



## Estimación de la humedad del suelo mediante regresiones lineales múltiples en Llano Brenes, Costa Rica<sup>1</sup>

### Estimation of soil moisture through multiple linear regressions in Llano Brenes, Costa Rica

Teresa Palominos-Rizzo<sup>2</sup>, Mario Villatoro-Sánchez<sup>3</sup>, Alfredo Alvarado-Hernández<sup>3</sup>, Víctor Cortés-Granados<sup>4</sup>, Darwin Paguada-Pérez<sup>5</sup>

- <sup>1</sup> Recepción: 23 de agosto, 2021. Aceptación: 11 de noviembre, 2021. El presente artículo formó parte de la tesis de doctorado de la primera autora. Los estudios fueron financiados por la Secretaría de Educación Superior, Ciencia, Tecnología e Innovación del Ecuador.
- <sup>2</sup> Universidad de Costa Rica, Sistema de Estudios de Posgrado Ciencias Agrícolas y Recursos Naturales, San José 11501-2060, Costa Rica. teresa.palominos@catie.ac.cr (autora para la correspondencia; <https://orcid.org/0000-0002-0705-6862>).
- <sup>3</sup> Universidad de Costa Rica, Centro de Investigaciones Agronómicas, San José 11501-2060, Costa Rica. mario.villatoro@ucr.ac.cr (<https://orcid.org/0000-0002-6678-5854>); alfredo.alvarado@ucr.ac.cr (<https://orcid.org/0000-0002-6930-6660>).
- <sup>4</sup> Universidad de Costa Rica, Escuela de Geografía, San José 11501-2060, Costa Rica. victor.cortes@ucr.ac.cr (<https://orcid.org/0000-0001-8053-9126>).
- <sup>5</sup> Consultor independiente, San José, Moravia 11401, Costa Rica. darwin.paguada@catie.ac.cr (<https://orcid.org/0000-0002-1257-9369>).

## Resumen

**Introducción.** La humedad del suelo es una variable muy importante en el suministro de agua para la agricultura y es su principal recurso. Sin embargo, su medición en campo suele presentar limitaciones, por lo que su predicción es necesaria para diversas actividades de planificación agrícola e investigación. **Objetivo.** Predecir la humedad diaria del suelo a escala de cultivo, a partir de información meteorológica mediante modelos de regresión lineal múltiple. **Materiales y métodos.** El estudio se desarrolló en Llano Brenes, Alajuela, Costa Rica. Se instalaron sensores de reflectometría de dominio temporal (TDR) y registraron información cada veinte minutos de humedad de suelo desde noviembre 2018 a diciembre 2019. El suelo se clasificó a nivel taxonómico como Lithic Ustorthents, en una finca con cultivo de café en producción. Se tomaron muestras de suelo no disturbadas para la calibración de los TDR y se realizó un análisis de estabilidad temporal. El primer modelo (RLM1) fue una regresión lineal múltiple con variables meteorológicas, en el segundo modelo (RLM2) además de las variables meteorológicas, se separó la precipitación en subperíodos, los cuales se introdujeron como variables “dummy”, mientras que el tercer modelo (PCA) consistió en un análisis de componentes principales y un modelo de regresión lineal. **Resultados.** Los modelos RLM2 ( $R^2 = 0,838$ ) y PCA ( $R^2 = 0,823$ ) presentaron un mejor desempeño en comparación con el modelo RLM1 ( $R^2 = 0,540$ ). Sin embargo, el modelo RLM2 se consideró más útil, debido a su simplicidad y a que presentó los mejores indicadores de bondad de ajuste. **Conclusión.** Los modelos de regresión lineal con variables meteorológicas permitieron estimar la humedad del suelo, debido a que esta tendió a seguir los patrones estacionales y las variaciones de la precipitación, tal como se observó en el RLM2 con la separación de subperíodos.

**Palabras claves:** contenido de agua en el suelo, *Coffea*, zona tropical.



## Abstract

**Introduction.** Soil moisture is a very important variable in the water supply for agriculture and it is its main resource. However, its field measurement usually has limitations, so its prediction is necessary for various agricultural planning and research activities. **Objective.** To predict daily soil moisture at the crop scale from meteorological information through multiple linear regression models. **Materials and methods.** The study was carried out in Llano Brenes, Alajuela, Costa Rica. Time domain reflectometry (TDR) sensors were installed and soil moisture information was recorded every twenty minutes from November 2018 to December 2019. The soil was classified at the taxonomic level as Lithic Ustorthents, in a farm with coffee cultivation in production. Undisturbed soil samples were taken for TDR calibration and a temporal stability analysis was performed. The first model (RLM1) was a multiple linear regression with meteorological variables, in the second model (RLM2) in addition to the meteorological variables, the precipitation was separated into sub-periods which were introduced as dummy variables, while the third model (PCA) consisted of a main component analysis and a linear regression model. **Results.** The RLM2 ( $R^2 = 0.838$ ) and PCA ( $R^2 = 0.823$ ) models performed better than the RLM1 model ( $R^2 = 0.540$ ). However, the RLM2 model was considered more useful due to its simplicity and the fact that it presented the best goodness-of-fit indicators. **Conclusion.** The linear regression models with meteorological variables allowed estimating soil moisture, because it tends to follow seasonal patterns and variations in precipitation, as observed in the RLM2 with the separation of sub-periods.

**Keywords:** soil water content, *Coffea*, tropical zone.

## Introducción

La humedad del suelo es una variable importante en los ciclos globales del agua, energía y carbono (Heathman et al., 2003). Es la principal fuente de agua para la agricultura y la vegetación natural (de Queiroz et al., 2020), y un factor fundamental en la dinámica de infiltración y escorrentía, ya que determina el agua disponible para la evapotranspiración, controla el flujo subterráneo y el movimiento de productos químicos hacia acuíferos (Martínez-Fernández & Ceballos, 2005). La humedad del suelo tiene relevancia en el modelado hidrológico, el manejo de cuencas y la investigación del suelo (Qiu et al., 2001); sin embargo, su predicción es compleja en el espacio y el tiempo (Chen et al., 2003).

Propiedades del suelo como la textura, estructura, mineralogía y contenido orgánico, limitan o favorecen la capacidad del suelo para suministrar agua a las plantas (Montoani Silva et al., 2019). La humedad del suelo es muy importante en la fenología del cultivo de café (*Coffea arabica*), ya que después del periodo de estrés hídrico, es necesaria para interrumpir la latencia de los botones florales y generar una floración homogénea (Amarasinghe et al., 2015; Masarirambi et al., 2009).

La humedad del suelo es influenciada por la evaporación, la precipitación, la temperatura, la vegetación y otros factores. Por lo que es posible conocer su dinámica mediante el cálculo y la derivación de los factores que influyen en esta (Zheng et al., 2017). En la actualidad existen tres enfoques para realizar estimaciones de la humedad del suelo: (1) observaciones *in situ*, (2) teledetección, y (3) datos modelados (Crow & Yilmaz, 2014; Tebbs et al., 2016). Para el pronóstico de la humedad del suelo a escala de cultivo, la variación espacial es pequeña y se pueden considerar menos factores de influencia (Zheng et al., 2017).

Con respecto a modelos, se han realizado estudios con regresiones lineales múltiple para predecir las propiedades de un suelo, como sus características morfológicas que son fáciles de medir (Mckenzie & Macleod, 1989; McKenzie & Ryan, 1999). Existen otros estudios donde las variables utilizadas en las regresiones corresponden a diferentes tipos de uso de suelo (Qiu et al., 2003), la relación entre el uso de suelo y variables topográficas (Qiu et al., 2003, 2010), y regresiones con variables espaciales y meteorológicas (Qiu et al., 2003). Sin

embargo, para construir modelos con observaciones meteorológicas como variables regresoras, estas deben ser de calidad, ya que el modelo puede fallar si los datos no cumplen criterios de calidad y densidad (Brocca et al., 2017).

Los modelos de regresión lineal múltiple permiten integrar los tipos de datos de predictores, incluyen datos numéricos y datos categóricos (Devore & Berk, 2012; Forkuor et al., 2017; Mckenzie & Macleod, 1989; Were et al., 2015). En casos en los cuales existen un gran número de variables, se ha aplicado el análisis de componentes principales (PCA) para simplificar la complejidad de las relaciones lineales entre variables ambientales (McKenzie & Austin, 1993; Qiu et al., 2010).

Con el fin de tener una mejor gestión del agua y del riego en la agricultura, se han empleado sensores de humedad para medir el contenido de esta en el suelo (Antonucci et al., 2011). Dichos sensores proporcionan datos viables y se pueden instalar a diferentes profundidades, debido a que son equipos de medición no destructivos.

Una de las tecnologías de sensores más común es la reflectometría en el dominio del tiempo (TDR), la cual utiliza la velocidad de una señal electromagnética, que pasa a través de un material que varía con el dieléctrico del material. Es un método bastante preciso para medir la humedad contenida del suelo (Robinson et al., 2003); sin embargo, es necesario realizar una calibración para los diferentes tipos de suelo con condiciones de sitio específicas con el fin de mejorar la precisión (Kargas & Soulis, 2012; Naranjo & Ataroff, 2015; Udawatta et al., 2011).

Existe una importante variación de la humedad del suelo en el espacio y el tiempo, lo que dificulta su caracterización (Zucco et al., 2014). Por tal razón, es necesario realizar un análisis de estabilidad temporal, para describir la persistencia de patrones espaciales y el comportamiento característico de la humedad del suelo, además de identificar, por medio de mediciones, aquellos puntos que reproducen el patrón de humedad promedio (Brocca et al., 2009; Heathman et al., 2012; Zucco et al., 2014).

El objetivo general de este estudio fue predecir la humedad diaria del suelo a escala de cultivo, a partir de información meteorológica mediante el uso de modelos de regresión lineal múltiple.

## Materiales y métodos

### Sitio de estudio

Los datos se recopilaron entre noviembre de 2018 y diciembre de 2019, en una finca en el caserío de Llano Brenes del distrito de San Rafael, en el cantón de San Ramón de la provincia de Alajuela (10,005439° N 84,467965° O) a una altitud de 1094 m, ubicado en la cuenca superior del río Jesús María. Esta cuenca tiene una superficie de 375,5 km<sup>2</sup> y está localizada en el Pacífico Central de Costa Rica (Instituto Meteorológico Nacional, 2017). El sitio de estudio corresponde a un cafetal de cincuenta años, sembrado con la variedad Catuaí, el cual se maneja con prácticas agronómicas tales como: arreglo de la sombra, deshije, fertilización, control de malezas con herbicidas o chapea (retiro de malezas con herramientas como por ejemplo machete) y control de enfermedades cuando es necesario. Además, cuenta con obras mecánicas de conservación de suelos. El suelo se clasifica a nivel taxonómico como Lithic Ustorthents (Soil Survey Staff, 2014), con una fertilidad aparente media y un material parental conformado por coluvios de origen volcánico. El relieve es escarpado, cuenta con buen drenaje y un nivel freático que se encuentra a más de 2 m (Molina-Campos, 2015).

### Calibración de los sensores reflectometría de dominio temporal (TDR)

Para la calibración de los sensores reflectometría de dominio temporal (TDR), se tomaron seis muestras de 6-7 kg de suelo no perturbado, que se colocaron en contenedores plásticos de las mismas dimensiones de las muestras

para evitar su alteración. En las muestras se instalaron los sensores de TDR, modelo CS616 (Campbell Sci, 2020), los cuales se colocaron y se aseguró que al menos 4 cm de suelo cubrieran todos los lados de las varillas de cada sensor. La composición física del suelo utilizado en este estudio se indica en el Cuadro 1.

**Cuadro 1.** Propiedades físicas del suelo en Llano Brenes, Alajuela, Costa Rica. 2018 - 2019.

**Table 1.** Physical properties of the soil in Llano Brenes, Alajuela, Costa Rica. 2018 - 2019.

Parámetro	Valor
Materia orgánica (%)	0,83
Arena (%)	40
Limo (%)	35
Arcilla (%)	25
Densidad aparente (g cm <sup>-3</sup> )	1,07

Al inicio del experimento se recolectaron muestras de suelo en la misma profundidad y sitio de cada muestra de suelo no perturbado (0,30 m). Para determinar el contenido inicial de agua gravimétrica, se cuantificó el peso húmedo y el peso seco, una vez sometido a estufa a 105 °C por 48 h en el Laboratorio de Recursos Naturales del Centro de Investigaciones Agronómicas de la Universidad de Costa Rica. Además, se tomaron muestras para determinar la densidad aparente en cada punto de muestreo (Naranjo & Ataroff, 2015; Udawatta et al. 2011). En la calibración, las muestras se humedecieron al inicio hasta saturación por un periodo de 24 h. La aplicación de agua fue en forma uniforme para evitar las subestimaciones debidas a la heterogeneidad de la humedad en el suelo (Mojid & Cho, 2002). Para el registro de las lecturas de los sensores, estos se conectaron a un datalogger Modelo CR800 (Campbell Sci. Inc., 2016), alimentado por una batería de 12 voltios. Las muestras se pesaron en una balanza todos los días a la misma hora, durante 91 días después de la saturación. El contenido volumétrico de agua medido por cada sensor, fue descargado a un computador para el respectivo análisis.

Al final de las mediciones, se determinó el contenido volumétrico de agua ( $\theta_v$ ) (Khan et al., 2011), por lo que las muestras de suelo donde se instalaron los sensores TDR se secaron en una estufa a 105 °C por 48 h, para determinar el contenido gravimétrico remanente de agua valor, el cual se multiplicó por la densidad aparente. Esta medida experimental de  $\theta_v$  se utilizó para comparar con la humedad volumétrica medida por el sensor ( $\theta_s$ ). Para el análisis estadístico, se realizaron cuatro tipos de regresiones: lineal, cuadrática, cúbica y logarítmica, donde se consideró como variable dependiente la  $\theta_v$ , mientras que la variable independiente fue la  $\theta_s$  (Naranjo & Ataroff, 2015).

### Monitoreo de la humedad del suelo en campo

En el sitio de estudio se instalaron seis sensores TDR, sin embargo, tres de ellos perdieron información por lo que no fue posible incluirlos en el presente análisis. Los TDR estuvieron conectados a dos dataloggers Modelo CR800 (Campbell Sci. Inc., 2016) para el registro de la información, los datos se obtuvieron con una frecuencia de registro de cada 20 min, a una profundidad de 0,30 m. La información de las variables meteorológicas se obtuvo de una estación meteorológica Davis Vantage ProPlus, instalada y administrada por el Instituto del Café de Costa Rica (ICAFE), ubicada a 6 km del área de estudio y a una altura de 1200 m s. n. m. Estos datos se contemplaron con los de otra estación Davis Vantage ProPlus instalada en el área de estudio perteneciente al Centro de Investigaciones Agronómicas de la Universidad de Costa Rica (Figura 1).



**Figura 1.** a) Instalación de un sensor de reflectometría de dominio temporal (TDR); b) un datalogger y una estación meteorológica en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Figure 1.** a) Time-domain reflectometry (TDR) sensor installation; b) a datalogger and a meteorological station in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Debido a que el conjunto de datos pudo presentar diferentes condiciones de humedad de suelo, a través de los diferentes periodos estacionales, estos se agruparon en subperíodos acorde al régimen local de precipitación (de Queiroz et al., 2020). Se consideraron seis subperíodos en forma arbitraria: seco, seco-lluvioso (transición), lluvioso 1, canícula (transición), lluvioso 2 y lluvioso-seco (transición). Como criterio de selección, se estableció que era un periodo lluvioso cuando la precipitación era mayor a 5 mm por día y no más de cinco días consecutivos secos (ausencia de precipitación), mientras que, era un periodo seco cuando la precipitación era menor o igual a 5 mm por día y más de cinco días consecutivos secos. Si alguno de los criterios no aplicaba, el subperíodo se consideró de transición.

### Análisis de la estabilidad temporal de la humedad del suelo

El análisis de estabilidad temporal evalúa la persistencia temporal de los patrones espaciales de la humedad del suelo (Zucco et al., 2014). Los valores cercanos a cero indican que las ubicaciones presentan una humedad cercana al promedio, la cual es la posición que mejor representa el área total de estudio. Los valores negativos y positivos de la diferencia relativa ( $\delta_{ij}$ ) indican que las ubicaciones tienen menor o mayor humedad que el promedio de campo y podrían subestimar o sobrestimar la humedad media del suelo (Heathman et al., 2012; Zucco et al., 2014). La estabilidad temporal se evaluó con la prueba de diferencia relativa  $\delta_{ij}$  entre las medidas individuales de la humedad del suelo, tomadas por los sensores TDR en la posición  $i$  (ubicación donde se instaló cada sensor), durante el día  $j$  ( $\theta_{ij}$ ) y el valor promedio de todas las ubicaciones medidas en cada día de muestreo ( $\bar{\theta}_j$ ) (ecuación 1).

$$\delta_{ij} = \frac{\theta_{ij} - \bar{\theta}_j}{\bar{\theta}_j} \quad (1)$$

La media temporal de las diferencias relativas en cada posición  $i$  (ubicación donde se instaló cada sensor) en el día  $j$  ( $\bar{\delta}_j$ ) está dada por la ecuación 2, donde  $N$  es el número de sitios analizados.

$$\bar{\delta}_i = \frac{1}{N} \sum_{j=1}^N \delta_{ij} \quad (2)$$

La desviación estándar de la diferencia relativa  $\sigma(\delta_i)$  está dada por la ecuación 3.

$$\sigma(\delta_i) = \sqrt{\frac{1}{N-1} \sum_{j=1}^N (\delta_{ij} - \bar{\delta}_i)^2} \quad (3)$$

Se aplicó una correlación de Spearman, debido a que los datos de humedad no tienen una distribución normal. Esto con el fin de evaluar la persistencia de los patrones espaciales de la humedad del suelo para los diferentes subperíodos monitoreados (de Queiroz et al., 2020; Heathman et al., 2012).

### Análisis estadístico

El análisis estadístico se realizó con el Software RStudio (R Core Team, 2020). En todos los modelos obtenidos se realizaron pruebas para verificar el cumplimiento de supuestos teóricos. Debido al incumplimiento de los supuestos en todos los modelos (normalidad, homocedasticidad y no colinealidad), se utilizó la técnica de método de *bootstrap*, la cual no requiere de distribuciones *a priori* específicas para los datos. El remuestreo mediante *bootstrap* ayudó a determinar si el incumplimiento de los supuestos afecta de manera importante las estimaciones de los modelos (Parker, 2006; Russell & Dean, 2000). Para efectos de esta investigación, se realizaron mil remuestreos (Zaman & McKee, 2014) y se verificó que los intervalos de confianza de *bootstrap* para los coeficientes, fueran similares o se traslaparan con los estimados mediante el método de mínimos cuadrados, lo que determinó que las estimaciones no se afectan y se puede trabajar con el modelo (Bishara & Hittner, 2017).

Para obtener los modelos de predicción de la humedad del suelo, se utilizaron las siguientes variables meteorológicas: temperatura ambiente (Tamb), temperatura mínima (Tmin), temperatura máxima (Tmax), humedad relativa (HR), velocidad del viento (Vviento), lluvia acumulada (Racum) y los seis subperíodos antes descritos. El primer modelo (RLM1) fue una regresión lineal múltiple con todas las variables meteorológicas sin la clasificación de la precipitación en subperíodos, en el segundo modelo (RLM2), además de las variables meteorológicas, se introdujeron los subperíodos de precipitación como variables “dummy” (Qiu et al., 2003; 2010); mientras que el tercer modelo (PCA) consistió en un análisis de componentes principales (PCA), para luego obtener otro modelo de regresión lineal múltiple (Qiu et al., 2010). Para determinar si era correcto realizar la separación de la precipitación en subperíodos, se realizó una prueba F entre el RLM1 y RLM2. Previo al análisis de componentes principales fue necesario hacer un análisis de valores extremos, para identificar que la correlación entre variables no se encontrara influenciada por estos.

### Bondad de ajuste de la predicción de los modelos del contenido de humedad del suelo

Se considera que un modelo es eficiente cuando los valores estimados se acercan sin presentar sesgos a los valores observados. Para que se considere satisfactorio el modelo, este debe cumplir con varios criterios de evaluación. Para los modelos desarrollados, se evaluó la bondad de ajuste por medio de seis diferentes medidas descritas a continuación:



### Índices de estadísticas resumidas

Las comparaciones de la media, desviación estándar, el mínimo y el máximo entre los valores estimados y los observados del contenido de la humedad del suelo, pueden proveer una información de soporte básico para evaluar el ajuste de los modelos, ya que permite identificar la cercanía de los datos estimados con respecto a los observados (Legates & McCabe, 1999; Willmott et al., 1985).

### Índice basado en correlación

El coeficiente de determinación  $R^2$  es el cuadrado del coeficiente de correlación de Pearson y representa la proporción de la varianza total en los datos observados que puede ser explicada por el modelo (McKenzie et al., 1991; Waseem et al., 2017). Tiene un rango de 0 a 1, los valores más altos indican mejor concordancia y está dado por la ecuación 4:

$$R^2 = \left\{ \frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\left[ \left( \sum_{i=1}^N (O_i - \bar{O})^2 \right)^{0.5} \left( \sum_{i=1}^N (P_i - \bar{P})^2 \right)^{0.5} \right]} \right\}^2 \quad (4)$$

Donde,  $O_i$  y  $P_i$  son la humedad de suelo observada y la estimada en el sitio  $i$ , respectivamente,  $\bar{O}$  y  $\bar{P}$  son la humedad del suelo media observada y estimada, respectivamente,  $N$  es el número de sitios.

### Índice del error absoluto medio (MAE, por sus siglas en inglés)

El índice de error absoluto medio describe la diferencia entre las estimaciones y las observaciones en las unidades de la variable (Willmott, 1981). Está dado por la ecuación 5.

$$MAE = \frac{\sum_{i=1}^N |O_i - P_i|}{N} \quad (5)$$

### Índices del error relativo

Los índices de error relativo son medidas adimensionales que permiten evaluar el desempeño del modelo. La eficiencia de Nash-Sutcliffe (E) determina la magnitud relativa de la varianza residual como ruido en comparación con la varianza de los datos medidos como información (Chuenhooklin et al., 2019). El coeficiente de eficiencia tiene un rango de menos infinito a 1, los valores más altos indican una mejor concordancia (Nash & Sutcliffe, 1970), su fórmula se describe en la ecuación 6:

$$E = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2} \quad (6)$$

### Índice de Concordancia de Willmott (d)

El índice de concordancia de Willmott (d) es la relación del error cuadrático medio y el error potencial (ecuación 7). Tiene un rango entre 0 y 1, valores más altos indican mejor concordancia entre lo estimado por el modelo y las observaciones (Willmott, 1981).

$$d = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (|P_i - \bar{O}_i| + |O_i - \bar{O}_i|)^2} \quad (7)$$

*Criterio de información de Akaike (AIC por sus siglas en inglés)*

El criterio de información de Akaike es un estadístico que permite comparar regresiones de las mismas observaciones en diferentes conjuntos de variables independientes (Webster & McBratney, 1989), la selección del modelo es en función de aquel que presente un valor menor AIC. Su fórmula se detalla en la ecuación 8.

$$AIC = N \ln (SSE) + 2Ne \quad (8)$$

Donde *Ne* es el número de variables regresoras, *N* es el número de observaciones y *SSE* es la suma del cuadrado del error, el cual está dado por la ecuación 9.

$$SSE = \sum_{i=1}^N (O_i - P_i)^2 \quad (9)$$

## Resultados

### Calibración de los sensores TDR

Se utilizaron para la calibración de los sensores TDR cuatro ecuaciones de regresión: lineal, cuadrática, cúbica y logarítmica (ecuaciones 10, 11, 12 y 13 respectivamente, en el Cuadro 2). Los modelos utilizados en la calibración tuvieron coeficientes de determinación altos ( $R^2 > 0,923$ ) y fueron altamente significativos ( $p < 0,00001$ ). Además, se evaluaron las medidas estadísticas de bondad de ajuste del índice de Willmott y la eficiencia de Nash y Sutcliffe, en los cuales la ecuación logarítmica representó los valores más altos ( $d=0,995$ ,  $E=0,995$ ). De acuerdo con el manual del fabricante del equipo, la respuesta de salida de la sonda a los cambios en el contenido de agua no es lineal y puede estar descrita por una forma cuadrática o logarítmica.

**Cuadro 2.** Ecuaciones de calibración de los sensores de reflectometría de dominio temporal (TDR) en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Table 2.** Calibration equations of time-domain reflectometry (TDR) sensors in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Ecuaciones		Coef. determinación, $R^2$	Willmott (d)	Nash y Sutcliffe (E)
$\theta_v = 0,960 * \theta_s + 0,089$	(10)	0,923	0,934	0,934
$\theta_v = -2,097 * \theta_s^2 + 2,180 * \theta_s - 0,044$	(11)	0,985	0,937	0,937
$\theta_v = 6,280 * \theta_s^3 - 7,809 * \theta_s^2 + 3,689 * \theta_s - 0,155$	(12)	0,994	0,992	0,992
$\theta_v = 0,240 * \ln(\theta_s) + 0,700$	(13)	0,991	0,995	0,995



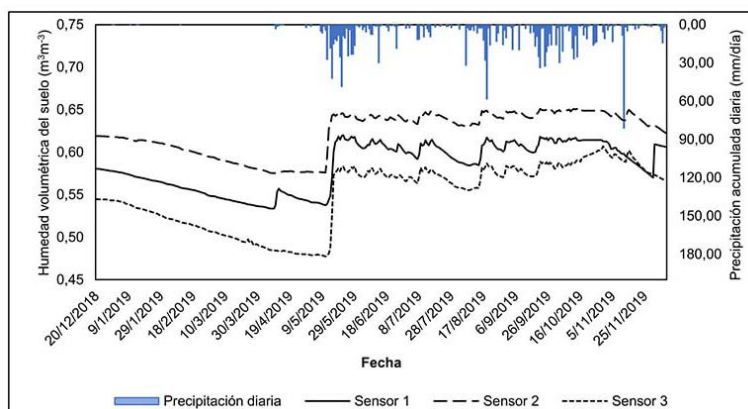
### Cambios estacionales en la humedad

Se identificó el inicio y fin de cada subperíodo de acuerdo con el régimen local de lluvias (Cuadro 3). Los valores de  $\theta_v$  variaron significativamente ( $p < 0,05$ ) entre los sensores y en los subperíodos monitoreados (Figura 2).

**Cuadro 3.** Delimitación del régimen de precipitación en subperíodos de acuerdo con el número de eventos y precipitación acumulada (mm) en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Table 3.** Precipitation regime delimitation in sub-periods according to the number of events and accumulated precipitation (mm) in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Subperíodos	Fecha de inicio	Fecha de fin	Precipitación acumulada (mm)
Seco	30-11-18	09-04-19	1,20
Seco-lluvioso	10-04-19	08-05-19	14,00
Lluvioso 1	09-05-19	15-07-19	482,40
Canícula	16-07-19	12-08-19	60,00
Lluvioso 2	13-08-19	12-11-19	773,10
Lluvioso-seco	13-11-19	08-12-19	38,8




**Figura 2.** Patrón de precipitación y humedad volumétrica del suelo en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Figure 2.** Precipitation pattern and soil volumetric humidity in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Un análisis de varianza con la prueba de Kruskal Wallis, de la humedad del suelo durante los seis subperíodos monitoreados, demostró que existieron diferencias significativas entre los subperíodos ( $H = 401,58$ ;  $p < 0,0001$ ). Los subperíodos secos ( $\theta_v = 0,56 \pm 0,04 \text{ m}^3\text{m}^{-3}$ ) y seco-lluvioso ( $\theta_v = 0,53 \pm 0,04 \text{ m}^3\text{m}^{-3}$ ) registraron la menor humedad volumétrica media. Mientras que los subperíodos lluviosos 1 ( $\theta_v = 0,60 \pm 0,04 \text{ m}^3\text{m}^{-3}$ ), canícula ( $\theta_v = 0,60 \pm 0,03 \text{ m}^3\text{m}^{-3}$ ) y lluvioso-seco ( $\theta_v = 0,60 \pm 0,03 \text{ m}^3\text{m}^{-3}$ ) no fueron significativamente diferentes; tanto la canícula como lluvioso-seco son subperíodos de transición que ocurren después de un subperíodo lluvioso. El subperíodo lluvioso 2 fue en el que mayor humedad volumétrica media registró ( $\theta_v = 0,61 \pm 0,03 \text{ m}^3\text{m}^{-3}$ ), lo cual coincide con la mayor cantidad de precipitación acumulada.

### Estabilidad temporal

El análisis de estabilidad temporal identifica los sitios muestreados donde la humedad promedio del suelo puede ser representativa de toda el área. Para la estimación de la diferencia relativa se consideraron los tres sitios monitoreados (Figura 3). Los datos se graficaron en orden para identificar los sitios donde la humedad del suelo fue sobrestimada o subestimada, con respecto al promedio. Con este análisis se identificó que el sensor 1, fue el sitio más representativo para el valor medio de humedad volumétrica a lo largo del tiempo entre los lugares donde se instalaron los sensores.



**Figura 3.** Diferencia relativa ordenada por fecha en los tres sensores instalados en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Figure 3.** Relative difference ordered by date in the three sensors installed in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Los valores para el coeficiente de correlación de Spearman cercanos a uno indican que hay una fuerte tendencia hacia la estabilidad temporal y la correlación espacial entre los subperiodos monitoreados, lo que significa que la humedad del suelo permanece similar en el tiempo durante cada subperiodo. En este análisis se buscó la correlación de la humedad media de cada subperiodo entre pares de sensores. Al haber pocos subperiodos y la diferencia de humedad entre estos es muy marcada, se encontró una relación monótona perfecta, por lo que la correlación de Spearman fue 1 en todas las combinaciones.

### Modelos de predicción de la humedad del suelo

Los modelos de regresión permiten explicar una variable de interés con base a un determinado conjunto de variables que guardan relación con esta. Las constantes del intercepto y los coeficientes de regresión de las variables independientes, para los modelos de predicción de la humedad del suelo, se detallan en el Cuadro 4.

#### Modelo de regresión lineal múltiple sin subperíodos (RLM1)

Con las variables meteorológicas se realizó un modelo de regresión lineal múltiple. El modelo obtuvo un coeficiente de determinación ( $R^2$ ) de 0,540. Los coeficientes para la lluvia acumulada diaria, la velocidad del viento y la humedad relativa en este modelo, resultaron significativos ( $p < 0,05$ ) y tuvieron una influencia significativa

**Cuadro 4.** Coeficientes estimados mediante mínimos cuadrados para tres modelos de regresión lineal múltiple en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Table 4.** Coefficients estimated through least squares for three multiple linear regression models in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Coeficientes	Modelos de regresión lineal múltiple		
	Sin subperíodos	Con subperíodos	Con análisis de componentes principales
Intercepto	0,449 ***	0,611 ***	0,595 ***
Temperatura ambiente	-0,007	0,023	-
Temperatura mínima	-0,053	-0,052	-
Temperatura máxima	0,054	0,024	-
Humedad relativa	0,003 ***	0,001 **	-
Velocidad del viento	-0,012 ***	0,000	-
Lluvia acumulada	0,000 *	0,000	-
Componente principal 1	-	-	0,000
Componente principal 2	-	-	-0,001 ***
Subperíodo lluvioso-Seco	-	-0,002	0,002
Subperíodo lluvioso 1	-	0,004	0,001
Subperíodo lluvioso 2	-	0,014 ***	0,017 ***
Subperíodo seco	-	-0,039 ***	-0,033 ***
Subperíodo seco-lluvioso	-	-0,054 ***	-0,055 ***

Nota: al ser el subperíodo una variable dummy, los modelos que incluyen esta toman como referencia la canícula. Nivel de significancia: 0 '\*\*\*\*' 0.001 '\*\*\*' 0.01 '\*\*' / Note: since the subperiod is a dummy variable, the models that include it take the heat wave as a reference. Significance level: 0 '\*\*\*\*' 0.001 '\*\*\*' 0.01 '\*\*'.

sobre la distribución de la humedad del suelo en el tiempo. Las variables Tamb, Tmax y Tmin resultaron no significativas, pero son variables meteorológicas que están asociadas con la pérdida de humedad del suelo a través de la evapotranspiración. El modelo presentó incumplimiento de supuestos (normalidad, homocedasticidad y no colinealidad), por lo que se aplicó el método de remuestreo mediante *Bootstrap* y se obtuvieron los intervalos de los coeficientes detallados en el Cuadro 5.

**Cuadro 5.** Intervalos del 95 % confianza para los coeficientes del modelo de regresión lineal múltiple sin subperíodos en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Table 5.** Confidence intervals of 95 % for the coefficients of the multiple linear regression model without subperiods in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Coeficientes	Bootstrap		Mínimos cuadrados	
	Límite inferior	Límite superior	Límite inferior	Límite superior
Intercepto	0,340	0,558	0,357	0,541
Temperatura ambiente	-0,334	0,321	-0,330	0,336
Temperatura mínima	-0,230	0,123	-0,234	0,118
Temperatura máxima	-0,104	0,212	-0,115	0,209
Humedad relativa	0,002	0,004	0,002	0,004
Velocidad del viento	-0,021	-0,011	-0,021	-0,011
Lluvia acumulada	0,000	0,001	0,000	0,001

### Modelo de regresión lineal múltiple con subperíodos (RLM2)

Para este modelo de regresión se obtuvo un coeficiente de determinación ( $R^2$ ) de 0,838, lo que evidenció que el régimen de precipitación clasificado en subperíodos fue una variable importante. Se realizó una prueba formal mediante un Test F, en el que se consideró como hipótesis nula que el modelo con los subperíodos explica lo mismo que el modelo sin los subperíodos. Esta prueba determinó que, con un nivel de significancia de  $\alpha=0,05$ , hubo suficiente evidencia para rechazar la hipótesis nula, ya que la probabilidad de cometer error tipo I fue menor a 0,05. Debido al incumplimiento de supuestos se utilizó la técnica no paramétrica de *bootstrap* (Cuadro 6). Los intervalos mediante este método indicaron que las estimaciones del modelo no estuvieron afectadas por este incumplimiento.

**Cuadro 6.** Intervalos del 95 % confianza para los coeficientes del modelo de regresión lineal múltiple con subperíodos en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

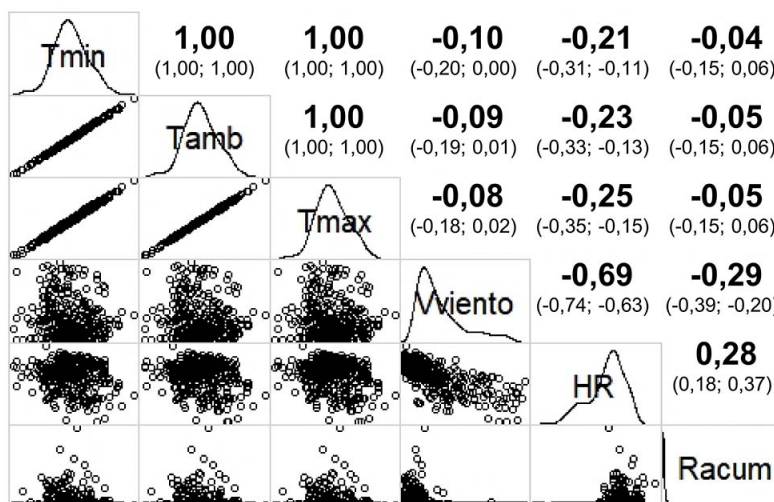
**Table 6.** Confidence intervals of 95 % for the coefficients of the multiple linear regression model with subperiods in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Coeficientes	Bootstrap		Mínimos cuadrados	
	Límite inferior	Límite superior	Límite inferior	Límite superior
Intercepto	0,527	0,695	0,543	0,677
Temperatura ambiente	-0,176	0,221	-0,147	0,216
Temperatura mínima	-0,159	0,055	-0,153	0,043
Temperatura máxima	-0,072	0,120	0,068	0,109
Humedad relativa	0,000	0,002	0,000	0,002
Velocidad del viento	-0,003	0,003	-0,003	0,003
Lluvia acumulada	0,000	0,000	0,000	0,000
Subperíodo lluvioso-seco	-0,009	0,005	-0,007	0,002
Subperíodo lluvioso 1	-0,002	0,009	-0,002	0,008
Subperíodo lluvioso 2	0,008	0,019	0,010	0,017
Subperíodo seco	-0,046	-0,033	-0,045	-0,033
Subperíodo seco-lluvioso	-0,061	-0,047	-0,059	-0,048

### Modelo de regresión múltiple con componentes principales (PCA)

Para realizar el análisis de componentes principales, se observaron las correlaciones entre las variables (Figura 4). Las variables  $T_{amb}$ ,  $T_{max}$  y  $T_{min}$  presentaron una relación lineal perfecta. Existió una correlación alta entre humedad relativa y la velocidad del viento. Para el caso de la lluvia acumulada, esta no tuvo una relación alta con ninguna de las otras variables. Para efectos de este análisis se eliminaron los subperíodos, puesto que solo se utilizaron las variables continuas.

Previo a proceder con la construcción de los PCA, se identificaron dieciséis valores extremos, los cuales no generaron variaciones significativas en las correlaciones, por lo que no fueron excluidos. Se determinaron los componentes principales y para la regresión lineal se utilizaron los dos primeros componentes, ya que representaron



**Figura 4.** Correlaciones entre las variables meteorológicas (354 observaciones en cada variable) en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Figure 4.** Correlations between meteorological variables (354 observations in each variable) in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

el 97 % de la variabilidad explicada. De acuerdo con la matriz de vectores obtenida en la descomposición espectral de la varianza, el mayor peso en la construcción de los componentes lo aportó la lluvia acumulada, seguido de la humedad relativa (Cuadro 7).

**Cuadro 7.** Coeficientes de los dos primeros componentes obtenidos en el análisis de componentes principales en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Table 7.** Coefficients of the first two components obtained in the principal component analysis in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Variable	Componente principal 1	Componente principal 2
Temperatura ambiente	0,007	0,062
Temperatura máxima	0,007	0,067
Temperatura mínima	0,006	0,057
Humedad relativa	-0,165	-0,975
Velocidad del viento	0,025	0,098
Lluvia acumulada	-0,986	0,167

En la regresión lineal múltiple se utilizaron como predictores dos variables numéricas las cuales fueron el componente principal 1 y el componente principal 2, mientras que los subperiodos se incluyeron como variables “dummy”. El modelo obtuvo un coeficiente de determinación ( $R^2$ ) de 0,823. Al igual que en los dos modelos anteriores, se realizaron mil remuestreos y se obtuvieron los intervalos mediante el método de *bootstrap* para los coeficientes (Cuadro 8).

**Cuadro 8.** Intervalos del 95 % confianza para los coeficientes del modelo de regresión lineal múltiple con análisis de componentes principales en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Table 8.** Confidence intervals of 95 % for the coefficients of the multiple linear regression model with principal component analysis in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Coeficientes	Bootstrap		Mínimos cuadrados	
	Límite inferior	Límite superior	Límite inferior	Límite superior
Intercepto	0,591	0,600	0,593	0,598
Componente principal 1	0,000	0,000	0,000	0,000
Componente principal 2	-0,002	-0,001	-0,002	-0,001
Subperíodo lluvioso-seco	-0,005	0,008	-0,002	0,005
Subperíodo lluvioso 1	-0,004	0,007	-0,004	0,007
Subperíodo lluvioso 2	0,011	0,023	0,014	0,020
Subperíodo seco	-0,039	-0,027	-0,038	-0,027
Subperíodo seco-lluvioso	-0,063	-0,048	-0,060	-0,050

### Bondad de ajuste de la predicción de los modelos del contenido de humedad del suelo

Las estadísticas de resumen entre la humedad del suelo predicha y observada indicaron que no se encontró diferencia entre la media observada y la predicha para los tres modelos (Cuadro 9). Un comportamiento similar sucedió con el contenido de humedad del suelo máximo y mínimo predicho y el observado, en los cuales la variación fue mínima.


**Cuadro 9.** Estadísticos de resumen entre la humedad de suelo predicha en los tres modelos y la humedad de suelo observada en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Table 9.** Summary statistics between the predicted soil moisture in the three models and the observed soil moisture in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Estadísticos resumen	Regresiones lineales múltiples			Humedad del suelo observada
	Sin subperíodo	Con subperíodos	Con análisis de componentes principales	
Máximo	0,624	0,622	0,617	0,623
Mínimo	0,512	0,522	0,526	0,530
Media	0,585	0,585	0,585	0,585
Desviación estándar	0,022	0,028	0,027	0,030

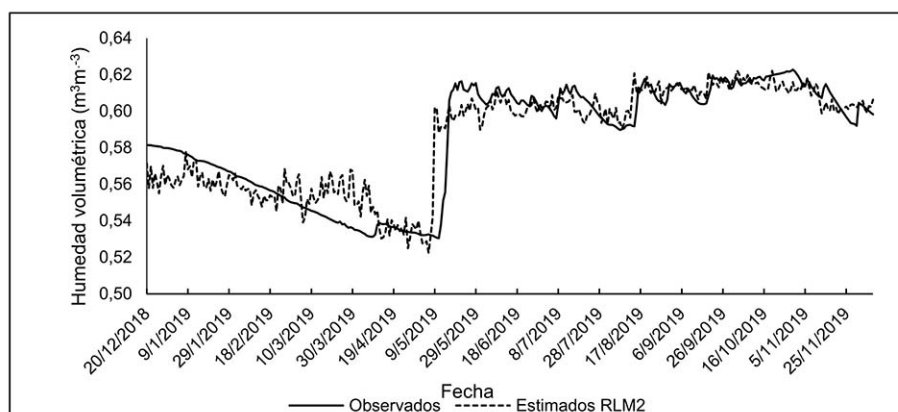
El coeficiente de determinación ( $R^2$ ) describió la proporción del total de la variación de la humedad del suelo explicada por las variables ambientales en cada uno de los modelos. Las variables ambientales explicaron el 54 % de la variabilidad de la humedad del suelo en el RLM1 (Figura 5). Mientras que para el modelo RLM2 (Figura 6), las variables ambientales y la clasificación en subperíodos de la precipitación permitieron explicar un 84 % esta variabilidad. El modelo PCA alcanzó el 82 % de coeficiente de determinación con el análisis de componentes principales (Figura 7).





**Figura 5.** Contenido de humedad del suelo observado y estimado mediante el modelo RLM1 (modelo de regresión lineal múltiple sin subperiodos) en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

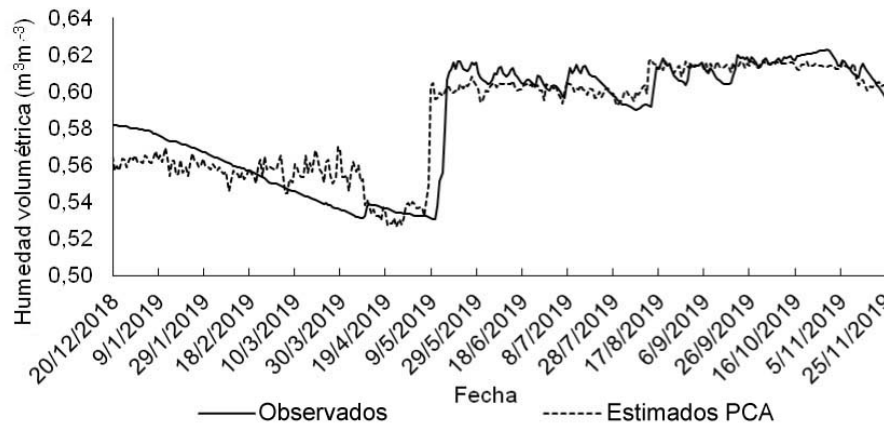
**Figure 5.** Soil moisture content observed and estimated through the RLM1 model (multiple linear regression model without subperiods) in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.



**Figura 6.** Contenido de humedad del suelo observado y estimado mediante el modelo RLM2 (modelo de regresión lineal múltiple con subperiodos) en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Figure 6.** Soil moisture content observed and estimated through the model RLM2 (multiple linear regression model with subperiods) in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

A pesar de que no hubo diferencias importantes entre los modelos RLM2 y PCA, el modelo RLM2 fue el que presentó el menor valor de MAE, contrario al RLM1 que tuvo el valor más alto. Con respecto al criterio de información de Akaike (AIC), el valor más bajo lo proporcionó el modelo RLM2. En relación con las medidas adimensionales ( $E$  y  $d$ ), los modelos RLM2 y PCA fueron muy similares entre sí y presentaron valores más cercanos a 1 a diferencia del modelo RLM1 (Cuadro 10). Los indicadores de los modelos RLM2 y PCA presentaron un buen ajuste; sin embargo, el mejor modelo fue el RLM2, esto se debió a que los predictores no estaban correlacionados entre sí, independiente de las temperaturas las cuales aportaron poca información al modelo.



**Figura 7.** Contenido de humedad del suelo observado y estimado mediante el modelo PCA (modelo de regresión lineal múltiple con análisis de componentes principales) en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Figure 7.** Soil moisture content observed and estimated through the model PCA (multiple linear regression model with principal component analysis) in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Cuadro 10.** Índices de bondad de ajuste para los tres modelos de regresión lineal múltiple en Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

**Table 10.** Goodness-of-fit indices for the three multiple linear regression models in Llano Brenes, Alajuela, Costa Rica, 2018 - 2019.

Índices de bondad de ajuste	Modelos de regresión lineal múltiple		
	Sin subperíodos	Con subperíodos	Con análisis de componentes principales
Coef. de determinación ( $R^2$ )	0,540	0,838	0,823
Error absoluto medio (MAE)	0,324	0,173	0,179
Criterio de información de Akaike (AIC)	-2740,918	-3100,146	-3075,994
Eficiencia de Nash y Sutcliffe (E)	0,540	0,842	0,823
Índice de concordancia Willmott (d)	0,655	0,842	0,835

## Discusión

Los modelos obtenidos para predecir la humedad de suelo diaria a escala de cultivo presentaron resultados óptimos con el uso de datos meteorológicos. El modelo RLM1 pudo explicar el 54 % de la variación total en la humedad del suelo, mientras que el modelo RLM2 pudo explicar el 84 %, lo que implicó una gran mejora. El modelo PCA pudo explicar el 82 %. Los modelos RLM2 y PCA presentaron los mejores indicadores de bondad de ajuste a diferencia del modelo RLM1 (Cuadro 10). Sin embargo, el modelo PCA, al tener variables correlacionadas ( $T_{amb}$ ,  $T_{max}$ ,  $T_{min}$ ), no presentó una mejora en comparación con el modelo RLM2, cuyo desarrollo fue más simple, por tanto, sería el recomendado bajo las características del sitio de estudio.

La capacidad explicativa del modelo RLM2, se encuentra dada por la separación de la precipitación en subperíodos de acuerdo con el régimen de lluvias, esto debido a que las variaciones estacionales en el contenido de humedad volumétrica del suelo tienden a seguir las variaciones de la precipitación, lo cual concuerda con lo

expuesto por Huang et al. (2016), Sacardi Biudes et al. (2015), y Sun et al. (2015). En el presente estudio, la humedad del suelo se incrementó después de las primeras lluvias y presentó a lo largo del tiempo un patrón similar. Los datos para la humedad volumétrica fueron más altos durante los subperíodos lluvioso1 y lluvioso2 y más bajos durante los subperíodos seco y seco-lluvioso.

En el modelo RLM2, los coeficientes para los subperiodos lluvioso-seco, seco-lluvioso y seco fueron negativos, ya que el suelo tuvo menor humedad por el cambio o la transición en el patrón de precipitaciones, por lo que el signo positivo o negativo de los coeficientes de regresión de las variables reflejan su relación con la humedad del suelo (Qiu et al., 2001). Además, el contenido de humedad del suelo también está influenciado por la humedad relativa, ya que esta, en conjunto con otras variables meteorológicas, está asociada con la pérdida de humedad del suelo por la evapotranspiración (Qiu et al., 2003; García et al., 2016).

Las estimaciones realizadas fueron para humedad del suelo a 0,30 m de profundidad, por lo que los factores meteorológicos (con alta variación temporal y baja espacial en escala de cultivo) juegan una influencia más significativa en la humedad superficial del suelo, lo cual coincide con lo indicado por Qiu et al. (2003), quienes concluyen que existe una influencia decreciente de la humedad del suelo con respecto a los factores meteorológicos conforme aumenta la profundidad del suelo. Por lo que una recomendación del presente estudio es realizar investigaciones que incluyan mediciones a diferentes profundidades de suelo.

Con respecto a la calibración de los sensores, todas las ecuaciones de regresión tuvieron altos coeficientes de determinación ( $R^2 > 0,923$ ), pero la ecuación logarítmica fue la que presentó el mejor ajuste y, por ende, una corrección más precisa de los datos medidos con los sensores comparados con la humedad volumétrica del suelo observada. Lo cual coincide con lo observado en el estudio de Dong et al. (2020), quienes presentaron curvas de calibración para suelos franco arcillo arenosos con sensores CS616, ajustadas a funciones logarítmicas con un coeficiente de determinación de  $R^2 0,94$ . Además de la calibración, la técnica de instalación de los sensores de humedad del suelo también es muy importante, debido a que es necesario un buen contacto entre el sensor y el suelo para evitar crear espacios de aire (Walker et al., 2004).

El análisis de estabilidad temporal mostró que el sensor 1 reproduce el patrón medio de la humedad volumétrica en el sitio y presentó valores pequeños de desviación estándar, por lo que se consideró el sitio más representativo. El análisis de estabilidad temporal resulta útil, debido a que es posible predecir la humedad del suelo en una gran escala a través de pocas observaciones, mediante un análisis de regresión entre los valores muestreados en el sitio más representativo y la humedad media del suelo (Brocca et al., 2010). En este estudio se obtuvo una correlación de Spearman de uno entre todos los subperíodos, lo cual indica una alta estabilidad de la humedad en campo. En general, esta correlación demostró que los patrones de humedad de suelo para el área de estudio tuvieron una alta dependencia temporal y fueron persistentes entre todos los subperiodos (de Queiroz et al., 2020).

## Conclusiones

Con base en el análisis y los resultados reportados en este estudio, se concluye que fue factible simular la humedad media del suelo con variables meteorológicas a nivel de cultivo, mediante técnicas de regresión lineal. La facilidad de obtención de las variables permite generar estimaciones de humedad de suelo con menor complejidad. El modelo RLM2 presentó mejores indicadores de bondad de ajuste, un mayor coeficiente de determinación y un desarrollo más simple, por lo que es el modelo recomendado de acuerdo con las condiciones del área de estudio.

A pesar de que las ecuaciones de calibración de los sensores presentaron altos valores de coeficiente de determinación, es muy importante evaluar la bondad de ajuste bajo diferentes índices, tales como los utilizados en el presente estudio, entre ellos, los índices de estadísticas resumidas que permiten visualizar la cercanía de los valores estimados y los observados del contenido de la humedad del suelo y seleccionar la ecuación que presente menor variación entre los dos conjuntos de datos.

El análisis de estabilidad temporal permitió identificar la persistencia de patrones espaciales y el comportamiento de la humedad de suelo; además del sensor que reprodujo el patrón medio de la humedad volumétrica en el sitio. También se identificó que existe una correlación perfecta (1) entre la humedad del suelo y los subperíodos en el área de estudio, lo cual respalda la importancia de la clasificación de la precipitación según su patrón estacional.

## Agradecimientos

Los autores expresan su agradecimiento a la Secretaría de Educación Superior, Ciencia, Tecnología e Innovación del Ecuador (SENESCYT), a la Comisión Asesora sobre Degradación de Tierras (CADETI) del Ministerio de Agricultura de Costa Rica y al Centro de Investigaciones Agronómicas (CIA) de la Universidad de Costa Rica por el aporte financiero y logístico. También agradecen a la Unidad de Manejo de Información de la Gerencia Técnica del Instituto del Café de Costa Rica (ICAFE) por proveer datos meteorológicos complementarios a los medidos en este estudio. Se extiende el agradecimiento a José Jiménez (†) por su colaboración en la instalación de los equipos y por permitir realizar el presente trabajo en su finca.

## Referencias

- Amarasinghe, U. A., Hoanh, C. T., D'haeze, D., & Hung, T. Q. (2015). Toward sustainable coffee production in Vietnam: More coffee with less water. *Agricultural Systems*, *136*, 96–105. <https://doi.org/10.1016/j.agsy.2015.02.008>
- Antonucci, F., Pallottino, F., Costa, C., Rimatori, V., Giorgi, S., Papetti, P., & Menesatti, P. (2011). Development of a rapid soil water content detection technique using active infrared thermal methods for in-field applications. *Sensors*, *11*(11), 10114–10128. <https://doi.org/10.3390/s111110114>
- Bishara, A. J., & Hittner, J. B. (2017). Confidence intervals for correlations when data are not normal. *Behavior Research Methods*, *49*, 294–309. <https://doi.org/10.3758/s13428-016-0702-8>
- Brocca, L., Ciabatta, L., Massari, C., Camici, S., & Tarpanelli, A. (2017). Soil moisture for hydrological applications: Open questions and new opportunities. *Water*, *9*(2), Article 140. <https://doi.org/10.3390/w9020140>
- Brocca, L., Melone, F., Moramarco, T., & Morbidelli, R. (2009). Soil moisture temporal stability over experimental areas in Central Italy. *Geoderma*, *148*(3–4), 364–374. <https://doi.org/10.1016/j.geoderma.2008.11.004>
- Brocca, L., Melone, F., Moramarco, T., & Morbidelli, R. (2010). Spatial-temporal variability of soil moisture and its estimation across scales. *Water Resources Research*, *46*(2), Article 8016. <https://doi.org/10.1029/2009WR008016>
- Campbell Sci. (2020). *CS616 and CS625 water content reflectometers*. Campbell Scientific, Inc.
- Campbell Sci. Inc. (2016). *CR800 Series Dataloggers*. Campbell Scientific, Inc.
- Chen, L., Messing, I., Zhang, S., Fu, B., & Ledin, S. (2003). Land use evaluation and scenario analysis towards sustainable planning on the Loess Plateau in China—Case study in a small catchment. *CATENA*, *54*(1–2), 303–316. [https://doi.org/10.1016/S0341-8162\(03\)00071-7](https://doi.org/10.1016/S0341-8162(03)00071-7)
- Chuenchooklin, S., Pangnakorn, U., & Soonthornnonda, P. (2019). Comparative study using the 2-hydrological models with the global weather in a small watershed, a case study in the upper Tha Chin River Basin, Thailand. *World Journal of Engineering and Technology*, *7*(2), 21–26. <https://doi.org/10.4236/wjet.2019.72B003>

- Crow, W. T., & Yilmaz, M. T. (2014). The Auto-Tuned Land Data Assimilation System (ATLAS). *Water Resources Research*, 50(1), 371–385. <https://doi.org/10.1002/2013WR014550>
- de Queiroz, M. G., Freire da Silva, T. G., Zolnier, S., da Rosa Ferraz Jardim, A. M., de Alves Souza, C. A., do Nascimento Araújo Júnior, G., Florentino de Moraes, J. E., & Bastos de Souza, L. S. (2020). Spatial and temporal dynamics of soil moisture for surfaces with a change in land use in the semi-arid region of Brazil. *CATENA*, 188, Article 104457. <https://doi.org/10.1016/j.catena.2020.104457>
- Devore, J. L., & Berk, K. N. (2012). *Modern mathematical statistics with applications*. Springer. <https://doi.org/10.1007/978-1-4614-0391-3>
- Dong, Y., Miller, S., & Kelley, L. (2020). Performance evaluation of soil moisture sensors in coarse- and fine-textured Michigan agricultural soils. *Agriculture*, 10(12), Article 598. <https://doi.org/10.3390/agriculture10120598>
- Forkuor, G., Hounkpatin, O. K. L., Welp, G., & Thiel, M. (2017). High resolution mapping of soil properties using remote sensing variables in South-Western Burkina Faso: A comparison of machine learning and multiple linear regression models. *PLoS ONE*, 12(1), Article e0170478. <https://doi.org/10.1371/journal.pone.0170478>
- García, G., Brogioni, M., Venturini, V., Rodríguez, L., Walker, E., & Graciani, S. (2016). Determinación de la humedad de suelo mediante regresión lineal múltiple con datos TerraSAR-X. *Revista de la Asociación Española de Teledetección*, 46, 73–81. <http://doi.org/10.4995/raet.2016.4024>
- Heathman, G. C., Cosh, M. H., Han, E., Jackson, T. J., McKee, L., & McFee, S. (2012). Field scale spatiotemporal analysis of surface soil moisture for evaluating point-scale in situ networks. *Geoderma*, 170, 195–205. <https://doi.org/10.1016/j.geoderma.2011.11.004>
- Heathman, G. C., Starks, P. J., Ahuja, L. R., & Jackson, T. J. (2003). Assimilation of surface soil moisture to estimate profile soil water content. *Journal of Hydrology*, 279(1–4), 1–17. [https://doi.org/10.1016/S0022-1694\(03\)00088-X](https://doi.org/10.1016/S0022-1694(03)00088-X)
- Huang, X., Shi, Z. H., Zhu, H. D., Zhang, H. Y., Ai, L., & Yin, W. (2016). Soil moisture dynamics within soil profiles and associated environmental controls. *CATENA*, 136, 189–196. <https://doi.org/10.1016/j.catena.2015.01.014>
- Instituto Meteorológico Nacional. (2017). *Estudio de cuencas hidrográficas de Costa Rica. Cuenca río Jesús María*. <http://cglobal.imn.ac.cr/documentos/publicaciones/EstudioCuencas/EstudioCuencas-cuencaRioJesusMaria.pdf>
- Kargas, G., & Soulis, K. X. (2012). Performance analysis and calibration of a new low-cost capacitance soil moisture sensor. *Journal of Irrigation and Drainage Engineering*, 138(7), 632–641. [https://doi.org/10.1061/\(ASCE\)IR.1943-4774.0000449](https://doi.org/10.1061/(ASCE)IR.1943-4774.0000449)
- Khan, M. A., Kakar, E., Baloch, D. M., & Azad, S. U. D. (2011). Calibration of Time Domain Reflectometry (TDR) soil moisture point probe for two soils. *Journal of Applied and Emerging Sciences*, 2(1), 19–26.
- Legates, D. R., & McCabe, G. J. (1999). Evaluating the use of “goodness-of-fit” Measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1), 233–241. <https://doi.org/10.1029/1998WR900018>
- Martínez-Fernández, J., & Ceballos, A. (2005). Mean soil moisture estimation using temporal stability analysis. *Journal of Hydrology*, 312(1–4), 28–38. <https://doi.org/10.1016/j.jhydrol.2005.02.007>
- Masarirambi, M. T., Chingwara, V., & Shongwe, V. D. (2009). The effect of irrigation on synchronization of coffee (*Coffea arabica* L.) flowering and berry ripening at Chipinge, Zimbabwe. *Physics and Chemistry of the Earth, Parts A/B/C*, 34(13), 786–789. <https://doi.org/10.1016/j.pce.2009.06.013>

- McKenzie, N., & Austin, M. P. (1993). A quantitative Australian approach to medium and small scale surveys based on soil stratigraphy and environmental correlation. *Geoderma*, 57(4), 329–355. [https://doi.org/10.1016/0016-7061\(93\)90049-Q](https://doi.org/10.1016/0016-7061(93)90049-Q)
- Mckenzie, N. J., & Macleod, D. A. (1989). Relationships between soil morphology and soil properties relevant to irrigated and dryland agriculture. *Soil Research*, 27(2), 235–258. <https://doi.org/10.1071/sr9890235>
- McKenzie, N. J., & Ryan, P. J. (1999). Spatial prediction of soil properties using environmental correlation. *Geoderma*, 89(1), 67–94. [https://doi.org/10.1016/S0016-7061\(98\)00137-2](https://doi.org/10.1016/S0016-7061(98)00137-2)
- McKenzie, N., Smettem, J., & Ringrose-Voase, A. J. (1991). Evaluation of methods for inferring air and water properties of soils from field morphology. *Australian Journal of Soil Research*, 29(5), 587–602. <https://doi.org/10.1071/SR9910587>
- Mojid, M. A., & Cho, H. (2002). Response of the core and shield rods of time-domain reflectometry probe to transverse soil-water content heterogeneity. *Journal of Hydrology*, 262(1–4), 21–27. [https://doi.org/10.1016/S0022-1694\(01\)00604-7](https://doi.org/10.1016/S0022-1694(01)00604-7)
- Molina-Campos, E. (2015). *Determinación y cuantificación de la tasa de erosión laminar en cafetales ubicados en la cuenca del Río Jesús María* [Tesis de Grado, no publicada]. Universidad de Costa Rica.
- Montoani Silva, B., Oliveira, G. C., Serafim, M. E., Silva, É. A., Gontijo Guimarães, P. T., Batista Melo, L. B., Darrell Norton, L., & Curi, N. (2019). Soil moisture associated with least limiting water range, leaf water potential, initial growth and yield of coffee as affected by soil management system. *Soil and Tillage Research*, 189, 36–43. <https://doi.org/10.1016/j.still.2018.12.016>
- Naranjo, M. E., & Ataroff, M. (2015). Calibración de equipos TDR para su uso en suelos no disturbados. *Interciencia*, 40(6), 416–422.
- Nash, J., & Sutcliffe, J. (1970). River flow forecasting through conceptual models part I — A discussion of principles. *Journal of Hydrology*, 10(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Parker, R. I. (2006). Increased reliability for single-case research results: Is the bootstrap the answer? *Behavior Therapy*, 37(4), 326–338. <https://doi.org/10.1016/j.beth.2006.01.007>
- Qiu, Y., Fu, B., Wang, J., & Chen, L. (2001). Spatial variability of soil moisture content and its relation to environmental indices in a semi-arid gully catchment of the Loess Plateau, China. *Journal of Arid Environments*, 49(4), 723–750. <https://doi.org/10.1006/jare.2001.0828>
- Qiu, Y., Fu, B., Wang, J., & Chen, L. (2003). Spatiotemporal prediction of soil moisture content using multiple-linear regression in a small catchment of the Loess Plateau, China. *CATENA*, 54(1-2), 173–195. [https://doi.org/10.1016/S0341-8162\(03\)00064-X](https://doi.org/10.1016/S0341-8162(03)00064-X)
- Qiu, Y., Fu, B., Wang, J., Chen, L., Meng, Q., & Zhang, Y. (2010). Spatial prediction of soil moisture content using multiple-linear regressions in a gully catchment of the Loess Plateau, China. *Journal of Arid Environments*, 73(2), 208–220. <https://doi.org/10.1016/j.jaridenv.2009.08.003>
- R Core Team. (2020). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing. <https://www.R-project.org/>
- Robinson, D. A., Jones, S. B., Wraith, J. M., Or, D., & Friedman, S. P. (2003). A Review of advances in dielectric and electrical conductivity measurement in soils using Time Domain Reflectometry. *Vadose Zone Journal*, 2(4), 444–475. <https://doi.org/10.2136/vzj2003.4440>



- Russell, C. J., & Dean, M. A. (2000). To log or not to log: bootstrap as an alternative to the parametric estimation of moderation effects in the presence of skewed dependent variables. *Organizational Research Methods*, 3(2), 166–185. <https://doi.org/10.1177%2F109442810032002>
- Sacardi Biudes, M., Vourlitis, G. L., Gomes Machado, N., Zanella de Arruda, P. H., Rodrigues Neves, G. A., de Almeida Lobo, F., Usher Neale, C. M., & de Souza Nogueira, J. (2015). Patterns of energy exchange for tropical ecosystems across a climate gradient in Mato Grosso, Brazil. *Agricultural and Forest Meteorology*, 202, 112–124. <https://doi.org/10.1016/j.agrformet.2014.12.008>
- Soil Survey Staff. (2014). *Keys to soil taxonomy*. United States Department of Agriculture.
- Sun, F., Lü, Y., Wang, J., Hu, J., & Fu, B. (2015). Soil moisture dynamics of typical ecosystems in response to precipitation: A monitoring-based analysis of hydrological service in the Qilian Mountains. *CATENA*, 129, 63–75. <https://doi.org/10.1016/j.catena.2015.03.001>
- Tebbs, E., Gerard, F., Petrie, A., & De Witte, E. (2016). Emerging and potential future applications of satellite-based soil moisture products. In P. K. Srivastava, G. P. Petropoulos, & Y. H. Kerr (Eds.), *Satellite Soil Moisture Retrieval* (Chapter 19, pp. 379–400). Elsevier. <https://doi.org/10.1016/B978-0-12-803388-3.00019-X>
- Udawatta, R. P., Anderson, S. H., Motavalli, P. P., & Garrett, H. E. (2011). Calibration of a water content reflectometer and soil water dynamics for an agroforestry practice. *Agroforestry Systems*, 82(1), 61–75. <https://doi.org/10.1007/s10457-010-9362-3>
- Walker, J. P., Willgoose, G. R., & Kalma, J. D. (2004). *In situ* measurement of soil moisture: A comparison of techniques. *Journal of Hydrology*, 293(1–4), 85–99. <https://doi.org/10.1016/j.jhydrol.2004.01.008>
- Waseem, M., Mani, N., Andiego, G., & Usman, M. (2017). A review of criteria of fit for hydrological models. *International Research Journal of Engineering and Technology*, 4(11), 1765–1772.
- Webster, R., & McBratney, A. B. (1989). On the Akaike information criterion for choosing models for variograms of soil properties. *Journal of Soil Science*, 40(3), 493–496. <https://doi.org/10.1111/j.1365-2389.1989.tb01291.x>
- Were, K., Bui, D. T., Dick, Ø. B., & Singh, B. R. (2015). A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping soil organic carbon stocks across an Afromontane landscape. *Ecological Indicators*, 52, 394–403. <https://doi.org/10.1016/j.ecolind.2014.12.028>
- Willmott, C. J. (1981). On the validation of models. *Physical Geography*, 2(2), 184–194. <https://doi.org/10.1080/02723646.1981.10642213>
- Willmott, C. J., Ackleson, S. G., Davis, R. E., Feddema, J. J., Klink, K. M., Legates, D. R., O'Donnell, J., & Rowe, C. M. (1985). Statistics for the evaluation and comparison of models. *Journal of Geophysical Research: Oceans*, 90(C5), 8995–9005. <https://doi.org/10.1029/JC090iC05p08995>
- Zaman, B., & McKee, M. (2014). Spatio-temporal prediction of root zone soil moisture using multivariate relevance vector machines. *Open Journal of Modern Hydrology*, 4(3), 80–90. <https://doi.org/10.4236/ojmh.2014.43007>
- Zheng, W., Zhangzhong, L., Zhang, X., Wang, C., Zhang, S., Sun, S., & Niu, H. (2017, August 12-15). *A review on the soil moisture prediction model and its application in the information system* [Conferencia internacional]. International Conference on Computer and Computing Technologies in Agriculture, Jilin, China. [https://doi.org/10.1007/978-3-030-06137-1\\_32](https://doi.org/10.1007/978-3-030-06137-1_32)
- Zucco, G., Brocca, L., Moramarco, T., & Morbidelli, R. (2014). Influence of land use on soil moisture spatial–temporal variability and monitoring. *Journal of Hydrology*, 516, 193–199. <https://doi.org/10.1016/j.jhydrol.2014.01.043>