

Modelado predictivo de evapotranspiración de referencia en malla sombra mediante programación genética

Predictive modeling of reference evapotranspiration under shade net conditions using genetic programming

Francisco Javier Ruiz-Ortega¹ , Manuel Fortis-Hernández¹ , Hugo Estrada-Esquivel² ,
Alicia Martínez-Rebollar² , Pablo Preciado-Rangel^{1*} 

¹Tecnológico Nacional de México - Instituto Tecnológico de Torreón. Antigua Carretera Torreón-San Pedro, km 7.5, CP. 27170. Torreón, Coahuila, México.

²Tecnológico Nacional de México - Centro Nacional de Investigación y Desarrollo Tecnológico. Interior Internado Palmira S/N, Palmira, CP. 62493. Cuernavaca, Morelos, México.

*Autor de correspondencia: ppreciador@yahoo.com.mx

Artículo científico

Recibido: 14 de agosto 2025

Aceptado: 28 de enero 2026

RESUMEN. La evapotranspiración de referencia (ETo) es un parámetro esencial para la gestión eficiente del riego, especialmente en sistemas de agricultura protegida ubicados en regiones de clima árido y semiárido. El presente estudio tuvo como objetivo desarrollar un modelo predictivo de ETo dentro de una malla sombra, empleando técnicas de cómputo evolutivo, en particular la programación genética (GP). Para la construcción del modelo, se recopilaron datos climáticos con frecuencia de un minuto, lo que permitió capturar con alta resolución las condiciones microclimáticas específicas del entorno protegido. El modelo fue entrenado utilizando como referencia los valores de ETo calculados mediante el método Penman-Monteith recomendado por la FAO, considerado el estándar internacional para la estimación de la evapotranspiración de referencia. El modelo generado mostró un desempeño sobresaliente, alcanzando un error cuadrático medio (RMSE) de 0.217 y un coeficiente de determinación (R^2) de 0.99, lo que evidencia una alta precisión en las predicciones. Al compararlo con modelos empíricos ampliamente utilizados, como Hargreaves-Samani (RMSE = 4.82, R^2 = -0.98) y Priestley-Taylor (RMSE = 1.00, R^2 = 0.913), se observó que el modelo propuesto supera de forma significativa ambos enfoques tradicionales. Los resultados destacan el potencial de la programación genética como herramienta eficaz para el desarrollo de modelos predictivos robustos, adaptados a condiciones específicas como las presentes en sistemas agrícolas protegidos bajo climas áridos y semiáridos.

Palabras clave: Cómputo evolutivo, modelos predictivos, agricultura protegida.

ABSTRACT. Reference evapotranspiration (ETo) is a key parameter for efficient irrigation management, especially in protected agriculture systems located in arid and semi-arid climates. This study aimed to develop a predictive ETo model within a shade net greenhouse using evolutionary computing techniques, specifically genetic programming (GP). For model development, climatic data were collected at one-minute intervals, allowing for high-resolution capture of the specific microclimatic conditions within the protected environment. The model was trained using ETo values calculated with the FAO-recommended Penman-Monteith method (FAO56-PM), considered the international standard for reference evapotranspiration estimation. The resulting model exhibited outstanding performance, achieving a root mean square error (RMSE) of 0.217 and a coefficient of determination (R^2) of 0.99, indicating high predictive accuracy. When compared to widely used empirical models such as Hargreaves-Samani (RMSE = 4.82, R^2 = -0.98) and Priestley-Taylor (RMSE = 1.00, R^2 = 0.913), the proposed model significantly outperformed both traditional approaches. These results highlight the potential of genetic programming as an effective tool for developing robust predictive models tailored to specific conditions, such as those found in protected agricultural systems under arid and semi-arid climates.

Keywords: Evolutionary computing, predictive models, protected agriculture.

Como citar: Ruiz-Ortega FJ, Fortis-Hernández M, Estrada-Esquivel H, Martínez-Rebollar A, Preciado-Rangel P (2026) Modelado predictivo de evapotranspiración de referencia en malla sombra mediante programación genética. Ecosistemas y Recursos Agropecuarios 13(1): e4729. DOI: 10.19136/era.a13n1.4729.

INTRODUCCIÓN

La gestión eficiente del agua en la agricultura es de gran importancia debido a la creciente escasez de recursos hídricos, la elevada demanda del sector agrícola y la necesidad de garantizar la seguridad alimentaria y la sostenibilidad de los sistemas productivos (Obayomi *et al.* 2025). La casa o malla sombra está diseñada para mitigar la radiación solar directa y facilitar la ventilación natural, han demostrado ser una solución viable para reducir el estrés térmico en los cultivos, además de ofrecer ventajas económicas y operativas (Kabir *et al.* 2024). Sin embargo, las condiciones microclimáticas internas de estas estructuras, caracterizadas por una mayor humedad relativa, menor velocidad del viento y radiación solar atenuada, modifican significativamente las necesidades hídricas de las plantas, dificultando la aplicación directa de modelos convencionales de estimación de evapotranspiración (Campi *et al.* 2020).

El método FAO56-Penman-Monteith (FAO56-PM) ha sido ampliamente reconocido como el estándar internacional para estimar la evapotranspiración de referencia (ET_o) en condiciones de campo abierto, bajo una superficie vegetal homogénea y bien irrigada (Santos *et al.* 2021). Este modelo integra variables meteorológicas clave como radiación solar, temperatura del aire, humedad relativa y velocidad del viento, y ha demostrado alta precisión en diversos contextos climáticos (Celestin *et al.* 2020). Aunque ha sido aplicado en sistemas protegidos, las diferencias microclimáticas dentro de los invernaderos tipo malla sombra pueden afectar la fiabilidad de sus estimaciones, requiriendo ajustes específicos en parámetros como la velocidad del viento efectiva o la radiación neta (Ghiat *et al.* 2021, Gong *et al.* 2022).

A pesar de su amplio reconocimiento, la aplicación del método FAO56-PM en sistemas de agricultura protegida presenta limitaciones operativas importantes. El método FAO56-PM, aunque recomendado como estándar para calcular la evapotranspiración de referencia (ET_o) en condiciones de campo abierto, requiere datos meteorológicos completos (radiación, temperatura, humedad relativa y velocidad del viento) que no siempre están disponibles, especialmente en estaciones meteorológicas rurales o entornos con recursos limitados, lo cual dificulta su aplicación práctica en muchos contextos agrícolas y de investigación (Acharki *et al.* 2025).

En entornos como la malla sombra o invernaderos, las condiciones microclimáticas difieren sustancialmente del campo abierto debido a la atenuación de la radiación solar, la reducción de la velocidad del viento y alteraciones en los gradientes de humedad relativa dentro del espacio protegido, lo que afecta la representatividad física de algunas de las variables requeridas por FAO56-PM y puede dar lugar a estimaciones menos precisas o a la necesidad de mediciones más complejas (Doria *et al.* 2021). Estudios recientes han demostrado que, debido a la escasez o limitación de variables climáticas completas en regiones áridas y semiáridas, los investigadores han explorado alternativas basadas en métodos estadísticos y técnicas de aprendizaje automático, incluidas redes neuronales y otros algoritmos de inteligencia artificial, para estimar la evapotranspiración de referencia con datos incompletos o reducidos. Estas técnicas han mostrado un rendimiento competitivo frente a métodos tradicionales y permiten modelar la ET_o en contextos con disponibilidad limitada de información climática (Sammen *et al.* 2023).

En las regiones áridas y semiáridas, donde estas estructuras generan un microclima semiprotegido, se requieren estimaciones precisas y frecuentes de la ETo, idealmente a escala horaria, para garantizar una gestión eficiente del riego y del ambiente interno (Costa-Filho *et al.* 2024). Sin embargo, no se ha establecido un método estandarizado para estimar la ETo en estas condiciones, lo que representa un vacío técnico relevante. En este contexto, la digitalización y el uso de tecnologías inteligentes han emergido como herramientas clave para optimizar la gestión hídrica (Flores-Mancheno y Palacios-López 2025). La integración de sensores, modelos de predicción y sistemas de riego automatizados permite una toma de decisiones más precisa y adaptada a las condiciones específicas del cultivo (Soussi *et al.* 2024, Mansoor *et al.* 2025). No obstante, uno de los aspectos técnicos más complejos sigue siendo la estimación precisa de la evapotranspiración de referencia (ETo) dentro de estos entornos protegidos, especialmente en climas áridos, donde las variaciones microclimáticas son más pronunciadas (Jaafar *et al.* 2019). Ante las limitaciones del FAO56-PM en estas condiciones, se han explorado alternativas basadas en inteligencia artificial (IA), particularmente técnicas de cómputo evolutivo como la programación genética (GP) y el *gene expression programming* (GEP) (Ajani *et al.* 2023). Estas metodologías han demostrado ser eficaces para modelar la ETo en contextos con disponibilidad limitada de datos meteorológicos, generando expresiones simbólicas precisas y fácilmente interpretables (Raza *et al.* 2024). Estudios comparativos han evidenciado que los modelos GEP alcanzan coeficientes de correlación y métricas de error similares o superiores a los obtenidos con redes neuronales artificiales o sistemas neuro-difusos (ANFIS), con la ventaja adicional de producir fórmulas explícitas que pueden integrarse en sistemas de monitoreo en tiempo real (Taheri *et al.* 2025). Esta capacidad de generar modelos autoajustables y simbólicos permite su implementación directa en entornos agrícolas mediante sensores in situ y sistemas de riego inteligente, sin requerir infraestructura computacional compleja.

A pesar de los avances, persiste un vacío de conocimiento relevante en cuanto al desarrollo de modelos alternativos de evapotranspiración de referencia específicamente diseñados para entornos protegidos, que sean al mismo tiempo precisos, interpretables y operativamente viables bajo escenarios de disponibilidad limitada de datos. Si bien los enfoques basados en inteligencia artificial han demostrado un alto potencial predictivo, muchos de ellos operan como cajas negras o requieren un número elevado de variables de entrada, lo que dificulta su implementación práctica en sistemas de riego inteligente (Ruiz-Ortega *et al.* 2024). Por ello, se requiere el desarrollo de modelos sencillos, explícitos y robustos, capaces de capturar la dinámica de la evapotranspiración en microclimas protegidos utilizando un conjunto reducido de variables climáticas clave. En este sentido, métodos como la programación genética ofrecen una ventaja distintiva al permitir la generación automática de expresiones matemáticas interpretables, sin imponer estructuras funcionales predefinidas, lo que facilita su integración directa en sistemas de monitoreo y control del riego. En este contexto, el objetivo del presente estudio es desarrollar un modelo predictivo simple, interpretable y preciso para estimar la evapotranspiración de referencia dentro de una malla sombra, utilizando técnicas de cómputo evolutivo y tomando como base los fundamentos físicos del modelo de referencia FAO56-PM.

MATERIALES Y MÉTODOS

Área de estudio y adquisición de datos

La investigación se desarrolló en una malla sombra ubicada en el Tecnológico Nacional de México campus Instituto Tecnológico de Torreón (TecNM/I.T.Torreón), en Torreón, Coahuila, México. El sitio experimental cuenta con una estación meteorológica inteligente previamente validada, diseñada para la monitorización continua del microclima en sistemas de agricultura protegida (Ruiz-Ortega *et al.* 2022).

La estación registró temperatura del aire, humedad relativa, velocidad del viento a 2 m de altura y radiación solar global mediante sensores comerciales de alta precisión. Las mediciones se realizaron con una frecuencia de un minuto, lo que permite capturar la elevada variabilidad microclimática característica de estructuras de malla sombra. Estudios recientes han documentado variaciones espaciales y temporales significativas de variables microclimáticas dentro de invernaderos y estructuras de producción protegida, lo que subraya la importancia de monitorear estas variables con alta resolución temporal para obtener información representativa del ambiente interno de cultivo (Islam *et al.* 2025). Los datos fueron transmitidos en tiempo real a un servidor en la nube para su almacenamiento y análisis posterior. Las especificaciones técnicas de los sensores se presentan en la Tabla 1.

Tabla 1. especificaciones técnicas de los sensores utilizados

No.	Sensor	Unidades	Descripción
1	DHT22	[°C/°F], %	Sensor de temperatura y humedad relativa
2	CYC-FS1-KV-W2	[m/s]	Sensor de velocidad del viento
3	Davis 6450	[W/m ²]	Sensor de Radiación Solar

Preprocesamiento de datos y construcción del conjunto de datos

Los datos meteorológicos correspondieron al periodo de 01 de marzo a 03 de julio de 2025. Aunque las mediciones se obtuvieron con una frecuencia de un minuto, fueron compactadas a escala horaria mediante el cálculo de valores máximos, mínimos o promedios, según la naturaleza de cada variable. Este procedimiento es consistente con estudios recientes de modelación de evapotranspiración basados en inteligencia artificial, donde la agregación horaria mejora la estabilidad del entrenamiento sin comprometer la información climática relevante (Heramb *et al.* 2023). El preprocesamiento incluyó la verificación de consistencia física, detección de valores atípicos y manejo de datos faltantes. El flujo general del proceso de adquisición, depuración y estructuración del conjunto de datos se presenta en la Figura 1. El conjunto final estuvo conformado por 3 047 registros horarios.

Variables de entrada y variable objetivo

Las variables meteorológicas de entrada consideradas en el modelo fueron: temperatura máxima y mínima del aire (°C), humedad relativa máxima y mínima (%), velocidad del viento (m s⁻¹) y radiación solar global (W m⁻²). Estas variables han sido utilizadas en estudios de estimación de ETo mediante enfoques de *machine learning* y cómputo evolutivo, tanto en campo abierto como en ambientes protegidos (Heramb *et al.* 2023, Ruiz *et al.* 2024). La variable objetivo fue la

evapotranspiración de referencia (ET_o), calculada mediante el método FAO56 Penman–Monteith, el cual continúa siendo empleado como referencia estándar para el entrenamiento y comparación de modelos basados en técnicas de inteligencia artificial (Allen *et al.* 1998).



Figura 1. flujo general del proceso de adquisición, depuración y estructuración del conjunto de datos

Desarrollo del modelo mediante programación genética

El modelo de estimación de la ET_o se desarrolló mediante programación genética (PG) utilizando el software MATLAB y la librería GPLab, siguiendo el enfoque evolutivo propuesto originalmente por Koza (1994). En estudios recientes, la PG y sus variantes han demostrado una alta capacidad para modelar procesos hidrometeorológicos no lineales, manteniendo interpretabilidad estructural y parsimonia en las expresiones obtenidas (Heramb *et al.* 2023, Kiraga *et al.* 2024).

Configuración del algoritmo evolutivo

El algoritmo se configuró con una población de 200 individuos y un máximo de 200 generaciones, utilizando el método de inicialización *ramped half-and-half*, el cual favorece la diversidad estructural inicial del conjunto de soluciones (Koza 1994). La selección de individuos se realizó mediante el método *lexictour*, mientras que las probabilidades de cruce y mutación se establecieron en 80 y 20%, respectivamente. Esta configuración es consistente con aplicaciones recientes de programación genética y *gene expression programming* en la estimación de ET_o, donde se busca un equilibrio entre exploración y explotación del espacio de búsqueda (Heramb *et al.* 2023). El criterio de paro del proceso evolutivo fue el número máximo de generaciones. Los principales parámetros del algoritmo evolutivo se presentan en la Tabla 2.

Tabla 2. Principales parámetros del algoritmo evolutivo

Parámetro	Valor
Tamaño de la Población	200
Número de Generaciones	200
Método de inicialización	<i>Ramped Half-and-Half</i>
Método de selección	<i>Lexictour</i>
Probabilidad de cruce	80%
Probabilidad de	20%

Conjunto de funciones, terminales y función de aptitud

El conjunto de terminales estuvo conformado por las variables meteorológicas de entrada y constantes numéricas. El conjunto de funciones incluyó operadores aritméticos básicos y funciones

matemáticas no lineales, como funciones cuadráticas, trigonométricas e hiperbólicas, las cuales han sido empleadas en modelos recientes de ETo basados en programación genética y aprendizaje automático (Ruiz *et al.* 2024). La función de aptitud se definió como la raíz del error cuadrático medio (RMSE), métrica ampliamente utilizada en trabajos recientes de evaluación de modelos de evapotranspiración por su sensibilidad a errores extremos y su estabilidad estadística (Ruiz *et al.* 2024).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (ET_{objetivo,i} - ET_{predicho,i})^2}$$

Donde: n es el número total de observaciones, $ET_{objetivo,i}$ y $ET_{predicho,i}$ son los valores observados y estimados, respectivamente. Un menor valor de RMSE indica un mejor ajuste del modelo.

Evaluación y validación del modelo

El conjunto de datos se dividió en 80% para entrenamiento y 20% para prueba, proporción comúnmente adoptada en estudios recientes de modelación climática mediante inteligencia artificial (Heramb *et al.* 2023, Ruiz *et al.* 2024). Adicionalmente, se realizó una validación temporal independiente utilizando datos del 7 al 18 de julio de 2025, los cuales no participaron en ninguna fase previa del modelado, con el objetivo de evaluar la capacidad de generalización del modelo bajo condiciones climáticas diferentes. El desempeño del modelo se evaluó mediante los indicadores estadísticos MAE, MBE, RMSE, nRMSE, MAPE, R^2 e índice de concordancia de Willmott, propuesto originalmente por Willmott (1981) y ampliamente utilizado en estudios recientes de validación de modelos hidrometeorológicos (Willmott *et al.* 2012).

RESULTADOS

Estadísticas del Proceso Evolutivo

Durante el entrenamiento del algoritmo evolutivo, se evaluó la tasa de convergencia y estabilidad mediante 10 ejecuciones independientes (Figura 2). En promedio, se alcanzaron soluciones con un RMSE inferior a 0.5 desde la generación 12, lo que evidencia una mejora rápida del desempeño en las primeras etapas del proceso evolutivo. La mejor solución alcanzó un RMSE mínimo de 0.1177 en la generación 170; sin embargo, este modelo presentó una complejidad estructural elevada, con expresiones matemáticas extensas y de difícil interpretación. Dado que uno de los objetivos centrales del estudio es el desarrollo de modelos simples, explícitos e interpretables para su integración en sistemas de riego inteligente, esta solución no fue incluida en la Tabla 3. En su lugar, se seleccionaron modelos con estructuras matemáticas más compactas, que equilibran adecuadamente precisión predictiva e interpretabilidad, favoreciendo su transferencia a entornos reales con recursos computacionales y de instrumentación limitados. La disminución progresiva en la desviación estándar indica convergencia efectiva hacia soluciones homogéneas y de alta calidad, sin pérdida prematura de diversidad. Este comportamiento sugiere que la presión evolutiva favoreció la propagación de individuos más aptos, reduciendo la variabilidad poblacional.




Figura 2. Mejor valor de aptitud (mejor ajuste), el promedio de los mejores ajustes por generación y la desviación estándar asociada.

Tabla 3. Modelos de estimación de la evapotranspiración de referencia (ETo) mediante programación genética y modelos empíricos clásicos (Hargreaves–Samani y Priestley–Taylor), fitness obtenido en la etapa de evolución y sus variables de entrada.

No.	Modelo Matemático	Fitness	Variables de entrada
1	$ET_{o_{gp1}} = 0.34rn$	0.506114	Radiación neta [MJ/m ² /día]
2	$ET_{o_{gp2}} = 0.34(1 + rn)$	0.459183	Radiación neta [MJ/m ² /día]
3	$ET_{o_{gp3}} = \frac{0.34(1 + rn)}{\coth(e_s - e_a)}$	0.407831	Radiación neta [MJ/m ² /día] Déficit de presión de vapor [kPa]
4	$ET_{o_{gp4}} = \frac{0.34(1 + rn)}{\coth(e_s - e_a)^2}$	0.401033	Radiación neta [MJ/m ² /día] Déficit de presión de vapor [kPa] Velocidad del viento [m/s]
5	$ET_{o_{gp5}} = \frac{vv + 0.34rn}{\coth(hr_{min}) * \coth(e_s - e_a)}$	0.281789	Humedad relativa mínima [%] Déficit de presión de vapor [kPa] Radiación neta [MJ/m ² /día]
6	$ET_{o_{gp6}} = 0.4197 * rn$	0.548039	Radiación neta [MJ/m ² /día]
7	$ET_{o_{HS}} = 0.0023 \cdot (T_{prom} + 17.8) \cdot (T_{max} - T_{min})^{0.5} \cdot Ra$		Temperatura máxima [°C] Temperatura mínima [°C] Radiación extraterrestre [MJ/m ² /día] Radiación neta en la superficie del cultivo [MJ/m ² /día] Flujo de calor en el suelo [MJ/m ² /día], suele considerarse 0 en escalas diarias
8	$ET_{o_{PT}} = \alpha \cdot \frac{\Delta}{\Delta + \gamma} \cdot \frac{R_n - G}{\lambda}$		Coefficiente de Priestley-Taylor (usualmente $\alpha = 1.26$ $\alpha = 1.26$) Pendiente de la curva de presión de vapor [kPa/°C] Constante psicrométrica [kPa/°C] Calor latente de vaporización [~2.45 MJ/kg]

Soluciones óptimas

De las 2 000 soluciones generadas, 317 presentaron un RMSE inferior a 0.55. Se seleccionaron seis modelos representativos (Tabla 3) considerando tanto la precisión como la complejidad estructural. Este enfoque permitió priorizar modelos con expresiones más simples y mayor interpretabilidad, sin comprometer significativamente la precisión, lo cual es esencial para su implementación práctica.

Comparación con modelos tradicionales

Los modelos evolutivos (ETogp1–ETogp6) mostraron desempeño superior en comparación con los modelos empíricos Hargreaves-Samani (EToH-S) y Priestley-Taylor (EToP-T) durante las fases de entrenamiento y prueba. Entre los modelos GP, ETogp5 destacó por su mayor precisión, menores errores (MAE = 0.1934 mm·día⁻¹, RMSE = 0.2817 mm día⁻¹, MAPE = 10.05 %) y valores mayores de coeficiente de determinación ($R^2 = 0.9841$) e índice de concordancia de Willmott (d-index = 0.9957). Esta tendencia se mantuvo en el conjunto de prueba, donde ETogp5 evidenció alta capacidad de generalización (RMSE = 0.2797 mm día⁻¹, $R^2 = 0.9883$). Los demás modelos GP también superaron consistentemente a los modelos empíricos, que presentaron errores significativamente mayores, particularmente Hargreaves-Samani, cuyo RMSE y MAE fueron elevados y R^2 bajo. La prueba de Wilcoxon confirmó que las diferencias entre los modelos evolutivos y los empíricos son estadísticamente significativas, lo que evidencia la robustez y superioridad de los primeros. Los valores completos de las métricas de desempeño se presentan en las Tablas 4 y 5 para entrenamiento y prueba, respectivamente.

Tabla 4. Métricas estadísticas obtenidas con datos de entrenamiento para los modelos evolucionados, Hargreaves-Samani y Priestley-Taylor

Modelo	MAE	MBE	RMSE	nRMSE %	MAPE %	R^2	d_index	p_valor Wilcoxon
ETogp1	0.3461	-0.2366	0.5061	20.2155	15.9483	0.9487	0.9855	2.99767E-81
ETogp2	0.3907	0.1033	0.4591	18.3410	31.9486	0.9578	0.9880	6.4726E-49
ETogp3	0.3283	0.0076	0.4078	16.2899	23.1211	0.9667	0.9908	5.32998E-09
ETogp4	0.3108	-0.0536	0.4010	16.0183	21.1196	0.9678	0.9913	0.015631442
ETogp5	0.1934	-0.1448	0.2817	11.2554g	10.0487	0.9841	0.9957	1.4703E-125
ETogp6	0.4393	0.2928	0.5480	21.8901	26.4634	0.9399	0.9862	4.3853E-196
EToH-S	4.3995	4.3655	4.9916	199.3800	314.4900	3.9833	0.5188	0
EToP-T	0.4124	0.2494	0.5864	23.4250	17.8890	0.9312	0.9852	1.9493e-144

Los gráficos de dispersión correspondientes a las Figuras 3 y 4 muestran el ajuste de los modelos evolutivos (ETogp1–ETogp6) y de los modelos clásicos Hargreaves-Samani y Priestley-Taylor frente a los valores de referencia de FAO56-PM, durante las etapas de entrenamiento y prueba, respectivamente. En ambas etapas, los modelos evolutivos evidenciaron un alto grado de concordancia con la línea de igualdad, presentando pendientes cercanas a 1 y coeficientes de determinación elevados (R^2 entre 0.940 y 0.988), lo que indica una predicción precisa y consistente de la evapotranspiración de referencia. Entre estos modelos, ETogp5 se distinguió por su mejor desempeño, con pendiente de 0.93–0.95 y $R^2 = 0.984$ –0.988, reflejando mínima desviación sistemática respecto a los valores observados. ETogp6 mostró una ligera sobreestimación en

determinados rangos de ETo, evidenciada por pendientes superiores a 1 y $R^2 \approx 0.940$ – 0.942 . En contraste, los modelos clásicos mostraron un desempeño significativamente inferior: Hargreaves-Samani presentó pendientes bajas o negativas y coeficientes de determinación negativos, indicando una predicción poco confiable y sesgo sistemático, mientras que Priestley-Taylor obtuvo un ajuste moderado (pendiente ≈ 1.15 , $R^2 \approx 0.931$), inferior al alcanzado por los mejores modelos evolutivos. Estos resultados confirman la superioridad predictiva y la robustez de los modelos generados mediante programación genética, tanto en la fase de entrenamiento como en la de prueba.

Tabla 5. Métricas estadísticas obtenidas con datos de prueba para los modelos evolucionados, Hargreaves-Samani y Priestley-Taylor

Modelo	MAE	MBE	RMSE	nRMSE [%]	MAPE [%]	R ²	d_index	p_valor Wilcoxon
ETogp1	0.3230	-0.2159	0.4894	19.2392	15.7896	0.9642	0.9902	5.80583E-16
ETogp2	0.3837	0.1240	0.4564	17.9398	32.6036	0.9689	0.9914	1.06501E-14
ETogp3	0.3158	0.0245	0.3994	15.6984	22.8407	0.9762	0.9936	0.000114014
ETogp4	0.2973	-0.0384	0.3895	15.3099	21.0206	0.9773	0.9940	0.930703446
ETogp5	0.1834	-0.1381	0.2797	10.9948	9.8834	0.9883	0.9969	5.4011E-28
ETogp6	0.4767	0.3278	0.6225	24.4694	27.1146	0.9421	0.9871	1.79113E-43
EToH-S	4.6877	4.6345	5.4540	214.3600	373.6700	-3.4370	0.5028	4.1793e-83
EToP-T	0.4529	0.2846	0.6771	26.6150	18.2390	0.9316	0.9856	2.2809e-30




Figura 3. Gráficos de dispersión de los modelos evolutivos y modelos clásicos de Hargreaves-Samani y Priestley-Taylor con datos de entrenamiento.




Figura 4. Gráficos de dispersión de los modelos evolutivos y modelos clásicos de Hargreaves-Samani y Priestley-Taylor con datos de prueba.

Validación externa del modelo EToyp5

Dado el rendimiento sobresaliente en las fases de entrenamiento y prueba, el modelo EToyp5 (Ec. 2) fue seleccionado para una validación externa utilizando un conjunto de datos completamente independiente, no empleado previamente en el desarrollo del modelo. Dicho conjunto de datos corresponde a un periodo temporal distinto, registrado bajo las mismas condiciones estructurales del sistema de malla sombra, pero no incluido previamente en el proceso de calibración del modelo. Esta estrategia permite evaluar su capacidad de generalización y robustez en condiciones reales, lo cual es fundamental para su aplicación práctica en entornos agroclimáticos diversos. La formulación matemática resultante se expresa como:

$$ET_{0gp5} = \frac{u_2 + 0.34rn}{\coth(hr_{min}) * \coth(e_s - e_a)}$$

Donde: EToyp5 representa la evapotranspiración de referencia estimada mediante el modelo evolutivo. La variable control u_2 corresponde a la velocidad del viento, rn indica la radiación neta, hr_{min} representa la humedad relativa mínima, y $(e_s - e_a)$ denota el déficit de presión de vapor.

La serie temporal horaria mostrada en la Figura 5 evidencia un comportamiento diferencial claro entre los modelos evaluados al compararlos con la referencia FAO56-PM. El modelo evolutivo EToyp5 reproduce de manera muy precisa la dinámica diurna de la evapotranspiración de referencia, capturando adecuadamente tanto el incremento matutino asociado al aumento de la

radiación neta como el pico máximo alrededor del mediodía y la posterior disminución vespertina. La cercanía sistemática entre ET₀gp5 y FAO56-PM a lo largo de todo el ciclo diario, junto con la reducida dispersión observada, confirma su alta capacidad para representar la variabilidad temporal de la ET₀ bajo condiciones de malla sombra. En contraste, el modelo de Hargreaves-Samani presenta una sobreestimación marcada durante gran parte del día, especialmente en las horas matutinas y vespertinas, lo que evidencia su incapacidad para reproducir adecuadamente los efectos del microclima protegido, caracterizado por una atenuación de la radiación y de la ventilación. Por su parte, el modelo de Priestley-Taylor muestra un mejor ajuste relativo que Hargreaves-Samani durante el periodo central del día; sin embargo, tiende a sobreestimar la ET₀ en torno al máximo diario y a subestimar durante las horas de menor demanda evaporativa, reflejando un sesgo sistemático.




Figura 5. Serie temporal: ET₀gp5 vs FAO56-PM, Hargreaves y Priestley-Taylor

En concordancia con las evidencias visuales obtenidas a partir de la serie temporal mostrada en la Figura 5 y los gráficos de dispersión (Figura 6), el análisis estadístico de la validación externa permitió cuantificar de manera objetiva el desempeño predictivo de los modelos evaluados. Los indicadores presentados en la Tabla 6 confirman que ET₀gp5 exhibe los menores valores de error (MAE = 0.168 mm h⁻¹, RMSE = 0.217 mm h⁻¹), un sesgo prácticamente nulo (MBE = -0.165 mm h⁻¹) y un grado de concordancia casi perfecto con FAO56-PM (R² = 0.996; d-index = 0.999), incluso frente a datos no utilizados durante su calibración. Asimismo, el resultado de la prueba de Wilcoxon (p ≈ 0) indica diferencias estadísticamente significativas respecto a los modelos clásicos, lo que respalda de forma robusta la superioridad del modelo evolutivo.

En conjunto, estos resultados confirman que ET₀gp5 no solo presenta mejores métricas estadísticas globales, sino que además reproduce con mayor fidelidad la evolución horaria de la evapotranspiración de referencia, un aspecto crítico para su aplicación en sistemas de riego de alta frecuencia y para el manejo dinámico del microclima en agricultura protegida. Adicionalmente, su estructura funcional simple y su bajo requerimiento de variables de entrada lo convierten en una

herramienta eficiente y adaptable para regiones con limitaciones tecnológicas o disponibilidad restringida de datos meteorológicos.




Figura 6. Gráficos de dispersión del modelo ETogp5 y los modelos clásicos de Hargreaves-Samani y Priestley-Taylor con datos no conocidos.

Tabla 6. Resultados estadísticos de la validación con datos no conocidos por los modelos ETogp5, Hargreaves-Samani y Priestley-Taylor

Modelo	MAE	MBE	RMSE	nRMSE [%]	MAPE [%]	R ²	d_index	p_valor Wilcoxon
ETogp5	0.168	-0.165	0.217	6.49%	15.67%	0.996	0.999	1.16e-43
EToH-S	4.000	3.848	4.818	144.14%	336.76%	-0.983	0.634	6.65e-45
EToP-T	0.664	0.525	1.007	30.11%	19.63%	0.913	0.983	5.34e-21

DISCUSIÓN

La gestión eficiente del agua constituye un desafío crítico en zonas áridas, especialmente en sistemas de producción bajo estructuras protegidas como invernaderos o malla sombra, donde el microclima difiere significativamente del ambiente exterior debido a alteraciones en la radiación, la temperatura, la humedad relativa y la ventilación natural (García-Caparrós *et al.* 2018). En este contexto, la estimación precisa de la evapotranspiración de referencia (ET_0) no solo representa un requisito técnico, sino un elemento estratégico para optimizar el uso del recurso hídrico, reducir pérdidas por riego excesivo o insuficiente, y mejorar la sostenibilidad de la producción agrícola.

Los resultados obtenidos en la validación externa con datos independientes (Tabla 6) muestran que el modelo ET_{0gp5} alcanzó un desempeño sobresaliente, con RMSE de $0.217 \text{ mm} \cdot \text{día}^{-1}$, MAE de $0.168 \text{ mm} \cdot \text{d}^{-1}$, MAPE de 15.67% y nRMSE de 6.49%. Asimismo, presentó un coeficiente de determinación $R^2 = 0.996$ y un índice de concordancia de Willmott ($d\text{-index}$) = 0.999, evidenciando una correspondencia casi perfecta con los valores de referencia calculados mediante FAO56-PM (Allen *et al.* 1998). La prueba no paramétrica de Wilcoxon arrojó un p-valor extremadamente bajo ($\sim 10^{-43}$), confirmando diferencias estadísticamente significativas respecto al modelo de referencia y validando la robustez del enfoque evolutivo.

En contraste, los modelos empíricos clásicos mostraron limitaciones evidentes. El modelo Hargreaves-Samani presentó errores muy elevados ($RMSE \approx 4.8 \text{ mm} \cdot \text{día}^{-1}$, $MAPE \approx 336\%$) y R^2 negativo, reflejando su inaplicabilidad en microclimas protegidos donde las condiciones de radiación y ventilación difieren de las originalmente consideradas (Hargreaves y Samani 1985). Priestley-Taylor mostró un desempeño intermedio ($RMSE \approx 1.0 \text{ mm} \cdot \text{día}^{-1}$, $R^2 \approx 0.913$), aunque el sesgo positivo ($MBE \approx 0.525 \text{ mm} \cdot \text{día}^{-1}$) indica una tendencia sistemática a sobreestimar la ET_0 , lo que podría derivar en sobreaplicación de riego en escenarios operativos reales (Priestley y Taylor 1972).

Un hallazgo clave de este estudio es la capacidad de la programación genética (GP) para generar modelos altamente parsimoniosos sin comprometer la precisión predictiva. Modelos como ET_{0gp1} , dependientes únicamente de la radiación neta (R_n), demuestran que en entornos protegidos una reducción significativa del número de variables puede ser suficiente para capturar la dinámica principal de la evapotranspiración. Esta simplificación representa una ventaja operativa relevante, al disminuir la necesidad de instrumentación meteorológica compleja y permitir la implementación de modelos precisos en escenarios con disponibilidad limitada de datos.

La elevada correlación entre la radiación neta y la ET_0 se fundamenta en principios físicos sólidos, dado que la radiación constituye la fuente de energía principal que impulsa la evaporación y transpiración (Allen *et al.* 1998). En sistemas de malla sombra o invernadero, donde la velocidad del viento está atenuada por la estructura y la humedad relativa es más estable, el término energético domina el balance evapotranspirativo, mientras que la contribución aerodinámica se reduce significativamente (Yan *et al.* 2021). Bajo estas condiciones, variables como la velocidad del viento o la temperatura del aire pueden volverse secundarias o incluso redundantes, especialmente cuando su variabilidad temporal es limitada.

Estos resultados sugieren que, en microclimas protegidos, la ET_0 puede ser conceptualizada no solo como una variable de monitoreo, sino como un parámetro de control activo en sistemas de riego inteligente. La estimación continua y precisa de la ET_0 permite ajustar dinámicamente el riego y manejar variables ambientales internas, como ventilación o sombreo, contribuyendo a mantener condiciones óptimas para el desarrollo del cultivo (Yan *et al.* 2021). Esta reinterpretación amplía el papel tradicional de la ET_0 y la posiciona como un componente central en la agricultura de precisión y la automatización agrícola.

El éxito de ET_{0gp5} se explica por la capacidad de la GP para generar expresiones matemáticas explícitas que capturan relaciones no lineales y multivariadas entre las variables climáticas y la ET_0 . A diferencia de los modelos empíricos, la aproximación evolutiva no impone estructuras funcionales predefinidas, permitiendo descubrir formulaciones adaptadas a las particularidades del microclima protegido y manteniendo alta interpretabilidad física. Además, la selección de modelos con estructura compacta y bajo número de variables asegura una mejor generalización, estabilidad y facilidad de integración en sistemas de riego inteligente, cumpliendo con el principio de parsimonia en modelado predictivo (Guyon *et al.* 2003, Koza 1994). En conjunto, los resultados confirman que los modelos basados en GP, y en particular aquellos con conjuntos de variables reducidos, constituyen una alternativa robusta, precisa y operativamente viable para la estimación de ET_0 en agricultura protegida. Su implementación permite optimizar la aplicación de riego,

reducir el consumo hídrico y mitigar impactos ambientales, aspectos críticos en regiones áridas y semiáridas y en el contexto de la creciente presión sobre los recursos hídricos derivada del cambio climático.

CONCLUSIONES

El modelo evolutivo ETogp5 tuvo capacidad predictiva sobresaliente, superando de manera consistente a los modelos empíricos tradicionales bajo condiciones de malla sombra. Su formulación matemática compacta y el reducido número de variables de entrada lo colocan como una herramienta eficiente, robusta y de fácil implementación, con elevado potencial de adopción en regiones áridas y semiáridas, donde la disponibilidad de infraestructura meteorológica suele ser limitada. Su precisión permite una estimación confiable de la evapotranspiración de referencia (ET_o) en ambientes de agricultura protegida, lo que favorece su aplicación en la programación del riego. En este contexto, la incorporación de enfoques evolutivos como ETogp5 contribuye a optimizar el uso del recurso hídrico. En contraste, el modelo de Hargreaves-Samani presentó errores y ausencia de capacidad predictiva bajo microclimas protegidos, por lo que no se recomienda su uso para la estimación de la ET_o en este tipo de sistemas. Por su parte, el modelo de Priestley-Taylor mostró un desempeño intermedio, caracterizado por alta correlación, pero sesgo positivo sistemático, lo que indica una tendencia a sobreestimar la demanda evaporativa.

CONFLICTO DE INTERÉS

Los autores declaran que no tienen intereses en competencia.

LITERATURA CITADA

- Acharki S, Raza A, Vishwakarma DK, Amharref M, Bernoussi AS, Singh SK, Al-Ansari N, Dewidar AZ, Al-Othman AA, Mattar MA (2025) Comparative assessment of empirical and hybrid machine learning models for estimating daily reference evapotranspiration in sub-humid and semi-arid climates. *Scientific Reports* 15(1): 2542. <https://doi.org/10.1038/s41598-024-83859-6>
- Ajani OS, Aboyeji E, Mallipeddi R, Dooyum-Uyeh D, Ha Y, Park T (2023) A genetic programming-based optimal sensor placement for greenhouse monitoring and control. *Frontiers in Plant Science* 14: 1152036. <https://doi.org/10.3389/fpls.2023.1152036>
- Allen RG, Pereira LS, Raes D, Smith M (1998) Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. Fao, Rome. https://www.avwatermaster.org/filingdocs/195/70653/172618e_5xAGWAx8.pdf. Fecha de consulta 27 de enero de 2026.
- Campi P, Gaeta L, Mastrorilli M, Losciale P (2020) Innovative soil management and micro-climate modulation for saving water in Peach Orchards. *Frontiers in Plant Science* 11: 1052. <https://doi.org/10.3389/fpls.2020.01052>

- Celestin S, Qi F, Li R, Yu T, Cheng W (2020) Evaluation of 32 simple equations against the Penman–Monteith method to estimate the reference evapotranspiration in the hexi corridor, Northwest China. *Water* 12(10): 2772. <https://doi.org/10.3390/w12102772>
- Costa-Filho E, Chávez JL, Zhang, H (2024) Assessing multi-sensor hourly maize evapotranspiration estimation using a one-source surface energy balance approach. *Irrigation and Drainage* 73(3): 988-1009. <https://doi.org/10.1002/ird.2923>
- Doria M, García M, Mancilla G, Buytaert W (2021) Estrategias para el aumento de la disponibilidad y mejoramiento de la eficiencia hídrica en América Latina y El Caribe. <https://unesdoc.unesco.org/ark:/48223/pf0000377174>. Fecha de consulta: 27 de enro del 2026.
- Flores-Mancheno CI, Palacios-López LA (2025) Tecnologías de riego inteligente y su contribución a la conservación del agua en agricultura. *Multidisciplinary Collaborative Journal* 3(1): 61-73. <https://doi.org/10.70881/mcj/v3/n1/46>
- Garcia-Caparrós P, Contreras JI, Baeza R, Segura ML, Lao MT (2017) Integral management of irrigation water in intensive horticultural systems of Almería. *Sustainability* 9(12): 2271. <https://doi.org/10.3390/su9122271>
- Ghiat I, Mackey HR, Al-Ansari T (2021) A Review of evapotranspiration measurement models, techniques and methods for open and closed agricultural field applications. *Water* 13(18): 2523. <https://doi.org/10.3390/w13182523>
- Gong X, Bo G, Liu H, Ge J, Li X, Gao S (2022) Performance of the improved Priestley-Taylor model for simulating evapotranspiration of greenhouse tomato at different growth stages. *Plants* 11(21): 2956. <https://doi.org/10.3390/plants11212956>
- Li Z, Li Y, Yu X, Jia G, Chen P, Zheng P, Wang Y, Ding B (2024) Applicability and improvement of different potential evapotranspiration models in different climate zones of China. *Ecological Processes* 13: 20. <https://doi.org/10.1186/s13717-024-00488-7>
- Kiraga S, Peters RT, Molaei B, Evett SR, Marek G (2024) Reference evapotranspiration estimation using genetic algorithm-optimized machine learning models and standardized Penman-Monteith equation in a highly advective environment. *Water* 16(1): 12. <https://doi.org/10.3390/w16010012>
- Guyon I, Elisseeff A, Kaelbling LP (2003) An introduction to variable and feature selection. *Journal of Machine Learning Research* 3(7-8): 1157-1182. <https://doi.org/10.1162/15324430322753616>
- Hargreaves GH, Samani ZA (1985) Reference crop evapotranspiration from temperature. *Applied Engineering in Agriculture* 1(2): 96-99. <https://doi.org/10.13031/2013.26773>
- Heramb P, Singh PK, Rao KR, Subeesh A (2023) Modelling reference evapotranspiration using gene expression programming and artificial neural network at Pantnagar, India. *Information Processing in Agriculture* 10(4): 547-563. <https://doi.org/10.1016/j.inpa.2022.05.007>
- Islam MN, Reza MN, Iqbal MZ, Lee KH, Jang MK, Chung SO (2025) Spatial and temporal variability of environmental variables in chinese solar greenhouses in the summer season. *Horticulturae* 11: 421. <https://doi.org/10.3390/horticulturae11040421>
- Jaafar HH, Ahmad F (2019) Determining reference evapotranspiration in greenhouses from external climate. *Journal of Irrigation and Drainage Engineering* 145(9): 04019018. [https://doi.org/10.1061/\(ASCE\)IR.1943-4774.000140](https://doi.org/10.1061/(ASCE)IR.1943-4774.000140)
- Koza JR (1994) Genetic programming as a means for programming computers by natural selection. *Statistics and Computing* 4: 87-112. <https://doi.org/10.1007/BF00175355>
- Mansoor S, Iqbal S, Popescu SM, Kim SL, Chung YS, Baek JH (2025) Integration of smart sensors and IOT in precision agriculture: trends, challenges and future perspectives. *Frontiers in Plant Science* 16: 1587869. <https://doi.org/10.3389/fpls.2025.1587869>
- Kabir MY, Nambeesan SU, Díaz-Pérez JC (2024) Shade nets improve vegetable performance. *Scientia Horticulturae* 334: 113326. <https://doi.org/10.1016/j.scienta.2024.113326>

- Obayomi OV, Attah R, Sayem SMS, Mustapha LS, Kolade SO, Obayomi KS (2025) Sustainable agriculture in the face of water scarcity: Opportunities, challenges, and global perspectives. *Next Research* 101293. <https://doi.org/10.1016/j.nexres.2025.101293>
- Priestley CHB, Taylor RJ (1972) On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly Weather Review* 100(2): 81-92. [https://doi.org/10.1175/1520-0493\(1972\)100<0081:OTAOSH>2.3.CO;2](https://doi.org/10.1175/1520-0493(1972)100<0081:OTAOSH>2.3.CO;2)
- Raza A, Vishwakarma DK, Acharki S, Al-Ansari N, Alshehri F, Elbeltagi A (2024) Use of gene expression programming to predict reference evapotranspiration in different climatic conditions. *Applied Water Science* 14: 152. <https://doi.org/10.1007/s13201-024-02200-8>
- Ruiz-Ortega FJ, Clemente E, Martínez-Rebollar A, Flores-Prieto JJ (2024) An evolutionary parsimonious approach to estimate daily reference evapotranspiration. *Scientific Reports* 14(1): 6736. <https://doi.org/10.1038/s41598-024-56770-3>
- Ruiz-Ortega J, Martínez-Rebollar A, Flores-Prieto J, Estrada-Esquivel H (2022) Diseño de una arquitectura IoT de bajo costo para monitoreo de Invernaderos. *Computación y Sistemas* 26(1): 221-232. <https://doi.org/10.13053/CyS-26-1-4166>
- Santos MSN, Castro IA, Oro CED, Zabot GL, Tres MV (2021) Reference crop evapotranspiration in distinct agricultural regions of Southern Brazil: a comparison of improved empirical models. *Revista Engenharia Na Agricultura* 29: 448-465. <https://doi.org/10.13083/reveng.v29i1.12418>
- Sammen SS, Kisi O, Al-Janabi AMS, Elbeltagi A, Zounemat-Kermani M (2023) Estimation of reference evapotranspiration in semi-arid region with limited climatic inputs using metaheuristic regression methods. *Water* 15(19): 3449. <https://doi.org/10.3390/w15193449>
- Soussi A, Zero E, Sacile R, Trincherro D, Fossa M (2024) Smart sensors and smart data for precision agriculture: A review. *Sensors* 24(8): 2647. <https://doi.org/10.3390/s24082647>
- Taheri M, Bigdeli M, Imanian H, Mohammadian A (2025) An overview of evapotranspiration estimation models utilizing artificial intelligence. *Water* 17(9): 1384. <https://doi.org/10.3390/w17091384>
- Willmott CJ, Robeson SM, Matsuura K (2012) A refined index of model performance. *International Journal of climatology* 32(13): 2088-2094. <https://doi.org/10.1002/joc.2419>