

SISTEMA DE ASESORAMIENTO AL REGANTE (SAR). ¿CUÁNDO REGAR Y CUÁNTO REGAR? LAS TECNOLOGÍAS DE INFORMACIÓN Y COMUNICACIÓN (TICs) COMO HERRAMIENTAS PARA FORTALECER LA CAPACIDAD DE LA TOMA DE DECISIONES DE LA AGRICULTURA FAMILIAR

AgTech 19037, Contrato C-RG-T3387-P002

Producto 4. Nota técnica con el informe técnico sobre el ajuste de datos de humedad de suelo obtenidos por diferentes tipos de sensores.

Gabriel A. Angella
Juana M. López
Claudio García
Luis M. Urbina Urbina
Carolina P. Frías
César Acevedo Narváez
Irving Paredes Martínez
Oscar Castillo Mendoza
Gabriela Barraza
Juan Rufail

2023



Códigos JEL: Q16

FONTAGRO (Fondo Regional de Tecnología Agropecuaria) es un programa de cooperación administrado por el Banco Interamericano de Desarrollo (BID), pero con su propia membresía, estructura de gobernabilidad y activos. Las opiniones expresadas en esta publicación son de los autores y no necesariamente reflejan el punto de vista del Banco Interamericano de Desarrollo, FONTAGRO, de sus Directorios Ejecutivos ni de los países que representan.

El presente documento ha sido preparado por: Gabriel Angella, Juana López, Carolina Frías, Gabriela Barraza, Juan Rufail (INTA de Argentina); Luis M. Urbina Urbina, César Acevedo Narvárez, Irving Paredes Martínez, Oscar Castillo Mendoza (INTA de Nicaragua); Claudio García (INIA de Uruguay).

Copyright © 2023 Banco Interamericano de Desarrollo. Esta obra se encuentra sujeta a una licencia Creative Commons IGO 3.0 Reconocimiento-NoComercial- SinObrasDerivadas (CC-IGO 3.0 BY-NC-ND) (<http://creativecommons.org/licenses/by-nc-nd/3.0/igo/legalcode>) y puede ser reproducida para cualquier uso no comercial otorgando el reconocimiento respectivo al BID. No se permiten obras derivadas. Cualquier disputa relacionada con el uso de las obras del BID que no pueda resolverse amistosamente se someterá a arbitraje de conformidad con las reglas de la CNUDMI (UNCITRAL). El uso del nombre del BID para cualquier fin distinto al reconocimiento respectivo y el uso del logotipo del BID no están autorizados por esta licencia CC-IGO y requieren de un acuerdo de licencia adicional. Note que el enlace URL incluye términos y condiciones adicionales de esta licencia.

Esta publicación puede solicitarse a:

FONTAGRO

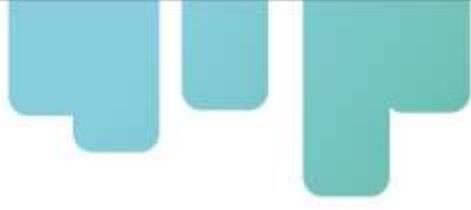
Correo electrónico: fontagro@fontagro.org





Índice

Abstract	4
Key words	4
Resumen ejecutivo	4
Palabras clave	5
Introducción	5
Consideraciones teóricas	6
Medición de humedad del suelo	8
Métodos directos	8
Métodos indirectos	10
Materiales y métodos	14
Calibración y validación de datos de humedad de suelo obtenidos mediante sensores de campo	14
Calibración y validación de datos de humedad de suelo obtenidos mediante sensores remotos	17
Resultados y discusión	22
Sensores de campo	22
Sensores remotos	27
Conclusiones	30
Referencias bibliográficas	32
Instituciones participantes	35



Abstract

This Technical Note corresponds to Product 4 of the Project, “Technical note with the technical report on the adjustment of soil moisture data obtained by different types of sensors.” Product 4 is part of Component 2 “Development of a study on the SAR’s Information Technologies System (ICTs)” and Activity 2.1 “Calibrate and validate soil moisture data obtained through field and remote sensors.”

Monitoring the water content in the soil is essential to make an efficient use of water, reduce environmental impacts and make better decisions in irrigation scheduling, that is, determining when and how much to irrigate. Precisely defining the irrigation depths helps to reduce water losses or avoid subirrigation. The methods used to measure water in soil are classified as direct and indirect. The direct method is the gravimetric method, against which the indirect methods are adjusted. Among the indirect field methods are the capacitance sensors. Remote sensors provide detailed, real-time information on soil, crop and environmental conditions. The combination of remote sensors with machine learning models provides a comprehensive platform to help irrigation scheduling. Current approaches mainly point to two categories: those based on active or passive microwave remote sensing, and those based on optical remote sensing (i.e., shortwave radiation and thermal radiation). Machine learning (ML) offers alternative approaches.


The capacitance sensors used in the project had a very good performance, without changing the factory calibration equation. The average values of the indicators were the following: R^2 0.757, RMSE 0.020 $m^3 m^{-3}$ and NRMSE 5.28%. The adjustment between observed and estimated values could be improved (especially R^2) by reviewing the installation of the sensors and having a greater range of soil moisture data for calibration and validation. The Gradient Boosting Tree (GBT) algorithm had a good performance in predicting soil moisture from data of texture and bulk density of soils and spectral indices, obtaining an RMSE of 3.46%. Other variables can be incorporated into the model, always seeking to maintain a balance between the precision of the predictions and the requirement for input data.

Key words: irrigation, soil moisture sensors, remote sensing, calibration, validation.

Resumen ejecutivo

La presente Nota Técnica corresponde al Producto 4 del Proyecto, “Nota técnica con el informe técnico sobre el ajuste de datos de humedad de suelo obtenidos por diferentes tipos de sensores”. El Producto 4 es parte del Componente 2 “Desarrollo de un estudio de un Sistema de Tecnologías de la Información (TICs) del SAR” y de la Actividad 2.1 “Calibrar y validar datos de humedad de suelo obtenidos mediante sensores de campo y remotos”.

Monitorear el contenido de agua en el suelo es fundamental para hacer un uso eficiente del agua, reducir los impactos ambientales y tomar mejores decisiones en la programación del riego, esto es, determinar cuándo y cuánto regar. Definir con precisión las láminas de riego ayuda a reducir



las pérdidas de agua o evitar la sub-irrigación. Los métodos utilizados para medir el agua en el suelo se clasifican en directos e indirectos. El método directo es el método gravimétrico, contra al cual se ajustan los métodos indirectos. Entre los métodos indirectos de campo se encuentran los sensores capacitivos. Los sensores remotos proporcionan información detallada y en tiempo real sobre el suelo, los cultivos y las condiciones ambientales. La combinación de sensores remotos con modelos de aprendizaje automático proporciona una plataforma integral para ayudar en la programación del riego. Los enfoques actuales apuntan principalmente a dos categorías: los basados en la teledetección activa o pasiva por microondas y los basados en la teledetección óptica (es decir, radiación de onda corta y radiación térmica). El aprendizaje automático (ML) ofrece enfoques alternativos.

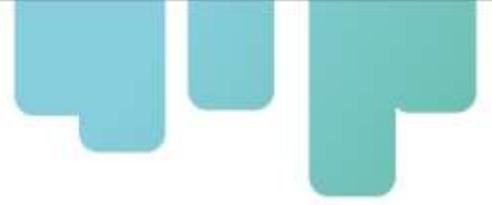
Los sensores de capacitancia utilizados en el proyecto tuvieron un comportamiento muy bueno, sin cambiar la ecuación de calibración de fábrica. Los valores promedio de los indicadores fueron los siguientes: R^2 0.757, RMSE 0.020 $m^3 m^{-3-1}$ y NRMSE 5.28%. El ajuste entre los valores observados y estimados podría mejorarse (especialmente R^2) revisando la instalación de los sensores y disponiendo de un mayor rango de datos de humedad del suelo para hacer el proceso de ajuste. El algoritmo Gradient Boosting Tree (GBT) tuvo un buen desempeño en la predicción de la humedad del suelo a partir de datos de textura y densidad aparente de los suelos e índices espectrales, obteniendo un RMSE de 3,46%. Se pueden incorporar otras variables al modelo, buscando siempre mantener un equilibrio entre la precisión de las predicciones y el requerimiento de datos de entrada.

Palabras Clave: riego, sensores de humedad de suelo, sensores remotos, calibración, validación.

Introducción

A los fines de brindar un marco al lector que no conoce en detalle el proyecto FONTAGRO AgTech 19037 “Los sistemas de asesoramiento al regante y las tecnologías de la información y la comunicación (SAR y TICs)”, se presentan sus principales características y aspectos conceptuales.

El sector agropecuario enfrenta el desafío de incrementar la producción de alimentos para satisfacer la demanda ocasionada por el crecimiento de la población mundial. En este escenario, el riego y la agricultura familiar (AF) tendrán un rol central. La AF es la forma de producción más extendida en el mundo, con más del 90 % del total de explotaciones agropecuarias (500 millones de EAPs) y aporta más del 80 % de los alimentos (FAO 2015). La mayor parte de la AF de América Latina y el Caribe utiliza el riego basado en el conocimiento empírico, lo que ha ocasionado un manejo poco adecuado e ineficiente del agua. El uso de Servicios de Asesoramiento al Regante (SAR), con mayor difusión en estratos de productores medianos y grandes, promueve un manejo sustentable del agua, proporcionando a los agricultores la información necesaria para un manejo más eficiente del riego, lo que aporta a incrementar el rendimiento de los cultivos. Ejemplos de diferentes aproximaciones de diseño de un SAR, su uso y su impacto en el uso del agua, se encuentran, entre muchos otros, en: Lorite *et al* (2012), Vuolo *et al* (2015), Palacios Vélez *et al* (2011), Altobelli *et al* (2018), Tapsuwan *et al* (2015), Unver *et al* (2020).



El creciente acceso a Internet, a la telefonía móvil y a servicios de sensores remotos, son una oportunidad para transferir información y conocimientos a la Agricultura Familiar (AF). El SAR permitirá fortalecer la capacidad de la toma de decisiones de los productores sobre el manejo del agua a través del uso de programaciones del riego ajustadas a los requerimientos de agua de los cultivos priorizados por la AF.

El objetivo general del proyecto es generar un estudio que permita identificar cómo disminuir la brecha de rendimientos en un grupo de cultivos seleccionados a través del uso de programaciones del riego ajustadas a los requerimientos de agua. Los objetivos específicos son: 1) Elaborar un diagnóstico inicial en las áreas de estudio y desarrollar la infraestructura del Sistema de Asesoramiento al Regante (SAR). 2) Desarrollar un estudio de un sistema de tecnologías de la información (TICs) que constituirán las bases operativas del SAR. 3) Realizar estudios de prueba para implementar el SAR y sentar las bases para su escalamiento.

El organismo ejecutor es la Fundación ArgenINTA y actúan como instituciones co-ejecutoras el Instituto Nacional de Tecnología Agropecuaria (INTA)-Argentina, el Instituto Nacional de Investigación Agropecuaria (INIA)-Uruguay y el Instituto Nicaragüense de Tecnología Agropecuaria (INTA)-Nicaragua. Son instituciones asociadas el Consejo Superior de Investigaciones Científicas (CSIC)-España, Wageningen University & Research (WUR) de Holanda y la empresa KILIMO de Argentina.

El proyecto está organizado en tres componentes técnicos: C1: “Diagnóstico de la situación inicial y desarrollo de la infraestructura del SAR”, C2: “Desarrollo de un estudio de un sistema de Tecnologías de la Información (TICs) del SAR” y C3: “Estudios de prueba para la implementación, impacto y escalamiento del SAR”.

La presente Nota Técnica corresponde al Producto 4 del Proyecto, “Nota técnica con el informe técnico sobre el ajuste de datos de humedad de suelo obtenidos por diferentes tipos de sensores”. El Producto 4 es parte del Componente 2 “Desarrollo de un estudio de un sistema de tecnologías de la información (TICs) del SAR” y de la Actividad 2.1 “Calibrar y validar datos de humedad de suelo obtenidos mediante sensores de campo y remotos”. Describe los procedimientos y resultados del ajuste de la estimación del contenido hídrico del suelo usando sensores de campo y modelos de aprendizaje automático, que se basan en mediciones de humedad del suelo por el método gravimétrico, textura y densidad aparente de los suelos, e índices espectrales derivados de sensores remotos.

Consideraciones teóricas

El manejo apropiado del riego requiere conocer el clima, el tipo de suelo, las necesidades de agua de los cultivos y la evolución del contenido de humedad del suelo. Para determinar cuándo regar, una de las metodologías es monitorear la evolución del agua en el suelo, lo cual puede hacerse de diversas formas. A medida que las plantas absorben agua, la humedad del suelo baja hasta un



nivel en el cual se requiere aplicar un riego; en caso contrario, el cultivo comienza a sufrir estrés hídrico, afectando el rendimiento. Si no se aplica agua, la planta continuará haciendo uso de la humedad remanente, hasta que finalmente utilice toda el agua disponible en el suelo y llegue al punto de marchitamiento permanente. Cuando el contenido de agua del suelo está en un estado que se conoce como capacidad de campo (Θ_{CC} , Θ_{FC}), se dice que el suelo se encuentra en un estado hídrico óptimo agronómico, lo cual ocurre en un rango de 0,1 a 0,3 bares de tensión, dependiendo de la textura del suelo. La tensión es una medida que determina la fuerza con la que las partículas del suelo retienen a las moléculas de agua: a menor contenido de agua del suelo, mayor es la retención de humedad y más alta es la tensión. En capacidad de campo, el agua no es retenida fuertemente por las partículas del suelo y las plantas pueden extraerla fácilmente. A medida de que la humedad del suelo disminuye por el proceso de evapotranspiración, la tensión con la cual el agua es retenida aumenta. Las plantas utilizan el agua del suelo hasta que el nivel de humedad alcanza el punto de marchitamiento permanente (Θ_{PMP} , Θ_{WP}). Una vez que el suelo se seca hasta llegar al PMP, las plantas ya no pueden seguir extrayendo agua del suelo y se marchitan de manera irreversible. Aunque por debajo del PMP todavía hay un poco de humedad, esta agua está retenida tan fuertemente por las partículas del suelo que las raíces de la planta no pueden extraerla. Dependiendo del tipo de planta y del tipo de suelo, el PMP ocurre a diferentes niveles de humedad. En la mayoría de los cultivos agronómicos, se acepta que el PMP se alcanza cuando la tensión en el suelo es de 15 bares. Esto significa que el suelo está reteniendo el agua en sus poros con tanta fuerza que para que las plantas puedan utilizar esta agua, deben crear una fuerza de succión mayor a 15 bares de tensión. Esto no es posible para la mayoría de los cultivos y, a 15 bares de tensión, la mayoría de las plantas comienzan a marchitarse. La diferencia en contenido de humedad entre la capacidad de campo y el punto de marchitamiento permanente se conoce como el agua disponible total (ADT) o agua útil (AU).

La programación del riego se fija, generalmente, en función de un nivel de agotamiento permisible (AP) o déficit permitido de manejo (DPM), referido al ADT. La mayoría de las investigaciones en riego recomiendan regar los cultivos extensivos (algodón, maíz, soja, trigo, sorgo, girasol, etc.) cuando el DPM se acerca al 50% del ADT. Para los cultivos intensivos (hortalizas, árboles frutales), el DPM comúnmente se reduce a un 30-40% del ADT, debido a su mayor sensibilidad al estrés hídrico. Estos valores de DPM se asocian con el riego por superficie, mientras que en los riegos presurizados (aspersión y, especialmente, goteo), el DPM es menor. Cuando se alcanza el DPM, se llega al umbral de riego (Θ_{UR} , Θ_t), es decir, el momento en que hay que reponer humedad para que el cultivo no sufra estrés hídrico. El contenido hídrico del suelo entre capacidad de campo y el umbral de riego se conoce como agua fácilmente disponible o aprovechable (AFD, AFA). En la Figura 1 se muestran las relaciones entre CC, PMP, ADT y AFD.




Figura 1. Relaciones entre CC, PMP, ADT y AFD. (Allen et al 2006)

Medición de humedad del suelo

El objetivo principal de una adecuada gestión del riego es dar a los cultivos el agua que necesitan en cada momento de su ciclo, aplicando dosis adecuadas y minimizando las ineficiencias. Entre otros aspectos, es necesario realizar un seguimiento del contenido hídrico del suelo, lo cual puede hacerse de distintas formas: por el método tradicional de gravimetría, usando dispositivos que estiman de manera indirecta la humedad de suelo, o con productos derivados de imágenes satelitales. Los métodos utilizados para medir el agua en el suelo se clasifican como directos e indirectos. El método directo es el método gravimétrico, en el cual se recolecta una muestra del suelo, se pesa, se seca en estufa y se pesa nuevamente para determinar el contenido de agua de la muestra. El método gravimétrico es el estándar, contra el cual se calibran los métodos indirectos. Entre los métodos indirectos utilizados para medir la humedad del suelo, pueden mencionarse los sensores granulares de matriz y bloques de yeso, la sonda de emisión de neutrones moderados y los sensores del tipo TDR y FDR.

Método directo

El método gravimétrico es una medición directa del contenido de agua en el suelo, que se basa en la determinación del peso de agua contenido en la masa de sólidos de una muestra del suelo.

Este es el método de referencia. El contenido de agua en el suelo se calcula por la siguiente ecuación (1):

$$\Theta_g = \frac{\text{Peso de suelo húmedo} - \text{peso de suelo seco}}{\text{peso de suelo seco}} \quad (1)$$

Θ_g es el porcentaje gravimétrico de agua. Para expresar el contenido hídrico en porcentaje, el resultado se multiplica por 100.

Procedimiento para la determinación de la humedad del suelo por gravimetría

Se toma una muestra de suelo (Figura 2) y se seca totalmente, midiendo por diferencia de pesada la cantidad de agua perdida. El proceso de secado se hace normalmente en estufa a una temperatura de 105 a 110 °C hasta que el suelo pierde totalmente su humedad (peso constante), proceso que usualmente dura entre 24 y 48 horas. La temperatura de secado no debe ser demasiado alta, pues aproximadamente a 165° C comienza la pérdida de agua estructural de las arcillas y entre 200 y 300 °C se produce degradación de la materia orgánica. Puede señalarse la desventaja que presenta en mediciones de rutina, pues el agua que penetra por los orificios que quedan en el suelo como consecuencia de la extracción de muestras, suele alterar el contenido hídrico de las capas adyacentes al igual que cuando se produce una lluvia o un riego. Además, no es posible realizar dos mediciones cronológicamente consecutivas sobre la misma muestra, con lo cual agrega otro error experimental debido a la heterogeneidad del suelo (Angella et al 2016).



Figura 2. Muestreo de suelos con barreno para determinación del contenido hídrico. (Angella et al 2016).

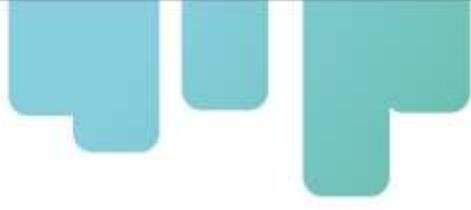
Métodos indirectos

Sensores de campo

Hay numerosos dispositivos que se usan para estimar el contenido de humedad del suelo de manera indirecta, entre los que se encuentran los sensores tipo FDR. Las sondas FDR (Frequency Domain Reflectometry) funcionan en el dominio de frecuencia. Estos dispositivos (también llamados sensores de capacitancia) utilizan un oscilador de corriente alterna para formar un circuito eléctrico en conjunto con el suelo. Las sondas pueden ser puntas paralelas o anillos de metal en el suelo, una vez en funcionamiento, el oscilador produce valores de frecuencia de acuerdo con el contenido de humedad del suelo. Estos sensores (Figura 3) miden la humedad del suelo respondiendo a cambios en su constante dieléctrica. La mayoría de los materiales del suelo tienen una constante dieléctrica que varía entre 2 y 4, mientras que la constante dieléctrica del agua es de 80. Por lo tanto, cuando el contenido hídrico del suelo aumenta, la constante dieléctrica también lo hace (Martin et al 2010; Angella et al 2016). Los dispositivos FDR tienen como principales ventajas la sencillez de manejo, la baja necesidad de mantenimiento y la sencillez en el registro y manejo de datos. Tienen algunas limitaciones, entre las que se mencionan: requieren una instalación cuidadosa, con muy buen contacto con el suelo, en algunos tipos de suelos se precisa ajustar la calibración de fábrica y pueden ser difíciles de instalar en suelos donde hay capas endurecidas (Marano et al 2012).



Figura 3. Sensores tipo FDR o de capacitancia. A) Sonda Diviner[®] (www.seedmech.com; <https://agriculturers.com>) B) Sensores Decagon[®] modelos ECHO, Teros I10 y datalogger (Angella et al 2016; <https://www.alphaomega-electronics.com/es/>)

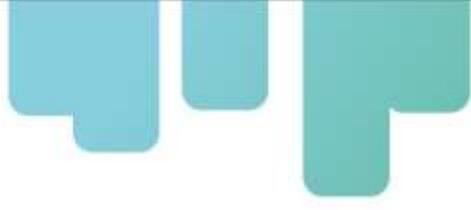


Los sensores dieléctricos o de capacitancia estiman la permitividad dieléctrica aparente (ϵ_b) de un volumen de suelo, la cual depende principalmente de su contenido hídrico, pero está determinada también por otras propiedades de los suelos, tales como la salinidad, textura y contenido de materia orgánica (Schilardi et al 2015). La influencia de estos factores depende de la frecuencia del campo electromagnético que generan los sensores y puede ser importante en aquellos que trabajan a frecuencias comprendidas entre 1 a 200 MHz (Schilardi et al 2015), rango en el cual opera el sensor Decagon Modelo Teros I10 (70 MHz), que se usó en el proyecto. Los sensores de capacitancia tienen una ecuación de fabricación para estimar el contenido hídrico de los suelos a partir de la ϵ_b . En general las diferencias entre la humedad gravimétrica y la humedad determinada por este tipo de sensores varían entre un 10% y 15%, por lo que hay necesidad de calibrarlos para disminuir los errores de medición, en caso de que se requiera hacer balances hídricos precisos.

Sensores remotos

La teledetección ofrece la posibilidad de realizar mediciones periódicas de la humedad del suelo. Especialmente para la agricultura, existe una fuerte demanda de cartografía de alta resolución espacial, los productos de humedad del suelo disponibles en la práctica tienen una resolución espacial media a gruesa (1 km) (Greifeneder et al 2021). Los enfoques actuales pertenecen a dos categorías principales: los basados en la teledetección activa o pasiva por microondas y los basados en la teledetección óptica (es decir, radiación de onda corta y radiación térmica). Más allá de los enfoques de modelización más tradicionales, el aprendizaje automático o machine learning (ML) ofrece algunos enfoques alternativos. Debido a la gran complejidad de los modelos físicos, la popularidad del ML para la estimación basada en teledetección de parámetros biofísicos ha crecido significativamente en la última década (Ali 2015). En comparación con los enfoques tradicionales, estos métodos presentan dos ventajas significativas: a) permiten la construcción de modelos de estimación más objetivos, basados exclusivamente en datos, independientes de los supuestos necesarios; y b) permiten la combinación de datos de diferentes fuentes (como la combinación de datos ópticos, de microondas, características de suelos), aprovechando su relación con una variable objetivo. En este proyecto se introduce un enfoque basado en el aprendizaje automático para ajustar modelos que permitan predecir la humedad de los suelos a partir de datos de sensores remotos ópticos y datos de campo medidos *in situ*.

Las tecnologías de sensores remotos en el rango de las microondas han demostrado tener el potencial de detectar y monitorear cambios relativos al contenido de humedad de una superficie a tiempos regulares y en condiciones independientes del clima y la luz solar (Solorza 2013). De allí que numerosos estudios están desarrollándose utilizando de manera complementaria, diferentes productos: SMAP - Soil Moisture Active and Passive y Sentinel-1 (Lievens et al 2017); Sentinel 1 con índices de vegetación derivados de sensores remotos ópticos para cuantificar el efecto de la



condición de la vegetación en la estimación de humedad de suelo (Qiu et al 2019); Sentinel 1A, Sentinel 2A, SMAP (Lizarazo y Mancera 2017). A todos los productos disponibles, se suman los productos SAOCOM (Misión del Satélite Argentino de Observación CON Microonda), impulsada por la CONAE y el INTA para estimar la humedad en el suelo. Los datos obtenidos por el satélite se calibran con una red telemétrica de instrumentos de medición in situ instalada en 67 sitios distribuidos en la Región Pampeana.

La mayoría de los algoritmos basados en microondas se basan en el mismo principio, utilizar las propiedades dieléctricas del agua y su efecto sobre la radiación de microondas reflejada (Ulaby et al 1978). Existen muchos enfoques diferentes para la teledetección óptica, que aprovechan la relación entre la reflectancia de la superficie y los cambios en los índices de vegetación o la temperatura de la superficie (Zhang y Zhou 2016). Las ventajas esenciales de las microondas son su baja sensibilidad a las condiciones atmosféricas, la iluminación solar y las nubes, y el hecho de que existe una relación física directa entre el contenido de humedad del suelo y la energía emitida y reflejada (Ulaby et al., 1978). Sin embargo, las mediciones también se ven muy influidas por el contenido de agua de la vegetación y la estructura y rugosidad de la superficie, que pueden ser difíciles de estimar.

Para las estimaciones basadas en la teledetección óptica, existen muchos enfoques diferentes, que se distinguen por la frecuencia temporal de los productos. Las principales ventajas de estos métodos son los numerosos satélites ópticos existentes y la gran disponibilidad de datos en diferentes resoluciones espaciales y espectrales. Los métodos basados en la luz visible y el infrarrojo cercano suelen aprovechar las propiedades de reflectancia de la superficie del suelo desnudo para el que los estudios han mostrado una correlación negativa de la reflectancia en las bandas de absorción de agua y el contenido de humedad del suelo. Debido a esta dependencia, varios índices de sequía, como el índice de vegetación de diferencia normalizada (NDVI) o el índice de agua de diferencia normalizada (NDWI), pueden servir como aproximación. La estimación del contenido de humedad del suelo basado en la teledetección térmica ha sido objeto de un gran número de estudios en las últimas décadas, lo que ha llevado al desarrollo de varios modelos y enfoques diferentes, explotando la relación con la temperatura de la superficie terrestre (Greifeneder et al., 2021).

Las imágenes Sentinel-2, distribuidas por la Agencia Espacial Europea (ESA) son ampliamente utilizadas por ser de libre distribución y por su resolución espacial, temporal y espectral, por lo que se utilizan índices espectrales derivados de Sentinel para monitorear el estado hídrico de los cultivos. La resolución espacial es la unidad mínima de información incluida en la imagen (píxel), mientras que la resolución temporal se refiere a la periodicidad con la que éste adquiere imágenes de la misma porción de la superficie terrestre, Sentinel 2 tiene un tiempo de revisita de 5 días. La resolución espectral es el número de bandas en la que el sensor puede registrar la energía que se refleja desde la superficie. Estas características, las convierte en una opción muy interesante para el seguimiento de los cultivos, especialmente, en lotes agrícolas de la AF. En la Tabla 1 se pueden ver las bandas de Sentinel-2. Para el seguimiento de cultivos, son

especialmente interesantes las bandas del verde, rojo e infrarrojo cercano (NIR), adquiridas a 10 m de resolución espacial (ESA, 2017a).

Tabla 1. Bandas espectrales en imágenes Sentinel 2.

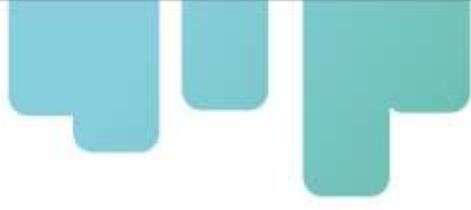
Resolución	Nombre	
10m	B02	Azul
	B03	Verde
	B04	Rojo
	B08	NIR
20m:	B05	Red Edge 1
	B06	Red Edge 2
	B07	Red Edge 3
	B8a	Red Edge 4
	B11	SWIR 1
	B12	SWIR 2
60m	B01	Aerosoles
	B09	Vapor de Agua
	B10	Nubes

Entre los productos derivados de satélites más difundidos se encuentran los índices de vegetación, que constituyen un resumen de la información satelital asociada a la vegetación. Se usan para determinar el tipo de cobertura, evaluar su variación temporal o establecer su estado de salud a partir de estimaciones de características como vigor vegetal, contenido de clorofila, estado nutricional o estado hídrico (Revelo Luna et al 2020). En diversos estudios, se han propuesto una variedad de índices de vegetación que usan diferentes bandas en el espectro visible e infrarrojo cercano para obtener características de interés. En este trabajo se utilizaron los índices NDVI, NDWI y MSAVI2. El índice NDVI o Índice de Vegetación de Diferencia Normalizado, más conocido como índice verde, es un indicador del vigor de la vegetación. Este índice utiliza las bandas NIR y rojo (R) del espectro electromagnético para estimar un indicador adimensional entre -1 y 1. Los valores negativos corresponden a áreas con superficies de agua, estructuras artificiales, rocas, nubes, nieve; el suelo desnudo generalmente cae dentro del rango de 0,1 a 0,2; y las plantas siempre tendrán valores positivos entre 0,2 y 1. El dosel de vegetación sano y denso debería estar por encima de 0,5, y la vegetación dispersa variará entre 0,2 y 0,5. Sin embargo, es solo una regla general y siempre debe tener en cuenta la temporada, el tipo de planta y las peculiaridades regionales para saber exactamente qué significan los valores de NDVI.

El índice NDVI, se calcula a partir de la siguiente ecuación:

$$NDVI = (NIR - R) / (NIR + R)$$

El MSAVI2 o Índice de Vegetación Ajustado al Suelo Modificado es un índice de vegetación que se utiliza como variante para ampliar los límites de aplicación del NDVI a las áreas con elevada presencia de suelo desnudo. Se lo usa en las áreas donde los índices NDVI proporcionan datos incompletos o erróneos, principalmente debido a una pequeña cantidad de vegetación o a la falta



de clorofila en ella (por ejemplo, en el estado fenológico de emergencia). De esta manera, sirve para minimizar la influencia del fondo del suelo y aumentar el rango dinámico que señala la vegetación. Este índice se calcula como la diferencia normalizada entre la banda roja (R) y la banda del infrarrojo cercano (NIR) donde se aplica una función que determina el valor “L” para reducir el efecto del suelo en la señal de la vegetación.

$$\text{MSAVI} = (2 * \text{NIR} + 1 - \sqrt{((2 * \text{NIR} + 1)^2 - 8 * (\text{NIR} - \text{R}))}) / 2$$

El NDWI, Índice Diferencial de Agua Normalizado, se utiliza para observar el estado hídrico del cultivo, identificar déficit y saturación de humedad. Al igual que otros índices, los valores obtenidos en el NDWI oscilan entre -1 y 1, donde los valores altos corresponden a un alto contenido de agua en la planta y a mayores coberturas del cultivo y los valores bajos representan bajo contenido de agua en vegetación y una cobertura escasa. Este índice se calcula como la diferencia normalizada entre la banda del infrarrojo cercano (NIR) y la banda del infrarrojo de onda corta 1 (SWIR1).

$$\text{NDWI} = (\text{NIR} - \text{SWIR1}) / (\text{NIR} + \text{SWIR1})$$

Materiales y métodos

Calibración y validación de datos de humedad de suelo obtenidos mediante sensores de campo

Uruguay

El objetivo fue comparar los datos de humedad de suelo obtenidos por sensores tipo de capacitancia, respecto de datos obtenidos por muestreos gravimétricos y analizar el grado de ajuste logrado. Se usaron sensores marca Decagon Modelo Teros I10 (70 MHz). En el Área piloto San José se hizo el seguimiento de humedad en cultivos de frutilla (*Fragaria Sp.*) implantados en los predios de los Sres. Parodi, Figueira y López mientras que en el Área Piloto de Canelones se siguió un cultivo de pimiento (*Capsicum annum*), en el predio del Sr. Fernández. En San José, el material geológico predominante corresponde a sedimentos limo arcillosos de color pardo y normalmente con concreciones de carbonato de calcio. El relieve es suavemente ondulado a ondulado con predominio de pendientes de 1 a 4%, existiendo regiones con pendientes de 3 a 6%. La erosión es moderada a ligera, de tipo laminar, con pérdida variable de los horizontes superiores. Los suelos corresponden a Vertisoles Rúpticos Típicos y Lúvicos (Grumosoles) y Brunosoles Eutrícos y Subéutrícos Típicos, de color negro o pardo muy oscuro, textura predominante franco arcillo limosa, fertilidad alta y moderadamente bien drenados. En Canelones, el material geológico corresponde a sedimentos limo arcillosos de color pardo y normalmente con concreciones de carbonato de calcio. El relieve y los procesos de erosión son similares a los del Área Piloto San José. Los suelos son Vertisoles Rúpticos Típicos y Lúvicos

(Grumosoles) y Brunosoles Eutrícos y Subéutrícos Típicos, de color negro o pardo muy oscuro, textura franco arcillo limosa, fertilidad alta y moderadamente bien drenados (Angella et al 2022).

En cada predio se siguió la humedad del suelo por el método gravimétrico, muestreando a las siguientes profundidades: 0-20 cm, 20-40 cm y 40-60 cm y se instalaron tres sensores, a iguales profundidades. Los sensores se conectaron a un datalogger marca Meter Group, modelo ZL6. La Figura 4 muestra los sensores conectados al datalogger en un cultivo de frutilla regado por goteo.



Figura 4. Sensores Decagon y datalogger Meter Group en cultivo de frutilla, San José, Uruguay.

La evaluación del ajuste de la estimación de la humedad del suelo por los sensores se hizo con tres indicadores estadísticos: el coeficiente de determinación (R^2), la raíz del error cuadrático medio (RMSE) y la raíz del error cuadrático medio normalizado (NRMSE). El R^2 da una indicación de la bondad de ajuste (precisión con la que los puntos de datos se encuentran en la línea de regresión) y varía entre 0 y 1, tomando el valor de 1 cuando el ajuste es perfecto. El RMSE representa una medida general de la diferencia absoluta entre valores observados y estimados, toma la misma unidad de la variable considerada y varía entre 0 e infinito. Valores cercanos a 0 indican buen desempeño; cuanto más pequeño es un valor RMSE, más cercanos son los valores estimados y observados. El NRMSE se expresa como porcentaje; el ajuste se considera excelente cuando es menor al 10%, bueno entre 10 y 20%, aceptable entre 20 y 30% y pobre cuando es mayor que 30%.

Argentina y Nicaragua

En las áreas piloto de Argentina, en la campaña agrícola 2021-2022 se hizo seguimiento de humedad por gravimetría en 24 parcelas y 2022-2023, 18 parcelas (cultivos de algodón y alfalfa). El grupo de sensores (de tipo capacitivos, ubicados a distintas profundidades) conforman nodos donde se realiza la toma de datos, que se envían a los concentradores, ubicados estratégicamente para poder recoger la información de los diferentes nodos y subirla a un sitio web para su visualización. El envío de datos desde los nodos al concentrador se hace por la tecnología inalámbrica LoRa. El nodo cuenta con un panel solar y batería que le permite auto abastecerse de energía, también tiene la particularidad de apagarse una vez que se realizó el envío de los datos de los sensores; de esta forma, se produce un ahorro de energía, lo cual en días poco soleados es muy importante dado que aumentando su autonomía de uso. El concentrador también tiene un panel solar y una batería (de mayor capacidad que los nodos) ya que funciona en todo momento, estando “atento” al envío de información por parte de los nodos. El concentrador está provisto por un modem *router*, que es el encargado de brindar conexión a internet para el envío de datos a la página web. Hasta el momento, se han instalado nodos y concentradores en dos predios del área piloto Nueva Francia. En el cultivo de algodón, se instalaron tres sensores de humedad por punto de medición, a profundidades de 20, 50 y 80 cm., mientras que, para la alfalfa, las profundidades son 40, 80 y 125 cm. Los sensores están en proceso de calibración y también está en etapa de ajuste la transmisión de datos desde los nodos al concentrador y de éste a la nube. Los primeros resultados son promisorios y se estima que esta tecnología, de desarrollo local, será de suma utilidad para el escalamiento del proyecto. En la Figura 5 (a, b, c) se muestra un predio con los sensores instalados y los componentes de un nodo y en la Figura 6 (a, b), el concentrador y sus componentes.




Figura 5. Sensores instalados y componentes del nodo en el predio del Sr. Cárdenas, área piloto Nueva Francia, Santiago del Estero, Argentina. Cultivo de alfalfa.



a




b

Figura 6. Concentrador y sus componentes en el predio del Sr. Cárdenas, área piloto Nueva Francia, Santiago del Estero, Argentina.


Por su parte, en Nicaragua, durante 2022 se hizo seguimiento de humedad del suelo por gravimetría en 10 fincas (4 en Ciudad Darío, 3 en Tisma y 3 en El Sauce), en cultivos de tomate, chiltoma (pimiento) y maíz. En 2023 se monitorean 6 predios (3 en Tisma y 3 en El Sauce), en tomate y frijol. Debido a la falta de proveedores locales, no fue posible adquirir sensores de capacitancia, por lo cual se decidió la compra de tensiómetros tradicionales, que serán aptos para definir estrategias de riego, sobre todo en cultivos que se riegan por goteo y aspersión, que normalmente se mantienen con un contenido de humedad adecuado para el rango de funcionamiento del tensiómetro. Lamentablemente, a causa del tiempo que insumió el trámite de compra, los tensiómetros pudieron adquirirse prácticamente sobre el cierre del proyecto. Como para el caso de Argentina, el ajuste de los datos obtenidos por los tensiómetros continuará luego de finalizado el proyecto.

Calibración y validación de datos de humedad de suelo obtenidos mediante sensores remotos


El área de estudio sobre la que se realizó el ajuste del modelo corresponde a los lotes de cultivos de las áreas pilotos del proyecto, en los que se realiza el seguimiento de humedad y que disponen de datos de textura y densidad aparente (Dap) de los suelos (Figura 7)



Salales, Nicaragua



Ciudad Darío, Nicaragua




Tisma, Nicaragua



Colonia El Simbolar, Argentina




Nueva Francia, Argentina



San José, Uruguay

Figura 7. Áreas pilotos y parcelas de seguimiento de cultivos.



Canelones, Uruguay

Figura 7 (cont.). Áreas pilotos y parcelas de seguimiento de cultivos.

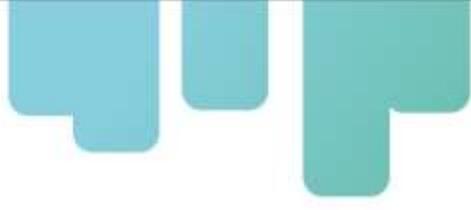
El set de datos contiene información sobre características físicas de suelos (densidad aparente, textura) e índices espectrales derivados de Sentinel 2, de 57 lotes de cultivos de algodón, alfalfa, frijol, chiltoma (pimiento), tomate y frutilla en las áreas piloto de Argentina, Nicaragua y Uruguay. Se realizaron mediciones de humedad de suelos aproximadamente cada 14 días, en el período julio del 2021 a marzo del 2023, a diferentes profundidades (según la profundidad de exploración radicular de los cultivos). Los intervalos de muestreo fueron: algodón 0-20, 20-40, 40-60, 60-80, 80-100 cm; alfalfa 0-20, 20-40, 40-60, 60-80, 80-100, 100-125, 125-150 cm; frutilla 0-15, 15-25 y 25-40 cm; frijol y chiltoma 0-20 y 20-40 cm. A cada dato de humedad se le asociaron los datos de textura (contenido de arena, limo y arcilla), y densidad aparente (Dap) del suelo en la profundidad de medición, y un conjunto de índices espectrales (MSAVI, NDVI y NDWI), calculados a partir de un apilado de imágenes del mes anterior a la fecha de medición. El set de datos contiene 2364 registros, la variable objetivo es la humedad en porcentaje, medida a partir de la aplicación del método gravimétrico. Los datos de textura y Dap se determinaron a través de extracciones de muestras en cada uno de los lotes. Los índices espectrales se obtuvieron a través de la plataforma en la nube Google Earth Engine (GEE), mediante scripts desarrollados ad hoc. La API de Google Earth Engine facilita la recopilación y el procesamiento de los datos, ya que se accede a sus catálogos de imágenes y el procesamiento se realiza en los servidores de Google, eliminando la necesidad de descargar o pre-procesar las imágenes. La Tabla 2 describe las variables incluidas en el set de datos.

Tabla 2. Variables del set de datos. Las variables predictoras en verde y la variable respuesta en azul.

Variables	Descripción
código	Identificador de lote.
fecha	Fecha de muestreo de humedad.
DAP	Densidad aparente.
arcilla	Contenido de arcilla en %.
limo	Contenido de limo en %.
arena	Contenido de arena en %.
profundidad	Profundidad de muestreo.
msavi_max	Valor medio de los valores máximos del MSAVI del mes previo a la fecha de muestreo.
msavi_mean	Valor medio de los valores medios del MSAVI del mes previo a la fecha de muestreo.
msavi_min	Valor medio de los valores mínimos del MSAVI del mes previo a la fecha de muestreo.
msavi_sum	Valor medio de los valores del MSAVI acumulados del mes previo a la fecha de muestreo.
ndvi_max	Valor medio de los valores máximos del NDVI del mes previo a la fecha de muestreo.
ndvi_mean	Valor medio de los valores medios del NDVI del mes previo a la fecha de muestreo.
ndvi_min	Valor medio de los valores mínimos del NDVI del mes previo a la fecha de muestreo.
ndvi_sum	Valor medio de los valores del NDVI acumulados del mes previo a la fecha de muestreo.
ndwi_max	Valor medio de los valores máximos del NDWI del mes previo a la fecha de muestreo.
ndwi_mean	Valor medio de los valores medios del NDWI del mes previo a la fecha de muestreo.
ndwi_min	Valor medio de los valores mínimos del NDWI del mes previo a la fecha de muestreo.
ndwi_sum	Valor medio de los valores del NDWI acumulados del mes previo a la fecha de muestreo.
Humedad_grav	Humedad gravimétrica en %.

Utilizando las observaciones del set de datos se realizaron los siguientes pasos:

- a) División del set de datos: se dividieron los datos disponibles en un conjunto de entrenamiento y un conjunto de test. El tamaño adecuado de las particiones depende en gran medida de la cantidad de datos disponibles y la seguridad que se necesite en la estimación del error, en este caso se dividieron 75% de observaciones (1773) para el entrenamiento y el 25% para validación (591). Los datos de entrenamiento y test



consideran todas las profundidades de muestreo con sus respectivos contenidos de humedad, como variable respuesta.

- b) Selección del algoritmo de ML: Se seleccionó el algoritmo Gradient Boosting Tree (GBT) para entrenar el modelo de estimación de humedad, utilizando los datos de entrenamiento. Un modelo Gradient Boosting Trees está formado por un conjunto de árboles de decisión individuales, entrenados de forma secuencial, de forma que cada nuevo árbol trata de mejorar los errores de los árboles anteriores. La predicción de una nueva observación se obtiene agregando las predicciones de todos los árboles individuales que forman el modelo.
- c) Ajuste de hiperparámetros: los hiperparámetros de los modelos de ML se refieren a parámetros preestablecidos que no pueden obtenerse a través del proceso de entrenamiento. Se aplicó un algoritmo de búsqueda de cuadrícula (RandomizedSearchCV) y una validación cruzada (kfold) de 5 pliegues. El modelo GBT tiene los siguientes hiperparámetros:
 - n_estimators: número de árboles incluidos en el modelo.
 - learning_rate: reduce la contribución de cada árbol multiplicando su influencia original por este valor.
 - max_depth: profundidad máxima que pueden alcanzar los árboles.
 - subsample: proporción de observaciones utilizadas para el ajuste de cada árbol.
 - max_features: número de predictores considerados a en cada división.Los valores óptimos encontrados por el método RandomizedSearchCV fueron: 'n_estimators': 1000, 'max_depth': 3, 'max_features': '5', 'subsample': 0.7
- d) Se entrenó el modelo utilizando el algoritmo GBT con los hiperparámetros óptimos encontrados.
- e) Evaluación del modelo de predicción de humedad de suelos: Se evaluó la capacidad predictiva del modelo, para comprobar cuán próximas son sus predicciones a los verdaderos valores de la variable respuesta. Para poder cuantificarla de forma correcta, se utilizan un conjunto de observaciones, de las que se conoce la variable respuesta, pero que el modelo no haya "visto", es decir, que no hayan participado en su ajuste en la etapa de entrenamiento. Se utilizaron los datos de test, separados inicialmente. Se calculó el error cuadrático medio (RMSE).

Selección de variables predictoras: es una de las técnicas más cruciales en el ML, especialmente para los conjuntos de datos de alta dimensión, ya que puede filtrar las características redundantes o irrelevantes. Se midió la importancia de las variables por permutación, permutando los valores de las variables individuales entre las muestras de entrenamiento y evaluando el error inducido como resultado.

Resultados y discusión


Sensores de campo

Proceso de calibración


En la Tabla 3 se presentan los cultivos, el rango de fechas de los muestreos, el número de muestreos y el tamaño de la muestra, en los cuatro predios en los que se hizo el seguimiento de humedad. En todos los casos, los datos corresponden a las tres profundidades (0-20, 20-40, 40-60). En la Figura 8 se muestran los valores observados y estimados de humedad volumétrica, los parámetros de la recta de ajuste y el R^2 . La línea azul punteada es la línea de tendencia y la línea negra llena es la relación 1:1. La Tabla 4 muestra los valores de RMSE y NRMSE, para cada predio.

Tabla 3. Períodos de fechas de muestreo de humedad, número muestreos y tamaño de la muestra usados para la calibración, en cada predio de seguimiento.


Predio	Cultivo	Períodos de muestreo	Número de muestreos	Tamaño de la muestra
Parodi	Frutilla	19/8/2022 al 12/12/2022	7	21
Figueira	Frutilla	11/8/2022 al 21/12/2022	7	21
López	Frutilla	19/8/2022 al 12/12/2022	7	21
Fernández	Pimiento	19/3/2023 al 2/5/2023	3	9




Predio Sr. Parodi



Predio Sr. Figueira



Predio Sr. López



Predio Sr. Fernández

Figura 8. Datos de humedad volumétrica observada y estimada por los sensores, parámetros de la recta de ajuste y R^2 en los predios en que se hizo el seguimiento de humedad. Proceso de calibración.

Tabla 4. RMSE y NRMSE para cada predio. Proceso de calibración.

Predio	RMSE	NRMSE (%)
Parodi	0,040	9,7
Figueira	0,025	5,9
López	0,025	7,4
Fernández	0,005	1,2

En todos los casos, tanto el RMSE como el NRMSE indicaron un muy buen ajuste (se recuerda que el RMSE toma la misma unidad de la variable considerada; en este caso, $m^3 m^{-3}$). El R^2 mostró


buenos a muy buenos ajustes. En dos casos (Parodi y Figueira) la nube de puntos se ubicó por debajo de la recta 1:1 (los sensores subestimaron la humedad del suelo, respecto de la medida gravimétrica). En el predio del Sr. López, hubo tanto subestimación como sobreestimación de humedad por los sensores, aunque la nube de puntos se ubicó cerca de la recta 1:1. En el predio del Sr. Fernández, se observó un muy buen arreglo de la nube de datos respecto de la recta 1:1. Considerando los buenos ajustes logrados sin necesidad de cambiar los parámetros de la calibración de fábrica de los sensores, se siguió con el proceso de validación, usando otros conjuntos de datos.

Proceso de validación


En la Tabla 5 se presentan los cultivos, el rango de fechas de los muestreos, el número de muestreos y el tamaño de la muestra, en los cuatro predios en los que se hizo el seguimiento de humedad. En todos los casos, los datos corresponden a las tres profundidades (0-20, 20-40, 40-60). En la Figura 9 se muestran los valores observados y estimados de humedad volumétrica, los parámetros de la recta de ajuste y el R^2 . La línea azul punteada es la línea de tendencia y la línea negra llena es la relación 1:1. La Tabla 6 muestra los valores de RMSE y NRMSE, para cada predio.

Tabla 5. Períodos de fechas de muestreo de humedad, número muestreos y tamaño de la muestra usados para la validación, en cada predio de seguimiento.


Predio	Cultivo	Período de muestreo	Número de muestreos	Tamaño de la muestra
Parodi	Frutilla	16/1/2023 al 10/6/2023	8	24
Figueira	Frutilla	25/1/2023 al 10/6/2023	8	24
López	Frutilla	16/1/2023 al 10/6/2023	8	24
Fernández	Pimiento	19/5/2023 al 10/6/2023	3	9




Predio Sr. Parodi



Predio Sr. Figueira



Predio Sr. López



Predio Sr. Fernández

Figura 9. Datos de humedad volumétrica observada y estimada por los sensores en los predios en que se hizo el seguimiento de humedad. Parámetros de la recta de ajuste y R^2 . Proceso de validación.

Tabla 6. RMSE y NRMSE para los datos de cada predio. Proceso de validación.

Predio	RMSE	NRMSE (%)
Parodi	0,028	7,9
Figueira	0,015	3,7
López	0,016	4,5
Fernández	0,008	2,0



Como para la calibración, tanto el RMSE como el NRMSE indicaron un muy buen ajuste. Por su parte, el R^2 mostró aceptables a buenos ajustes, menos sólidos que en la calibración. En los predios de los Sres. Parodi y Fernández, la nube de puntos se distribuyó tanto por encima como por debajo de la recta 1:1, indicando un balance entre valores de humedad que fueron sub o sobreestimados por los sensores. En el predio del Sr. López, los puntos se situaron mayoritariamente por encima de la recta 1:1 (predominio de sobreestimación de humedad por los sensores, respecto de los valores medidos). Finalmente, en el predio del Sr. Figueira, hubo un predominio de valores de humedad subestimados por los sensores.

Análisis general de los datos

En la Tabla 7 se presentan los valores medios, mínimo y máximo de los indicadores, para todos los datos usados en calibración y validación (153 pares de muestras).

Tabla 7. valores medios, mínimo y máximo de R^2 , RMSE y NRMSE para todos los datos de humedad de suelo observados y estimados en las áreas piloto de Uruguay.

Indicador	Promedio	Mínimo	Máximo
R^2	0,757	0,621	0,957
RMSE	0,020	0,005	0,040
NRMSE (%)	5,28	1,2	9,7

Para el RMSE, al estar expresado el contenido hídrico en $m^3 m^{-3-1}$, el valor promedio (0,020) significa una diferencia del 2,0%, referido al contenido volumétrico de agua. El NRMSE no superó en ningún caso el 10%. Respecto de la distribución de los datos en relación a la recta 1:1, los datos se ajustaron a la recta en cuatro casos, en tres casos los sensores subestimaron la humedad y en un caso, la sobreestimaron. Cierta tendencia a la subestimación de la humedad del suelo por este tipo de sensores se menciona en Silva et al (2012) y Abanto-Rodríguez et al (2020). El ajuste entre valores observados y simulados (especialmente el R^2 y a la recta 1:1) podría mejorarse aplicando ciertas correcciones. Una de ellas es revisar la instalación de los sensores, para comprobar si se logró un adecuado contacto con el suelo, lo cual suele ser problemático. Otro aspecto importante sería disponer de un mayor rango de datos de humedad a los registrados en las parcelas. Las mediciones se hicieron en cultivos comerciales regados por goteo, en los que la humedad se mantuvo en valores altos durante todo el ciclo (entre el 30% y el 45% HV aproximadamente), no disponiéndose de datos en condiciones de suelo más seco. La calibración es un trabajo laborioso, que, en general, hay que hacer para cada sensor individualmente, para cada tipo de suelo e, incluso, para cada horizonte. Es recomendable hacer una calibración fina de los sensores cuando se necesita hacer balances hídricos precisos, tarea esencialmente ligada a experimentos de

investigación sobre las necesidades de agua de los cultivos. Cuando se requiere hacer un seguimiento de la humedad del suelo para tomar decisiones prácticas de riego en un cultivo comercial (objetivo central del SAR) sería más recomendable concentrar esfuerzos en estimar la capacidad de campo y el umbral de riego con la información que brindan los sensores, basando la toma de decisiones de riego en esos valores relativos. Por lo expuesto, se considera que los sensores Decagon Modelo Teros I10 brindaron datos suficientemente precisos, sin necesidad de cambiar los parámetros de la ecuación de calibración de fábrica.

Sensores remotos

Se ajustó un modelo para estimar la humedad de los suelos utilizando aprendizaje automático en base a un set de datos conformado por datos de textura, dap de los suelos e índices espectrales (variables predictoras) y datos de humedad de suelos obtenidos por muestreos gravimétricos, (variable respuesta). Asimismo, la disponibilidad de imágenes satelitales (libres de nubes) permite realizar un monitoreo temporal del NDVI, con el fin de observar su evolución en el tiempo. En la Figura 10, a la izquierda, se observan los lotes de cultivos del área piloto de Nueva Francia y a la derecha la dinámica del índice verde de 3 lotes de algodón (21, 22 y 23) en el período noviembre/2021 a mayo/2022.




Figura 10. Lotes de cultivos del área piloto Nueva Francia, Argentina (izquierda) y evolución del NDVI entre noviembre de 2021 y mayo de 2022 (derecha) de los lotes identificados con la etiqueta 21, 22 y 23.

Como el objetivo del estudio es predecir la humedad del suelo, se hizo un análisis de cada variable predictora en relación con la variable respuesta para observar cuáles de las variables están más relacionadas con la humedad y de qué forma (Figura 11). Cada punto representa los valores medidos de ambas variables para el set de datos completo.




Figura 11. Relación de las variables predictoras con la humedad del suelo.





Figura 11 (cont.). Relación de las variables predictoras con la humedad del suelo.



Como medida de capacidad predictiva del modelo de estimación de humedad de suelos, utilizando GBM, se obtuvo un RMSE de 3,46% y las seis variables predictoras más importantes, determinadas por permutación fueron: ndwi_sum, arena, arcilla, limo, msavi2_min, ndwi_min. Los resultados muestran que GBT tiene un buen desempeño para predecir la humedad de los suelos a partir de datos de textura, densidad aparente e índices espectrales. Se pueden incorporar otras variables al modelo con el fin de obtener el modelo más parsimonioso.

Conclusiones

Los sensores Decagon Modelo Teros I10 usados en el área piloto San José, Uruguay, han tenido un buen a muy buen comportamiento, sin necesidad de cambiar los parámetros de calibración de fábrica. Los valores medios de los indicadores fueron los siguientes: R^2 0,757, RMSE 0,020 $m^3 m^{-3-1}$ y NRMSE 5,28%. Respecto de la distribución de los datos en relación a la recta 1:1, no se observó una tendencia clara; los datos se ajustaron a la recta en cuatro casos, en tres casos los sensores subestimaron la humedad y en un caso, la sobreestimaron. El ajuste entre valores observados y estimados (especialmente el R^2 y el ajuste a la recta 1:1) podría mejorarse revisando la instalación de los sensores y disponiendo de un mayor rango de datos de humedad de suelo a los registrados en las parcelas. La calibración es un trabajo laborioso, que, en general, hay que hacer para cada sensor individualmente, para cada tipo de suelo e, incluso, para cada horizonte. En general, es recomendable hacer una calibración fina de los sensores cuando se necesita hacer balances hídricos precisos, tarea esencialmente ligada a experimentos de investigación sobre las necesidades de agua de los cultivos. Cuando se requiere hacer un seguimiento de la humedad del suelo para tomar decisiones prácticas de riego en un cultivo comercial (objetivo central del SAR), sería más recomendable concentrar esfuerzos en estimar la capacidad de campo y el umbral de riego con la información que brindan los sensores, basando la toma de decisiones de riego, con tales valores relativos.

Como medida de capacidad predictiva del modelo de estimación de humedad de suelos, utilizando el algoritmo GBM, se obtuvo un RMSE de 3,46% y las seis variables predictoras más importantes, determinadas por permutación, fueron: ndwi_sum, arena, arcilla, limo, msavi2_min, ndwi_min. El ajuste de este tipo de modelos y su aplicación en el manejo del riego requiere disponer de mediciones permanentes de humedad. La creciente disponibilidad de productos satelitales de acceso libre y la emergencia de la plataforma de Google Earth Engine facilitan la integración y análisis de múltiples fuentes de datos. Los datos disponibles se pueden usar para alimentar modelos tradicionales y/o modelos de aprendizaje automático. Los satélites SAR (Synthetic Aperture Radar, por sus siglas en inglés) son instrumentos valiosos para la estimación de humedad del suelo debido a su capacidad para penetrar las nubes y la vegetación, y para proporcionar información independientemente de las condiciones climáticas o de iluminación solar. La retrodispersión del radar SAR proporciona información sobre las características del suelo, incluida su rugosidad y contenido de humedad. No fue posible incluir estos productos debido a que no hay imágenes Sentinel 1 y/o SAOCOM disponibles, para el área de estudio con la



periodicidad necesaria, para las campañas de cultivos consideradas. La combinación de sensores remotos con tecnologías de riego inteligente y modelos de aprendizaje automático proporciona una plataforma integral para una programación del riego más precisa y eficiente, contribuyendo a la sostenibilidad y optimización de los recursos hídricos en la agricultura.

Referencias bibliográficas

Abanto-Rodríguez, Carlos; Wellington Farias Araújo; Pollyana Cardoso Chagas; Edvan Alves Chagas; João Lopes Monteiro N.; Raphael Da Silva Siqueira; Samara Martins Barbosa; Valdinar Ferreira Melo y Miguel A. Maffei Valero. 2020. Calibración de sensores de reflectometría de dominio de frecuencia para estimar la humedad en un suelo Geric Xanthic Ferrasol. *Bioagro* 32(2): 123-130. 2020.

Ali, I, F. Greifeneder, J. Stamenkovic, M. Neumann, C. Notarnicola. 2015. Review of Machine Learning Approaches for Biomass and Soil Moisture Retrievals from Remote Sensing Data. *Remote Sens.* 2015, 7, 16398–16421.

Allen, R.; L. S. Pereira; D. Raes; M. Smith. 2006. Evapotranspiración del cultivo. Guías para la determinación de los requerimientos de agua de los cultivos. Estudio FAO Riego y Drenaje 56. Organización de las Naciones Unidas para la Agricultura y la Alimentación. Roma, 2006.

Altobelli, F., Lall, U., Dalla Marta, A., Caracciolo, F., Cicia, G., D'Urso, G., & Del Giudice, T. 2018. Willingness of farmers to pay for satellite-based irrigation advisory services: a southern Italy experience. *The Journal of Agricultural Science*, 156(5), 723-730. Doi:10.1017/S0021859618000588.

Angella, G.; C. Frías; R. Salgado. 2016. Conceptos básicos de las relaciones agua-suelo-planta. INTA Ediciones. Colección Divulgación. ISSN: 1850-4086. Nº 93, octubre de 2016.

Angella, G.; Urbina Urbina, L.; García, C.; Garay, R.; Frías, C. Sistema de Asesoramiento al Regante (SAR). ¿Cuándo regar y cuánto regar? Las tecnologías de la Información y la comunicación (TICs) como herramientas para fortalecer la capacidad de toma de decisiones de la agricultura familiar. Proyecto FONTAGRO AgTech 19037, Contrato C-RG-T3387-P002. Producto 1. Nota Técnica con el informe técnico del diagnóstico inicial de las áreas de estudio.

chrome-

extension://efaidnbmnnnibpcajpcgiclfndmkaj/https://www.fontagro.org/new/uploads/productos/Proy_FONTAGRO_AgTech_19037_Nota_t%C3%A9cnica_Producto_1_3_mar_2022.pdf

FAO. 2015. El estado mundial de la agricultura y la alimentación. Organización de las Naciones Unidas para la Alimentación y la Agricultura. ISBN 978-92-5-308536-1 (edición impresa) E-ISBN 978-92-5-308537-8 (PDF). Roma, 2015.

Juan M. Enciso, Dana Porter and Xavier Périès. 2007. Uso de sensores de humedad del suelo para eficientizar el riego. Texas A&M AgriLife Extension Service. B-6194S 08/07. Descargado el 7/12/2022.

<http://baen.tamu.edu/wp-content/uploads/sites/24/2017/01/E-618S-Irrigation-Monitoring->

[with-Soil-Water-Sensors.-Spanish-Version.pdf](#)

Lievens, H., R. Reichle, Q. Liu, G. De Lannoy, R. Dunbar, S. Kim & W. Wagner. 2017. Joint Sentinel-1 and SMAP data assimilation to improve soil moisture estimates. *Geophysical Research Letters*, 44(12), 6145–6153. <https://doi.org/10.1002/2017GL073904>

Lizarazo, I., & R. Mancera. 2017. Humedad del suelo a partir de datos obtenidos mediante teledetección. Uso de técnicas de regresión lineal múltiple para obtener una propiedad de interés en la zona de estudio: Disponible en https://rstudio-pubs-static.s3.amazonaws.com/324020_6826d946a9e04a59905e5db23aa0b6ca.html Consultado 8/10/2019

Lorite, I.J., García-Vila, M., Carmona, MA. *et al.* Assessment of the Irrigation Advisory Services' Recommendations and Farmers' Irrigation Management: A Case Study in Southern Spain. *Water Resour Manage* 26, 2397–2419 (2012). <https://doi.org/10.1007/s11269-012-0023-3>

Marano, R.; F. Ledesma; G. Camussi e I. Carnevale. 2012. Uso de sondas FDR para balance de agua en el suelo: calibración y aplicación. XXIII Congreso Argentino de la Ciencia del Suelo. Mar del Plata, Argentina, 2012.

Martin, Edward C.; Muñoz, C. 2010. Métodos para medir la humedad del suelo para la programación del riego. ¿Cuándo? Arizona Cooperative Extension. College of Agriculture, University of Arizona (Tucson, AZ). 2010. Descargado el 7/12/2022. Item License <http://creativecommons.org/licenses/by-nc-sa/4.0/>.

Link to Item

<http://hdl.handle.net/10150/625275>

Palacios-Vélez, E.; Julio Enrique Palacios-Sánchez, Luis Alberto Palacios-Sánchez. 2011. Agricultura de riego asistida con satélites. *Tecnología y Ciencias del Agua, antes Ingeniería Hidráulica en México*, vol. II, núm. 2, abril-junio de 2011, pp. 69-81.

Qiu J, W. Crow, W. Wagner & T. Zhao. 2019. Effect of vegetation index choice on soil moisture retrievals via the synergistic use of synthetic aperture radar and optical remote sensing. *Int J Appl Earth Obs Geoinf*;80:47-57. doi:10.1016/J.JAG.2019.03.015.

Revelo Luna, D., J. Megía Manzano, B. Montoya Bonilla y J. Hoyos García. 2020. Análisis de los índices de vegetación NDVI, GNDVI y NDRE para la caracterización del cultivo de café (*Coffea arabica*). *Ingeniería y Desarrollo*, vol. 38, núm. 2, pp. 298-312, Fundación Universidad del Norte

Schilardi, C; Rearte, E.; Martín, L.; Morábito, J. 2015. Calibración a campo de sensores FDR. Limitaciones y potencialidades. Jornadas de Riego y Fertilización. Mendoza Argentina.



https://www.researchgate.net/publication/309513454_CALIBRACION_A_CAMPO_DE_SENSOR_S_FDR_LIMITACIONES_Y_POTENCIALIDADES

Silva, B.M., G.C. Oliveira, M.E. Serafim, J.J. Silva Júnior, A. Colombo y J.M. I. Lima. 2012. Acurácia e calibração de sonda de capacitância em Latossolo Vermelho cultivado com cafeeiro. *Pesq. Agropec. Bras.* 47(2): 277-286.

Solorza, R. 2013. Estimación de la humedad superficial del suelo mediante el uso combinado de modelos electromagnéticos y el enfoque bayesiano. Estudio exploratorio en imágenes SARAT. Facultad de Matemática, Astronomía y Física y el Instituto de Altos Estudios Espaciales Mario Gulich. Tesis de Magister en Aplicaciones Espaciales de alerta y respuesta temprana a emergencias – Universidad Nacional de Córdoba. Consultado 9/10/2019

Tapsuwan, S.; Johannes Hunink, Francisco Alcon, Aakfe N. Mertens-Palomares and Alain Baille. 2015. Assessing the design of a model-based irrigation advisory bulletin: the importance of end-user participation. *Irrigation and Drainage. Irrig. and Drain.* 64: 228–240 (2015). Published online 29 November 2014 in Wiley Online Library (wileyonlinelibrary.com) DOI: 10.1002/ird.1887.

Ulaby, F., P. Batlivala, M. Dobson. 1978. Microwave Backscatter Dependence on Surface Roughness, Soil Moisture, and Soil Texture: Part I-Bare Soil. *IEEE Trans. Geosci. Electron.* 1978, 16, 286–295.

Unver, O.; Melvyn Kay, Konda Chavva, Amali Abraham Amali, Eva Pek, Maher Salma. 2020. Development for water, food and nutrition in a competitive environment-How NGOs and CSOs are reshaping traditional farmer irrigation advisory services. *Irrig. and Drain.* 2021;70:431-447. DOI: 10.1002/ird.2444.

Vuolo, F.; Guido D’Urso, Carlo De Michele, Biagio Bianchi, Michael Cutting. 2015. Satellite-based irrigation advisory services: A common tool for different experiences from Europe to Australia. *Agricultural Water Management* 147 (2015) 82-95.

Zhang, D.; G. Zhou. 2016. Estimation of Soil Moisture from Optical and Thermal Remote Sensing: A Review. *Sensors* 2016, 16, 1308.

Instituciones participantes



Secretaría Técnica Administrativa



Con el apoyo de:



www.fontagro.org

Correo electrónico: fontagro@fontagro.org