

Estimación de un sistema de evapotranspiración en Autlán de Navarro mediante un modelo ANFIS

José Eduardo Hernández Haro¹, Jorge Arturo Pelayo López¹, Benjamín Antonio Lobato González¹, Jesús Alejandro Rodríguez Herrera¹

¹Departamento de Ingenierías, Universidad de Guadalajara CUCSUR, Av. Independencia Nacional No. 151, Autlán, Jalisco, México

Resumen: La evapotranspiración corresponde a una de las mediciones climatológicas más relevantes de las últimas décadas debido a su impacto en la agricultura, forestación y otras áreas de la Tierra. Específicamente, el estudio de la evapotranspiración en la región de Autlán de Navarro, Jalisco, México, tiene una gran importancia debido a que corresponde a una de las regiones agrícolas más importantes del occidente mexicano. No obstante, la medición de estos parámetros es bastante compleja, lo cual implica que nunca se obtiene una medición directa, sino una estimación. Por ello, en este trabajo se presenta la estimación de evapotranspiración en dicha región mediante un modelo neuronal ANFIS. Los resultados muestran una precisión competitiva respecto a los datos de entrada, con errores inferiores al 1%.

Palabras clave: evapotranspiración, ANFIS, red neuronal, Autlán de Navarro.

1. Introducción

La producción agrícola (PA) constituye una actividad vital para el sustento y el crecimiento de los seres vivos. La PA depende de condiciones dinámicas como el clima, las condiciones meteorológicas, la radiación, la humedad del suelo, etc. [1]. En el ámbito de la PA, la gestión del agua se ha identificado como la tarea más crucial [2], mientras que el crecimiento de la población mundial incrementa significativamente la demanda de recursos hídricos, especialmente en los procesos de riego de la industria agrícola. Se requiere una gestión sostenible del agua para reducir el consumo sin afectar a la producción de cultivos agrícolas. La evapotranspiración (ET) es un indicador importante para la planificación y la gestión de los recursos hídricos sostenibles, lo cual es realmente relevante para nuestro estado medioambiental actual. La ET es un componente complejo y no lineal del ciclo hidrológico [3], donde se representa la combinación de los procesos de evaporación y transpiración. El proceso de evaporación es la vaporización de la superficie del suelo, mientras que el proceso de transpiración se refiere a la capacidad de absorción de agua del suelo. Ambos procesos constituyen un indicador importante del clima de la región y se utilizan como herramienta de toma de decisiones para la gestión del agua en la agricultura.

La ET puede representarse en un modelo matemático compuesto por varios factores climáticos, como la temperatura, la humedad del suelo, la velocidad del viento, la humedad relativa y la radiación solar, entre muchos otros. La evapotranspiración de referencia de los cultivos (ET_0) cuantifica el balance hídrico para caracterizar el clima de una región basándose en las variables climáticas, con el fin de calcular con precisión el valor real de la ET [4]. Dado que el cálculo de la ET_0 se basa en cambios dinámicos de las variables climáticas, la estimación de una ET precisa se considera una tarea de predicción compleja. La mayoría de los mecanismos de estimación de la ET_0 pueden dividirse, a grandes rasgos, en dos categorías diferentes: métodos directos y métodos indirectos. Los métodos directos calculan el valor de la ET basándose en mediciones directas de las variables climáticas. Estos métodos son precisos, pero requieren una gran cantidad de datos para elaborar un esquema de predicción, lo que se traduce en un procedimiento de alto costo. Además, muchos de estos datos requieren un análisis complejo para obtener la información y, en la mayoría de los casos, dicha información es solo una estimación. Por otro lado, los métodos indirectos adoptan diferentes factores e incluso un alto procesamiento de datos con un esfuerzo computacional relativamente bajo sin perder precisión [5].

Según la bibliografía especializada, resulta bastante evidente que los métodos directos para la estimación de ET dependen en gran medida de grandes conjuntos de datos, lo que conlleva un elevado esfuerzo computacional. Desde la aparición de los avances tecnológicos, muchos investigadores han adoptado métodos indirectos, como las técnicas de inteligencia artificial (IA), para superar estas dificultades y obtener mejores resultados al analizar enormes cantidades de datos [6].

Por ello, algunos investigadores han propuesto los sistemas de inferencia difusa basados en redes adaptativas (ANFIS) para superar esas dificultades. Los modelos ANFIS son técnicas híbridas que combinan los sistemas difusos con las arquitecturas de redes neuronales. La hibridación implica la sinergia de varias técnicas para superar las limitaciones de cada enfoque individual. Los modelos ANFIS presentan algunas ventajas, entre las que se incluyen la capacidad de adaptación, la rapidez de aprendizaje y la estructura no lineal. Estas características han atraído la atención de las comunidades científica y de ingeniería, que utilizan los modelos ANFIS para predecir los procesos de evapotranspiración. El ANFIS utiliza dos procedimientos fundamentales: de paso hacia adelante (FP – Forward Propagation) y de paso hacia atrás (BP – Back Propagation) [7]; en el procedimiento FP, el ANFIS utiliza un conjunto fijo de parámetros de premisa y un método de estimación por mínimos cuadrados (LSE – Least Square Error) en la capa de consecuencias. Por otro lado, el procedimiento BP utiliza un método de gradiente descendente (GD) para ajustar la capa de parámetros de premisa. Este proceso de aprendizaje se repite hasta alcanzar un número determinado de iteraciones. Este mecanismo de aprendizaje FP-BP puede dar lugar a varios problemas, como soluciones subóptimas, ya que los

métodos basados en gradientes son propensos a quedarse estancados en mínimos locales.

Por ello, en este trabajo de investigación se propone adaptar el algoritmo ANFIS a una base de datos climatológica en la región de Autlán de Navarro, Jalisco, México. Esto se realiza mediante una metodología FP-BP basada en el filtro de Kalman y gradiente descendente. Los resultados demuestran una mejoría competitiva respecto al ANFIS común, en términos de estabilidad, precisión y adaptabilidad a sistemas complejos. El resto del artículo se estructura de la siguiente manera: en la sección 2 se define el modelo de evapotranspiración en términos generales y el utilizado en este trabajo; en la sección 3 se explica la estructura ANFIS y su mejora propuesta; en la sección 4 se presentan y analizan los resultados obtenidos; y, por último, en la sección 5 se exponen las conclusiones de este trabajo.

2. Sistema regional de evapotranspiración

Tal como se ha explicado anteriormente, cada sistema de ET varía en función de las condiciones climatológicas y geográficas, como la densidad de población de la región. En este sentido, los datos del sistema de ET estimados en este trabajo se basan en las condiciones de Autlán de Navarro. La Figura 1 muestra que el municipio de Autlán de Navarro se encuentra en el suroeste del estado de Jalisco, México, entre las coordenadas 19° 45' y 19° 48' de latitud norte, y 104° 20' y 104° 24' de longitud oeste, a una altitud media de 920 metros sobre el nivel del mar.

La ciudad de Autlán de Navarro se encuentra dentro de la cuenca del río Armería. El clima de la zona es semiseco, con una temperatura media anual de 21.2 °C y una precipitación media anual de 635.7 mm. En el municipio, la producción agrícola es una de las actividades económicas más importantes, ya que representa el 1.13 % de la producción del estado [8]. Además, el 54.36 % de los cultivos de Jalisco, como el maíz, el sorgo, el maní y el tomate, se producen en esta región. Por lo tanto, la optimización de este sector agrícola es fundamental para la economía de la ciudad y sus alrededores.




Figura 1. Municipio de Autlán de Navarro, Jalisco, México.

La Tabla 1 muestra las especificaciones estadísticas de las variables predictoras, en este estudio se tienen en cuenta seis parámetros estimados, entre los que se incluyen la evapotranspiración (ET), la temperatura (T), la humedad relativa (RH), la radiación solar (RS), la velocidad del viento (WS) y la presión barométrica (p). En la Tabla 1 se muestra una columna que indica la unidad de medida, y se describen los valores máximo, mínimo, medio y la desviación estándar. Cabe mencionar que dicho conjunto de datos se ha normalizado con el fin de visualizar de forma orgánica la información proporcionada. Como se puede observar, la variable de presión es la más difícil de controlar debido a su diferencia numérica con respecto al resto de predictores.

Tabla 1. Especificaciones estadísticas y variables de predicción.

Variabes de predicción	Unidad	Mínimo	Máximo	Promedio	Desviación estándar
<i>T</i>	°C	18.35	33.8333	23.6658	3.5330
<i>RH</i>	%	36.6666	98.0000	82.0684	13.1416
<i>WS</i>	Km/h	0	6.9300	1.2448	1.4980
<i>p</i>	mb	1006.5166	1017.1000	1011.71	1.8140
<i>RS</i>	W/m ²	0	950.8333	180.5198	272.9796
<i>ET</i>	mm	0	0.7600	0.1404	0.2105

3. La red ANFIS y su mejora computacional

3.1. Adaptive Network based Fuzzy Inference System (ANFIS)

El ANFIS es un modelo difuso de Takagi-Sugeno que se compone de reglas «si-entonces» [9]. Para simplificar, el modelo ANFIS puede considerarse como dos elementos: el antecedente del sistema difuso y el consecuente, tal como se muestra en la Figura 2. Asimismo, se puede apreciar que el ANFIS cuenta con cinco capas en su estructura, cuya finalidad se describe a continuación.

Capa 1. Cada nodo i determina el grado con el cual una determinada entrada u satisface al cuantificador A_i , como se describe en la Ecuación 1.

$$O_i^1 = \mu_{A_i}(u) \quad (1)$$

Con esto, el cuantificador se puede modelar como una función de membresía de la forma que se expresa en la Ecuación 2:

$$\mu_{A_i}(u) = e^{-\frac{(u-\sigma_i)^2}{(2s_i)^2}} \quad (2)$$

donde $\{\sigma_i, s_i\}$ son los parámetros de la función de membresía que son comúnmente conocidos como parámetros de premisa.

Capa 2. En esta capa, cada nodo es nombrado como Π , lo que implica la capacidad de activación de su regla difusa correspondiente $O_i^2 = \omega_i$.

Capa 3. Cada nodo i es nombrado como N y representa la normalización de la capacidad de activación y se puede establecer como la Ecuación 3, donde h corresponde al número de nodos en esta capa.

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_{j=1}^h w_j} \quad (3)$$

Capa 4. En esta capa, una función lineal que actúa como una unidad de procesamiento adaptativo se implementa en cada nodo i de la forma como expresa la Ecuación 4:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i u_1 + q_i u_2 + r_i) \quad (4)$$

donde $\{p_i, q_i, r_i\}$ son los parámetros adaptables que determinan la respuesta de la función lineal. Estos elementos son conocidos como parámetros consecuentes. Generalmente, la función f_i se puede definir como cualquier función lineal que

mejor describa el comportamiento del modelo en la región difusa, la cual se especifica en la regla antecedente i .

Capa 5. El último nodo llamado $\sum i$ determina la salida y como una suma de todas las señales, tal como se muestra en la Ecuación 5.

$$y = O_i^5 = \sum_i \bar{w}_i \cdot f_i = \frac{\sum_i w_i \cdot f_i}{\sum_i w_i} \quad (5)$$




Figura 2. Estructura del algoritmo ANFIS.

3.2. Filtro de Kalman aplicado al ANFIS

Una vez comprendidos el modelo ANFIS básico y su estructura, es el momento de abordar sus respectivos procesos de hibridación. Para simplificar la explicación, todo el proceso se divide en dos partes principales que comprenden los procedimientos FP y BP de los sistemas.

La primera parte del proceso corresponde al establecimiento de los parámetros iniciales para todas las secciones. El aspecto más destacable radica en la creación de la matriz de nodos de conexión, ya que la conexión exacta es precisamente la que se presenta en la Figura 2 para este modelo específico de evapotranspiración. Sin embargo, la relación entre los nodos de conexión es la misma para un modelo ANFIS con cualquier número de entradas. Cabe mencionar que cada modelo ANFIS específico generará un número determinado de nodos; no obstante, dado que esta generación de nodos puede interpretarse como un resultado, se explicará en detalle

en la siguiente sección. Lo más importante es saber que este modelo ANFIS concreto establece 112 nodos para cinco entradas. Las operaciones del ANFIS se distribuyen a lo largo de un proceso iterativo, en el que el conjunto de valores de cada entrada debe desarrollarse en las tres primeras capas del modelo ANFIS. Este proceso iterativo es equivalente al método de entrenamiento utilizado en otros trabajos relacionados [10]. Puede apreciarse que, una vez que los valores de la entrada actual se colocan en sus respectivos nodos, los valores iniciales de la capa 1 se determinan de forma estocástica. No obstante, los valores de los nodos de conexión entre la capa 1 y la capa 2 están directamente relacionados con los valores iniciales mencionados anteriormente; esta relación se expresa mediante la Ecuación 6:

$$Si \rightarrow \frac{x-c}{a} \begin{cases} = 0 & \mu_{A_i}(x) = 1 \\ \neq 0 & \mu_{A_i}(x) = \frac{1}{1 + \left(\left(\frac{x-c}{a}\right)^2\right)^b} \end{cases} \quad (6)$$

donde x, a, b y c son los valores premisa que corresponden a los parámetros definidos por la campana generalizada de las funciones de membresía, mientras que $\mu_{A_i}(x)$ es el nodo a completarse.

A continuación, a partir de los valores de los nodos de salida de la capa 3, se estiman los parámetros resultantes mediante un método de predicción, normalmente la estimación por mínimos cuadrados, o en este caso el filtro de Kalman. En términos simples, este filtro propuesto en 1960 identifica el estado no medible de un sistema dinámico lineal, y debido a su recursividad es ideal para trabajarlo en sistemas de tiempo real como las redes neuronales [11]. El filtro de Kalman asume que el estado verdadero en el tiempo k evoluciona desde el estado $k - 1$, tal como lo muestra la Ecuación 7 adaptada al ANFIS:

$$\mu_{A_i}(x) = F_{A_i} \mu_{A_i}(x-1) + B_{A_i} u_{A_i} + w_{A_i} \quad (7)$$

Donde, F_{A_i} es el modelo de transición de estado que se aplica al estado previo $\mu_{A_i}(x-1)$, B_{A_i} es el modelo de entrada de control que se aplica al vector de control u_{A_i} , w_{A_i} es el ruido del proceso que en este caso proviene de la Ecuación 6. Por lo tanto, se puede inferir que el filtro de Kalman ayuda al modelo ANFIS a estabilizar los nodos de la capa 3, provenientes de la generación de la capa 2. El hecho más destacable es que los parámetros resultantes corresponden a seis valores estimados debido a la función polinómica de primer orden de la Ecuación 8. Sin embargo, estos seis valores se estiman para cada uno de los nodos de salida de la capa 3, lo que corresponde a 32 nodos en este caso de un sistema de cinco entradas, lo que genera 192 datos que deben estimarse para cada entrada del conjunto de datos. Una vez estimados los 192 parámetros resultantes de cada entrada del conjunto de datos, se procesan mediante un modelo iterativo con el fin de obtener los valores ponderados de la capa 4, tal y

como se explica en la sección 3.1 con la Ecuación 4. Finalmente, la salida real del modelo ANFIS se calcula en la capa 5 con la Ecuación 5.

Ahora bien, el BP tiene como objetivo principal generar los errores de retropropagación con el fin de mejorar los valores iniciales de la capa 1. La generación de dichos errores se lleva a cabo siguiendo las reglas de una red neuronal clásica de retropropagación [12]. A continuación, se aplica el esquema de la Ecuación 8, donde se establece un valor denominador de acuerdo con los valores de premisa estocásticos originales. El valor denominador se calcula entonces como se expone en la Ecuación 9 para obtener la diferencia entre los valores de premisa reales y los errores de retropropagación, donde mf_i es el valor de la función de pertenencia actual de la capa 1, mientras que x, a, b y c son los nuevos parámetros de premisa de cada función de pertenencia.

$$Si \rightarrow \frac{x-c}{a} \begin{cases} = 0 & den = 1 \\ \neq 0 & den = \left(\left(\frac{x-c}{a}\right)^2\right)^b \end{cases} \quad (8)$$

$$Si \rightarrow mf_i \begin{cases} x & mf_i = \frac{2b \times den}{a \times (1 + 2den + den^2)} \\ c & \begin{cases} Si \rightarrow den = 1 & mf_i = 0 \\ Si \rightarrow den \neq 1 & mf_i = \frac{-\log\left(\frac{x-c}{a}\right)^2 \times den}{1 + 2den + den^2} \end{cases} \\ a & \begin{cases} Si \rightarrow x = c & mf_i = 0 \\ Si \rightarrow x \neq c & mf_i = \frac{2b \times den}{(x-c) \times (1 + 2den + den^2)} \end{cases} \end{cases} \quad (9)$$

Una vez calculada la diferencia mencionada, el modelo ANFIS clásico sugiere aplicar un algoritmo GD para estimar los nuevos valores de las premisas. Finalmente, la función objetivo propuesta como índice de evaluación para estos algoritmos se define en la Ecuación 10:

$$\mu_{A_{i,j}} = \sum_{i=n_i+1}^{n_i \times n_{MF}} \sum_{j=1}^3 Be_i \times mf_i \quad (10)$$

donde n_i y n_{mf} son el número predefinido de entradas y el número de funciones de pertenencia, respectivamente; i y j son el nodo actual y el parámetro correspondiente de la función de pertenencia respectiva, mientras que Be_i es el error de retropropagación actual. Por último, $\mu_{A_{i,j}}$ debe entenderse como el valor fitness de la función. Con todo lo anterior, se puede resumir que el ANFIS original utiliza un método LSE para el FP y un GD para el BP, mientras que en este trabajo se propone sustituir la estimación LSE por un filtro de Kalman, por lo tanto, estos dos

métodos se compararán a continuación denominándolos LSE/GD y Kalman/GD, respectivamente.

4. Resultados computacionales

En esta sección se presentan los resultados obtenidos por el modelo ANFIS con las dos estrategias de estimación (LSE/GD y Kalman/GD). La comparación de los enfoques se realiza teniendo en cuenta el sistema de evapotranspiración expuesto en la sección 2, entendiendo que dicho conjunto de datos se analiza en su forma normalizada. Los resultados computacionales que se presentan a continuación se obtuvieron en el entorno de programación MATLAB en un portátil (procesador de 2,70 GHz, 8 GB de RAM) con el sistema operativo Windows 10.

Independientemente del enfoque evaluado, se utilizan e interconectan 112 nodos durante la programación ANFIS para las cinco entradas del conjunto de datos; la Figura 3 muestra la conexión de estos 112 nodos. Tal y como se menciona en la sección 2, los primeros 5 nodos corresponden a la capa de entrada, por lo que almacenan las cinco entradas del conjunto de datos. Posteriormente, dado que se definen dos funciones de pertenencia para cada entrada, esto genera 10 nodos para la capa 1; la conexión de esta primera capa se observa de forma escalonada en la parte superior izquierda de la Figura 3.




Figura 3. Distribución de nodos del ANFIS.


En cuanto a la Tabla 2, se puede observar que está dividida en dos módulos: el módulo superior muestra los valores iniciales obtenidos mediante un proceso estocástico al inicio de las pruebas, por lo que todos los valores son iguales para todos los esquemas.

Por otro lado, en el módulo inferior se presentan los valores finales alcanzados por cada algoritmo al término de 35 ejecuciones y 100 épocas. En esencia, cabe señalar que existe un cambio considerable entre los valores de premisa iniciales y finales para cada técnica, sin embargo, es imposible determinar la eficiencia de dichos parámetros analizándolos únicamente en forma tabular. Por ello, la Figura 4 muestra gráficamente las funciones de pertenencia obtenidas a partir de los valores de premisa del módulo inferior de la Tabla 2, donde las funciones azul y roja corresponden a la primera y segunda funciones de pertenencia.


Tabla 2. Valores premisa iniciales y finales del conjunto normalizado.

ANFIS	LSE/GD			Kalman/GD		
	a	b	x_0	a	b	x_0
I1	0.0091	2	-0.5521	0.0091	2	-0.5521
	0.0091	2	-0.4976	0.0091	2	-0.4976
I2	0.0179	2	-0.5521	0.0179	2	-0.5521
	0.0179	2	-0.4976	0.0179	2	-0.4976
I3	0.0100	2	-0.5521	0.0100	2	-0.5521
	0.0100	2	-0.4976	0.0100	2	-0.4976
I4	0.0210	2	-0.5521	0.0210	2	-0.5521
	0.0210	2	-0.4976	0.0210	2	-0.4976
I5	0.0566	2	-0.5521	0.0566	2	-0.5521
	0.0566	2	-0.4976	0.0566	2	-0.4976
I1	-0.0493	2.0074	-0.6088	-0.0172	2.0093	-0.5671
	-0.0511	2.0031	-0.4812	-0.0343	2.0041	-0.4934
I2	0.0359	1.9996	-0.5515	0.0359	1.9996	-0.5515
	-0.0002	2.0004	-0.4964	-0.0002	2.0004	-0.4964
I3	-0.0528	2.0050	-0.6297	-0.0243	2.0060	-0.6099
	0.1746	2.0009	-0.5739	0.1744	2.0009	-0.5732
I4	-0.0003	2.0009	-0.5524	-0.0003	2.0009	-0.5524
	0.0372	1.9992	-0.4974	0.0372	1.9992	-0.4974
I5	0.3162	1.9584	-0.5758	0.3268	1.9562	-0.5760
	-0.0669	2.0675	-0.2025	-0.0654	2.0774	-0.2054

El cambio más notable se produce en las funciones de la primera entrada (temperatura - *temperature*), ya que los valores de pertenencia alcanzados por la estrategia de estimación LSE/GD tiende a reducir su separación, mientras que la estrategia Kalman/GD tiende a lo contrario. Algo relativamente similar se observa en la tercera entrada (velocidad del viento - *wind speed*), donde la primera función tiende a reducir su anchura y a aumentar su pendiente con el Kalman/GD.



a) ANFIS LSE/GD MFs



b) ANFIS Kalman/GD MFs

Figura 4. Funciones de membresía obtenidas.


A partir de los parámetros de premisa obtenidos, el resto del proceso ANFIS se ejecutó tal y como se describe en la sección 3. Con el fin de determinar la calidad del rendimiento de cada algoritmo, se proponen los cinco índices estadísticos siguientes: el error cuadrático medio (RMSE) y el error absoluto medio (MAE) son métricas bien conocidas que se utilizan en este trabajo con el objetivo de conocer el error existente entre los datos previstos y los observados [13]. Por otro lado, el índice de concordancia (d) es una técnica adimensional que permite comprender la correlación entre los datos previstos y los observados, bajo el principio de que el índice de concordancia perfecta debe valorarse como 1 [14]. La desviación estándar (STD) es una de las métricas estadísticas básicas en las ciencias computacionales para conocer la dispersión en un conjunto de mediciones. Además, ninguna de las métricas mencionadas presenta la distribución del error de los resultados; por ello, se propone el índice de discrepancia desarrollado (DDR). Básicamente, esta última métrica establece que los datos previstos y observados son iguales si el DDR es 0, mientras que dichos datos están subestimados o sobreestimados si el DDR es <0 y >0 , respectivamente [15]. La Tabla 3 presenta los resultados de las métricas mencionadas, obtenidas mediante las dos estrategias ANFIS para 2, 3, 4 y 5 entradas del sistema de evapotranspiración. Como se puede apreciar, el LSE/GD presentó un menor tiempo de ejecución que el Kalman/GD, pero este último logró mejores resultados métricos, lo cual concuerda con la modelación matemática que requiere el filtro de Kalman para operar, pero su rendimiento compensa totalmente ese incremento computacional.

Tabla 3. Resultados métricos con el conjunto normalizado.


ANFIS	Entrada	RMSE (mm/day)	MAE (mm/day)	d	STD	DDR	Tiempo (segundos)
LSE/GD	2	0.03259	0.02405	0.98496	0.21689	0.02301	0.84599
	3	0.02610	0.01761	0.98939	0.21793	-0.00472	1.97230
	4	0.00921	0.00644	0.99840	0.21927	-0.00060	9.64055
	5	0.00887	0.00610	0.99851	0.21950	0.00967	17.49915
Kalman/GD	2	0.03259	0.02405	0.98496	0.21689	0.02301	2.13139
	3	0.02554	0.01666	0.98969	0.21790	-0.00590	4.80287
	4	0.00874	0.00636	0.99856	0.21930	0.02426	23.47474
	5	0.00715	0.00522	0.99901	0.21939	0.00593	43.44830

Por otra parte, se decidió mostrar la comparación entre los resultados del conjunto de datos y la predicción correspondiente del enfoque ANFIS mediante los gráficos de la Figura 5. Según el conocimiento de los autores, esta es la representación gráfica óptima para este conjunto de datos normalizados, ya que permite visualizar la comparación precisa de cada uno de los 30 resultados de datos con su respectiva predicción. Como se puede observar, la diferencia en las predicciones del esquema Kalman/GD es casi nula, mientras que la diferencia en el enfoque LSE/GD es considerable. De hecho, es fácil apreciar que la peor predicción

la realiza el LSE/GD en la Figura 5a, mientras que, por otro lado, la mejor predicción la realiza el Kalman/GD en la Figura 5b. Estos resultados son comparables a los analizados en la Figura 4, ya que, como se ha mencionado anteriormente, las estrategias de filtrado de Kalman superan considerablemente a las técnicas LSE.



a) Predicción del ANFIS LSE/GD



b) Predicción del ANFIS Kalman/GD

Figura 5. Comparación entre salidas y predicción del ANFIS.

Todos los resultados presentados hasta ahora han corroborado las ventajas del filtro de Kalman frente al enfoque clásico de LSE para la mejora de ANFIS. No obstante, es importante verificar la competitividad del algoritmo mediante una prueba estadística no paramétrica. Existen diferentes técnicas estadísticas que permiten determinar esta competencia; en este caso, se aplica la prueba de Wilcoxon a los dos algoritmos, tomando en consideración la técnica de Kalman como el algoritmo contra el cual comparar al ANFIS LSE/GD debido a su rendimiento durante los experimentos computacionales mostrados. En primer lugar, hay que entender que la prueba de Wilcoxon establece el cumplimiento o incumplimiento de una hipótesis nula mediante la obtención de los denominados valores p de los enfoques comparados [16]. Ahora bien, según la teoría de Wilcoxon, se define un valor crítico y, si el valor p respectivo es menor que el valor crítico, se rechaza la hipótesis nula, lo que implica que la prueba no ha encontrado ninguna similitud estadística entre los enfoques comparados. Por el contrario, si se confirma la hipótesis nula, significa que la prueba ha encontrado similitud estadística entre ambas técnicas, lo cual es el caso indeseable para cualquier enfoque.

Tabla 4. Análisis de Wilcoxon para el ANFIS.

Entradas	LSE/GD	Kalman/GD
2	0.000360	0.000360
3	0.058970	0.041105
4	0.003930	0.000360
5	0.000751	0.000671

Con base en lo anterior, la Tabla 4 presenta los resultados no paramétricos de los conjuntos de datos normalizados. En dicha tabla, el valor crítico se define como 0.05, lo que corresponde al 5% de las medidas estadísticas. Del mismo modo, se compara la técnica Kalman/GD con el LSE/GD, considerando una estructura ANFIS de evapotranspiración con 2, 3, 4 y 5 entradas del sistema. Los resultados muestran que el enfoque Kalman/GD superó al LSE/GD en todos los casos, siendo el sistema de una entrada la única estructura ANFIS en la que el LSE/GD pudo competir.

5. Conclusiones

El modelo ANFIS ha mejorado el rendimiento de predicción de muchos sistemas de la vida real a lo largo de los años desde su creación en 1993. Sin embargo, su propia arquitectura restrictiva siempre ha limitado sus capacidades de hibridación con otras técnicas de predicción y optimización. En ese sentido, este trabajo presenta un interesante proceso de hibridación con el fin de mejorar las capacidades de predicción del modelo ANFIS mediante un rendimiento de filtrado de los parámetros premisa. Esencialmente, la propuesta consiste en la sustitución de la evaluación clásica de los parámetros premisa en el proceso FP por la aplicación de

estrategias de filtrado de Kalman con datos de inicialización específicos. Aunque el coste computacional se ve ligeramente afectado, las características de predicción mejoradas compensan dicho coste. Por otra parte, el modelo ANFIS propuesto se probó en un sistema de evapotranspiración real modelado con cinco entradas.

Los resultados obtenidos demuestran que la estrategia de Kalman/GD supera a la clásica estructura LSE/GD de predicción en casi todos los aspectos. Se llevaron a cabo diversos análisis estadísticos y representaciones gráficas con el fin de corroborar la información obtenida. Este trabajo ofrece una interesante forma de mejorar el modelo ANFIS mediante enfoques de filtrado, y se podrían llevar a cabo varios trabajos futuros desde esta perspectiva. La aplicación de esquemas similares a los parámetros correspondientes es una tarea difícil, pero supondría una mejora significativa para el ANFIS. Asimismo, la aplicación de diferentes esquemas de filtrado e incluso técnicas de optimización con este procedimiento constituye una línea de investigación futura relevante, por mencionar solo algunos ejemplos.

Referencias

1. A. Srivastava, S. Jain, R. Maity, and V. R. Desai, "Demystifying artificial intelligence amidst sustainable agricultural water management," in *Current Directions in Water Scarcity Research*, vol. 7, pp. 17-35, 2022. doi: 10.1016/B978-0-323-91910-4.00002-9
2. K. Chartzoulakis and M. Bertaki, "Sustainable water management in agriculture under climate change," *Agriculture and Agricultural Science Procedia*, vol. 4, pp. 88-98, 2015. doi:10.1016/J.AASPRO.2015.03.011
3. S. Jovic, B. Nedeljkovic, Z. Golubovic, and N. Kostic, "Evolutionary algorithm for reference evapotranspiration analysis," *Computers and Electronics in Agriculture*, vol. 150, pp. 1-4, 2018. doi:10.1016/J.COMPAG.2018.04.003
4. H. L. Penman, "Natural evaporation from open water, bare soil and grass," *Proceedings of the Royal Society of London. Series A, Mathematical and Physical Sciences*, vol. 193, no. 1032, pp. 120-145, 1948. doi: 10.1098/RSPA.1948.0037
5. R. G. Allen, L. S. Pereira, D. Raes, and M. Smith, *Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements*, FAO Irrigation and Drainage Paper 56. Rome, Italy: FAO, 1998, <http://www.climasouth.eu/sites/default/files/FAO%2056.pdf>.
6. M. Y. Chia, Y. F. Huang, C. H. Koo y K. F. Fung, "Recent advances in evapotranspiration estimation using artificial intelligence approaches with a focus on hybridization techniques—A review," *Agronomy*, vol. 10, no. 1, p. 101, 2020. doi:10.3390/AGRONOMY10010101
7. S. Kambalimath and P. C. Deka, "A basic review of fuzzy logic applications in hydrology and water resources," *Applied Water Science*, vol. 10, no. 8, pp. 1-14, 2020. doi:10.1007/S13201-020-01276-2
8. IIEG, "Autlán de Navarro diagnóstico del municipio agosto 2021," Instituto de Información Estadística y Geográfica de Jalisco, 2021. [Online]. Available: <https://iieg.gob.mx/ns/wp-content/uploads/2021/10/Autl%C3%A1n-de-Navarro-1.pdf>.
9. J. S. R. Jang, "ANFIS: Adaptive-network-based fuzzy inference system," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 3, pp. 665-685, 1993. doi: 10.1109/21.256541.

10. A. Z. Zangeneh, M. Mansouri, M. Teshnehlab, and A. K. Sedigh, "Training ANFIS system with DE algorithm," in *Proceedings of the 4th International Workshop on Advanced Computational Intelligence (IWACI)*, pp. 308–314, 2011. doi:10.1109/IWACI.2011.6160022
11. M. S. Grewal, "Kalman filtering", in *International encyclopedia of statistical science*, pp. 1285–1289, 2025. doi:10.1007/978-3-662-69359-9_310
12. B. J. Wythoff, "Backpropagation neural networks: A tutorial," *Chemometrics and Intelligent Laboratory Systems*, vol. 18, pp. 115–155, 1993. doi:10.1016/0169-7439(93)80052-J
13. Y. Yang, Y. Chen, Y. Wang, C. Li, and L. Li, "Modelling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short-term electricity demand forecasting," *Applied Soft Computing*, vol. 49, pp. 663–675, 2016, doi:10.1016/j.asoc.2016.07.053
14. P. K. Pandey, P. P. Dabral, and V. Pandey, "Evaluation of reference evapotranspiration methods for the northeastern region of India," *International Soil and Water Conservation Research*, vol. 4, no. 1, pp. 52–63, 2016. doi:10.1016/j.iswcr.2016.02.003
15. R. Noori *et al.*, "Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction," *Journal of Hydrology*, vol. 401, no. 3–4, pp. 177–189, 2011. doi:10.1016/j.jhydrol.2011.02.021
16. F. Wilcoxon, "Individual comparisons by ranking methods," in *Breakthroughs in Statistics*, S. Kotz and N. L. Johnson, Eds. New York, NY, USA: Springer, pp. 196–202, 1992. doi:10.1007/978-1-4612-4380-9_16