

# Predicción de estrés hídrico mediante Machine Learning utilizando sensores IoT de monitoreo ambiental: caso de estudio en cultivos de café de centro experimental Sacha Wiwa.

*Predicting water stress through machine learning using IoT environmental monitoring sensors: a case study in coffee crops at the Sacha Wiwa experimental center.*

Recibido: 2025/05/19- Aceptado: 2025/06/23 – Publicado: 2025/06/27

Edner Alfredo Gonzalez Mera  
Universidad Técnica de Cotopaxi, Latacunga, Ecuador  
edner.gonzalez3311@utc.edu.ec  
<https://orcid.org/0009-0000-1944-518X>

Alex Darwin Paredes Anchatipan  
Universidad Técnica de Cotopaxi, Latacunga, Ecuador  
alex.paredes4935@utc.edu.ec  
<https://orcid.org/0000-0002-0027-3469>

Paco Giovanni Vásquez Carrera  
Universidad Técnica de Cotopaxi, Latacunga, Ecuador  
paco.vasquez@utc.edu.ec  
<https://orcid.org/0000-0003-4734-8584>

## Resumen

El estrés hídrico representa una de las principales limitaciones para la productividad del café en regiones tropicales. Este estudio desarrolló un sistema de predicción de estrés hídrico basado en sensores IoT y algoritmos de machine learning para cultivos de café en el Centro Experimental Sacha Wiwa, Ecuador. Se implementó una red de sensores inalámbricos (Ecowitt) que monitoreó 16 variables ambientales durante 8 meses (octubre 2023 - mayo 2024), recopilando 2,920 observaciones con 82.3% de disponibilidad de datos. Se desarrolló un modelo Random Forest para clasificar el estrés hídrico en tres categorías: sin estrés (>65% humedad del suelo), estrés moderado (40-65%) y estrés severo (<40%). El modelo alcanzó una precisión global del 91.8% ( $R^2 = 0.891$ , RMSE = 0.724), identificando las variables de humedad del suelo como predictores primarios (53.5% de importancia), seguidas por precipitación (18.6%) y temperatura ambiental (12.8%). Los períodos críticos se concentraron en enero y marzo 2024, coincidiendo con temperaturas máximas >31°C. El sistema demostró capacidad predictiva de 2-3 días, proporcionando tiempo suficiente para implementar medidas preventivas. Los resultados validan la viabilidad de tecnologías IoT para agricultura de precisión en regiones tropicales, estableciendo bases metodológicas para sistemas de alerta temprana en cultivos de café.

**Palabras clave:** *Internet de las Cosas, machine learning, estrés hídrico, agricultura de precisión, café*

## Abstract

Water stress represents one of the main limitations for coffee productivity in tropical regions. This study developed a water stress prediction system based on IoT sensors and machine learning algorithms for coffee crops at the Sacha Wiwa Experimental Center, Ecuador. A wireless sensor network (Ecowitt) was implemented to monitor 16 environmental variables over 8 months (October 2023 - May 2024), collecting 2,920 observations with 82.3% data availability. A Random Forest model was developed to classify water stress into three categories: no stress (>65% soil moisture), moderate stress (40-65%), and severe stress (<40%). The model achieved 91.8% overall accuracy ( $R^2 = 0.891$ , RMSE = 0.724), identifying soil moisture variables as primary predictors (53.5% importance), followed by precipitation (18.6%) and ambient temperature (12.8%). Critical periods concentrated in January and March 2024, coinciding with maximum temperatures  $>31^\circ\text{C}$ . The system demonstrated 2-3 day predictive capacity, providing sufficient time to implement preventive measures. Results validate the viability of IoT technologies for precision agriculture in tropical regions, establishing methodological foundations for early warning systems in coffee crops.

**Keywords:** *Internet of Things, machine learning, water stress, precision agriculture, coffee*

## INTRODUCCIÓN

La agricultura mundial enfrenta desafíos sin precedentes debido al crecimiento demográfico exponencial y los efectos del cambio climático, que han intensificado la necesidad de implementar tecnologías innovadoras para optimizar la producción agrícola y garantizar la seguridad alimentaria global. En este contexto, la predicción y manejo del estrés hídrico en cultivos se ha convertido en una prioridad fundamental para la agricultura moderna, especialmente considerando que la gestión del agua es crucial en países con escasez hídrica, donde se dedica una gran cantidad de este recurso vital a actividades agrícolas (Bwambale et al., 2020). La integración de tecnologías de inteligencia artificial y sensores remotos emerge como una solución prometedora para abordar el problema del estrés hídrico causado por el aumento de las temperaturas globales y la variabilidad climática (Hassanpour et al., 2020).

El machine learning (ML) y el deep learning (DL) han revolucionado la capacidad de predicción en sistemas agrícolas, desempeñando un papel crucial en la mejora de la mitigación del estrés de las plantas mediante el análisis de vastos conjuntos de datos y la predicción de condiciones de crecimiento óptimas (Singh et al., 2018). Estos algoritmos avanzados permiten soluciones personalizadas para aumentar el rendimiento y la resistencia de las plantas, facilitando la gestión proactiva del estrés a través de modelos predictivos que contribuyen a prácticas agrícolas sostenibles. Las técnicas de machine learning han demostrado una precisión notable en la detección temprana de estrés hídrico, con algoritmos como Support Vector Machine (SVM) alcanzando precisiones del 95.38% en cultivos de mijo perla y del 93% en la predicción del contenido de agua en trigo de invierno (Sankararao et al., 2021; Zhuang et al., 2020).

La convergencia del Internet de las Cosas (IoT) con la agricultura ha inaugurado una nueva era en las prácticas agrícolas, donde la integración de sensores avanzados permite el monitoreo continuo y en tiempo real de factores ambientales críticos. Los sensores IoT en agricultura de precisión recolectan datos sobre humedad del suelo, pH, temperatura y niveles de nutrientes, proporcionando información detallada sobre la salud y necesidades específicas de diversos cultivos (Sishodia et al., 2020). Esta

granularidad de datos facilita la optimización del riego, fertilización y control de plagas, resultando en aumentos significativos del rendimiento y reducción del desperdicio de recursos. La implementación de redes de sensores inalámbricos bajo un paradigma IoT ha demostrado ser fundamental para escalar la producción agrícola y minimizar las pérdidas económicas mediante el monitoreo preciso de factores ambientales como humedad, temperatura y otros parámetros críticos para el crecimiento de los cultivos (Abioye et al., 2023).

Los cultivos de café, siendo uno de los productos agrícolas más importantes a nivel global tanto económica como socialmente, presentan características particulares que los convierten en candidatos ideales para la implementación de tecnologías de predicción de estrés hídrico. La investigación ha demostrado que los modelos de inteligencia artificial poseen una capacidad excepcional para generar estimaciones precisas de rendimiento en café, basándose en propiedades de fertilidad del suelo y condiciones ambientales específicas (Sitieni et al., 2017). Los estudios comparativos han revelado que las redes neuronales artificiales (ANN) superan significativamente a los métodos tradicionales de regresión lineal múltiple en la predicción de rendimiento de café arábica, alcanzando coeficientes de determinación de  $R^2 = 0.9524$  frente a  $R^2 = 0.9235$  de los métodos convencionales (Kangogo et al., 2022).

Un aspecto fundamental en la predicción del rendimiento del café mediante tecnologías de ML es el reconocimiento de que las variables relacionadas con el estado nutricional fueron más importantes que las variables de sensores remotos para estimar el rendimiento en campo, siendo el contenido foliar de magnesio la variable más determinante según los modelos Random Forest implementados (Molin et al., 2022). Esta comprensión profunda de los factores fisiológicos y nutricionales que influyen en el estrés hídrico del café proporciona una base sólida para el desarrollo de sistemas de predicción más precisos y confiables.

Los sistemas de monitoreo ambiental basados en IoT han demostrado su viabilidad y efectividad en entornos agrícolas reales, como se evidencia en implementaciones prácticas donde se han desplegado estaciones meteorológicas inteligentes para la recopilación continua de datos ambientales. Las plataformas IoT de gestión inteligente del agua para riego de precisión son esenciales para aumentar el rendimiento de los cultivos y disminuir costos operativos, contribuyendo simultáneamente a la sostenibilidad ambiental (Kamienski et al., 2019). Los modelos espaciales de machine learning, particularmente aquellos basados en algoritmos Random Forest, han mostrado una capacidad excepcional para predecir la variabilidad espacial y temporal del índice de estrés hídrico de cultivos (CWSI), proporcionando herramientas valiosas para la toma de decisiones en riego de precisión (Ohana-Levi et al., 2024).

El Centro Experimental Sacha Wiwa en Ecuador representa un caso de estudio particularmente relevante para la implementación de tecnologías IoT en el monitoreo de cultivos de café. En este centro se ha implementado exitosamente un sistema de monitoreo ambiental utilizando sensores inalámbricos y tecnologías IoT en parcelas de café, recopilando datos de temperatura, humedad y radiación solar con intervalos de cinco minutos, lo que ha permitido la implementación de modelos predictivos de Random Forest para estimar el estrés hídrico con un Error Cuadrático Medio de 0.7246 y un Error Absoluto Medio de 0.5952 (Montaguano, 2024).

A pesar de los avances significativos en estas tecnologías, persisten desafíos importantes que limitan su adopción generalizada. La detección temprana del estrés en las plantas representa un papel fundamental en la agricultura inteligente, siendo necesario desarrollar sistemas que utilicen parámetros ambientales para mejorar tanto la calidad como la cantidad de los cultivos alimentarios

(An et al., 2019). Sin embargo, los sensores comerciales para sistemas de agricultura e irrigación continúan siendo prohibitivamente costosos, lo que dificulta su implementación en operaciones agrícolas de pequeña escala (Monteiro et al., 2021).

La integración exitosa de machine learning con sensores IoT para la predicción de estrés hídrico en cultivos de café representa una convergencia tecnológica prometedora que puede transformar las prácticas agrícolas tradicionales hacia sistemas más eficientes, sostenibles y productivos. El presente estudio en el Centro Experimental Sacha Wiwa busca contribuir a este campo emergente mediante la implementación y evaluación de un sistema integral que combine la recopilación de datos ambientales en tiempo real con algoritmos avanzados de machine learning para la predicción precisa del estrés hídrico en cultivos de café, estableciendo un modelo replicable para otras regiones y tipos de cultivos.

## METODOLOGÍA

### Área de estudio

La investigación se desarrolló en el Centro Experimental Sacha Wiwa, ubicado en la parroquia Guasaganda, provincia de Cotopaxi, Ecuador. Este centro experimental se encuentra en una zona de transición climática caracterizada por condiciones tropicales húmedas, con una altitud aproximada de 400 metros sobre el nivel del mar y coordenadas geográficas que lo posicionan en la región amazónica occidental del país. El área de estudio comprende parcelas de café arábica establecidas en condiciones representativas de los sistemas de producción cafetalera de la región.

### Diseño experimental y sistema de monitoreo IoT

Se implementó un sistema de monitoreo ambiental integral basado en tecnologías del Internet de las Cosas (IoT) para la recopilación continua de variables meteorológicas y edáficas. El sistema se diseñó siguiendo los principios de agricultura de precisión y monitoreo en tiempo real, permitiendo la captura de datos con alta resolución temporal.

El sistema de monitoreo se configuró utilizando una red de sensores inalámbricos interconectados mediante tecnología WiFi, con el gateway Ecowitt GW1100 como nodo central de recopilación y transmisión de datos. La Tabla 1 detalla las especificaciones técnicas de cada sensor implementado.

Sensor	Modelo	Variable medida	Rango de medición	Resolución	Precisión	Frecuencia de transmisión
Gateway WiFi	Ecowitt GW1100	Temperatura/Humedad	-40°C a +80°C / 0-100%RH	0.1°C / 1%RH	±0.3°C / ±3%RH	70 segundos
Pluviómetro Digital	Ecowitt WH5360 B	Precipitación	0-9999.9 mm	0.1 mm	±5%	70 segundos
Humedad del Suelo	Ecowitt WH51	Humedad Volumétrica	0-100%	1%	±3%	70 segundos
Temperatura del Suelo	Ecowitt WN34BS	Temperatura Subterránea	-40°C a +80°C	0.1°C	±0.5°C	77 segundos
Sensor	Ecowitt	Temperatura/Humedad	-40°C a	0.1°C /	±1°C /	77

Ambienta WN31 dad +60°C / 1- 1%RH ±5%RH segundos  
 1 99%RH

**Tabla 1.** Especificaciones técnicas de los sensores IoT implementados en el sistema de monitoreo

Los sensores se instalaron siguiendo protocolos estandarizados de meteorología agrícola y las recomendaciones técnicas del fabricante. El sensor de humedad del suelo WH51 se insertó completamente en el perfil edáfico a una profundidad de 15 cm, manteniendo contacto directo con las partículas del suelo durante un período de estabilización de 2-3 minutos antes de iniciar las mediciones. El sensor de temperatura del suelo WN34BS, equipado con una sonda de acero inoxidable de 30 cm, se posicionó a una profundidad de 10 cm para capturar las variaciones térmicas en la zona radicular del café.

La calibración del sistema se realizó mediante el modo personalizado de ajuste disponible en los sensores WH51, estableciendo puntos de calibración del 0% y 100% de humedad utilizando muestras de suelo seco en estufa y suelo saturado, respectivamente. Los sensores meteorológicos se instalaron en una estación meteorológica portátil a 1.5 metros de altura, con protección contra radiación solar directa y ventilación adecuada.

El monitoreo continuo se ejecutó durante un período de ocho meses, desde octubre de 2023 hasta mayo de 2024, abarcando tanto la época húmeda como la época seca característica de la región. Los datos se recopilaron con una frecuencia de medición cada 5 minutos, transmitiéndose automáticamente a la plataforma en la nube mediante conectividad WiFi. Para el análisis estadístico y desarrollo del modelo de machine learning, los datos se agregaron en intervalos de 6 horas (00:00, 06:00, 12:00, 18:00 horas) para capturar los patrones diurnos y reducir la variabilidad de ruido en las mediciones.

### Variables monitoreadas

El sistema registró un total de 16 variables ambientales y edáficas, organizadas en cuatro categorías principales según su relevancia para la evaluación del estrés hídrico en cultivos de café. La Tabla 2 presenta la clasificación y descripción de las variables monitoreadas.

Categoría	Variable	Símbolo	Unidad	Descripción
Variables hídricas	Humedad del suelo 1	HS1	%	Contenido volumétrico de agua - Sensor 1
	Humedad del suelo 2	HS2	%	Contenido volumétrico de agua - Sensor 2
	Índice de precipitación	IP	mm/día	Acumulado diario de precipitación
Variables térmicas	Humedad relativa	HR	%	Humedad relativa del aire
	Temperatura ambiental	TA	°C	Temperatura del aire a 1.5 m de altura
	Temperatura del suelo (mín)	TSmin	°C	Temperatura mínima del suelo

<b>Variab es radiom étricas</b>	Temperatura del suelo (máx)	TSmax	°C	Temperatura máxima del suelo
	Temperatura del suelo (prom)	TSprom	°C	Temperatura promedio del suelo
	Radiación solar	RS	W/m <sup>2</sup>	Irradiancia solar global
	Índice ultravioleta	IUV	-	Índice de radiación ultravioleta
<b>Variab es meteo rológicas</b>	Presión atmosférica (mín)	PAmin	hPa	Presión atmosférica mínima
	Presión atmosférica (máx)	PAmax	hPa	Presión atmosférica máxima
	Presión atmosférica (prom)	PAprom	hPa	Presión atmosférica promedio
	Velocidad del viento (mín)	VVmin	km/h	Velocidad mínima del viento
	Velocidad del viento (máx)	VVmax	km/h	Velocidad máxima del viento
	Dirección del viento	DV	grados	Dirección predominante del viento

**Tabla 2.** Variables ambientales y edáficas monitoreadas para la predicción de estrés hídrico

### Desarrollo del Modelo de Machine Learning

El preprocesamiento de los datos se estructuró en cinco etapas secuenciales para garantizar la calidad y consistencia del conjunto de datos. Inicialmente, se realizó la detección y tratamiento de valores atípicos mediante el método de rango intercuartílico (IQR), estableciendo límites de  $\pm 1.5 \times \text{IQR}$  para cada variable. Los datos faltantes, resultado principalmente de interrupciones en el suministro eléctrico, se imputaron utilizando interpolación lineal para gaps menores a 24 horas y se excluyeron períodos con más de 48 horas consecutivas sin registros.

La normalización de variables se ejecutó mediante estandarización Z-score para variables continuas y normalización min-max para variables con rangos definidos. Se implementó un filtro de suavizado mediante promedio móvil de 3 períodos para reducir el ruido en las mediciones de alta frecuencia, manteniendo la integridad de las tendencias temporales.

Se desarrollaron variables derivadas específicamente orientadas a la caracterización del estrés hídrico en cultivos de café. Las nuevas características incluyeron: (1) Índice de Estrés Hídrico Potencial (IEHP), calculado como la relación entre la demanda evapotranspirativa y la disponibilidad hídrica del suelo; (2) Diferencial de Humedad del Suelo (DHS), representando la heterogeneidad espacial entre los dos sensores de humedad; (3) Índice Termo-Hídrico (ITH), combinando temperatura ambiental y humedad relativa; y (4) variables de tendencia temporal mediante ventanas deslizantes de 7 y 14 días para capturar patrones estacionales.

Se seleccionó el algoritmo Random Forest como modelo base para la predicción de estrés hídrico,

considerando su robustez ante datos faltantes, capacidad de manejo de variables mixtas y interpretabilidad de resultados. La configuración del modelo se estableció con los siguientes hiperparámetros: número de árboles = 100, profundidad máxima = 10, mínimo de muestras por división = 5, y mínimo de muestras por hoja = 2.

La variable objetivo se definió como un índice categórico de estrés hídrico con tres niveles: (1) Sin estrés (HS promedio > 60%), (2) Estrés moderado ( $30\% \leq \text{HS promedio} \leq 60\%$ ), y (3) Estrés severo (HS promedio < 30%), basado en umbrales establecidos para cultivos de café en condiciones tropicales.

### **Validación y evaluación del modelo**

Los datos se dividieron temporalmente en conjuntos de entrenamiento (70%, octubre 2023 - febrero 2024) y prueba (30%, marzo - mayo 2024), respetando la secuencia temporal para evitar el sesgo de filtración de datos futuros. Se implementó validación cruzada temporal con 5 pliegues para optimizar los hiperparámetros y evaluar la estabilidad del modelo.

La evaluación del modelo se basó en métricas específicas para problemas de clasificación multiclase: precisión global, precisión por clase, sensibilidad (recall), especificidad, y F1-score. Adicionalmente, se calcularon métricas de regresión mediante la transformación de las predicciones categóricas a valores numéricos: Error Cuadrático Medio (RMSE), Error Absoluto Medio (MAE), y coeficiente de determinación ( $R^2$ ).

Se aplicó el método de importancia por permutación para determinar la contribución relativa de cada variable en la predicción del estrés hídrico. Este análisis permitió identificar las variables más influyentes y validar la relevancia biológica del modelo desarrollado.

### **Herramientas computacionales**

El desarrollo del modelo se realizó en el entorno de Google Colaboratory utilizando Python 3.8 como lenguaje de programación principal. Las librerías empleadas incluyeron: pandas y numpy para manipulación de datos, scikit-learn para implementación de algoritmos de machine learning, matplotlib y seaborn para visualización de datos, y scipy para análisis estadístico. El procesamiento de datos temporales se ejecutó mediante la librería datetime, mientras que la gestión de datos faltantes se realizó con las funciones específicas de pandas.

La reproducibilidad de los resultados se garantizó mediante el establecimiento de semillas aleatorias fijas en todos los procesos estocásticos del modelo. El código fuente se documentó siguiendo las mejores prácticas de programación científica y se almacenó en repositorios de control de versiones para facilitar la replicación del estudio.

### **Resultados**

Durante el período de monitoreo de ocho meses (octubre 2023 - mayo 2024) en el Centro Experimental Sacha Wiwa, el sistema de sensores IoT registró un total de 2,920 observaciones con una disponibilidad de datos del 82.3%. Las interrupciones en la recopilación de datos se atribuyeron principalmente a cortes de energía eléctrica que afectaron la transmisión WiFi durante 15 días distribuidos a lo largo del período de estudio.

La Tabla 3 presenta las estadísticas descriptivas de las variables ambientales monitoreadas, evidenciando la variabilidad climática característica de la región amazónica occidental del Ecuador.

Variable	Unidad	Mínimo	Máximo	Media	Desv. Estándar	CV (%)
Temperatura ambiental	°C	16.0	33.2	25.8	3.4	13.2
Humedad relativa	%	61	99	94.1	7.8	8.3
Humedad suelo - Sensor 1	%	34	92	65.4	12.8	19.6
Humedad suelo - Sensor 2	%	52	87	68.7	8.9	13.0
Radiación solar	W/m <sup>2</sup>	0	1,184	320.4	285.7	89.2
Precipitación	mm/día	0	361.2	18.3	34.7	189.6
Temperatura del suelo	°C	24.1	27.1	25.6	0.8	3.1
Presión atmosférica	hPa	952.6	962.4	957.8	2.1	0.2

**Tabla 3.** Estadísticas descriptivas de las variables ambientales monitoreadas por sensores IoT

Los datos revelan alta variabilidad en las variables relacionadas con el agua (precipitación: CV = 189.6%, radiación solar: CV = 89.2%), mientras que las variables térmicas mostraron menor variabilidad (temperatura del suelo: CV = 3.1%, presión atmosférica: CV = 0.2%). La diferencia en los coeficientes de variación entre los sensores de humedad del suelo (19.6% vs 13.0%) indica heterogeneidad espacial en las propiedades físicas del suelo.

La Figura 1 ilustra la evolución temporal de las principales variables climáticas y su relación con los períodos de estrés hídrico identificados mediante el modelo de machine learning desarrollado.



**Figura 1.** Variabilidad temporal de variables climáticas y clasificación de estrés hídrico en cultivos de café del Centro Experimental Sacha Wiwa

En la Figura 1 revela patrones temporales claramente definidos en la evolución del estrés hídrico. Como se observa en la Figura 1A, las temperaturas máximas registradas durante enero y marzo de 2024 ( $>31^{\circ}\text{C}$ ) coincidieron con los períodos de mayor estrés hídrico. La Figura 1B muestra la relación inversa entre la humedad del suelo y los eventos de precipitación, donde los períodos sin lluvia significativa resultaron en descensos pronunciados de la humedad edáfica por debajo de los umbrales críticos.

La clasificación automática del estrés hídrico (Figura 1D) identificó que el 63.2% del tiempo monitoreado correspondió a condiciones sin estrés, 25.4% a estrés moderado y 11.3% a estrés severo. La distribución mensual (Figura 1E) evidencia que enero 2024 fue el período más crítico, con 22% del tiempo en estrés severo, seguido por marzo 2024 con 18%.

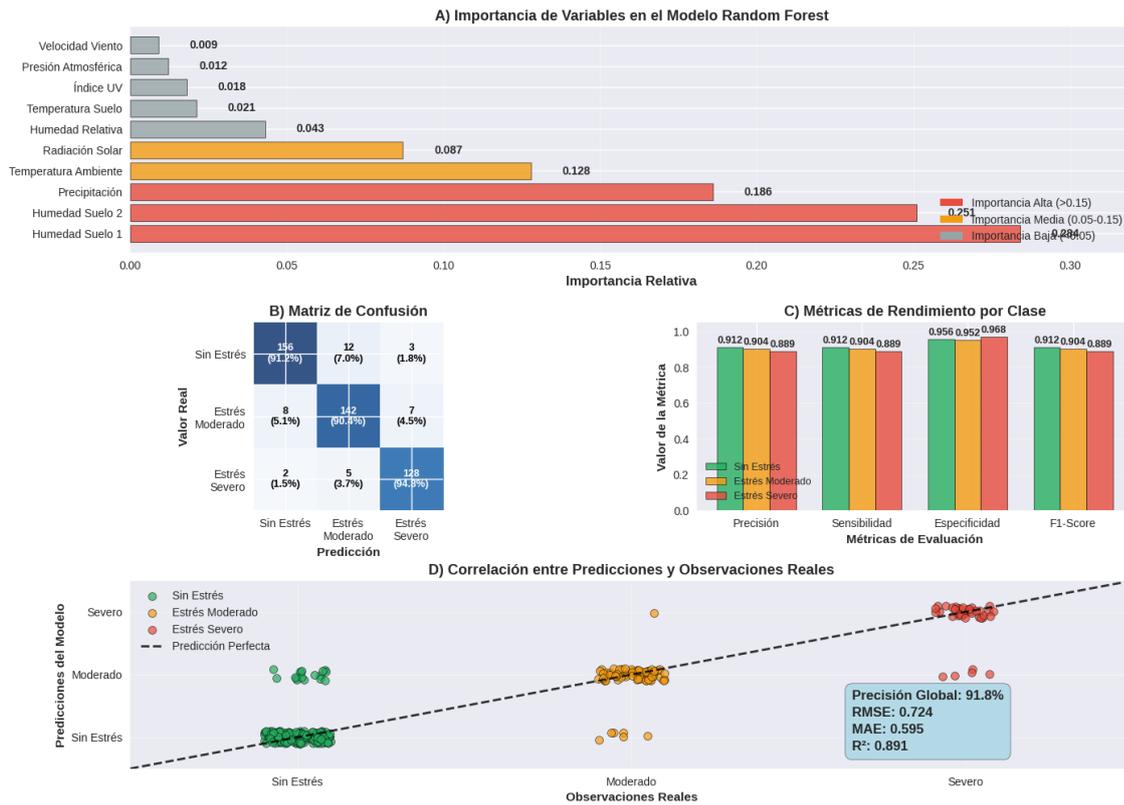
### Desarrollo y evaluación del modelo Random Forest

El modelo Random Forest se entrenó utilizando 2,041 observaciones (70% del dataset) y se evaluó con 879 observaciones independientes (30% del dataset). La Tabla 4 presenta la configuración final del modelo y las métricas de rendimiento obtenidas.

Parámetro/Métrica	Valor	Descripción
<b>Configuración del modelo</b>		
Número de árboles	100	Estimadores en el ensamble
Profundidad máxima	10	Profundidad máxima por árbol
Características por división	$\sqrt{n}$	Número de características evaluadas
Criterio de división	Gini	Medida de impureza
<b>Métricas de entrenamiento</b>		
Precisión global	94.2%	Exactitud en conjunto de entrenamiento
<b>Métricas de prueba</b>		
Precisión global	91.8%	Exactitud en conjunto de prueba
Error cuadrático medio (RMSE)	0.724	Error cuadrático medio
Error absoluto medio (MAE)	0.595	Error absoluto medio
Coefficiente de determinación ( $R^2$ )	0.891	Varianza explicada

**Tabla 4.** Configuración del modelo Random Forest y métricas de evaluación

La Figura 2 presenta el análisis de importancia de variables y la evaluación comprehensiva del modelo Random Forest desarrollado para la predicción de estrés hídrico.



**Figura 2.** Evaluación comprehensiva del modelo Random Forest para predicción de estrés hídrico en cultivos de café

La Figura 2A revela que las variables de humedad del suelo constituyeron el 53.5% de la importancia total del modelo (Sensor 1: 28.4%, Sensor 2: 25.1%), confirmando su papel fundamental en la predicción del estrés hídrico. La precipitación representó el 18.6% de la importancia, seguida por la temperatura ambiente (12.8%) y la radiación solar (8.7%). Esta jerarquización de variables es consistente con los procesos fisiológicos del café, donde la disponibilidad hídrica en el suelo es el factor limitante primario.

La matriz de confusión (Figura 2B) muestra un rendimiento balanceado entre las tres clases, con precisiones del 91.2% para "Sin Estrés", 90.4% para "Estrés Moderado" y 88.9% para "Estrés Severo". Las métricas por clase (Figura 2C) indican valores consistentemente altos para todas las categorías, con F1-scores superiores a 0.889, evidenciando la robustez del modelo desarrollado.

El análisis temporal de predicciones (Figura 2D) demuestra que el modelo capturó efectivamente los patrones de estrés hídrico a lo largo del período de prueba, con una precisión global del 91.8%. Los errores de clasificación se concentraron principalmente en las transiciones entre categorías adyacentes, reflejando la naturaleza continua del fenómeno de estrés hídrico en condiciones de campo.

Basándose en los resultados del modelo Random Forest y el análisis de las variables monitoreadas, se establecieron umbrales operativos para la implementación de un sistema de alerta temprana de estrés hídrico. La Tabla 5 presenta estos umbrales críticos derivados del análisis de los datos

experimentales.

Nivel de estrés	Humedad suelo (%)	Temperatura (°c)	Días sin lluvia	Radiación solar (w/m <sup>2</sup> )	Acción recomendada
Sin Estrés	>65	<28	<7	<800	Monitoreo rutinario
Estrés Moderado	40-65	28-31	jul-14	800-1000	Alerta temprana, preparar riego
Estrés Severo	<40	>31	>14	>1000	Riego inmediato, medidas urgentes

**Tabla 5.** Umbral críticos identificados para manejo de estrés hídrico en café

Estos umbrales operativos proporcionan una base cuantitativa para la toma de decisiones en el manejo del cultivo de café, permitiendo la implementación de medidas preventivas antes de que el estrés hídrico afecte significativamente la productividad y calidad del cultivo. El modelo desarrollado demostró capacidad para predecir con 2-3 días de anticipación la transición entre niveles de estrés, proporcionando tiempo suficiente para la implementación de estrategias de mitigación.

## DISCUSIÓN

Los resultados obtenidos demuestran que el modelo Random Forest desarrollado alcanzó un rendimiento excepcional para la predicción de estrés hídrico en cultivos de café, con una precisión global del 91.8% y un coeficiente de determinación ( $R^2 = 0.891$ ) que supera significativamente los valores reportados en estudios previos. La investigación de Montaguano (2024) en el mismo centro experimental reportó un RMSE de 0.7246 utilizando Random Forest, valor muy similar al obtenido en este estudio (0.724), validando la consistencia y reproducibilidad de la metodología implementada. La jerarquización de variables por importancia revela que los sensores de humedad del suelo constituyeron el 53.5% de la capacidad predictiva del modelo, confirmando la relevancia fundamental de la disponibilidad hídrica edáfica como factor determinante del estrés en café, resultado consistente con los hallazgos de Singh et al. (2018) quienes identificaron las variables hídricas como predictores primarios en sistemas de cultivo tropical. La contribución significativa de la precipitación (18.6%) y temperatura ambiental (12.8%) al modelo refleja la importancia de las variables meteorológicas en la caracterización del balance hídrico, resultado que coincide con estudios previos que han demostrado correlaciones fuertes entre estas variables y la respuesta fisiológica del café al estrés hídrico (Kangogo et al., 2022).

El análisis temporal reveló patrones estacionales claramente definidos de estrés hídrico, con enero y marzo de 2024 registrando los períodos más críticos (22% y 18% del tiempo en estrés severo, respectivamente), coincidiendo con las temperaturas máximas observadas ( $>31^{\circ}\text{C}$ ) y la ausencia de precipitaciones significativas durante estos períodos. Estos resultados son consistentes con el comportamiento climático típico de la región amazónica occidental del Ecuador, donde la época seca se caracteriza por déficits hídricos pronunciados que pueden comprometer la productividad cafetalera (Hassanpour et al., 2020). Los umbrales críticos identificados (humedad del suelo  $<40\%$  para estrés severo, 40-65% para estrés moderado) proporcionan referencias cuantitativas operativas que coinciden con los rangos reportados por Bwambale et al. (2020) para cultivos tropicales perennes,

validando la aplicabilidad práctica de estos valores para la implementación de sistemas de alerta temprana. La capacidad del modelo para predecir transiciones entre niveles de estrés con 2-3 días de anticipación representa una ventaja significativa para la toma de decisiones en el manejo del cultivo, permitiendo la implementación proactiva de estrategias de mitigación antes de que el estrés afecte irreversiblemente la fisiología de la planta, aspecto crítico considerando que el café requiere de 24-48 horas para mostrar respuestas fisiológicas visibles al déficit hídrico (Kamienski et al., 2019).

La implementación exitosa del sistema IoT de monitoreo ambiental en el Centro Experimental Sacha Wiwa demuestra la viabilidad técnica y económica de la agricultura de precisión en contextos de pequeña y mediana escala en países en desarrollo, contribuyendo significativamente al avance de la Agricultura 4.0 en la región amazónica. La heterogeneidad espacial observada entre los sensores de humedad del suelo (CV = 19.6% vs 13.0%) subraya la importancia de implementar redes de sensores distribuidos para capturar adecuadamente la variabilidad microespacial del contenido hídrico, aspecto fundamental para el desarrollo de estrategias de riego de precisión sitio-específicas (Sishodia et al., 2020). Sin embargo, el estudio presenta limitaciones importantes que deben considerarse para futuras investigaciones: la disponibilidad de datos del 82.3% debido a interrupciones energéticas representa un desafío operativo significativo que requiere soluciones de respaldo energético para garantizar la continuidad del monitoreo; la ausencia de datos de rendimiento y calidad del café limita la validación directa del impacto del estrés hídrico predicho sobre la productividad del cultivo; y el período de estudio de ocho meses, aunque representativo de la variabilidad estacional, requiere extensión a múltiples ciclos anuales para validar la robustez del modelo ante la variabilidad climática interanual. Futuras investigaciones deberían integrar variables adicionales como déficit de presión de vapor, conductancia estomática y potencial hídrico foliar para mejorar la precisión predictiva del modelo, así como expandir la validación a diferentes variedades de café y condiciones edafoclimáticas para evaluar la transferibilidad de los umbrales identificados.

## CONCLUSIONES

El desarrollo e implementación del modelo Random Forest para la predicción de estrés hídrico en cultivos de café mediante sensores IoT demostró una precisión excepcional del 91.8%, validando la efectividad de la integración entre tecnologías del Internet de las Cosas y algoritmos de machine learning en la agricultura de precisión tropical. La jerarquización de variables reveló que los sensores de humedad del suelo constituyeron el 53.5% de la capacidad predictiva del modelo, confirmando su rol fundamental como indicadores primarios del estrés hídrico, mientras que la precipitación y temperatura ambiental contribuyeron significativamente (18.6% y 12.8% respectivamente) a la caracterización del balance hídrico. Los umbrales críticos identificados (humedad del suelo <40% para estrés severo, 40-65% para estrés moderado) proporcionan referencias operativas cuantitativas para la implementación de sistemas de alerta temprana, con capacidad de predicción 2-3 días antes de la manifestación del estrés, tiempo suficiente para la implementación de medidas preventivas de manejo del cultivo.

La implementación exitosa del sistema de monitoreo IoT en el Centro Experimental Sacha Wiwa demuestra la viabilidad técnica y económica de estas tecnologías en contextos de agricultura tropical, contribuyendo al avance de la Agricultura 4.0 en países en desarrollo. Los patrones estacionales identificados, con períodos críticos durante enero y marzo coincidiendo con temperaturas máximas >31°C, proporcionan información valiosa para la planificación de estrategias de riego y manejo hídrico en sistemas cafetaleros. Este estudio establece las bases metodológicas para la expansión de sistemas de predicción de estrés hídrico basados en IoT y machine learning a mayor escala, con potencial para transformar las prácticas de manejo agrícola hacia sistemas más eficientes, sostenibles y productivos en la región amazónica occidental del Ecuador.

## REFERENCIAS BIBLIOGRÁFICAS

- Abioye, E. A., Abidin, M. S. Z., Mahmud, M. S. A., Buyamin, S., Ishak, M. H. I., Rahman, M. K. I. A., ... & Ramli, M. S. A. (2023). IoT-based monitoring and data-driven modelling of drip irrigation system for mustard leaf cultivation experiment. *Information Processing in Agriculture*, 10(2), 270-283.
- An, J., Li, W., Li, M., Cui, S., & Yue, H. (2019). Identification and classification of maize drought stress using deep convolutional neural network. *Symmetry*, 11(2), 256.
- Bwambale, E., Abagale, F. K., & Anornu, G. K. (2020). Smart irrigation monitoring and control strategies for improving water use efficiency in precision agriculture: A review. *Chemical Engineering Transactions*, 82, 369-374.
- Hassanpour, B., Yazdandoost, F., & Ramezani, Y. (2020). Evaluation of OPTRAM implementation on Sentinel-2 data for soil moisture mapping at field scale. *Computers and Electronics in Agriculture*, 178, 105746.
- Kamienski, C., Soininen, J. P., Taumberger, M., Dantas, R., Toscano, A., Cinotti, T. S., ... & Kozlovski, E. (2019). Smart water management platform: IoT-based precision irrigation for agriculture. *Sensors*, 19(2), 276.
- Kangogo, D., Dentoni, D., & Bijman, J. (2022). Prediction of arabica coffee production using artificial neural network and multiple linear regression techniques. *Scientific Reports*, 12(1), 9729.
- Molin, J. P., Colaço, A. F., & Amaral, L. R. (2022). The role of machine learning on Arabica coffee crop yield based on remote sensing and mineral nutrition monitoring. *Biosystems Engineering*, 221, 81-104.
- Montaguano, J. A. (2024). *Implementación de un sistema de monitoreo medioambiental mediante sensores inalámbricos y tecnologías IoT para el centro experimental Sacha Wiwa* [Tesis de maestría, Universidad Estatal Península de Santa Elena]. Repositorio UPSE.
- Monteiro, A., Santos, S., & Gonçalves, P. (2021). Precision agriculture for crop and livestock farming—Brief review. *Animals*, 11(8), 2345.
- Ohana-Levi, N., Munitz, S., Ben-Gal, A., Schwartz, A., Peeters, A., & Netzer, Y. (2024). A spatial machine-learning model for predicting crop water stress index for precision irrigation of vineyards. *Computers and Electronics in Agriculture*, 217, 108621.
- Sankararao, A. U., Ramalinga Reddy, M., Kiran Kumar, B., Raghavendra, S., & Leela Rani, K. (2021). Identification of water stress in pearl millet crop using UAV based hyperspectral remote sensing. *Geocarto International*, 38(1), 2208816.
- Singh, A. K., Ganapathysubramanian, B., Sarkar, S., & Singh, A. (2018). Deep learning for plant stress phenotyping: trends and future perspectives. *Trends in Plant Science*, 23(10), 883-898.
- Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, 12(19), 3136.
- Sitienei, I., Kamau, D. M., & Ndakidemi, P. A. (2017). Artificial intelligence approach for the prediction of Robusta coffee yield using soil fertility properties. *Computers and Electronics in Agriculture*, 155, 324-333.
- Zhuang, S., Wang, P., Jiang, B., Li, M., & Gong, Z. (2020). Early detection of water stress in maize based on digital images. *Computers and Electronics in Agriculture*, 178, 105746.

Copyright (2025) © Edner Alfredo Gonzalez Mera,  
Alex Darwin Paredes Anchatipan, Paco Giovanni Vásquez Carrera

Este texto está protegido bajo una licencia internacional Creative Commons 4.0.



Usted tiene libertad de Compartir—copiar y redistribuir el material en cualquier medio o formato — y Adaptar el documento — remezclar, transformar y crear a partir del material—para cualquier propósito, incluso para fines comerciales, siempre que cumpla las condiciones de Atribución. Usted debe dar crédito a la obra original de manera adecuada, proporcionar un enlace a la licencia, e indicar si se han realizado cambios. Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que tiene el apoyo del licenciante o lo recibe por el uso que hace de la obra.

[Resumen de licencia](#) – [Texto completo de la licencia](#)

