias incluyendo P , T , HR , RS , θ_{CU_LOA} , y TCU_{LOA} para el conjunto de datos de evaluación. La figura 9b ofrece una vista detallada de la previsión incluida en la figura 9a con información del 22 de enero de 2022 al 4 de marzo de 2022. La Figura 10a-d muestra las previsiones para cuatro puntos temporales diferentes de la serie de evaluación θ_{CU_LOA} .

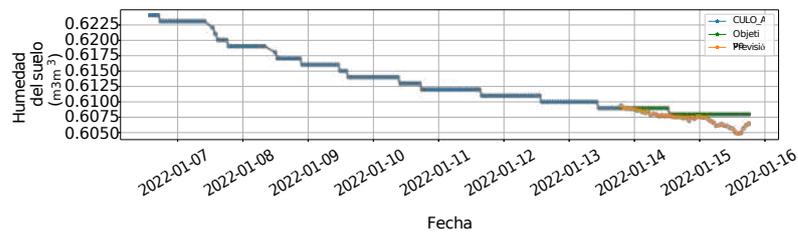


(a)

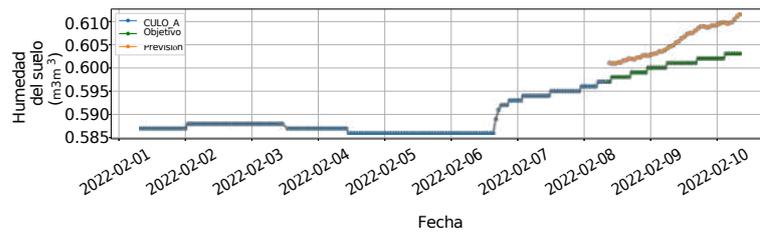


(b)

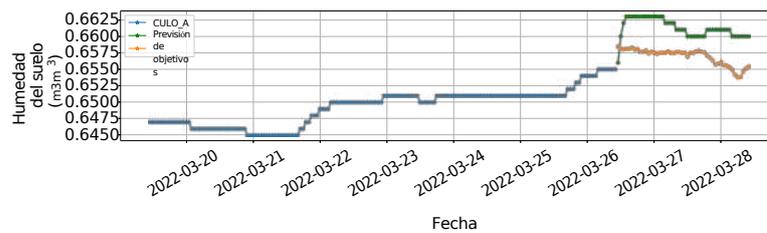
Figura 9. Previsión de 48 h de θ_{CU_LOA} para el conjunto de datos de evaluación compuesto por datos horarios de 7 días de P , T , HR , RS , θ_{CU_LOA} y TCU_LOA . (a) Previsión para el conjunto de datos de evaluación. (b) Ampliación de la subfigura (a) del 22 de enero de 2022 al 4 de marzo de 2022.



(a)

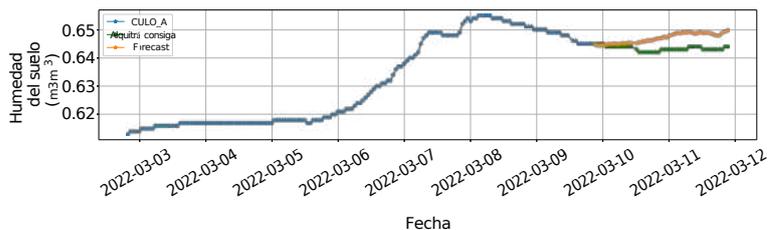


(b)



(c)

Figura 10 Cont.



(d)

Figura 10. Previsión para distintos momentos de la serie de evaluación $\theta_{CU_{LOA}}$. (a) Previsión de la serie de evaluación a 14 de enero de 2022. (b) Previsión de la serie de evaluación a 8 de febrero de 2022. (c) Previsión de la serie de evaluación a 26 de marzo de 2022. (d). Previsión de la serie de evaluación a 9 de marzo de 2022.

La red base evaluada fue capaz de predecir $\theta_{CU_{LOA}}$ para las próximas 48 h, utilizando las variables ambientales P , T , HR , RS , $\theta_{CU_{LOA}}$, y $T_{CU_{LOA}}$ de los siete días anteriores. En cuanto a las métricas de evaluación del rendimiento, como se muestra en la Tabla 7, la función de pérdida utilizada durante el entrenamiento de la red alcanzó un valor mínimo de $1,26 \times 10^{-6}$ en el conjunto de entrenamiento. En cuanto a la precisión de la predicción de $\theta_{CU_{LOA}}$, la red base mostró un error medio absoluto (MAE) de 0,0025, un error cuadrático medio (RMSE) de 0,0036 y un error logarítmico cuadrático medio (MSLE) de $4,77 \times 10^{-6}$ en el conjunto de entrenamiento. En general, estos resultados indican que la red base evaluada funcionó bien en el conjunto de entrenamiento, pero no tan bien en los conjuntos de validación y evaluación, lo que sugiere un ligero grado de sobreajuste a los datos de entrenamiento. Además, se observó que la capacidad de la red para ajustarse a los valores reales variaba en función de la métrica utilizada y del conjunto de datos evaluado.

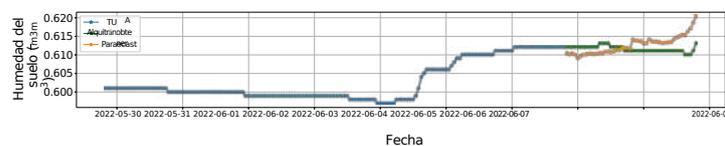
Tabla 7. Resultados métricos obtenidos para la red base que predice 48 h de $\theta_{CU_{LOA}}$, dados P , T , HR , RS , $\theta_{CU_{LOA}}$, y $T_{CU_{LOA}}$ datos de siete días.

	Formación	Validación	Evaluación
Pérdida	$1,26 \times 10^{-6}$	$2,03 \times 10^{-5}$	$2,54 \times 10^{-5}$
MAE	0.0025	0.0033	0.0039
RMSE	0.0036	0.0045	0.005
MSLE	$4,77 \times 10^{-6}$	$7,47 \times 10^{-6}$	$9,59 \times 10^{-6}$
NSE	0.97	0.89	-21.4
KGE	0.97	0.94	0.87

4.2.3. Aplicación de la Red Base para la Predicción de la Humedad del Suelo bajo Pasto Tussock Utilizando el Aprendizaje por Transferencia

En esta sección se presentan los resultados de la aplicación de las técnicas de aprendizaje por transferencia en tareas similares, incluidas las previsiones y la evaluación de los resultados con las métricas establecidas en la metodología. A partir del conocimiento adquirido de la red base y mediante el uso de técnicas de transferencia-aprendizaje, se han realizado previsiones de humedad del suelo para 48 h.

realizados para $\theta_{TU_{UPA}}$, $\theta_{TU_{UP2A}}$, $\theta_{TU_{URA}}$, $\theta_{TU_{UR2A}}$, $\theta_{TU_{MIA}}$, $\theta_{TU_{MI2A}}$, $\theta_{TU_{MIA}}$, $\theta_{TU_{LOA}}$ y $\theta_{TU_{LO2A}}$ Figura 11a-h. Los modelos utilizaron como entrada la información horaria de los 7 días anteriores, utilizando el mismo dominio que la red de base: P , T , HR , RS , θ_{TU} , y T_{TU} .



(a)

Figura 11 Cont.

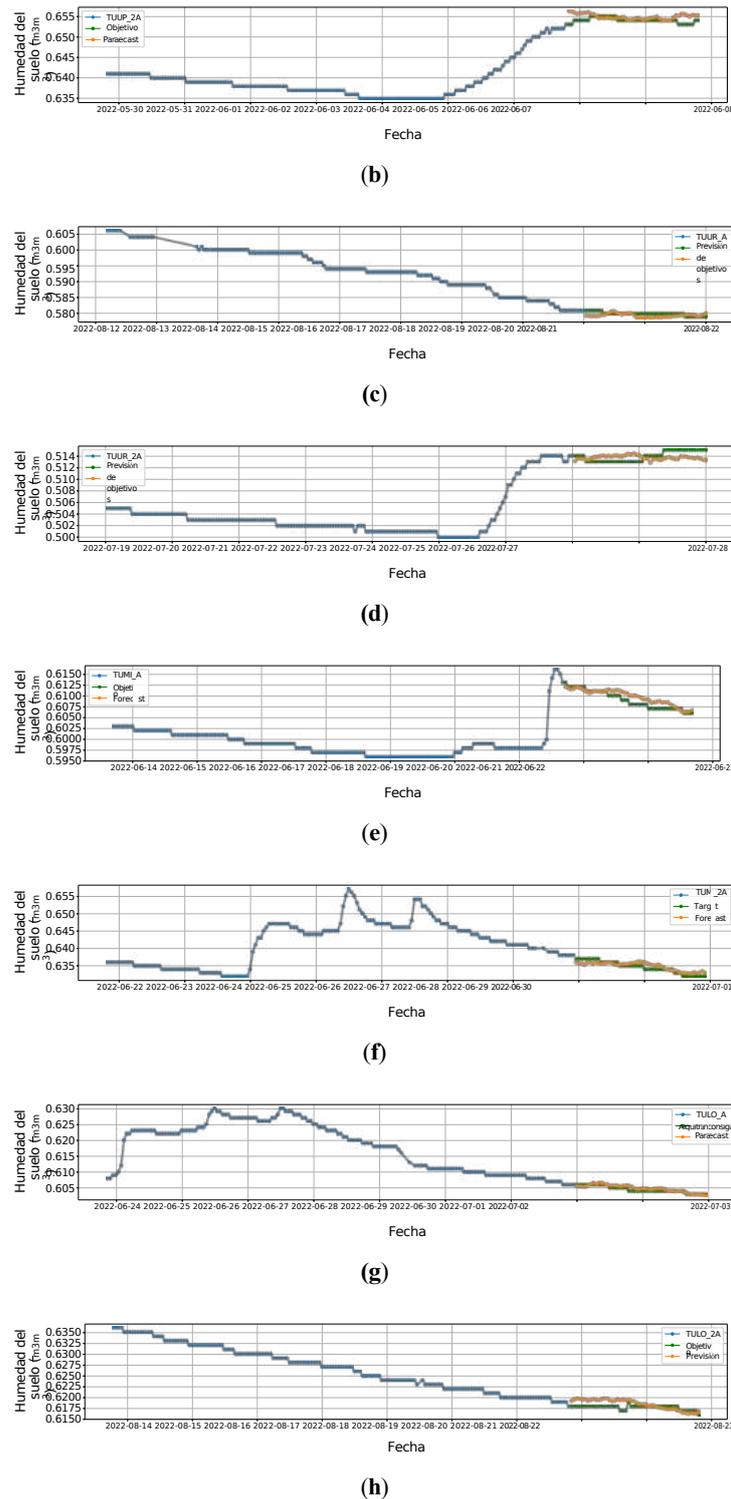


Figura 11. Previsiones de la humedad del suelo bajo pastos tussock θ_{TU} para diferentes posiciones topográficas y horizontes del suelo. (a) Predicción de θ_{TU_UPA} mediante aprendizaje por transferencia a partir de la red base θ_{CU_LOA} . (b) Previsión de θ_{TU_UP2A} utilizando el aprendizaje por transferencia de la red base θ_{CU_LOA} . (c) Previsión de θ_{TU_URA} mediante aprendizaje por transferencia a partir de la red de base θ_{CU_LOA} . (d) Previsión de θ_{TU_UR2A} utilizando el aprendizaje por transferencia de la red base θ_{CU_LOA} . (e) Previsión de θ_{TU_MIA} mediante aprendizaje por transferencia a partir de la red base θ_{CU_LOA} . (f) Previsión de θ_{TU_MI2A} mediante aprendizaje por transferencia a partir de la red de base θ_{CU_LOA} . (g) Previsión de θ_{TU_LOA} mediante aprendizaje por transferencia a partir de la red de base θ_{CU_LOA} . (h) Previsión de θ_{TU_LO2A} mediante aprendizaje por transferencia de la red base θ_{CU_LOA} .

La tabla 8 muestra las métricas de rendimiento de las redes profundas que pronostican 48 h ϑ_{TU} utilizando las variables $P, T, HR, RS, \vartheta_{TU}$ y T_{TU} . Las métricas incluyen estadísticas como pérdida, MAE, RMSE y MSLE para los conjuntos de datos de entrenamiento, validación y evaluación. En esta tabla se observan resultados muy prometedores. Los valores resaltados en negrita indican un rendimiento especialmente sobresaliente. Por ejemplo, una pérdida de $3,6 \times 10^{-6}$ para ϑ_{TU_UPA} en el conjunto de entrenamiento denota una excelente capacidad del modelo para ajustarse a los datos de entrenamiento.

El MAE y el RMSE también son notables, con valores tan bajos como $1,4 \times 10^{-3}$ y $1,9 \times 10^{-3}$, respectivamente. Estas cifras sugieren que los modelos son muy precisos a la hora de predecir ϑ_{TU} en diversas condiciones. El MSLE, con valores en la escala de 1×10^{-6} , indica que los modelos son particularmente eficaces en la predicción dentro de un entorno logarítmico, crucial en muchas aplicaciones.

Tabla 8. Métricas obtenidas para redes profundas que pronostican 48 h de ϑ_{TU} utilizando información de las variables $P, T, HR, RS, \vartheta_{TU}$, y T_{TU} .

Variable objetivo	Conjunto de datos	Métricas			
		Pérdida	MAE	RMSE	MSLE
ϑ_{TU_UPA}	Formación	3.60×10^{-6}	1.40×10^{-3}	1.90×10^{-3}	1.42×10^{-6}
	Validación	2.49×10^{-5}	3.70×10^{-3}	5.00×10^{-3}	9.69×10^{-5}
	Evaluación	2.11×10^{-5}	3.39×10^{-3}	4.60×10^{-3}	8.16×10^{-6}
ϑ_{TU_UP2A}	Formación	3.90×10^{-6}	1.40×10^{-3}	2.00×10^{-3}	1.46×10^{-6}
	Validación	2.58×10^{-5}	3.70×10^{-3}	5.10×10^{-3}	9.50×10^{-6}
	Evaluación	2.84×10^{-5}	3.60×10^{-3}	5.30×10^{-3}	1.04×10^{-5}
ϑ_{TU_URA}	Formación	4.95×10^{-6}	1.50×10^{-3}	2.20×10^{-3}	1.94×10^{-6}
	Validación	3.82×10^{-5}	3.90×10^{-3}	6.20×10^{-3}	1.52×10^{-5}
	Evaluación	2.38×10^{-5}	3.20×10^{-3}	4.88×10^{-3}	9.63×10^{-6}
ϑ_{TU_UR2A}	Formación	7.64×10^{-6}	1.70×10^{-3}	2.80×10^{-3}	3.34×10^{-6}
	Validación	3.22×10^{-5}	2.70×10^{-3}	5.70×10^{-3}	1.42×10^{-5}
	Evaluación	9.13×10^{-6}	2.02×10^{-3}	3.03×10^{-3}	4.07×10^{-6}
ϑ_{TU_MIA}	Formación	3.65×10^{-6}	1.40×10^{-3}	1.90×10^{-3}	1.44×10^{-6}
	Validación	2.38×10^{-5}	3.50×10^{-3}	4.90×10^{-3}	9.32×10^{-6}
	Evaluación	2.70×10^{-5}	3.37×10^{-3}	5.20×10^{-3}	1.05×10^{-5}
ϑ_{TU_MI2A}	Formación	5.27×10^{-6}	1.50×10^{-3}	2.30×10^{-3}	2.13×10^{-6}
	Validación	3.03×10^{-5}	3.00×10^{-3}	5.70×10^{-3}	1.39×10^{-5}
	Evaluación	1.77×10^{-5}	2.21×10^{-3}	4.21×10^{-3}	6.95×10^{-6}
ϑ_{TU_LOA}	Formación	3.43×10^{-6}	1.30×10^{-3}	1.90×10^{-3}	1.40×10^{-6}
	Validación	2.14×10^{-5}	3.10×10^{-3}	4.60×10^{-3}	8.40×10^{-6}
	Evaluación	2.51×10^{-5}	2.87×10^{-3}	5.01×10^{-3}	9.70×10^{-6}
ϑ_{TU_LO2A}	Formación	3.27×10^{-6}	1.20×10^{-3}	1.80×10^{-3}	1.26×10^{-6}
	Validación	1.49×10^{-5}	2.20×10^{-3}	3.90×10^{-3}	5.64×10^{-6}
	Evaluación	2.70×10^{-5}	2.24×10^{-3}	4.54×10^{-3}	7.77×10^{-6}

4.2.4. Aplicación de la Red Base para la Predicción de la Humedad del Suelo en Plantas Acolchadas mediante Aprendizaje por Transferencia

En esta sección se presentan los resultados de la aplicación de las técnicas de transferencia-aprendizaje en dominios similares, presentando las predicciones y la evaluación de los resultados para plantas en cojín con las métricas establecidas en la metodología. La Figura 12 muestra la previsión de 48 h de humedad del suelo para todos los perfiles y horizontes de plantas en cojín, donde utilizamos 7 días de información horaria como entrada, con el mismo dominio que la red base: $P, T, HR, RS, \vartheta_{CU}$, y T_{CU} . La Figura 12a-g muestra los pronósticos para diferentes momentos de la serie de evaluación: $\vartheta_{CU_UPA}, \vartheta_{CU_UP2A}, \vartheta_{CU_URA}, \vartheta_{CU_UR2A}, \vartheta_{CU_MIA}, \vartheta_{CU_MI2A}, \vartheta_{CU_MIA}$, Y ϑ_{CU_LO2A} .

La Tabla 9 presenta las métricas de rendimiento de los modelos de aprendizaje profundo. Cabe destacar de esta tabla son los valores resaltados en negrita. Por ejemplo, en el caso de ϑ_{CU_UPA} en el conjunto de entrenamiento, se observa una pérdida extraordinariamente baja de $1,4 \times 10^{-6}$, lo que refleja la excepcional capacidad del modelo para ajustarse a los datos de entrenamiento. Este nivel de precisión se ve reforzado por un MAE y un RMSE de $2,3 \times 10^{-3}$ y $3,8 \times 10^{-3}$, respectivamente, lo que indica un rendimiento sobresaliente en la predicción de ϑ_{CU} . Los valores MSLE también son dignos de mención, con cifras del orden de 1×10^{-6} , lo que sugiere que los modelos son muy eficaces en la predicción en un entorno logarítmico. En general, las métricas de rendimiento ilustran el potencial de los modelos de aprendizaje profundo en la predicción de ϑ_{CU} , demostrando una precisión excepcional en varios conjuntos de datos. Estos resultados respaldan la utilidad potencial de estos modelos en aplicaciones prácticas que requieren predicciones precisas basadas en múltiples entradas.

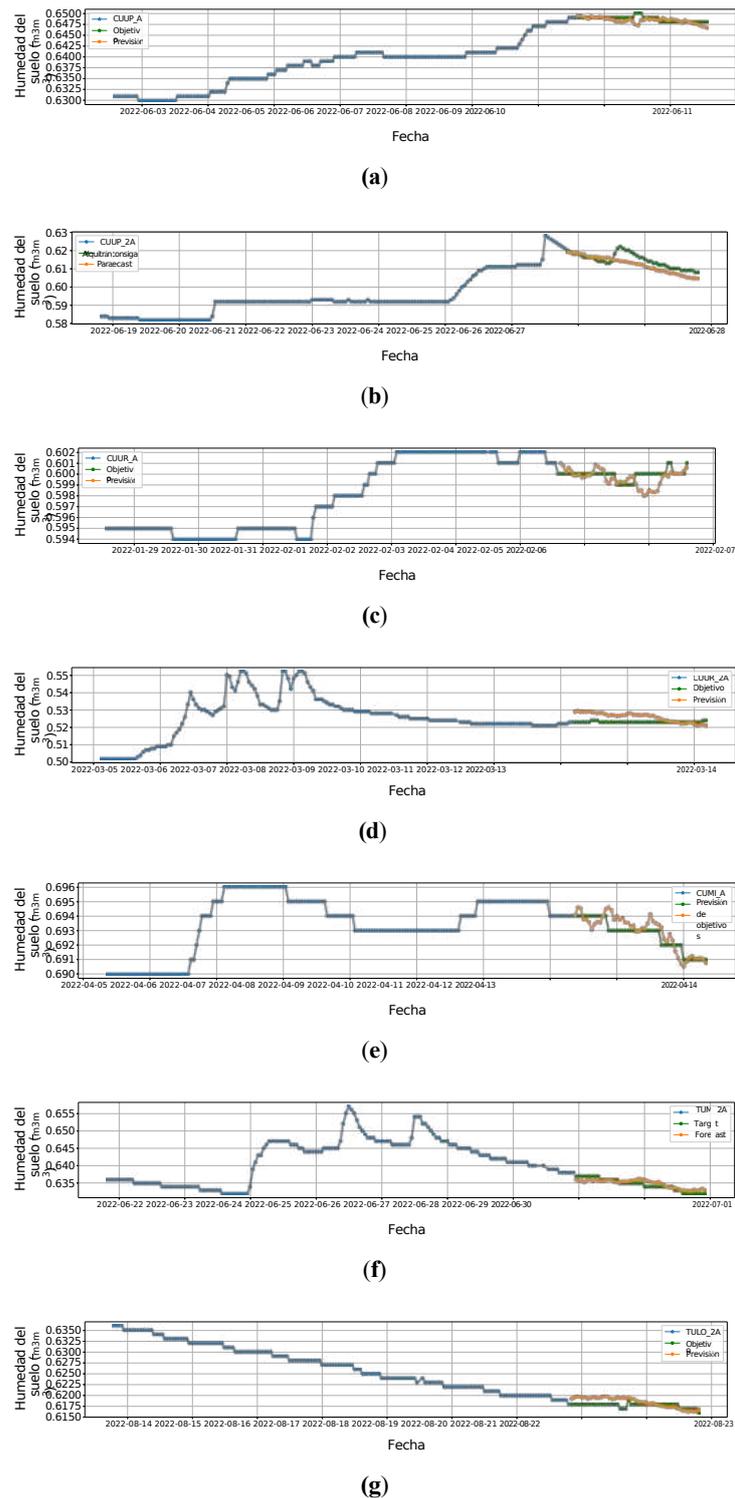


Figura 12. Predicciones en diferentes momentos de la humedad del suelo en tussock grass en todos los perfiles y horizontes analizados- (a) Predicción de Ocu_upA utilizando aprendizaje por transferencia a partir de la red base OCII_IOA. (b) Predicción de OCU_LOA utilizando aprendizaje por transferencia a partir de la red base OCII_IOA. (c) Previsión de OCU_URA mediante aprendizaje por transferencia a partir de la red base OCII_IOA. (d) Previsión de OCU_UR2A utilizando el aprendizaje por transferencia de la red base OCII_IOA. (e) Previsión de OCII_MIA mediante aprendizaje por transferencia a partir de la red base OCII_IOA. (f) Previsión de la utilización del aprendizaje por transferencia de la red de base OCII_IOA. (g) Previsión de OCII_102A mediante aprendizaje por transferencia a partir de la red de base OCII_IOA.

Tabla 9. Métricas obtenidas para los modelos de aprendizaje profundo que predicen 48 h de θ_{CU} utilizando información de las variables P , T , HR , RS , θ_{CU} , y TCU .

Variable objetivo	Conjunto de datos	Métricas			
		Pérdida	MAE	RMSE	MSLE
θ_{CU_UPA}	Formación	1.40×10^{-6}	2.30×10^{-3}	3.80×10^{-3}	5.26×10^{-6}
	Validación	2.64×10^{-5}	3.70×10^{-3}	5.10×10^{-3}	9.70×10^{-5}
θ_{CU_UP2A}	Evaluación	2.87×10^{-5}	3.55×10^{-3}	5.36×10^{-3}	1.08×10^{-5}
	Formación	5.27×10^{-6}	1.50×10^{-3}	2.30×10^{-3}	2.13×10^{-6}
θ_{CU_URA}	Validación	3.30×10^{-5}	3.00×10^{-3}	5.70×10^{-3}	1.30×10^{-5}
	Evaluación	1.77×10^{-5}	2.21×10^{-3}	4.21×10^{-3}	6.95×10^{-6}
θ_{CU_UR2A}	Formación	4.95×10^{-6}	1.50×10^{-3}	2.20×10^{-3}	1.94×10^{-6}
	Validación	3.82×10^{-5}	3.90×10^{-3}	6.20×10^{-3}	1.52×10^{-5}
θ_{CU_MIA}	Evaluación	2.38×10^{-5}	3.20×10^{-3}	4.88×10^{-3}	9.63×10^{-6}
	Formación	1.59×10^{-5}	2.50×10^{-3}	4.00×10^{-3}	6.95×10^{-6}
θ_{CU_MIA}	Validación	2.96×10^{-5}	3.40×10^{-3}	5.40×10^{-3}	1.28×10^{-5}
	Evaluación	4.03×10^{-5}	3.84×10^{-3}	6.35×10^{-3}	1.76×10^{-5}
θ_{CU_MIA}	Formación	9.32×10^{-6}	2.10×10^{-3}	3.10×10^{-3}	3.36×10^{-6}
	Validación	3.08×10^{-5}	3.80×10^{-3}	5.60×10^{-3}	1.09×10^{-5}
θ_{CU_MIA}	Evaluación	7.03×10^{-5}	5.55×10^{-3}	8.39×10^{-3}	2.61×10^{-5}
	Formación	7.84×10^{-6}	1.90×10^{-3}	2.80×10^{-3}	3.27×10^{-6}
θ_{CU_MIA}	Validación	2.96×10^{-5}	3.50×10^{-3}	5.40×10^{-3}	1.20×10^{-5}
	Evaluación	7.03×10^{-5}	5.55×10^{-3}	8.39×10^{-3}	2.61×10^{-5}
θ_{CU_LO2A}	Formación	3.27×10^{-6}	1.20×10^{-3}	1.80×10^{-3}	1.26×10^{-6}
	Validación	1.49×10^{-5}	2.20×10^{-3}	3.90×10^{-3}	5.64×10^{-6}
θ_{CU_LO2A}	Evaluación	2.70×10^{-5}	2.24×10^{-3}	4.54×10^{-3}	7.77×10^{-6}

5. Debate

El presente estudio ha demostrado la eficacia de la utilización de redes neuronales y técnicas de aprendizaje por transferencia en la predicción de la humedad del suelo en los Andes ecuatorianos de gran altitud. Sin embargo, existen numerosas oportunidades para ampliar y aplicar estos hallazgos en diferentes áreas de interés.

Una posible vía de investigación futura es la aplicación de los modelos desarrollados a la predicción de corrimientos de tierras o movimientos en masa. La humedad del suelo desempeña un papel crucial en la estabilidad de taludes y laderas, y su predicción precisa podría proporcionar una herramienta valiosa para la predicción de deslizamientos de tierra utilizando, por ejemplo, enfoques de umbrales hidrometeorológicos. La integración de datos de precipitación, temperatura y humedad del suelo en los modelos de predicción de corrimientos de tierras podría ayudar a identificar umbrales críticos y generar alertas tempranas para mitigar los riesgos asociados a estos fenómenos.

Otro campo de aplicación potencial es la predicción de incendios forestales. Una información precisa sobre la humedad del suelo puede ayudar a evaluar el nivel de riesgo de incendios forestales. Combinando los datos de humedad del suelo con variables climáticas relevantes, como precipitaciones, temperatura, humedad relativa y radiación solar, podrían desarrollarse modelos predictivos para identificar condiciones favorables para la propagación de incendios. Estas previsiones podrían contribuir a la planificación de la gestión del riesgo y a la toma de decisiones, permitiendo una respuesta más eficaz y oportuna.

Además, los resultados de esta investigación ofrecen la posibilidad de utilizarlos como insumo para estimar la cantidad de agua disponible en una cuenca hidrográfica. La humedad del suelo es un indicador clave de la disponibilidad de agua para la vegetación y los recursos hídricos en general. Combinando los datos de humedad del suelo obtenidos mediante modelos de previsión con información adicional sobre las características hidrológicas de una cuenca hidrográfica, podrían elaborarse estimaciones fiables de la cantidad de agua almacenada y de su disponibilidad para diversos fines, como la agricultura, el abastecimiento de agua potable y la generación de energía hidroeléctrica.

Estas posibilidades son sólo algunas de las aplicaciones potenciales que se derivan de los resultados obtenidos en este estudio. Explorar y ampliar estas aplicaciones, así como considerar otras áreas en las que una previsión precisa de la humedad del suelo podría tener un impacto significativo, representan vías prometedoras para futuras investigaciones. El desarrollo de modelos más complejos, la optimización del número de variables que mejor contribuyen a la predicción de la humedad del suelo y el perfeccionamiento de las técnicas de aprendizaje por transferencia son retos apasionantes para futuras investigaciones en este campo.

Nuestro estudio se enfrenta a importantes limitaciones en cuanto a la generalizabilidad de los resultados, ya que el aprendizaje por transferencia puede suponer un reto cuando existen diferencias ambientales entre

zonas de entrenamiento y predicción. La disponibilidad limitada de lugares con capacidades de medición similares también puede afectar a la generalización de nuestra metodología. Además, el análisis se basó en un periodo de casi cuatro años de datos, que puede no captar plenamente la variabilidad de la humedad del suelo; esto podría sesgar nuestros resultados hacia las condiciones específicas del páramo del norte de Ecuador y no reflejar la variabilidad natural a lo largo del tiempo. Por lo tanto, es importante interpretar nuestros resultados con cautela.

En la investigación realizada por Páez-Bimos et al. [33], donde se empleó el modelo dinámico HYDRUS-1D, se alcanzó una precisión en las predicciones de humedad del suelo, con valores de R^2 que oscilaban entre 0,49 y 0,91 y $RMSE \leq 0,02 \text{ cm}^3 \text{ cm}^{-3}$. Por el contrario, nuestra implementación de redes neuronales mostró unas pérdidas mínimas de $1,26 \times 10^{-6}$ y un RMSE mínimo de 0,0036, con unos coeficientes de eficacia elevados como un NSE y un KGE de 0,97. Ambos enfoques proporcionan representaciones eficaces de los procesos hidrológicos, con puntos fuertes específicos en cuanto a precisión y aplicabilidad.

6. Conclusiones

Se utilizaron modelos de última generación que emplean redes neuronales, concretamente CNN-LSTM-ANN, para pronosticar la humedad del suelo en 48 h a varias profundidades y ubicaciones utilizando siete días de información horaria. La red neuronal empleada en este estudio es una arquitectura profunda con hiperparámetros optimizados, lo que permite a las neuronas captar eficazmente la relación entre las variables hidrometeorológicas y la humedad del suelo. Las métricas de evaluación del pronóstico indican resultados prometedores, con un rango de error de $1 \times 10^{-6} < \epsilon < 1 \times 10^{-3}$.

La técnica de aprendizaje por transferencia empleada con el aprendizaje por transferencia basado en redes

sirvió para un doble propósito: en primer lugar, demostró la capacidad de transferir conocimientos de un dominio específico, es decir, un perfil de suelo, a otro dominio relacionado, es decir, un perfil de suelo distinto situado en un sitio diferente; en segundo lugar, optimizó indirectamente el tiempo de entrenamiento de las redes neuronales que utilizaban la red base preentrenada.

Contribuciones de los autores: Conceptualización, V.V., M.V., D.E.-G. y S.P.-B.; diseño experimental, V.V. y S.P.-B.; recopilación de datos, S.P.-B. y M.V.; validación de datos, S.P.-B. y D.E.-G.; obtención de financiación, V.V. y M.V.; administración del proyecto, V.V. y M.V.; redacción-borrador original, D.E.-G.; redacción-revisión y edición, todos los autores. Todos los autores han leído y aceptado la versión publicada del manuscrito.

Financiación: Esta investigación ha contado con el apoyo de la Académie de Recherche et Enseignement Supérieur de la Fédération Wallonie-Bruxelles (ARES CCD) a través del proyecto PDR páramoSUS (2017-2023) y se ha realizado en colaboración con el Fondo para la Protección del Agua (FONAG), la Empresa Pública Metropolitana de Agua Potable y Saneamiento (EPMAPS), el Programa para el Manejo de Agua y Suelo (PROMAS) de la Facultad de Ingeniería Civil de la Universidad de Cuenca, la Empresa Pública Municipal de Telecomunicaciones, Agua Potable, Alcantarillado y Saneamiento de Cuenca (ETAPA-EP), y ElecAustro.

Declaración de disponibilidad de datos: Los datos serán facilitados por los autores previa solicitud razonable.

Agradecimientos: Agradecemos a Jordan Cruz, Isaías Quinatoa y estudiantes de pregrado de la Escuela Politécnica Nacional (EPN) y de la Universidad Central del Ecuador (UCE) por su ayuda en la preparación y muestreo de las campañas de campo en el Antisana. Esta investigación ha sido apoyada por el proyecto de cooperación en investigación "Vinculando el Cambio Global con la Conservación de Suelos y Aguas en los Altos Andes" (páramoSus). SPB fue apoyado por EPN en el desarrollo de su programa de doctorado, y DEG agradece a Viviana Velasteguí por su apoyo en SIG. Adicionalmente, DEG recibió apoyo continuo de la EPMAPS durante su programa de maestría.

Conflictos de intereses: Los autores declaran no tener conflictos de intereses.

Referencias

1. Oki, T.; Kanae, S. Global hydrological cycles and world water resources. *Science* **2006**, *313*, 1068-1072. [[CrossRef](#)] [[PubMed](#)].
2. Trenberth, K.E.; Fasullo, J.T.; Kiehl, J. Earth's global energy budget. *Bull. Am. Meteorol. Soc.* **2009**, *90*, 311-324. [[CrossRef](#)]
3. Berg, A.; Sheffield, J. Cambio climático y sequía: La perspectiva de la humedad del suelo. *Curr. Clim. Chang. Rep.* **2018**, *4*, 180-191. [[CrossRef](#)]

4. Seneviratne, S.I.; Corti, T.; Davin, E.L.; Hirschi, M.; Jaeger, E.B.; Lehner, I.; Orlowsky, B.; Teuling, A.J. Investigating soil moisture-Climate interactions in a changing climate: A review. *Earth-Sci. Rev.* **2010**, *99*, 125-161. [[CrossRef](#)]
5. Mukhlisin, M.; Astuti, H.W.; Wardihani, E.D.; Matlan, S.J. Técnicas de medición terrestre de la humedad del suelo: A detailed overview. *Arab. J. Geosci.* **2021**, *14*, 2032. [[CrossRef](#)]
6. Kelly, E.F.; Chadwick, O.A.; Hilinski, T.E. The effect of plants on mineral weathering. *Biogeochemistry* **1998**, *42*, 21-53. [[CrossRef](#)]
7. Páez-Bimos, S.; Molina, A.; Calispa, M.; Delmelle, P.; Lahuatte, B.; Villacís, M.; Muñoz, T.; Vanacker, V. Soil-vegetation-water interactions controlling solute flow and chemical weathering in volcanic ash soils of the high Andes. *Hydrol. Earth Syst. Sci.* **2023**, *27*, 1507-1529. [[CrossRef](#)]
8. Brück, S.A.; Torres, B.D.M.; de Lourdes Teixeira de Moraes Polizeli, M. El páramo ecuatoriano en peligro: Lo que sabemos y lo que se podría aprender de los humedales del norte. *Glob. Ecol. Conserv.* **2023**, *47*, e02639. [[CrossRef](#)]
9. Patiño, D.T.; Sánchez, P.C.; Rojas, G.M. Umbrales en la respuesta de humedad del suelo a condiciones meteorológicas en una ladera Altoandina. *Maskana* **2018**, *9*, 53-65. [[CrossRef](#)]
10. Vanacker, V.; Molina, A.; Torres, R.; Calderon, E.; Cadilhac, L. Desafíos para la investigación sobre el cambio global en el Ecuador continental. *Neotrop. Biodivers.* **2018**, *4*, 114-118. [[CrossRef](#)]
11. Tenorio, G.E.; Vanacker, V.; Campforts, B.; Álvarez, L.; Zhiminaicela, S.; Vercruyse, K.; Molina, A.; Govers, G. Tracking spatial variation in river load from Andean highlands to inter-Andean valleys. *Geomorfología* **2018**, *308*, 175-189. [[CrossRef](#)]
12. Ruiz-Hernández, J.C.; Condom, T.; Ribstein, P.; Le Moine, N.; Espinoza, J.C.; Junquas, C.; Villacís, M.; Vera, A.; Muñoz, T.; Maisincho, L.; et al. Spatial variability of diurnal to seasonal cycles of precipitation from a high-altitude equatorial Andean valley to the Amazon Basin. *J. Hydrol. Reg. Stud.* **2021**, *38*, 100924. [[CrossRef](#)]
13. Molina, A.; Vanacker, V.; Corre, M.D.; Veldkamp, E. Patterns in Soil Chemical Weathering Related to Topographic Gradients and Vegetation Structure in a High Andean Tropical Ecosystem. *J. Geophys. Res. Earth Surf.* **2019**, *124*, 666-685. [[CrossRef](#)]
14. Buytaert, W.; Cuesta-Camacho, F.; Tobón, C. Potential impacts of climate change on the environmental services of humid tropical alpine regions. *Glob. Ecol. Biogeogr.* **2011**, *20*, 19-33. [[CrossRef](#)]
15. Buytaert, W.; Célleri, R.; De Bièvre, B.; Cisneros, F.; Wyseure, G.; Deckers, J.; Hofstede, R. Human impact on the hydrology of the Andean páramos. *Earth-Sci. Rev.* **2006**, *79*, 53-72. [[CrossRef](#)]
16. Bonnesoeur, V.; Locatelli, B.; Guariguata, M.R.; Ochoa-Tocachi, B.F.; Vanacker, V.; Mao, Z.; Stokes, A.; Mathez-Stiefel, S.L. Impacts of forests and forestation on hydrological services in the Andes: A systematic review. *For. Ecol. Manag.* **2019**, *433*, 569-584. [[CrossRef](#)]
17. Iñiguez, V.; Morales, O.; Cisneros, F.; Bauwens, W.; Wyseure, G. Análisis de la recuperación a la sequía de Andosoles en páramos andinos del sur de Ecuador. *Hydrol. Earth Syst. Sci.* **2016**, *20*, 2421-2435. [[CrossRef](#)]
18. Gonzalez-Zeas, D.; Erazo, B.; Lloret, P.; Steinschneider, S.; Dangles, O. Linking global climate change to local water availability: Limitations and prospects for a tropical mountain watershed. *J. Sci. Tot. Env.* **2019**, *650*, 2577-2586. [[CrossRef](#)]
19. Molina, A.; Govers, G.; Vanacker, V.; Poesen, J.; Zeelmaekers, E.; Cisneros, F. Generación de escorrentía en un ecosistema andino degradado: Interacción de la cobertura vegetal y el uso del suelo. *Catena* **2007**, *71*, 357-370. [[CrossRef](#)]
20. Molina, A.; Govers, G.; Cisneros, F.; Vanacker, V. Vegetation and topographic controls on sediment deposition and storage on gully beds in a degraded mountain area. *Earth Surf. Processes Landforms* **2009**, *34*, 755-767. [[CrossRef](#)]
21. Mosquera, G.M.; Crespo, P.; Breuer, L.; Feyen, J.; Windhorst, D. Water transport and tracer mixing in volcanic ash soils at a tropical hillslope: A wet layered sloping sponge. *Hydrol. Processes* **2020**, *34*, 2032-2047. [[CrossRef](#)]
22. Prasad, R.; Deo, R.C.; Li, Y.; Maraseni, T. Predicción semanal de la humedad del suelo con enfoque multivariante secuencial, modo empírico ensemble decomposición y algoritmo híbrido Boruta-random forest. *Catena* **2019**, *177*, 149-166. [[CrossRef](#)]
23. Gao, P.; Qiu, H.; Lan, Y.; Wang, W.; Chen, W.; Han, X.; Lu, J. Modeling for the Prediction of Soil Moisture in Litchi Orchard with Deep Long Short-Term Memory. *Agricultura* **2021**, *12*, 25. [[CrossRef](#)]
24. Han, H.; Choi, C.; Kim, J.; Morrison, R.R.; Jung, J.; Kim, H.S. Multiple-depth soil moisture estimates using artificial neural network and long short-term memory models. *Agua* **2021**, *13*, 2584. [[CrossRef](#)]
25. Suebsombut, P.; Sekhari, A.; Sureephong, P.; Belhi, A.; Bouras, A. Field data forecasting using LSTM and Bi-LSTM approaches. *Appl. Sci.* **2021**, *11*, 11820. [[CrossRef](#)]
26. Sivasankaran, S.; Mohan, K.J.; Nazer, G.M. Soil Moisture Quantity Prediction using Optimized Deep Learning Supported model for Sustainable cultivation of Groundnut plant. *Nat. Volatiles Essent. Oils J. NVEO* **2021**, *8*, 13184-13205.
27. Liu, D.; Liu, C.; Tang, Y.; Gong, C. A GA-BP Neural Network Regression Model for Predicting Soil Moisture in Slope Ecological Protection. *Sostenibilidad* **2022**, *14*, 1386. [[CrossRef](#)]
28. Zhang, L.; Xue, Z.; Zhang, Y.; Ma, J.; Li, H. Enhanced Generalized Regression Neural Network for Soil Moisture Estimation Over the Qinghai-Tibet Plateau. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2022**, *15*, 3815-3829. [[CrossRef](#)]
29. Prasad, R.; Deo, R.C.; Li, Y.; Maraseni, T. Soil moisture forecasting by a hybrid machine learning technique: ELM integrado con ensemble empirical mode decomposition. *Geoderma* **2018**, *330*, 136-161. [[CrossRef](#)]
30. Rostami, S.; He, J.; Hassan, Q.K. Respuesta de la calidad del agua fluvial a la precipitación y su cambio. *Environments* **2018**, *5*, 8. [[CrossRef](#)]
31. Vanacker, V.; Vanderschaeghe, M.; Govers, G.; Willems, E.; Poesen, J.; Deckers, J.; De Bievre, B. Linking hydrological, infinite slope stability and land-use change models through GIS for assessing the impact of deforestation on slope stability in high Andean watersheds. *Geomorphology* **2003**, *52*, 299-315. [[CrossRef](#)]

32. Zhao, B.; Dai, Q.; Zhuo, L.; Zhu, S.; Shen, Q.; Han, D. Assessing the potential of different satellite soil moisture products in landslide hazard assessment. *Remote Sens. Environ.* **2021**, *264*, 112583. [[CrossRef](#)]
33. Páez-Bimos, S.; Villacís, M.; Morales, O.; Calispa, M.; Molina, A.; Salgado, S.; de Bievre, B.; Delmelle, P.; Muñoz, T.; Vanacker, V. Vegetation effects on soil pore structure and hydraulic properties in volcanic ash soils of the high Andes. *Hydrol. Processes* **2022**, *36*, e14678. [[CrossRef](#)]
34. Lahuatte, B.; Mosquera, G.M.; Páez-Bimos, S.; Calispa, M.; Vanacker, V.; Zapata-Ríos, X.; Muñoz, T.; Crespo, P. Delineation of water flow paths in a tropical Andean headwater catchment with deep soils and permeable bedrock. *Hydrol. Processes* **2022**, *36*, e14725. [[CrossRef](#)]
35. Empresa Pública Metropolitana de Agua Potable y Saneamiento (EPMAPS) y Fideicomiso Mercantil Fondo Ambiental para la Protección de las Cuencas y Agua (FONAG). *Actualización del Plan de Manejo del Área de Conservación Hídrica Antisana*; EPMAPS-FONAG: Quito, Ecuador, 2018.
36. Fideicomiso Mercantil Fondo Ambiental para la Protección de las Cuencas y Agua (FONAG). *Plan estratégico 2021-2025*; FONAG: Quito, Ecuador, 2020.
37. Espinosa, J.; Moreno, J.; Bernal, G. *The Soils of Ecuador*; World Soils Book Series; Springer International: Cham, Suiza, 2017.
38. Hall, M.L.; Mothes, P.A.; Samaniego, P.; Militzer, A.; Beate, B.; Ramón, P.; Robin, C. Volcán Antisana: Un volcán andesítico representativo de la cordillera oriental de Ecuador: Petrografía, química, tefra y estratigrafía glaciaria. *J. South Am. Earth Sci.* **2017**, *73*, 50-64. [[CrossRef](#)]
39. Zhuang, F.; Qi, Z.; Duan, K.; Xi, D.; Zhu, Y.; Zhu, H.; Xiong, H.; He, Q. A comprehensive survey on transfer learning. *Proc. IEEE* **2020**, *109*, 43-76. [[CrossRef](#)]
40. Alpaydın, E. *Aprendizaje automático: The New AI*; MIT Press: Cambridge, MA, EE.UU., 2016.
41. Kelleher, J.D.; Tierney, B.; Tierney, B. *Ciencia de datos*; MIT Press: Cambridge, MA, EE. UU., 2018.
42. Goodfellow, I.; Bengio, Y.; Courville, A. *Aprendizaje profundo*; MIT Press: Cambridge, MA, EE.UU., 2016.
43. Sit, M.; Demiray, B.Z.; Xiang, Z.; Ewing, G.J.; Sermet, Y.; Demir, I. A comprehensive review of deep learning applications in hydrology and water resources. *Water Sci. Technol.* **2020**, *82*, 2635-2670. [[CrossRef](#)]
44. Tan, C.; Sun, F.; Kong, T.; Zhang, W.; Yang, C.; Liu, C. A survey on deep transfer learning. En *Actas de la Conferencia Internacional sobre Redes Neuronales Artificiales*, Rodas, Grecia, 4-7 de octubre de 2018; Springer: Cham, Suiza, 2018; pp. 270-279.

Descargo de responsabilidad/Nota del editor: Las declaraciones, opiniones y datos contenidos en todas las publicaciones son responsabilidad exclusiva de los autores y colaboradores individuales y no de MDPI y/o el/los editor/es. MDPI y/o el/los editor/es declinan toda responsabilidad por daños personales o materiales derivados de ideas, métodos, instrucciones o productos a los que se haga referencia en el contenido.