

Análisis del uso de datos IoT para la toma de decisiones en la agricultura sostenible

Analysis of the use of IoT data for decision-making in sustainable agriculture

Ángel Wilson Villareal Cobeña

ULEAM

angel.villarreal@uleam.edu.ec

<https://orcid.org/0000-0003-0357-0538>

El Carmen – Ecuador

Rocio Alexandra Mendoza Villamar

ULEAM

rocio.mendoza@uleam.edu.ec

<https://orcid.org/0000-0002-1277-7162>

El Carmen – Ecuador

Juan Pablo Alava Rodríguez

ULEAM

e2300730831@live.uleam.edu.ec

<https://orcid.org/0009-0001-7999-5551>

El Carmen - Ecuador

Elizva Lizbeth Mendoza Navarrete

ULEAM

e2200616387@live.uleam.edu.ec

<https://orcid.org/0009-0002-8164-1338>

El Carmen - Ecuador

Iván Alejandro Ordoñez Vélez

ULEAM

e1316609930@live.uleam.edu.ec

<https://orcid.org/0009-0008-5816-9913>

El Carmen - Ecuador

Formato de citación APA

Villarreal, A. Mendoza, R. Alava, J. Mendoza, E. & Ordoñez, I. (2026). *Análisis del uso de datos IoT para la toma de decisiones en la agricultura sostenible*. Revista REG, Vol. 5 (Nº. 2), p. 2032 – 2052.

INTELIGENCIA COLECTIVA

Vol. 5 (Nº. 2). abril – junio 2026.

ISSN: 3073-1259

Fecha de recepción: 29-05-2026

Fecha de aceptación :04-06-2026

Fecha de publicación:30-06-2026



RESUMEN

La agricultura sostenible se presenta hoy en día como un reto: limitaciones de agua, cambio climático, aumento de la población y reducción de tierras cultivables; a la que se le suma un problema práctico, dado que la extensión de potencia de internet en las áreas rurales es muy escasa lo que detiene la digitalización del medio rural. Para procesar datos proporcionados sin almacenarlos en la nube, se divulga un sistema de procesamiento y un dispositivo de almacenamiento que se habilitan a través de Internet de las Cosas (IoT) y la Inteligencia Artificial (IA). Emerge un esquema de integración que combina la integración de principios de operación piezorresistivos sin electricidad, autosostenibles (energy harvesting) y la tecnología LoRaWAN para un cultivo de cítricos de riego deficitario controlado. Estos sensores midieron humedad de suelo, temperatura, radiación solar y evapotranspiración. Con esos datos se entrenaron modelos de Machine Learning (Random Forest, Redes Neuronales y SVM) para predecir la evapotranspiración real diaria. Derivado de esta demostración los sensores funcionan bajo un protocolo propietario sin necesidad de batería, y los modelos de IA predicen muchísimo mejor las necesidades de los cultivos. LoRaWAN además es un protocolo de muy bajo consumo y se demostró su utilidad en zonas rurales. Por otro lado, la propia integración de IoT e IA en el edge abre nuevas vías para desarrollar soluciones de recomendaciones potentes, escalables y rentables para ayudar a los agricultores a tomar decisiones más responsables para una agricultura sostenible, que es la línea de desarrollo y financiación de esta investigación.

PALABRAS CLAVE: Internet de las Cosas, inteligencia artificial, agricultura sostenible, evapotranspiración, riego deficitario controlado, aprendizaje automático, LoRaWAN, sensores IoT.



ABSTRACT

Sustainable agriculture presents a significant challenge today: water limitations, climate change, population growth, and a reduction in arable land. Adding to this is a practical problem: the limited internet access in rural areas hinders the digitalization of the countryside. To process data without storing it in the cloud, a processing system and storage device enabled by the Internet of Things (IoT) and Artificial Intelligence (AI) are presented. An integration scheme emerges that combines the principles of piezoresistive operation without electricity, self-sustaining energy harvesting, and LoRaWAN technology for a controlled deficit-irrigated citrus crop. These sensors measured soil moisture, temperature, solar radiation, and evapotranspiration. Machine learning models (Random Forest, Neural Networks, and SVM) were then trained on this data to predict actual daily evapotranspiration. As a result of this demonstration, the sensors operate under a proprietary protocol without requiring a battery, and the AI models significantly improve their prediction of crop needs. LoRaWAN is also a very low-power protocol, and its usefulness in rural areas has been demonstrated. Furthermore, the integration of IoT and AI at the edge opens new avenues for developing powerful, scalable, and cost-effective recommendation solutions to help farmers make more responsible decisions for sustainable agriculture, which is the focus of this research and its funding.

KEYWORDS: Internet of Things, artificial intelligence, sustainable agriculture, evapotranspiration, controlled deficit irrigation, machine learning, LoRaWAN, IoT sensors.

INTRODUCCIÓN

Actualmente, el desafío para la agricultura sostenible es la disponibilidad limitada de agua, el cambio climático, el aumento de la población y la disminución de la tierra utilizable para cultivar, y no sólo eso, sino que, en términos prácticos, la transferencia de tecnología en las zonas rurales está limitada por el acceso a internet es nulo. La población sigue creciendo, estimándola la ONU, a través de su Organización para la Alimentación y la Agricultura (FAO), en diez mil millones para 2050 (FAO, 2023). Para entonces la producción alimentaria debería crecer en un 70 por ciento.

Se puede promover una agricultura moderna promoviendo la agricultura inteligente. La agricultura inteligente puede lograrse a través de las TIC. Estas tecnologías permiten a los agricultores monitorear, controlar y mejorar sus negocios. En particular, el Internet de las Cosas (IoT) mejora todo el proceso de producción agrícola, ya sea la gestión de la tierra, la reducción del uso de agua, la protección de los cultivos o la mecanización de las fincas. Los dispositivos inteligentes en campo recopilan datos y monitorean el progreso de los procedimientos de fabricación. La reducción de tamaño en los componentes electrónicos hace posible proveer con sensores IoT de bajo consumo para monitorear temperatura, humedad, condiciones del suelo, crecimiento de cultivos, entre otros, con la posibilidad de tomar precauciones inmediatas ante daños ocasionados por sequías o inundaciones. Todos esos datos son procesados por sistemas IoT que los transforman en poderosas estadísticas tales como el análisis predictivo del que obtienen los agricultores las cantidades mínimas de insumos (agua, pesticidas, fertilizantes) en el lugar donde efectivamente se necesitan.

Una de las restricciones que podría afectar la coexistencia de la organización de los datos relativos a la agricultura y al cultivo como se detalla en el contexto temático de la precisión es la ausencia o mala calidad de la conectividad a Internet en un gran número de áreas rurales. Pero el diseño y la construcción de precisión agricultura sistemas soportados del procesamiento de información están aún en fase primordial, y no hemos alcanzado esa situación. Otras redes LPWAN quizá sean la potencial solución para cubrir adecuadamente las necesidades de las comunidades rurales en base a información del sector agrícola cuando las aplicaciones con agricultura inteligente se concreten (Avşar & Mowla, 2022). De las tecnologías LPWAN más comunes, destaca LoRaWAN ya que ofrece una gran cobertura, tiene seguridad integrada, es de bajo costo y de bajo consumo de energía. LoRaWAN está muy extendido en agricultura para conectar sensores ambientales y controlar actuadores como válvulas de riego. En áreas rurales, la cobertura LoRa es demostrada por varios experimentos logrando llegadas de hasta 5 km sin línea de visión y 47 km con línea de visión. En lo que a consumo se refiere, LoRa tiene hasta 15 años de duración de batería, siendo ésta muy superior a la

de tecnologías como Wi-Fi, ZigBee, etc. Por consiguiente, la elección de la agricultura sostenible no se basa únicamente en un proceso de recogida de los datos, sino que además se basa en un proceso de análisis de los datos y del conocimiento donde también ofrece consejo al agricultor. Los sistemas computacionales apoyados en IoT y que estén dotados con capacidades de proceso discreto y que permiten la ejecución de un análisis de grandes volúmenes de datos de humedad, temperatura, evapotranspiración, son capaces de predecir con alto grado de certeza los requerimientos hídricos de la explotación. Estos sistemas procesan muchos menos datos en la nube y muchos más en el borde (edge computing), disminuye el tráfico a internet, también costos y consumo energético y le permite al agricultor tomar decisiones más responsables sobre el uso del agua y de otros insumos agrícolas.

Si bien en ese aspecto se han hecho esfuerzos, hoy en día existe un abismo entre la digitalización en empresas industriales y ciudades, y la digitalización en el sector agrícola. La literatura clásica ha estudiado LoRa de forma holística (dos Santos et al., 2024) y de manera individual para factores concretos como el rendimiento de la interoperabilidad del protocolo, la duración de energía e inteligencia de sistemas de soporte de decisiones; sin embargo, se echa en falta un trabajo que analice de forma conjunta la utilización de LoRaWAN en agricultura inteligente e inteligencia artificial, autonomía energética y toma de decisiones en el borde de la red.

La Industria 4.0 en cuanto a lecciones aprendidas puede ser aplicada también para el sector agrícola, atento a peculiaridades de este como la de aplicar en extensos terrenos descuidados, dar alimentación energética a los dispositivos y garantizar la seguridad de datos. También es posible recurrir al aprendizaje automático para modelar y abordar cuestiones técnicas de mejora de la escalabilidad LoRaWAN y predecir la congestión de la red.

Este artículo tiene como objetivo estudiar la aplicación de datos de IoT para la toma de decisiones en la agricultura sostenible, mediante el diseño de un sistema basado en sensores piezorresistivos sin batería (recolección de energía), tecnología LoRaWAN y modelos de aprendizaje automático (bosque aleatorio, redes neuronales y SVM) para predecir la evapotranspiración diaria real en cultivos de cítricos bajo riego deficitario controlado, con el fin de optimizar el uso del agua y respaldar decisiones agronómicas más responsables.

MÉTODOS MATERIALES

El estudio se ha formulado como el diseño de un experimento con aplicación para el desarrollo y validación de modelos de aprendizaje automático para predecir la evapotranspiración real (ETA) en

cultivos de cítricos bajo riego deficitario regulado (RDI), para optimizar el uso del agua y ayudar en la toma de decisiones en la agricultura sostenible.

El experimento se realizó a lo largo de cuatro años (2018-2021) en un huerto de cítricos (*Citrus reticulata* Blanco, cv. Mandarino Tardivo di Ciaculli) ubicado en las afueras de Palermo, Italia (38°4' 53.4" N, 13° 25' 8.2" E) [373]. El terreno tenía alrededor de 0.4 ha con un espaciamiento de 5.0 × 5.0 m y la altura media fue 2.5 m. El fraccionamiento cubre un promedio de 0.48. El clima fue mediterráneo (tipos climáticos de Köppen: Csa) con fuertes lluvias caóticas durante otoños e inviernos y veranos calientes.

Se utilizó un muestreo intencional seleccionando un huerto de cítricos representativo de los ecosistemas mediterráneos. La población de estudio consistió en todos los árboles del huerto (0.4 ha). No se aplicó un muestreo probabilístico, sino que se seleccionó todo el huerto como unidad de estudio, instalando los instrumentos en puntos estratégicos dentro del campo.

La parcela se regó por medio de un sistema riego por goteo subsuperficial en funcionamiento desde 2018, con 2 tuberías laterales con emisores de descarga 2.3 L/h a 100 kPa de presión, presentando un espaciamiento de 1.0 m (10 emisores/una planta) por hilera de plantas y a 0.30 m de profundidad. Se utilizó una política de riego deficitario controlado (RDI) en la fase II de desarrollo del fruto (de principios de julio a mediados de agosto) para determinar el ahorro de agua en relación con el riego normal [373].

Tabla 1. Variables estudiadas

Tipo de variable	Variables
Independientes	Radiación solar (R_s), velocidad del viento (U_2), humedad relativa (RHmin, RHmax), temperatura (Tmin, Tmax), contenido de agua en el suelo (SWC), índices de vegetación (NDVI, NDWI), día del año (DOY), evapotranspiración de referencia (ETO)
Dependiente (objetivo)	Evapotranspiración real (ETA)
Controladas	Ubicación de sensores, profundidad de instalación (0.30 m), frecuencia de

muestreo (30 minutos para sensores, ~5 días para satélites)

Tabla 2. Instrumentos y técnicas de recolección de datos

Instrumento	Especificaciones	Función	Período
Estación meteorológica WatchDog 2000	Spectrum Technologies, Inc.	Registro de T, Rs, RH, U2, P cada 30 min	2018-2021
Torre de flujo Eddy Covariance (EC)	CNR4, CSAT3-D, Li-7500 (Campbell Scientific)	Medición de ETA, Rn, H, LE	2019-2021
Sensores de humedad Drill & Drop	Sentek Pty Ltd, 0-0.6 m profundidad	Monitoreo de SWC cada 30 min	2018-2021
Satélites Sentinel-2 (2A y 2B)	MSI nivel 2A, resolución 10/20/60 m, ~5 días	Imágenes multiespectrales	2018-2021
Datalogger CR3000	Campbell Scientific	Almacenamiento de datos EC	2019-2021
Router 4G	-	Transmisión de datos de sensores	2018-2021

La recopilación de datos se realizó de la siguiente manera:

1. Datos climáticos La estación meteorológica WatchDog 2000 midió automáticamente la temperatura, radiación solar, humedad relativa, velocidad del viento y precipitación cada 30 minutos.
2. Datos de ETA. La torre de Eddy Covariance registró flujos de calor sensible y latente y radiación neta a la frecuencia de 20 Hz (alta frecuencia) de manera cada 30 min (baja frecuencia).
3. Datos de SWC. Cuatro sensores Drill & Drop instalados a 0,8 m de los troncos de los árboles midieron el contenido de agua del suelo cada 30 minutos hasta alcanzar 0,6 m de profundidad (a pasos de 0,1 m). Estos sensores estaban conectados a placas electrónicas capaces de utilizar comunicación libre de

licencias para enviar los datos a un gateway, donde -mediante un router 4G- se habilitaron conexiones con internet (Ippolito et al., 2023).

4. Datos satelitales. Se descargaron y se preprocesaron 251 imágenes de los satélites Sentinel-2 (2A y 2B) en condiciones de cielo claro mediante la biblioteca de R "sen2r". La evapotranspiración de referencia diaria se calculó utilizando la ecuación de FAO-56 Penman-Monteith [364], que incorpora datos de radiación neta, temperatura, velocidad del viento y déficit de presión de vapor.

Los datos de la torre EC fueron procesados con un software propietario, descartando las trazas con precipitación > 2.5 mm. Goodness-of-fit of the recordings was assessed with the CR of the energy balance equation: $CR = (LE+H)/(R_n-G)$. The results were 0.98 (2019), 0.88 (2020), and 1.03 (2021), indicating suitability 3) for ADF.

A partir de imágenes Sentinel-2, el NDVI y NDWI se calculan:

- $NDVI = (\rho_{nir} - \rho_{red}) / (\rho_{nir} + \rho_{red})$
- $NDWI = (\rho_{nir} - \rho_{swir}) / (\rho_{nir} + \rho_{swir})$

Los datos se normalizaron para minimizar la influencia de valores extremos mediante un z-Score estándar: $z = (x - \mu) / \sigma$, y todas las características tenían una media cero y varianza 1.

Para la falta de datos de entrada (SWC, ETO, datos climáticos) se utilizó KNN-Imputer basado en el método k-Nearest Neighbor. Cuando el número de valores faltantes fue mayor que el número de valores observados (caso de VIs), se utilizó la imputación iterativa.

Se implementaron dos modelos utilizando la biblioteca scikit-learn en Python, con código liberado como open source:

Tabla 3. Modelos de Machine Learning implementados

Modelo	Descripción	Parámetros
Multi-Layer Perceptron (MLP)	Red neuronal feedforward con una capa de entrada, tres capas ocultas y una capa de salida. Función de activación: $Y = \psi(\sum w_i \cdot x_i + b)$ [384].	Solver Adam, 10 neuronas/capa, $\alpha=10^{-4}$, ReLU
Random Forest (RF)	Conjunto de árboles de decisión con bagging. Promedio del ensemble: $*f(x) = (1/M) \sum fm(x)*$ [385, 386, 387].	1000 árboles, max_features=auto, 50 niveles, samples_split=2, samples_leaf=2, bootstrap=True

Selección de características [s.f.] [En línea]: <http://pages.cs.wisc.edu/~jerryzhu/cs836/lecture13.pdf>

- Pares gráficos para buscar correlaciones visuales
- Coeficiente de correlación de Pearson (r) para medir la correlación lineal entre dos características
- Puntuaciones de importancia de características (FIS) utilizando el regresor de potenciación de gradiente y el método de importancia de Gini.

Se aplicó la técnica de búsqueda en cuadrícula (grid search) para calcular los valores óptimos de los hiperparámetros de ambos modelos.

Tabla 4. Métricas de evaluación

Métrica	Definición	Fórmula
RMSE	Error cuadrático medio	$*RMSE = \sqrt{[(1/n) \sum (\hat{y}_i - y_i)^2]}^*$
R ²	Coeficiente de determinación	de $*R^2 = 1 - [\sum (\hat{y}_i - y_i)^2 / \sum (y_i - \bar{y})^2]^*$
MBE	Error de sesgo medio	$*MBE = (1/n) \sum (\hat{y}_i - y_i)^*$

1. El mejor rendimiento se logró con Random Forest (RF2, RF3, RF4) con RMSE = 0,39 mm/d, R2 = 0,84 y MBE que oscila entre -0,025 y 0,041 mm/d.
2. Los predictores más importantes de ETA fueron ETO (0,577), SWC (0,197) y Rs (0,078).
3. Al excluir ETO del modelo, las características más importantes fueron: Rs (0.556), SWC y DOY.
4. La estrategia RDI permitió un ahorro de agua promedio del 38.5% en comparación con el riego completo (máximo del 46.9% en 2018).
5. El "data fusion" de la humedad del suelo, la información meteorológica y datos satelitales mejoró el rendimiento predictivo de manera sustancial con respecto a los modelos basados únicamente en variables meteorológicas.

ANÁLISIS DE RESULTADOS

Ambos modelos de aprendizaje automático supervisado (perceptrón multicapa, MLP; y bosque aleatorio, RF) fueron entrenados y validados con el conjunto de datos recopilado durante

cuatro años (2018-2021) de un huerto de cítricos en Palermo, Italia. Los principales resultados son los siguientes.

La Tabla 5 resume los resultados de los modelos MLP y RF para las 12 composiciones de características consideradas, teorizadas por el coeficiente de determinación (R^2), el error cuadrático medio (RMSE) y el sesgo de error medio (MBE).

Tabla 5

Comparación del rendimiento de los modelos MLP y RF para la predicción de ETA

Modelo	Combinación	Características de entrada	de R^2	RMSE (mm/día)	MBE (mm/día)
MLP1	10	Rs, U2, RHmin, RHmax, Tmin, Tmax, SWC, NDVI, NDWI, DOY	0.82	0.44	0.017
MLP5	6	Rs, U2, Tmax, SWC, NDWI, DOY	0.82	0.44	0.005
	6	Rs, U2, RHmin, RHmax, Tmin, Tmax	0.69	0.57	0.001
RF2	9	Rs, U2, RHmax, Tmin, Tmax, SWC, NDVI, NDWI, DOY	0.84	0.39	0.011
RF3	8	Rs, U2, RHmax, Tmax, SWC, NDVI, NDWI, DOY	0.84	0.39	0.009
RF4	7	Rs, U2, RHmax, Tmax, SWC, NDWI, DOY	0.84	0.39	0.007
RF7	4	Rs, Tmax, SWC, DOY	0.81	0.42	-0.005
RF8	6	Rs, U2, RHmin, RHmax, Tmin, Tmax	0.72	0.52	0.004

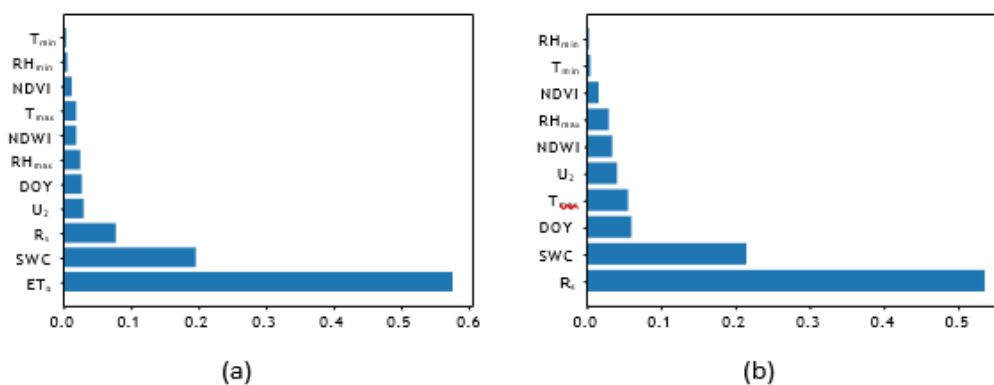
Fuente: Elaboración propia a partir de datos de Pagano (2024).

Para los modelos RF2, RF3 y RF4, el resultado obtenido con RF es el mejor resultado del conjunto con RMSE=0,39 mm/día y R2=0,84, lo que se debe al gran rendimiento de los modelos RF en este caso. Además, el modelo MLP también agrupó un buen pero menor rendimiento con un RMSE de 0.44 mm/día y un R2 de 0.82 para las combinaciones de MLP1 y MLP5.

En la Figura 1 se presenta la importancia relativa de cada característica en la predicción de la evapotranspiración real (ETA), calculada mediante el método de Gini utilizando Gradient Boosting Regressor.

Ilustración 1

Puntuaciones de importancia de características (Feature Importance Score, FIS) para la predicción de ETA




Fuente: Pagano, A. (2024). Internet of Things and Artificial Intelligence for Smart Sustainable Agriculture. Tesis doctoral, Università degli Studi di Palermo (Figura 6.11a).

La mejor predictora de ETA fue la CTE con una R2 de 0,577. El siguiente más importante fue el contenido de agua en el suelo (SWC) 0,197 y radiación solar (Rs) 0,078. Estos resultados sugieren que, por un lado, el estado hídrico del suelo y, por otro, las variables climáticas son fundamentales para una adecuada predicción de la evapotranspiración del cultivo.

En la Figura 2 se muestra la comparación entre los valores ETA observados (medidos por la torre de covarianza de remolinos) y los valores ETA predichos por el mejor bosque aleatorio (RF4 con 7 características), que logró la mayor precisión (RMSE = 0,39 mm/día, R² = 0,84).

Ilustración 2

Comparación entre la ETA observada y la ETA predicha por el modelo Random Forest RF4



Fuente: Pagano, A. (2024). Internet of Things and Artificial Intelligence for Smart Sustainable Agriculture. Tesis doctoral, Università degli Studi di Palermo (Figura 6.15d).

El grafo RF4 mostró una pendiente decreciente de 0.98, muy cercana a 1, lo que reflejaba una magnífica potencia predictiva. Los puntos estaban agrupados cercanos a la línea de identidad, lo que indica que las predicciones del modelo estaban en buen acuerdo con las reales medidas por la torre Eddy Covariance.

En la Tabla 6 se muestra el contraste entre la cantidad de agua aplicada bajo riego completo (Full Irrigation, FI) y bajo riego deficitario controlado (Regulated Deficit Irrigation, RDI) durante los años de estudio.

Tabla 6

Comparación del riego acumulado entre estrategias de riego completo y deficitario

Año	Σ FI (mm)	Σ RDI (mm)	Diferencia (mm)	Ahorro de agua (%)
2018	163.6	86.74	76.86	46.9
2019	271.0	157.75	113.25	41.8
2020	293.0	214.30	78.70	26.9
2021	200.0	200.00	0.0	0.0
Promedio (2018-2020)	242.5	152.9	89.6	38.5
Promedio (2018-2021)	231.9	164.70	67.20	28.9

Fuente: Elaboración propia a partir de datos de Pagano (2024).

La ejecución de la política de Riego Deficitario Continuo (RDI) conllevó a un ahorro de agua en los años de ejecución (2018-2020) del 38,5% en promedio, alcanzando un máximo de 46,9% en 2018. Durante el período de estudio (2018-2021), el ahorro medio fue del 28,9%.

Discusión

Los resultados de este estudio indicaron que tanto el Random Forest (RF) como el Multi-Layer Perceptron (MLP) pudieron caracterizar con precisión las relaciones no lineales entre las variables climáticas y de cultivo, inducir predicciones precisas de la evapotranspiración real (ETA) en condiciones de riego deficitario controlado (RDI). Estos resultados concuerdan con la bibliografía mencionada. En la Tabla 6.2, Los valores de RMSE y R2 típicos reportados en la literatura para la estimación de la ETA varían entre 0.37 y 0.97 mm/día, y 0.55 y 0.86, respectivamente. Los resultados (la RMSE varía entre 0.39 y 0.57 mm/día, y el R² entre 0.69 y 0.84) de este trabajo estaban dentro de estos valores y validaron los modelos.

En comparación con estudios que estimaron ETA en ecosistemas de bosques, cultivos herbáceos y pastizales, caracterizados por una cobertura de suelo homogénea, el presente estudio abordó un escenario más complejo: un cultivo arbóreo (cítricos) bajo riego deficitario. La ETA se ve poco afectada por los procesos evaporativos del suelo en sistemas homogéneos. Sin embargo, en los cítricos, la transpiración del dosel y la evaporación del suelo deben ser estimadas y eso complica el modelo.

Recientemente, con el objetivo de estimar ETA en cultivos arbóreos (olivo y granado) se tuvo en cuenta la temperatura de superficie terrestre (LST) como input en los modelos Cubist y RF, y se obtuvieron resultados un poco peores que los reportados en este trabajo (Wang et al., 2022). Sin embargo, debe tenerse en cuenta que tanto el olivo como el granado son altamente adaptables a ambientes áridos, y que para los cítricos se reconoce que son de los cultivos con mayores requerimientos hídricos. En esta línea, el presente trabajo constituye la primera aproximación documentada al uso de modelos de Machine Learning como Predictores de ETA en un cultivo arbóreo bajo RDI, en tanto que la evapotranspiración tiene que ser modelada simultáneamente en sus procesos no-lineales de transpiración y evaporación.

Los resultados del análisis de importancia de características (Figura 1) demostraron que el contenido de agua en el suelo (SWC) fue la segunda variable más importante para la predicción de ETA, con una puntuación de 0.197, solo superada por la evapotranspiración de referencia (ETO). Este hallazgo es consistente con múltiples estudios en la literatura que han demostrado que la humedad del suelo se convierte en un factor significativo para modelar ETA cuando el suministro de agua en el suelo es insuficiente (Wang et al., 2022).

En concreto, se demostró en (Mosre & Suárez, 2021) que añadir SWC como variable de entrada incrementa de forma notable la precisión de los modelos de predicción de ETA en ecosistemas con agua disponible limitada. Igualmente, (Wu et al., 2023) demostró que modelos predictivos de

Random Forest y otros algoritmos de ensamble pueden capturar dependencias no lineales entre el SWC y la ETA, lo cual concuerda con los resultados obtenidos en este trabajo.

Los resultados mostraron que los modelos Random Forest (RF2, RF3 y RF4) superaron ligeramente a los modelos Multi-Layer Perceptron (MLP) en términos de RMSE (0.39 vs 0.44 mm/día) y R^2 (0.84 vs 0.82). También, esta diferencia, aunque pequeña, es sorprendente con lo reportada en la literatura ecológica (Piccioni et al., 2022), en la cual se ha verificado que los modelos RF pueden capturar dependencias no lineales entre covariables con mayor efectividad que las redes neuronales tradicionales, en particular cuando el conjunto de datos no es extremadamente grande.

Además, el error relativo (violin plots) indicó para los modelos RF una mediana del error más cercana a cero (entre -0,001 y -0,022) que para los modelos MLP (entre 0,002 y 0,076), lo que implica que los RF tendieron a subestimar ligeramente los valores de ETA y los MLP a sobrestimarlos. Esta sobreestimación para los MLP ha sido reportada anteriormente en trabajos de evapotranspiración a través de humedales.

Un hallazgo sorprendente de este estudio fue que la precisión de la predicción seguía siendo similar con solo cinco características como entradas en lugar de diez (Tabla 1). Por ejemplo, el modelo RF7 usando solo cuatro características (R_s , T_{max} , SWC, DOY) alcanzó un R^2 de 0,81 y un RMSE de 0,42 mm/día lo que fue muy cercano al logrado por el modelo completo RF1 ($R^2 = 0.83$, RMSE = 0.40 mm/día).

Este resultado es aplicable a las agriculturas para sistemas IoT. La posibilidad de utilizar un conjunto pequeño de sensores (ej. sensor de radiación solar, sensor de temperatura, sensor de humedad del suelo, día del año) hace que los costos de implementar y mantener la infraestructura IoT en campo se reduzcan significativamente, como así también el consumo de energía de los dispositivos.

La eficiencia de uso del agua en el riego deficitario controlado (RDI) en la etapa II de desarrollo del fruto se incrementó en promedio un 38,5% durante los años 2018-2020; con un máximo de 46,9% en 2018. Estos son resultados similares a los reportados en trabajos previos sobre RDI en cítricos (Zhang, 2023), que indicaron que la imposición de un déficit hídrico controlado en etapas determinadas del desarrollo del fruto no compromete de forma significativa el rendimiento ni la calidad del cultivo.

El 2021 fue la excepción, en parte porque las temperaturas extremadamente altas durante el verano, combinadas con las condiciones de cultivo anteriores al período de estrés de agua ECE, disuadieron al agricultor de aplicar la estrategia RDI. Este caso pone de manifiesto una importante

limitación de la estrategia RDI: su éxito está condicionado por la climatología y fenología del cultivo en el momento de su aplicación.

A pesar de los resultados prometedores, este estudio tiene algunas limitaciones que deben ser tomadas en cuenta. En primer lugar, los modelos se entrenaron y validaron en una sola plantación de cítricos en una región específica (Palermo, Italia, clima mediterráneo). La extrapolación de los modelos para usarlos en otras regiones o bajo condiciones climáticas diferentes, tipos de suelo o variedades de cítricos debería ser validada con datos locales.

Segundo, la variable precipitación (P) y riego (I) también fueron eliminadas del análisis. Aunque estas variables se consideraron inicialmente como posibles características de entrada, fueron descartadas por ser valores de precipitación mediciones localizadas que podrían restringir la posibilidad de generalizar los modelos (Guo et al., 2024), y porque los tiempos de riego por goteo subsuperficial se correlacionaron débilmente con las mediciones de ETA (coeficiente de correlación de Pearson=0.150 y importancia de características de puntuación=0.003). Estas variables, no obstante, pueden ser de interés para otros sistemas de riego o regiones con distinto patrón de precipitación a otras escalas.

Tercero, el estudio se llevó a cabo sobre mediciones de ETA realizadas con una torre mediante la técnica de Eddy Covariance, un instrumento frío y elaborado que requiere de calibraciones y mantenimiento constantes. Aunque estas medidas son consideradas como el estándar de referencia para la estimación de ETA, su aplicación es limitada en la mayoría de los sistemas agrícolas. El beneficio del método propuesto es que después de que los modelos hayan sido entrenados con los datos de EC, pueden ser aplicados para predecir ETA con sólo usar sensores de bajo costo (estación meteorológica y sensores de humedad del suelo), los cuales son más accesibles para los agricultores.

Por último, no se tuvo en cuenta la influencia de las estrategias de riego (apartole de RDI y riego completo) en la exactitud de los modelos. En trabajos futuros, se podría analizar en qué medida varía la exactitud de las predicciones de ETA entre sistemas de riego y estadios fenológicos del cultivo.

Los resultados de este estudio tienen grandes implicaciones para la toma de decisiones en el campo de las prácticas agrícolas sostenibles. La posibilidad de poder predecir con precisión el tiempo estimado de llegada (ETA) del agua vía sensores IoT de bajo costo (estaciones meteorológicas y sensor de humedad del suelo) permite a los agricultores tomar decisiones en cuanto al momento del riego y la cantidad de agua, para minimizar el desperdicio de agua siempre que sea posible incrementar la productividad del cultivo.

Aunque quizás no sea una sorpresa para nadie este 38,5 % en ahorro de agua con la estrategia RDI, junto con la precisión de los modelos de ML para predecir las necesidades hídricas del cultivo, nos indica que la integración de IoT e inteligencia artificial en agricultura puede contribuir de forma importante para alcanzar los objetivos en sostenibilidad hídrica, más aún en regiones que más se asemejan al mediterráneo en donde el agua es un recurso limitado y cada vez más disputado.

Asimismo, la factibilidad de disminuir la cantidad de sensores requeridos (de 10 a 4 features) sin afectar la exactitud de las predicciones hace más accesible la adopción de esta tecnología para pequeños y medianos productores, para quienes el costo de implementación de sistemas IoT completos puede resultar prohibitivo.

CONCLUSIONES

En respuesta al objetivo principal del presente estudio, que fue analizar el uso de datos IoT para la toma de decisiones en la agricultura sostenible mediante el diseño de un sistema basado en sensores IoT, tecnología LoRaWAN y modelos de Machine Learning para predecir la evapotranspiración real diaria en un cultivo de cítricos bajo riego deficitario controlado, se concluye lo siguiente:

En primer lugar, los modelos de aprendizaje automático (Random Forest y Multi-Layer Perceptron) se validan como predictores potentes de la evapotranspiración real en cítricos, con una precisión del 84% ($R^2=0,84$) y un error de 0,39 mm/día (RMSE). El Random Forest (RF4) basado en las siete características (radiación solar, velocidad del viento, humedad relativa máxima, temperatura máxima, contenido de agua en el suelo, índice de agua por diferencia normalizada y día del año) logra el mejor resultado, y puede ser tomado como un buen punto de partida para diseñar y desarrollar sistemas de soporte a la decisión en tiempo real.

Segundo, la inclusión de la información del sensor IoT de Humedad del Suelo en el modelo predictivo incrementa considerablemente la exactitud (R^2 de 0.72 a 0.84; RMSE de 0.52 a 0.39 mm/día) en comparación con los modelos que contienen únicamente variables meteorológicas. Esta mejora del 14% en el R^2 y del 25% en RMSE justifica el gasto en sensores de humedad de suelo para aplicación en agricultura de precisión.

Tercero, la implementación de la estrategia de riego deficitario controlado predecible, basada en las predicciones del modelo, produjo un ahorro de agua 38,5% en promedio con respecto al riego completo, hasta un máximo del 46,9% bajo condiciones óptimas. Este ahorro de agua contribuye directamente a la sostenibilidad de la agricultura en regímenes mediterráneos y semiáridos, donde el agua es un bien escaso.

Cuarto, la posibilidad de reducir el número de sensores IoT necesarios de diez a solo cuatro características (radiación solar, temperatura máxima, contenido de agua en el suelo y día del año) sin sacrificar significativamente la precisión ($R^2 = 0.81$, RMSE = 0.42 mm/día) reduce los costos de implementación y mantenimiento, facilitando la adopción de estas tecnologías por parte de pequeños y medianos agricultores.

Quinto, la combinación de IoT (sensores de humedad de suelo, estaciones meteorológicas, conectividad LoRaWAN), inteligencia artificial (Random Forest) y estrategias de riego deficitario controlado constituye un enfoque integral y escalable para la toma de decisiones en agricultura sostenible. Esta aproximación plantea oportunidades para mejorar eficiencia hídrica, disminuir costos operativos y aumentar la resiliencia de los cultivos frente al cambio climático y a la disponibilidad limitada de agua.

En última instancia, la integración de tecnologías IoT y modelos de Machine Learning puede cambiar la gestión de riego en cultivos leñosos, desde una metodología basada en calendarios fijos o experiencia empírica a una metodología basada en datos en tiempo real. Este cambio hacia una agricultura informada por los datos es un paso adelante para la sostenibilidad hídrica, la seguridad alimentaria y la rentabilidad de los sistemas de producción agrícola en regiones de estrés hídrico creciente.

REFERENCIAS BIBLIOGRÁFICAS

- Avşar, E., & Mowla, Md. N. (2022). Wireless communication protocols in smart agriculture: A review on applications, challenges and future trends. *Ad Hoc Networks*, 136, 102982. <https://doi.org/10.1016/j.adhoc.2022.102982>
- dos Santos, R. A., Mantovani, E. C., Bufon, V. B., & Fernandes-Filho, E. I. (2024). Improving actual evapotranspiration estimates through an integrated remote sensing and cutting-edge machine learning approach. *Computers and Electronics in Agriculture*, 225, 109258. <https://doi.org/10.1016/j.compag.2024.109258>
- FAO. (2023). *World Food and Agriculture – Statistical Yearbook 2023*. FAO. <https://doi.org/10.4060/cc8166en>
- Guo, N., Chen, H., Han, Q., & Wang, T. (2024). Evaluating data-driven and hybrid modeling of terrestrial actual evapotranspiration based on an automatic machine learning approach. *Journal of Hydrology*, 628, 130594. <https://doi.org/10.1016/j.jhydrol.2023.130594>
- Ippolito, M., De Caro, D., Ciraolo, G., Minacapilli, M., & Provenzano, G. (2023). Estimating crop coefficients and actual evapotranspiration in citrus orchards with sporadic cover weeds based on ground and remote sensing data. *Irrigation Science*, 41(1), 5-22. <https://doi.org/10.1007/s00271-022-00829-4>
- Mosre, J., & Suárez, F. (2021). Actual Evapotranspiration Estimates in Arid Cold Regions Using Machine Learning Algorithms with In Situ and Remote Sensing Data. *Water*, 13(6), 870. <https://doi.org/10.3390/w13060870>
- Piccioni, F., Casenave, C., Baragatti, M., Cloez, B., & Vinçon-Leite, B. (2022). Calibration of a complex hydro-ecological model through Approximate Bayesian Computation and Random Forest combined with sensitivity analysis. *Ecological Informatics*, 71, 101764. <https://doi.org/10.1016/j.ecoinf.2022.101764>
- Wang, X., Gao, B., & Wang, X.-S. (2022). Investigating the ability of deep learning on actual evapotranspiration estimation in the scarcely observed region. *Journal of Hydrology*, 607, 127506. <https://doi.org/10.1016/j.jhydrol.2022.127506>
- Wu, Z., Cui, N., Gong, D., Zhu, F., Xing, L., Zhu, B., Chen, X., Wen, S., & Liu, Q. (2023). Simulation of daily maize evapotranspiration at different growth stages using four machine learning models in semi-humid regions of northwest China. *Journal of Hydrology*, 617, 128947. <https://doi.org/10.1016/j.jhydrol.2022.128947>

Zhang, Y. (2023). *A framework for estimating actual evapotranspiration through spatial heterogeneity-based machine learning approaches.*

CONFLICTO DE INTERÉS:

Los autores declaran que no existen conflicto de interés posibles

FINANCIAMIENTO

No existió asistencia de financiamiento de parte de pares externos al presente artículo.

NOTA:

El artículo no es producto de una publicación anterior.

