



# Sistema para la toma de decisiones en el riego de cultivos protegidos basado en aprendizaje de máquina

*Dennis Villavicencio\_Quintero, Emilio Cabrera\_Hernández, Alain Godo\_Alonso, Ivan Santana Ching*

## RESUMEN / ABSTRACT

La escasez de agua constituye una preocupación de la industria agropecuaria, y es que esta emplea en la irrigación cuatro quintas partes del total de agua fresca consumida y dos tercios del total empleado para consumo humano. Por tal razón resulta esencial el desarrollo de sistemas que optimicen el empleo de agua en el riego. En las casas de cultivo protegido de la UEB “Valle del Yabú” del municipio Santa Clara el riego se realiza mediante un sistema basado en goteo que requiere la presencia de un operario para la toma de decisiones, el cual no tiene información sobre algunas de las variables hidrometeorológicas que rigen al cultivo. Este artículo se centró en diseñar un sistema de apoyo a la toma de decisiones en el riego basado en aprendizaje de máquina. Como parámetro de importancia del sistema se calcula el coeficiente de evapotranspiración del cultivo utilizando para ello la fórmula de Turc. Se realiza un acondicionamiento de los datos ambientales recopilados y con ellos se entrenan modelos de regresión lineal, bosques aleatorios regresivos y bosques aleatorios de gradiente mejorado para determinar valores de evapotranspiración futuros empleando la plataforma Apache Spark. El modelo que obtuvo los mejores resultados fue el bosque aleatorio regresivo con un coeficiente de determinación ( $r^2$ ) de 0,79 y con él se calcula el volumen de agua perdido por el cultivo. Finalmente, el sistema fue capaz de proveer las estimaciones de ambas variables las que favorecen la toma de decisiones por parte de los especialistas.

Palabras claves: cultivo protegido, inteligencia artificial, aprendizaje de máquina, evapotranspiración, bosques aleatorios regresivos.

*The water scarcity is a concern of the agricultural industry as it uses four fifths of the of the total fresh water consumed for irrigation and two thirds of the total used for human consumption. For this reason, the development of systems that optimize the use of water in irrigation is essential. In the greenhouses of the UEB "Valle del Yabú" of the Santa Clara municipality, irrigation is carried out using a drip-based system that requires the presence of an operator for decision-making who does not have information about some of the hydrometeorological variables that govern the crop. This paper focused on to design a support system for decision-making in irrigation based on machine learning. As an important parameter of the system, the evapotranspiration coefficient of the crop is calculated using the Turc formula. The collected environmental data is conditioned and linear regression, regressive random forests, and gradient-boosted trees regression models are trained with them to determine future evapotranspiration values using the Apache Spark framework. The model that obtained the best results was the regressive random forest with a coefficient of determination ( $r^2$ ) of 0,79 and with it the volume of water lost by the crop is calculated. Finally, the system was able to provide the estimates of both variables, which favour decision-making by specialists.*

*Keywords: greenhouse cultivation, artificial intelligence, machine learning, evapotranspiration, random regressive forests.*

*Title: Decision-making system for irrigation of protected crops based on machine learning*

# 1. -INTRODUCCIÓN

Para finales del año 2050 se prevé un incremento de la población mundial a aproximadamente 9,1 billones de personas, lo que constituye un 34% más que la población actual; bajo esas condiciones, los requerimientos de alimentos se incrementarán un 70% [1]. En este sentido la agricultura juega un papel predominante, al ser la mayor fuente de alimentos. Sin embargo, para su desarrollo, es necesario el uso de varios recursos dentro de los que se destaca el agua, con un impacto significativo en la irrigación. Ante este complejo panorama es necesario optimizar el consumo de agua en la agricultura [2].

Los sistemas de irrigación por goteo ofrecen los mejores índices de conservación de agua entre todos los demás sistemas de irrigación. La principal razón de esta conservación se encuentra en que limita la zona humedecida a aproximadamente un 30% de lo permitido por los demás sistemas, reduciendo, por tanto, el drenaje profundo, el escurrimiento, y la evaporación de la superficie del suelo [3]. Pero el sistema por sí solo no basta, es necesario emplear alguna herramienta que permita perfeccionar los tiempos de irrigación para lograr su optimización [4, 5].

En función de dicho objetivo se debe tener una idea clara de las necesidades de los cultivos y se requiere elaborar algún modelo que relacione las principales variables que describen a la planta. Pero obtener el modelo matemático es complejo, demanda de numerosos análisis bajo el criterio de expertos que puedan definir el peso y tipo de la relación entre todos los parámetros, además, el modelo elaborado para un área o cultivo determinada puede no ser aplicable en otros casos que los analizados [5].

En la actualidad, el manejo de grandes cantidades de datos se vuelve una necesidad recurrente, entre otras causas, por el uso reiterado de la inteligencia artificial y su integración con numerosas áreas de la técnica, la investigación y la sociedad. Viendo el caso de la agricultura, resulta evidente como el empleo de dichas herramientas puede traer beneficios no solo al sector sino a la sociedad como un todo, ya que este se ha caracterizado comúnmente por tener un alto nivel de incertidumbre a causa de condiciones climáticas y ambientales y un balance volátil entre oferta y demanda [6, 7].

Resulta evidente entonces como el recopilar datos de variables que rigen los cultivos influiría de forma positiva en su manejo eficiente [8]. Sobre el tema Osinga [7] realiza una revisión sobre la adopción del Big Data en aplicaciones reales, mientras Tantalaki [9] lo hace sobre artículos publicados sobre el tema; ambos llegan a la conclusión de que esta tecnología desempeñará un papel fundamental en el futuro de la agricultura, si bien todavía su uso es discreto en la mayoría de los casos, con poca difusión. Cravero [10] investiga sobre las principales dificultades que enfrenta el Big Data en la agricultura y llega a la conclusión que el aumento exponencial en la cantidad de datos, que provoca que se deban modificar los modelos elaborados, resulta uno de los problemas principales y por lo tanto la dificultad a enfrentar.

Apache Spark es un motor informático rápido y versátil diseñado para el procesamiento de datos a gran escala. Realizando cálculos en memoria con conjuntos de datos distribuidos resilientes, Spark utiliza la memoria principal de manera más eficiente y minimiza las transferencias de datos de disco a disco. Internamente Spark emplea Hadoop, el cual es una infraestructura de sistemas distribuidos ideal para analizar y procesar cantidades masivas de datos. Por dicha razón tanto varios autores emplean la herramienta para el procesamiento de datos derivados de la agricultura [11, 12].

## 2.- METODOLOGÍA

Para la elaboración del conjunto de datos procesados es necesario inicialmente establecer un método de recogida y/o obtención de la data referente a las variables agrometeorológicas, posteriormente debe utilizarse alguna herramienta de software capaz de procesar los datos según se determine, así como elaborar gráficas, tablas e información relevante para la toma de decisiones.

### 2.1.- RECOPIACIÓN DE DATOS Y PROCESAMIENTO CON APACHE SPARK

Como resultado del empleo de una aplicación IoT encargada de la recopilación de datos, se obtuvo un histórico de valores de las variables iluminación, temperatura y humedad ambiental y humedad del suelo. Para esto se montaron tres nodos de recopilación de datos; dos de ellos destinados a medir humedad y temperatura del aire, los cuales se colocaron dos en un mismo cantero, y el nodo restante destinado a medir iluminación fue colocado en medio de la casa de cultivo. Los nodos se comunicaban a través de una red inalámbrica de largo alcance con un nodo enrutador que se encargaba de procesar la comunicación, al que se le enviaban las mediciones cada 15 minutos, y que se conectó a una Raspberry Pi 4 colocada en la sala de control del riego, que se encargaba de almacenar los datos y de comunicarse con el usuario [6].

Spark constituye una herramienta de software lo suficientemente versátil y ligera para ser empleada en la aplicación. Las funciones incluidas dentro del paquete Spark SQL permiten modificar grandes conjuntos de datos con una carga de procesamiento adecuada para el trabajo con sistemas computacionales discretos como el RaspberryPi [13], mientras que con

Recibido: 07/2023 Aceptado: 11/2023

MLlib se accede de manera rápida a algoritmos de reducción de dimensionalidad. Adicionalmente se explotan librerías como matplotlib y pandas con sus paquetes pensados para la elaboración y visualización de gráficos.

## 2.2.- DETERMINACIÓN DEL COEFICIENTE DE EVAPOTRANSPIRACIÓN

El principal causante de pérdida de la humedad en el suelo lo constituye el agua evaporada desde la superficie libre del suelo y la transpirada por la planta [14]. A la combinación de ambos factores se la conoce como evapotranspiración (ETo) y se define como la cantidad de agua perdida en forma de vapor, desde una superficie cubierta de vegetación. Dicha variable resulta de gran utilidad a la hora de tomar decisiones en la agricultura, principalmente en lo referente al riego, por lo que constituye un buen añadido para la base de datos.

La forma más precisa y usual para estimar la Eto es mediante la ecuación de la FAO-56 Penman-Monteith [15], pero requiere valores de numerosos parámetros ambientales como la pendiente de la curva de la presión de vapor de saturación vs temperatura del aire, el flujo de calor en la superficie del suelo y la presión de vapor de saturación. Como alternativa se emplea la ecuación de Turc [16], la cual requiere una menor cantidad de variables ambientales para determinar el valor de la ETo y cuya expresión matemática es:

Para  $RH < 50\%$ :

$$ETo = 0.013 * \left(\frac{T}{T+15}\right) * (23.89 * R_s + 50) * \left(1 + \frac{50-RH}{70}\right) \quad (1)$$

Para  $RH > 50\%$ :

$$ETo = 0.013 * \left(\frac{T}{T+15}\right) * (23.89 * R_s + 50) \quad (2)$$

Donde Eto es la evapotranspiración de referencia, expresada en mm/día;  $R_s$  es la radiación solar incidente sobre la superficie del cultivo, expresada en MJ/m<sup>2</sup>/día; T es la temperatura del aire, expresada en °C y RH es la humedad relativa, expresada en % [16]. La evapotranspiración real del cultivo se determina multiplicando la evapotranspiración de referencia por el coeficiente de cultivo, un factor adimensional cuyo valor depende del cultivo, de su ciclo relativo, y de su fenología, así como de las condiciones específicas del cultivo en la explotación y de las condiciones climáticas locales. Otros investigadores se han basado en técnicas de Inteligencia Artificial para realizar esta estimación [17-19].

## 2.3.- PREPARACIÓN DE LOS DATOS PARA EL MODELADO

De la base de datos obtenida de los nodos debieron ser filtrados valores de variables propias de la comunicación como manejadores de alarmas, estados del sistema y ajustes de límites, las cuales resultaban innecesarias para el entrenamiento de los modelos. Las variables que se mantuvieron debieron ser indexadas, pues los indicadores asignados automáticamente durante la comunicación y almacenamiento eran poco sugerentes. Para ajustar la base de datos se agruparon los valores medidos con una diferencia de tiempo menor a 15 minutos, por ser el tiempo de muestreo de la red. En caso de los dos nodos que midieron temperatura, humedad y humedad del suelo se determinó emplear el valor promedio de sus mediciones en los instantes donde existía el dato de ambos. En los casos donde uno de los dos fallaba, se utilizaba la información del segundo [6].

La ETo obtenida de la ecuación de Turc constituye un promedio diario, pero el valor de radiación solar que se empleó provino de una medición instantánea. Por tanto, se determinó expresar el cálculo de ETo con una unidad de 0,1 mm<sup>3</sup>/ha/s. Para el entrenamiento de los modelos se crearon siete conjuntos de variables, los cuales agruparon diferente cantidad y distribución de los puntos de datos para formar series de tiempo, ya que estas constituyen una herramienta clave para modelar fenómenos dependientes del tiempo, así como para detectar patrones estacionales, ciclos y anomalías en los datos [20]. Dichas series contaron como variables de entrada o características los valores de: la hora a la que se planea predecir el valor; la diferencia de tiempo entre la hora a la que se desea predecir y el punto actual de la serie de tiempo; los valores de temperatura, humedad del ambiente y humedad del suelo en el punto de la serie de tiempo. Como variable a predecir o etiqueta de todos los conjuntos de datos se estableció un valor de evapotranspiración.

## 3.- RESULTADOS Y DISCUSIÓN

Los datos obtenidos por la red de sensores IoT corresponden a un período de siembra de pepino ocurrido en las casas de cultivo protegido de la UEB “Valle del Yabú” en el municipio Santa Clara, provincia Villa Clara en Cuba en agosto del año 2022.

### 3.1.- EVALUACIÓN, AJUSTE Y DEPURACIÓN DE LOS DATOS PARA EL TRABAJO

La base de datos original contaba con mediciones de 58 variables, con un tamaño de data de 130446 elementos (Figura 1), de las cuales se mantuvieron la iluminación, la temperatura ambiental, la humedad ambiental y la humedad del suelo, reduciéndose la cantidad de datos a 16264.

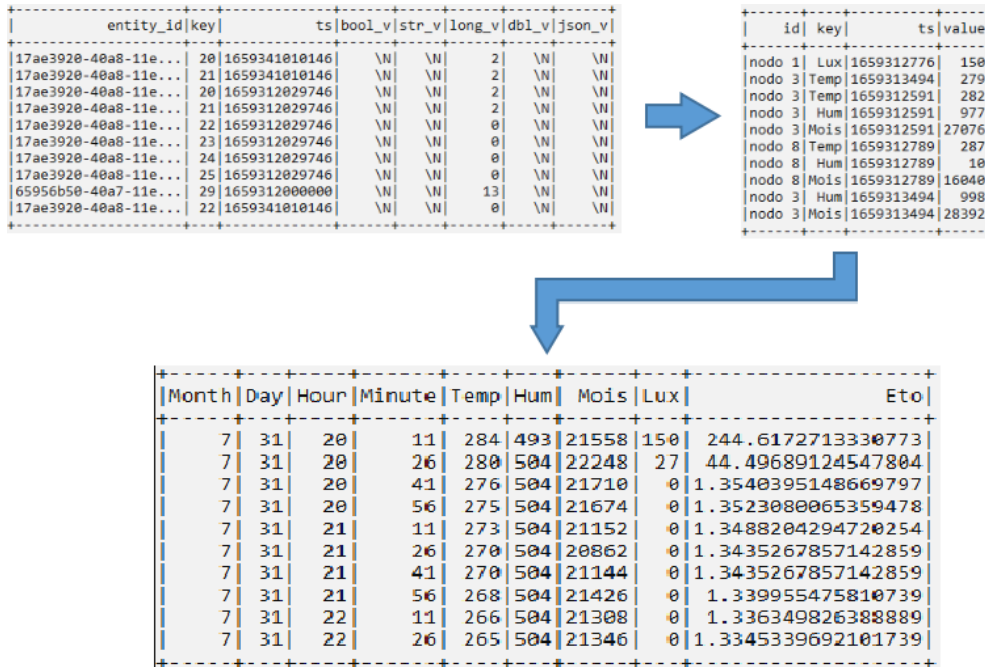


Figura 1

**Modificaciones y agrupamientos del conjunto de datos recopilados por los sensores (Fuente: elaboración propia).**

Los datos fueron agrupados por instante de tiempo convertido a formato de fecha. Se determinó un valor único por variable y se filtraron los datos con valores de luminosidad incorrectos, lo que disminuyó el tamaño de la data a 2182 elementos. Posteriormente, empleando la fórmula de Turc (Ecuaciones 1 y 2), se determinó la evapotranspiración para cada punto de la base de datos (Figura 2). La evapotranspiración promedio determinada entre todos los puntos fue de 7263,03 mm<sup>3</sup>/ha/s, en el caso de los valores diurnos el promedio fue de 18332,66 mm<sup>3</sup>/ha/s, el cual representó el valor más cercano a la incidencia diaria, ya que esta se ve afectada en su mayoría por los valores diurnos. Del total, el valor más alto calculado fue de 56312,95 mm<sup>3</sup>/ha/s y el mínimo 1,24 mm<sup>3</sup>/ha/s.

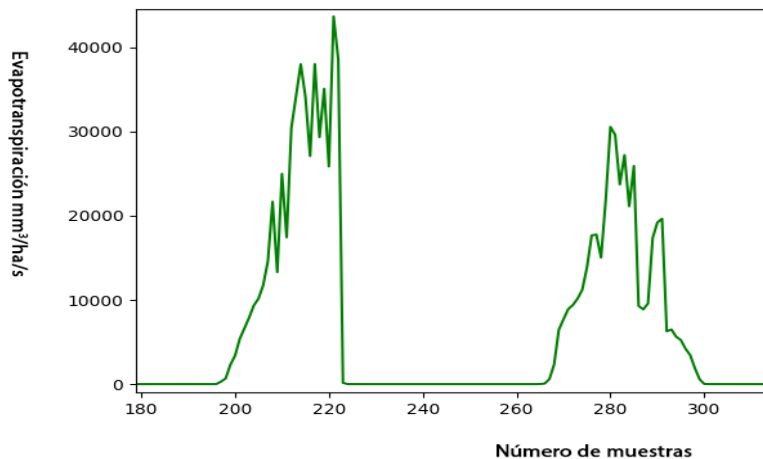


Figura 2

**Fragmento de los valores de evapotranspiración determinados con la fórmula de Turc (Fuente: elaboración propia).**

Se determinó el factor de correlación entre los datos y se observó que las variables con mayor factor de correlación fueron la temperatura, la humedad del suelo y la luminosidad (Figura 3), por lo que se consideró el aplicar una reducción de dimensionalidad que englobara dichas variables.




Figura 3

Correlación entre las variables de trabajo (Fuente: elaboración propia).

### 3.2.- CREACIÓN DE LOS CONJUNTOS DE DATOS

Para la creación de las series de tiempo se decidió optar por un máximo de cuatro puntos temporales, con el objetivo de reducir la carga de procesamiento del sistema encargado de modelar el algoritmo inteligente futuro. Se decidió seguir dos desarrollos temporales diferentes, uno basado en mediciones del mismo día de la predicción, separadas por un período de 2 horas, que aportaran datos de la variación de las condiciones climáticas en dicho día; la otra variante consistió en tomar los datos de la misma hora de la medición con diferencias de un día, los que aportan información de como se ha comportado el clima en un período más amplio. Ambos desarrollos fueron combinados dando como resultado los siguientes conjuntos de datos, listos para ser empleados por algún sistema inteligente:

- 1p\_2h: Un punto, de dos horas previas a la predicción.
- 1p\_1d: Un punto, a la misma hora del día anterior a la predicción.
- 2p\_2h: Dos puntos, de dos y cuatro horas previas a la predicción.
- 2p\_1d: Dos puntos, de los dos días anteriores a la predicción.
- 2p\_2h\_1d: Dos puntos, uno de dos horas previas y uno del día anterior.
- 3p\_2h\_1d: Tres puntos, dos de dos y cuatro horas previas y uno del día anterior.
- 4p\_2h\_1d: Cuatro puntos, dos de dos y cuatro horas previas y dos de los dos días anteriores.

### 3.3.- ENTRENAMIENTO DE LOS MODELOS

Para cada modelo se realizaron varias pruebas con diferentes parámetros de ajuste, con el objetivo de determinar la configuración que presentó los mejores resultados por cada modelo. Dicha configuración fue empleada en el paso comparativo entre modelos.

Con el modelo de Regresión Lineal (LR), se modificó el valor de las iteraciones máximas, probándose con 100, 10000 y 1000000 en los conjuntos de datos de 1p\_2h, 1p\_1d y 2p\_2h\_1d. Se observó que el valor de 10000 tenía mejores resultados para los datos con diferencia de dos horas con respecto al valor de 100, y resultados análogos con el valor de 1000000.

Los parámetros modificados en el caso de los Bosques Aleatorios Regresivos (RRF) fueron numTrees, maxDepth y maxBins, los cuales se variaron entre los valores de diez, 20 y 30 para los dos primeros, y 32, 80 y 120 para los compartimientos máximos. Los resultados de la combinación numTrees=20, maxDepth=20 y maxBins=80 fueron al menos tan buenos como los de las demás, por lo que fue seleccionada para entrenar el modelo. Para el caso de los Bosques Aleatorios de Gradiente Mejorado (GBTR) se inició el ajuste modificando el parámetro maxIter, dándole valores de 20 y 100. Se observó que el valor 20 obtuvo resultados ligeramente mejores que el de 100, por lo que este fue seleccionado.

Se realizó una comparación entre los diferentes algoritmos de ML utilizados, en un primer caso, los grupos de datos originalmente formados. En un segundo caso, se empleó un algoritmo de reducción de dimensionalidad que redujo la cantidad de variables de entrada en los grupos de datos originales y con ellos fueron entrenados los modelos con parámetros idénticos en ambos. Los modelos entrenados con los datos originales y los entrenados con datos de dimensionalidad reducida mostraron valores semejantes en los criterios de error para algoritmos de RRF.

Los mejores resultados en todos los parámetros se obtuvieron en los modelos de RRF, y los peores en los modelos de LR. En los modelos de RRF, el grupo de datos que mostró los mejores resultados fue el 2p\_2h. En la figura 4 se muestra la predicción y el valor real para dicho grupo.




Figura 4

Comparación del valor real y la predicción de evapotranspiración en el grupo de datos 2p\_2h (Fuente: elaboración propia).

### 3.4.- DETERMINACIÓN DEL VOLUMEN DE AGUA PERDIDA POR EVAPOTRANSPIRACIÓN

Empleando el modelo de RRF con dimensionalidad reducida que presentó el mejor resultado con el grupo de datos 2p\_2h se realizó una predicción del valor de evapotranspiración en cada punto que se encontraba en el período de siete horas entre las ocho de la mañana y las tres de la tarde. Período donde se realizaban los riegos, obteniéndose un valor promedio de

23162,75 mm<sup>3</sup>/ha/s. Como diferencia de tiempo para la estimación se dividió el período en cinco riegos, determinándose un intervalo entre ellos de 84 minutos.

Con los valores de evapotranspiración presente y futura que predijo el modelo, multiplicados por el coeficiente del cultivo el cual fue de 0,75, pues el pepino se encontraba en la etapa final de siembra cuando se realizaron las mediciones. Además, teniendo en cuenta la diferencia de tiempo en segundos entre dos instantes de riego en un cantero de la casa de cultivo, se calculó el volumen de agua por área de cultivo que se pierde (en mm<sup>3</sup>/ha) como el área debajo de una curva de evapotranspiración en función del tiempo, ya que la evapotranspiración es una medida de velocidad de pérdida de agua. El volumen perdido promedio durante el tiempo analizado fue de 4,37 L, con un valor máximo de 8,67 L y un mínimo de 1,57 L.

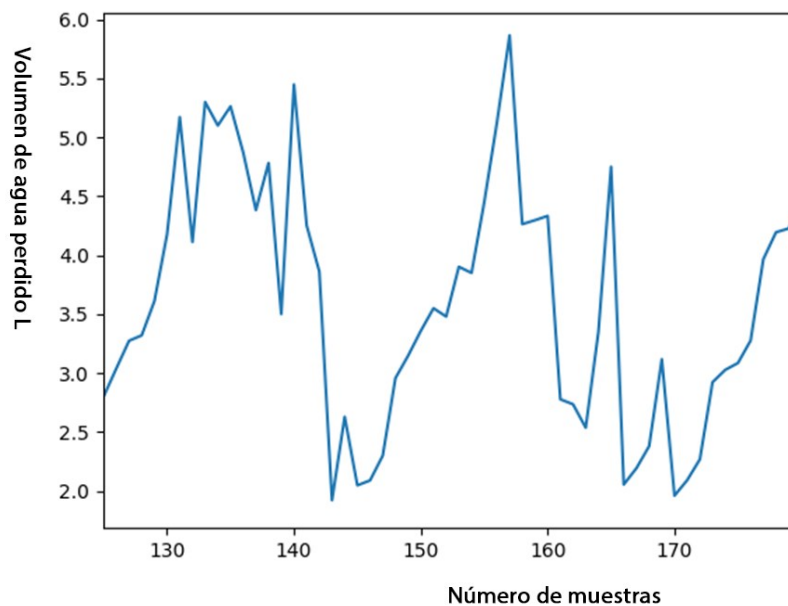


Figura 5

Fragmento de distribución de los datos de volumen de agua perdida por causa de la evapotranspiración (Fuente: elaboración propia).

## 4.- CONCLUSIONES

Como resultado final de esta investigación se obtuvo un sistema de apoyo al riego para condiciones de cultivo protegido basado en ML. La eficacia del modelo quedó demostrada tras un análisis de sus parámetros de ajuste y una comparación con fuentes bibliográficas actualizadas. El sistema obtenido mostró una toma de decisiones óptima en comparación a la planificación existente. En base a estos resultados pueden plantearse las siguientes conclusiones:

- Se evidenció cómo a partir de los datos disponibles la función más apropiada para el cálculo de la Eto fue la de Turc, la que arrojó un valor promedio diario equivalente a 1,5 mm/día.
- A partir de la literatura consultada se determinó que las técnicas de ML más apropiadas para el sistema fueron la LR, los RRF y los GBTR. De ellas la que mejor resultados obtuvo fue los RRF, con un coeficiente r<sup>2</sup> máximo de 0,79.
- A partir de los datos recopilados el sistema fue capaz de proveer las estimaciones de la evapotranspiración y el volumen de agua perdido, los cuales constituyen indicadores del estado del cultivo que favorecen la correcta toma de decisiones de los especialistas.

## REFERENCIAS

1. Pérez Vázquez A, Leyva Trinidad DA, Gómez Merino FC. Desafíos y propuestas para lograr la seguridad alimentaria hacia el año 2050. *Revista mexicana de ciencias agrícolas*. 2018;9(1):175-89.
2. Wang J, Liu L, Zhao K, Wen Q. Farmers' adoption intentions of water-saving agriculture under the risks of frequent irrigation-induced landslides. *Climate Risk Management*. 2023;39:100484.
3. Abd-Elaty I, Fathy I, Kuriqi A, John AP, Straface S, Ramadan EM. Impact of Modern Irrigation Methods on Groundwater Storage and Land Subsidence in High-water Stress Regions. *Water Resources Management*. 2023;37(4):1827-40.
4. Gamal Y, Soltan A, Said LA, Madian AH, Radwan AG. Smart Irrigation Systems: Overview. *IEEE Access*. 2023:1-.
5. Vallejo-Gómez D, Osorio M, Hincapié CA. Smart Irrigation Systems in Agriculture: A Systematic Review. *Agronomy*. 2023;13(2):342.
6. Cardenas\_Rivero A, De\_la\_Paz R, Portal J, Duran-Faundez C, Santana I. Potentialities of data processing in internet of things applications. *International Journal of Embedded Systems*. 2021;14(5):486-96.
7. Osinga SA, Paudel D, Mouzakitis SA, Athanasiadis IN. Big data in agriculture: Between opportunity and solution. *Agricultural Systems*. 2022;195:103298.
8. Madruga-Peláez A, Estevez-Pérez A, Sosa R, García Algora CM, Santana I. Red de Sensores Inalámbricos para la Adquisición de Datos en Casas de Cultivo. *Ingeniería*. 2019;24:224-34.
9. Tantalaki N, Souravlas S, Roumeliotis M. Data-Driven Decision Making in Precision Agriculture: The Rise of Big Data in Agricultural Systems. *Journal of Agricultural & Food Information*. 2019;20(4):344-80.
10. Cravero A, Pardo S, Sepúlveda S, Muñoz L. Challenges to Use Machine Learning in Agricultural Big Data: A Systematic Literature Review. *Agronomy*. 2022;12(3):748.
11. Tang R, Aridas NK, Talip MSA. Design of a data processing method for the farmland environmental monitoring based on improved Spark components. *Front Big Data*. 2023;6:1282352.
12. Madhuri J, Indiramma M. Big Data Analytics-Based Agro Advisory System for Crop Recommendation Using Spark Platform. In: Hossain MS, Ho RC, Trajkovski G, editors. *Handbook of Research on AI and Machine Learning Applications in Customer Support and Analytics*. Hershey, PA, USA: IGI Global; 2023. p. 227-47.
13. James N, Ong L-Y, Leow M-C. Exploring Distributed Deep Learning Inference Using Raspberry Pi Spark Cluster. *Future Internet*. 2022;14(8):220.
14. Romero E, Rodríguez A, Rázuri LR, Suniaga J, Montilla E. Estimación de las necesidades hídricas del cultivo de pepino (*Cucumis Sativus* L.) Durante las diferentes etapas fenológicas, mediante la tina de evaporación. *Agricultura andina*. 2009;16:56-69.
15. Gloria I E, Nkpouto U E, Jane L T, Felix U A, Sunday E O. An overview of uncertainties in evapotranspiration estimation techniques. *Journal of Agrometeorology*. 2023;25(1):173-82.
16. Niranjan S, Nandagiri L. Performance evaluation of simpler reference crop evapotranspiration estimation equations with and without local calibration. *Journal of Applied Water Engineering and Research*. 2023:1-18.
17. Goyal P, Kumar S, Sharda R. A review of the Artificial Intelligence (AI) based techniques for estimating reference evapotranspiration: Current trends and future perspectives. *Computers and Electronics in Agriculture*. 2023;209:107836.
18. Makwana JJ, Tiwari MK, Deora BS. Development and comparison of artificial intelligence models for estimating daily reference evapotranspiration from limited input variables. *Smart Agricultural Technology*. 2023;3:100115.
19. Yong SLS, Ng JL, Huang YF, Ang CK. Estimation of Reference Crop Evapotranspiration with Three Different Machine Learning Models and Limited Meteorological Variables. *Agronomy*. 2023;13(4):1048.
20. Güzel H, Üneş F, Erginer M, Kaya YZ, Taşar B, Erginer İ, et al. A comparative study on daily evapotranspiration estimation by using various artificial intelligence techniques and traditional regression calculations. *Mathematical Biosciences and Engineering*. 2023;20(6):11328-52.

## CONFLICTO DE INTERESES

Ninguno de los autores manifestó la existencia de posibles conflictos de intereses en relación con este artículo.

## CONTRIBUCIONES DE LOS AUTORES

**Dennis Villavicencio Quintero** participa en: Conceptualización, Curación de datos, Análisis formal, Investigación, Software, Redacción- borrador original, Redacción – revisión y edición.



**Emilio Cabrera Hernández** participa en: Curación de datos, Análisis formal, Metodología, Software.

**Alain Godo Alonso** participa en: Curación de datos, Análisis formal, Metodología, Software, Validación -Verificación.

**Ivan Santana Ching** participa en: Conceptualización, Análisis formal, Adquisición de fondos, Investigación, Metodología, Validación -Verificación, Administración de proyecto, Supervisión, Redacción-borrador original, Redacción – revisión y edición.

## AUTORES

**Dennis Villavicencio Quintero:** Ingeniero en Automática. Universidad Central Marta Abreu de Las Villas, Departamento de Control Automático, Villa Clara, Cuba. [dvillavicencio@uclv.cu](mailto:dvillavicencio@uclv.cu) ORCID: 0000-0002-5433-6947. Los intereses de investigación están en Machine Learning, Programación Competitiva, IIoT.

**Emilio Cabrera Hernández:** Ingeniero en Automática. Universidad Central Marta Abreu de Las Villas, Departamento de Control Automático, Villa Clara, Cuba. [emcabrera@uclv.cu](mailto:emcabrera@uclv.cu) ORCID: 0000-0003-3142-7253. Los intereses de investigación están en Sistemas empotrados, Redes de Sensores inalámbricos, Machine Learning, IIoT.

**Alain Godo Alonso:** Ingeniero en Automática. SORBA.ai, Jacksonville, FL, USA. [alaindga@gmail.com](mailto:alaindga@gmail.com) ORCID: 0000-0002-1501-0696. Los intereses de investigación están en Sistemas empotrados, sistemas distribuidos, Inteligencia Artificial, Machine Learning, IIoT.

**Ivan Santana Ching** Ingeniero en Automática. Doctor en Ciencias Técnicas por la UPM. Universidad Central Marta Abreu de Las Villas, Departamento de Control Automático, Villa Clara, Cuba. [ching@uclv.edu.cu](mailto:ching@uclv.edu.cu) ORCID: 0000-0001-5089-520X. Los intereses de investigación están en Sistemas empotrados, Redes de Sensores inalámbricos, Inteligencia Artificial, Machine Learning, IIoT.



Esta revista se publica bajo una [Licencia Creative Commons Atribución-No Comercial-Sin Derivar 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)