

# Jornadas de Automática

## Estimación de la distribución de caudal en plantas solares de colectores cilindro-parabólicos

Ruiz-Moreno, Sara<sup>a,\*</sup>, Gallego, Antonio J.<sup>a</sup>, Camacho, Eduardo F.<sup>b</sup>

<sup>a</sup>Depto. de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos sin número, 41092, Sevilla, España

<sup>b</sup>AICIA - Depto. de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos sin número, 41092, Sevilla, España

**To cite this article:** Ruiz-Moreno, Sara, Gallego, Antonio J., Camacho, Eduardo F. 2025. Flow distribution estimation in parabolic-trough collector solar plants. *Jornadas de Automática*, 46.  
<https://doi.org/10.17979/ja-cea.2025.46.12053>

### Resumen

Este trabajo presenta una metodología para la estimación del reparto de caudal en plantas termosolares de colectores cilindro-parabólicos combinando técnicas de optimización con redes neuronales recurrentes para reducir su alto coste computacional. Primero, se aplica un algoritmo para estimar la temperatura en el lazo y obtener el reparto de caudal que minimiza los errores de estimación. Después, se entrenan redes neuronales para reproducir el algoritmo. Los caudales obtenidos se utilizan como punto inicial en el proceso de optimización, limitando el espacio de búsqueda y reduciendo significativamente el tiempo de cómputo. El método se evalúa en sectores de distinto tamaño (4, 20 y 50 lazos), comparando tres variantes: optimización, combinación red neuronal+optimización, y red neuronal. Los resultados muestran que el enfoque propuesto mejora la estimación respecto a la suposición clásica de distribución uniforme, y permite una reducción significativa del tiempo de cálculo respecto al uso único del optimizador, especialmente relevante en sectores de gran escala.

**Palabras clave:** Estimación, Detección de fallos, Mantenimiento y garantía de calidad, Energía solar, Métodos para FDI basados en IA, Redes neuronales

### Flow distribution estimation in parabolic-trough collector solar plants

#### Abstract

This work presents a methodology to estimate the flow distribution in parabolic-trough collector solar plants combining optimization techniques with recurrent neural networks to reduce their high computational cost. First, an algorithm estimates the loop temperatures and obtains the flow rates that minimize the estimation error. Next, neural networks are trained to reproduce the algorithm. The obtained flow rates are used as initial points to the optimization problem. This way, the search space is limited and the computation time is significantly reduced. The method is evaluated in sectors of 4, 20, and 50 loops, and three versions are compared: only optimization, optimization+neural network and only neural network. The results prove that the flow rate estimation improves with respect to assuming a uniform distribution. Moreover, the neural networks reduce significantly the computation time, which is specially relevant in large-scale sectors.

**Keywords:** Estimation, Fault detection, Quality assurance and maintenance, Solar energy, AI methods for FDI, Neural networks

### 1. Introducción

La principal fuente de energía de la Tierra es el Sol, responsable de la mayoría de las formas de energía (Şen, 2004), y representa una solución clave para satisfacer la creciente de-

manda energética global (Rakhshani et al., 2019), ya que permite reducir las emisiones de gases de efecto invernadero y fomentar el crecimiento económico (Jacob et al., 2021). La energía solar puede aprovecharse principalmente de dos ma-

\*Autor para correspondencia: [srmoreno@us.es](mailto:srmoreno@us.es)  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

neras: mediante paneles fotovoltaicos y mediante sistemas de energía solar por concentración (CSP, por sus siglas en inglés, *Concentrating Solar Power*). Estos últimos emplean espejos para concentrar la radiación solar en un receptor, generando energía térmica y produciendo electricidad. Dentro de las tecnologías CSP, este trabajo se centra en los colectores cilindro-parabólicos (PTC, *Parabolic-Trough Collectors*).

Las plantas PTC comerciales constan de numerosos lazos distribuidos sobre grandes superficies. Para facilitar su monitorización y control, suelen dividirse en sectores, asumiendo una distribución uniforme del caudal entre los distintos lazos. Sin embargo, debido a factores como las largas distancias entre lazos (que afectan al rendimiento de las bombas) y fallos en componentes, aparecen desbalances que pueden pasar desapercibidos durante largos periodos.

Diversos estudios han abordado el problema del desbalance de caudal entre lazos mediante estrategias de control que ajustan las válvulas para homogeneizar las temperaturas de salida (Sánchez et al., 2019; Gallego et al., 2023). Asimismo, se han propuesto métodos de control predictivo distribuido (Frejo and Camacho, 2020), basados en técnicas de clustering (Chanfreut et al., 2023) y coalicionales (Sánchez-Amores et al., 2023), con el objetivo de reducir la carga computacional.

A menudo se asume que la distribución de caudal está directamente correlacionada con la apertura de las válvulas, sin considerar las pérdidas y fallos mencionados, especialmente relevantes en plantas de gran escala. Algunos trabajos (Ma et al., 2019; Gallego et al., 2022b) han subrayado la necesidad de tener en cuenta estos efectos mediante modelos hidráulicos. Sin embargo, la integración de estos modelos no lineales resulta compleja y computacionalmente costosa.

En este trabajo, se propone una nueva metodología centrada directamente en la estimación de la distribución de caudal mediante una estrategia de optimización asistida por redes neuronales. Esta técnica busca reducir el coste computacional y permitir su aplicación en tiempo real en plantas PTC.

El resto del documento se organiza de la siguiente manera: la Sección 2 describe el sistema, el modelo de planta y los parámetros utilizados; la Sección 3 detalla la metodología propuesta; los resultados de simulación se presentan en la Sección 4; y finalmente, en la Sección 5, se recogen las conclusiones y posibles líneas de trabajo futuro.

## 2. Descripción del Sistema

Una planta de colectores cilindro-parabólicos está compuesta por lazos de espejos con forma parabólica, diseñados para reflejar la radiación solar y concentrarla en una línea focal por la que circula un fluido. Este fluido, normalmente agua o aceite, se calienta y se conduce a una turbina para generar energía eléctrica, como se ilustra en la Figura 1. Los lazos se agrupan en sectores y, a su vez, están formados por varios módulos de colectores. Además, en muchas plantas de gran escala, se incorporan válvulas en la entrada de cada lazo para permitir el control individual del caudal.

### 2.1. Modelo de la Planta

En este trabajo se utiliza un modelo de una planta de 50 MW compuesta por 90 lazos de 620 m de longitud, cada

uno con 4 colectores (Sánchez et al., 2018) (aunque se realizan pruebas adicionales con distinto número de lazos). Los colectores, orientados de norte a sur, cuentan con un sistema de seguimiento solar que les permite rotar alrededor de un eje paralelo a la tubería para seguir el movimiento del sol. Cada lazo está formado por una sección activa de 593 m que recibe radiación solar, y una sección pasiva. Además, el fluido de trabajo es Therminol VP-1, operando a una temperatura nominal de aproximadamente 390 °C.

Cada lazo se modela mediante un modelo de parámetros distribuidos que representa los balances de energía en el fluido y la tubería (Camacho et al., 1997). Este modelo se describe mediante las Ecuaciones 1 y 2:

$$\rho_m C_m A_m \frac{\partial T_m}{\partial t} = I K_{opt} \eta_d n_o G + -H_t G (T_m - T_a) - L H_t (T_m - T_f) \quad (1)$$

$$\rho_f C_f A_f \frac{\partial T_f}{\partial t} + \alpha_q \rho_f C_f q \frac{\partial T_f}{\partial x} = L H_t (T_m - T_f) \quad (2)$$

donde  $\rho$  es la densidad,  $C$  es la capacidad calorífica específica,  $A_f = 3,6 \cdot 10^{-3} \text{ m}^2$  y  $A_m = 2,1677 \cdot 10^{-4} \text{ m}^2$  son las áreas transversales interior y exterior de la tubería,  $I$  es la irradiancia,  $K_{opt}$  es la eficiencia óptica,  $\eta_d$  es la eficiencia de desenfoque,  $n_o$  es la eficiencia geométrica,  $G = 5,75 \text{ m}$  es la apertura del colector,  $H_t$  son las pérdidas térmicas,  $L = 2,136 \cdot 10^{-1} \text{ m}$  es la longitud de la circunferencia interior de la tubería y  $H_t$  es el coeficiente de transmisión de calor por convección. Además, los subíndices f, m y a se refieren al fluido, al metal y al ambiente. Para integrar las ecuaciones, el lazo se divide en 297 segmentos de 2.0625 m cada uno y se emplea un paso de 0.25 s.

La tubería está fabricada con acero DIN 1.4404, con densidad  $\rho_m = 7800 \text{ kg/m}^3$  y capacidad específica  $C_m = 550 \text{ J/(kg} \cdot ^\circ\text{C)}$ . Las propiedades del fluido se definen por las Ecuaciones 3 y 4 (Gallego et al., 2022a):

$$\rho_f = -4,810 \cdot 10^{-4} T_f^2 - 8,110 \cdot 10^{-1} T_f + 9,537 \cdot 10^2 \quad (3)$$

$$C_f = 1,561 \cdot 10^{-8} T_f^2 + 1,707 \cdot 10^{-1} T_f + 1,574 \cdot 10^2 \quad (4)$$

Los coeficientes de pérdidas y de transmisión de calor se obtienen mediante las Ecuaciones 5 y 6:

$$H_1 = 1,137 \cdot 10^{-8} (T_f - T_a)^3 - 3,235 \cdot 10^{-6} (T_f - T_a)^2 + + 1,444 \cdot 10^{-4} (T_f - T_a) + 8,179 \cdot 10^{-2} - \frac{4,796}{(T_f - T_a)} \quad (5)$$

$$H_t = \frac{q}{3600}^{0,818} (-3,243 \cdot 10^{-4} T_f^3 + 2,442 \cdot 10^{-1} T_f^2 + + 2,320 \cdot 10^2 T_f + 2,532 \cdot 10^4) \quad (6)$$

Por último, la eficiencia geométrica se determina mediante la Ecuación 7 (Teleszewski et al., 2021) donde  $\phi$  es la latitud,  $\delta_s$  es la declinación y  $\omega_s$  es el ángulo horario:

$$n_o = \left( (\sin(\phi) \sin(\delta_s) + \cos(\phi) \cos(\delta_s) \cos(\omega_s))^2 + + \cos^2(\delta_s) \sin^2(\omega_s) \right)^{\frac{1}{2}} \quad (7)$$



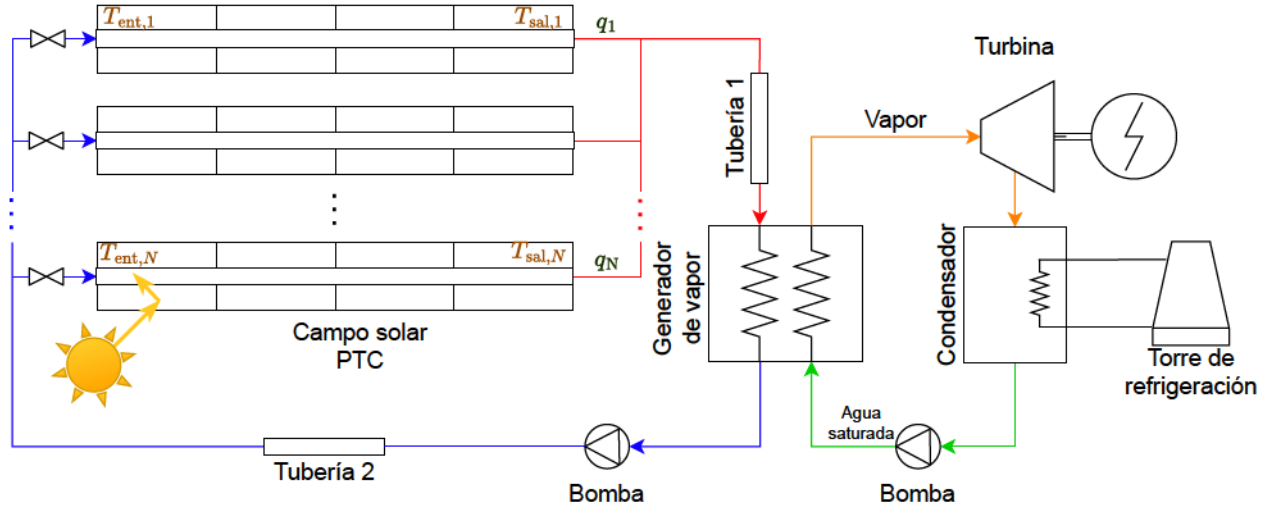


Figura 1: Esquema de una planta de colectores cilindro-parabólicos formada por  $N$  lazos. A la izquierda: campo solar. A la derecha: ciclo Rankine. La temperatura de entrada al lazo  $i$  es  $T_{ent,i}$ , la temperatura de salida es  $T_{sal,i}$  y el caudal es  $q_i$ .

## 2.2. Algoritmo de Desenfoque

La planta cuenta con un algoritmo de desenfoque para reducir la eficiencia de los colectores en situaciones en las que existen limitaciones de potencia o se superan ciertos límites máximos de temperatura para asegurar la seguridad de la planta. Consiste en desviar el colector de su foco para reducir la cantidad de radiación que llega a los receptores. Este algoritmo es comúnmente utilizado en plantas comerciales y se basa en un sistema de tres estados, representado en la Figura 2.




Figura 2: Estrategia de desenfoque.  $T_i$  es la temperatura en el centro del colector  $i$  y  $\theta_d$  es el ángulo de desenfoque. Sólo los colectores 3 y 4 pueden alcanzar los tres estados.

En este esquema, el estado 0 corresponde a un ángulo de desenfoque  $\theta_d = 0^\circ$ , el estado 1 a  $\theta_d = 2^\circ$  y el estado 2 a  $\theta_d = 5^\circ$ . La transición entre estos estados depende de la temperatura medida en el centro de cada colector. Los colectores 1 y 2 pueden alcanzar los dos primeros estados, mientras que los colectores 3 y 4 pueden alcanzar los tres estados.

La relación entre el ángulo de desenfoque y la eficiencia de desenfoque viene dada por la curva que se muestra en la Figura 3.




Figura 3: Curva de eficiencia en función del ángulo de desenfoque.

## 2.3. Control de la Planta

Para controlar el sistema, se emplea un controlador *feed-forward* que permite seguir una referencia  $T_{ref}$  en la temperatura de salida mediante la manipulación del caudal total que alimenta el sector, utilizando un tiempo de muestreo de 30 s. El diseño del controlador se basa en un modelo de parámetros concentrados en estacionario, considerando temperaturas medias entre todos los lazos. Esto da lugar a la expresión de la Ecuación 8:

$$Q = \frac{n_o K_{opt} S I - H_1 S (T_{med} - T_a)}{P_{cp} (T_{ref} - T_{ent})} \quad (8)$$

donde  $Q$  es el caudal total del sector,  $S$  es el área total del campo,  $T_{med}$  es la temperatura media entre la entrada y la salida y  $P_{cp} = \rho_m C_m$ .

El controlador se diseña para mantener el caudal dentro del intervalo operativo de entre  $9 \text{ m}^3/\text{h}$  y  $33 \text{ m}^3/\text{h}$ , y garantizar que la temperatura de salida no supere los  $400^\circ\text{C}$ .

Por otra parte, la apertura de las válvulas de los lazos  $v_i$  se controla cada 5 minutos mediante controladores PI con  $K_p = -0,0005$  y  $K_i = -0,000005$ , donde el error en la temperatura se calcula a partir de la temperatura media de salida del sector para favorecer el balance térmico.

## 2.4. Apertura de Válvulas

La distribución del caudal total  $Q$  entre los lazos  $i$  se realiza mediante coeficientes de reparto  $\gamma_i$  según la Ecuación 9:

$$q_i = \gamma_i Q \quad (9)$$

## 3. Metodología Propuesta

El objetivo del trabajo realizado es estimar la distribución de caudal real de la planta en cada momento. Para ello, se propone una metodología basada en un enfoque híbrido de optimización y aprendizaje automático. En primer lugar, se plantea un problema de optimización para estimar los valores  $\gamma$ . Posteriormente, se genera un conjunto de datos y se entrena una red neuronal para imitar el comportamiento del optimizador con menor coste computacional. Finalmente, se propone el uso de dicha red neuronal para obtener el punto inicial que se envía al optimizador restringiendo el número de iteraciones permitidas.

### 3.1. Problema de Optimización

Cada minuto se resuelve un problema de optimización que estima la distribución de caudal real, minimizando la discrepancia entre las temperaturas medidas en la planta y las temperaturas simuladas mediante un modelo de parámetros distribuidos simplificado, como se muestra en la Ecuación 10.

$$\begin{aligned} \tilde{\gamma}^*(k) = \min_{\gamma} & \lambda_1 \sum_{i=1}^{N_{\text{lazos}}} \sum_{j=1}^4 (T_{ij}(k) - \tilde{T}_{ij}(k|k-15))^2 \\ & + \lambda_2 \left\| 1 - \sum_{i=1}^{N_{\text{lazos}}} \tilde{\gamma}_i(k) \right\| + \lambda_3 \sum_{i=1}^{N_{\text{lazos}}} \Delta \tilde{\gamma}_i(k) \end{aligned} \quad (10)$$

$$s.a \begin{cases} \text{Modelo simplificado} \\ \tilde{\gamma}_i(k) > 0 \quad \forall i = 1, \dots, N_{\text{lazos}} \\ |\Delta \tilde{\gamma}_i(k)| < 0,1 \end{cases}$$

donde  $\Delta \tilde{\gamma}_i(k) = \tilde{\gamma}_i(k) - \tilde{\gamma}_i(k-1)$  y  $\tilde{T}_{ij}(k|k-15)$  es la temperatura del lazo  $i$  y colector  $j$  estimada a partir de los datos obtenidos 15 minutos antes. Para estimar las temperaturas, se simula el sistema utilizando un modelo de parámetros distribuidos simplificados durante 15 minutos, que es aproximadamente el tiempo de residencia del fluido. El modelo empleado es una versión simplificada del descrito en las Ecuaciones 1 y 2, dividido en 32 segmentos e integrado con un paso temporal de 5 segundos.

Se dispone de sensores para  $T_{\text{ent}}$ ,  $T_{\text{sal}}$  y  $T_i$ ,  $i = 1, \dots, 4$  para cada lazo y de  $I$  y  $T_a$  para la planta entera. Además, se suponen conocidas las eficiencias de los colectores. El problema se resuelve tomando como punto inicial la distribución estimada en el instante anterior y se utiliza el algoritmo *active-set* con un máximo de 500 iteraciones y tolerancia de convergencia de 0.005.

### 3.2. Redes Neuronales

El inconveniente de resolver un problema de optimización en cada instante es el elevado coste computacional asociado a la búsqueda en todo el espacio de soluciones. Para reducir este tiempo de cómputo, se propone el uso de redes neuronales

que aprendan a estimar directamente la solución proporcionada por el optimizador.

En particular, se emplean redes neuronales recurrentes tipo Elman, que incorporan realimentación en sus capas. Cuentan con capas de entrada, capas ocultas y capas de salida. Cada capa contiene múltiples neuronas que realizan regresiones lineales seguidas de funciones de activación no lineales (en concreto, tangente hiperbólica), permitiendo capturar relaciones complejas entre variables. Estas redes permiten procesar secuencias temporales, ya que pueden modelar la dinámica del sistema considerando la evolución temporal de las variables. Su estructura puede expresarse mediante un modelo en espacio de estados:

$$\begin{aligned} x(k+1) &= f_x(x(k), u(k), \theta_x) \\ \tilde{y}(k) &= f_y(x(k), u(k), \theta_y) \end{aligned} \quad (11)$$

donde  $x$  es el estado,  $u$  son las entradas, y son las salidas y  $\theta_x$  y  $\theta_y$  son los parámetros entrenables de la red.

El entrenamiento se ha realizado mediante descenso por gradiente con una función de pérdida cuadrática. Se ha utilizado un número máximo de 5000 iteraciones y un mínimo de 15, empleando *mini-batch learning* con *mini-batches* de tamaño 300. Los datos han sido estandarizados y divididos en tres subconjuntos: entrenamiento (70 %), validación (15 %) y prueba (15 %).

La red se aplica para cada lazo independientemente, estimando directamente el caudal para evitar el uso de redes de gran tamaño y facilitar el conocimiento de la dinámica del sistema, aunque se entrena con información de todos los lazos. Las entradas son  $u(k) = [K_{\text{opt}1}(k)\eta_{d1}(k), \dots, K_{\text{opt}4}(k)\eta_{d4}(k), T_{\text{ent}}(k), T_1(k), \dots, T_4(k), I(k)n_o(k), T_a(k)]^T$  y las salidas son  $\hat{y}(k) = \hat{q}(k)$  tomando datos de cada lazo.

### 3.3. Combinación de Métodos

Las redes neuronales entrenadas se utilizan para proporcionar un punto inicial al problema de optimización definido en la Ecuación 10, con el objetivo de restringir el espacio de búsqueda y reducir el tiempo de cómputo. La salida de cada red neuronal se traduce en un reparto de caudal mediante la expresión  $\hat{\gamma}_i = \hat{q}_i / \sum_j \hat{q}_j$ . Posteriormente, se ajustan las restricciones del problema de optimización, dadas por la Ecuación 12, y se fuerza al algoritmo a iterar sólo una vez.

$$\begin{cases} \text{Modelo simplificado} \\ \tilde{\gamma}_i(k) > 0 \quad \forall i = 1, \dots, N_{\text{lazos}} \\ |\tilde{\gamma}_i(k) - \hat{\gamma}_i(k)| < \frac{1}{N_{\text{lazos}}} \end{cases} \quad (12)$$

Para suavizar el efecto de posibles perturbaciones y variaciones en las predicciones de las redes neuronales, se filtran las estimaciones obteniendo  $\hat{\gamma}_i^{\text{filtr}}$ . Se han probado dos tipos de filtros: un filtro paso bajo y un filtro de media móvil. Finalmente, para asegurar que el caudal total se mantenga, se reajustan las estimaciones filtradas utilizando la Ecuación 13. Por comodidad, se omitirá el superíndice *filtr*, aunque el filtrado se aplicará a todas las estimaciones.

$$\tilde{\gamma}_i^{\text{filtr}} = \tilde{\gamma}_i^{\text{filtr}} + \frac{1 - \sum_j \tilde{\gamma}_j^{\text{filtr}}}{N_{\text{lazos}}} \quad (13)$$






Figura 4: Caudales reales  $q_i$  y estimados  $\hat{q}_i$  en una simulación de 4 lazos mediante optimización (izquierda), red neuronal + optimización (centro) y red neuronal (derecha). Desviación típica sombreada.

$N_{\text{lazos}}$	Método	ECM	Err. abs.	Máx. err. abs.	Err. porc. (%)	Máx. err. porc. (%)	Tiempo (s)
4	Base	5.804	1.755	6.600	5.984	16.667	0
4	Optimización	0.179	0.245	2.780	0.895	7.672	53.213
4	Red + Optimización	0.400	0.455	2.558	1.647	7.963	9.396
4	Red	1.697	1.022	4.703	3.752	15.066	$9.859 \cdot 10^{-5}$
20	Base	3.917	1.288	7.301	4.348	26.688	0
20	Optimización	0.322	0.311	7.154	1.030	22.765	3358.975
20	Red + Optimización	0.603	0.555	5.744	1.834	21.321	155.183
20	Red	1.565	0.886	6.196	3.001	20.920	$4.280 \cdot 10^{-4}$
50	Base	7.710	2.170	8.325	7.651	27.446	0
50	Optimización	0.814	0.317	24.824	1.183	83.297	39855.025
50	Red + Optimización	0.965	0.700	12.269	2.721	61.288	857.789
50	Red	2.424	1.085	17.142	4.444	78.087	$4.860 \cdot 10^{-4}$

Tabla 1: Errores de estimación de  $\gamma$  y tiempo medio de cálculo con filtro de media móvil (45 observaciones para optimización y combinación, 60 para red neuronal).

#### 4. Resultados de Simulación

En esta sección se presentan los resultados obtenidos al aplicar tres versiones de la metodología: sólo el optimizador, usando la red neuronal como punto inicial del optimizador, y aplicando sólo la red neuronal. Todas las simulaciones se han realizado en MATLAB R2020b con Intel® Core™ i7-9700F CPU a 3 GHz y 16 GB RAM, utilizando CasADi (Andersson et al., 2019) para diferenciación automática. Los parámetros de penalización se han fijado en  $\lambda_1 = 7,77$ ,  $\lambda_2 = 1,28$  y  $\lambda_3 = 7,09$  mediante prueba y error.

Para entrenar las redes neuronales, se generaron 126 simulaciones aplicando el estimador basado en optimización sobre un sector de 4 lazos (504 secuencias en total). Las perturbaciones empleadas provienen de datos reales que cubren días soleados y nublados, con temperaturas ambiente entre 17 °C y 38 °C y temperaturas de entrada entre 158 °C y 317 °C. Además, se han variado las eficiencias de los colectores para representar suciedad y fallos en los mismos.

La Figura 4 muestra un ejemplo de estimación de caudales con los tres métodos en un sector de cuatro lazos. Se observa que todos los estimadores son capaces de aproximar con bastante precisión los valores reales. Aunque las redes neuronales presentan errores mayores, permiten identificar correctamente qué lazos transportan mayor o menor caudal para detectar posibles fallos. Para suavizar la señal, se aplicó un filtro de media móvil con 45 observaciones en los métodos con optimización y 60 en la red neuronal.

Se evaluaron diferentes tamaños de red, seleccionándose

finalmente una arquitectura con dos estados intermedios. Las funciones  $f_x$  y  $f_y$  incluyen tres capas con 15, 10 y 5 neuronas, respectivamente. El entrenamiento, realizado con tasa de aprendizaje 0.1, finalizó en 14.6 minutos tras 70 iteraciones, alcanzando errores cuadráticos medios (ECMs) de 0.0503, 0.0519 y 0.0575 en los conjuntos de entrenamiento, validación y prueba, respectivamente.

Posteriormente, se probaron diferentes parámetros para los filtros y se seleccionó un conjunto representativo. Se realizaron ocho simulaciones independientes para cada método y tres tamaños de sector: 4, 20 y 50 lazos, ya que el método es escalable al aplicar las redes a cada lazo independientemente. En la Tabla 1 se muestran los errores cuadrático medio, absoluto, máximo absoluto, porcentual y máximo porcentual, junto con el tiempo medio de cómputo. Como referencia, se incluye también el error del reparto uniforme de caudal. En todos los casos, se observa una mejora en los errores medios respecto al método base. Sin embargo, los errores máximos aumentan en sectores de 50 lazos. Por otra parte, el método basado únicamente en redes neuronales muestra una ventaja clara en cuanto a tiempo de cómputo, siendo prácticamente instantáneo. Sin embargo, cuando se utiliza la combinación, aunque los tiempos disminuyen, siguen siendo superiores al tiempo de muestreo en los casos de 20 y 50 lazos.

Los mismos experimentos se han realizado con un filtro paso bajo, con los resultados de la Tabla 2. Aunque los errores generales siguen siendo inferiores a los del reparto uniforme, se observa que el filtro paso bajo tiene peor desempeño que

$N_{\text{lazos}}$	Método	ECM	Err. abs.	Máx. err. abs.	Err. porc. (%)	Máx. err. porc. (%)	Tiempo (s)
4	Base	5.804	1.755	6.600	5.984	16.667	0
4	Optimización	2.642	1.153	5.616	3.937	14.181	53.213
4	Red + Optimización	3.030	1.250	5.787	4.283	14.614	9.396
4	Red	3.618	1.372	5.933	4.683	14.982	$9.859 \cdot 10^{-5}$
20	Base	3.917	1.288	7.301	4.348	26.688	0
20	Optimización	1.913	0.875	6.188	2.951	23.586	3358.975
20	Red + Optimización	2.336	0.978	6.407	3.295	24.420	155.187
20	Red	2.334	0.990	6.424	3.323	24.485	$4.280 \cdot 10^{-4}$
50	Base	7.710	2.170	8.325	7.651	27.446	0
50	Optimización	3.637	1.447	6.389	5.093	24.585	39855.025
50	Red + Optimización	4.265	1.591	7.778	5.673	28.747	857.7885
50	Red	4.954	1.727	10.545	6.230	39.933	$4.8602 \cdot 10^{-4}$

Tabla 2: Errores de estimación de  $\gamma$  y tiempo medio de cálculo utilizando filtro paso bajo (180 minutos para optimización, 240 para combinación y red).

el de media móvil en sectores pequeños (4 y 20 lazos), pero mejora los errores máximos en sectores grandes (50 lazos).

## 5. Conclusiones

En este trabajo se ha propuesto un método para estimar el reparto de caudal en plantas de colectores cilindro-parabólicos, combinando redes neuronales recurrentes con un esquema de optimización basado en la minimización de residuos de temperatura. La metodología se ha evaluado en sectores de 4, 20 y 50 lazos, comparando tres variantes: optimización pura, red neuronal como punto de partida para la optimización, y red neuronal sin optimización posterior. Los resultados obtenidos demuestran la eficacia del método, con errores de estimación significativamente menores en comparación con el supuesto habitual de distribución uniforme del caudal.

En sectores de gran tamaño, sólo las redes neuronales pueden ser aplicadas en menos de un minuto, aunque a costa de un mayor error en la estimación. Como trabajo futuro, se plantea el perfeccionamiento del método para mejorar la precisión manteniendo tiempos de cálculo dentro del intervalo de muestreo, lo que facilitará su aplicación en plantas reales. Además, se explorará la integración del algoritmo dentro de una metodología más general que considere otros tipos de fallos en la planta e incluya sistemas de estimación de la eficiencia de los colectores. De este modo, no será necesario añadir sensores adicionales, ya que se podrán utilizar los comúnmente disponibles en la planta.

## Agradecimientos

Este trabajo ha recibido financiación del Ministerio de Ciencia, Innovación y Universidades (FPU, acuerdo N° FPU20/01958 y el proyecto Control Coalicional para la Optimización de Sistemas Ciberfísicos: Ronda 3, acuerdo N° PID2023-152876OB-I00).

## Referencias

- Andersson, J. A. E., Gillis, J., Horn, G., Rawlings, J. B., Diehl, M., 2019. CasADi – a software framework for nonlinear optimization and optimal control. *Mathematical Programming Computation* 11, 1–36.
- Camacho, E. F., Berenguel, M., Rubio, F. R., 12 1997. *Advanced control of solar plants*. Springer.

- Chanfreut, P., Maestre, J. M., Gallego, A. J., Annaswamy, A. M., Camacho, E. F., 2023. Clustering-based model predictive control of solar parabolic trough plants. *Renewable Energy* 216, 118978. DOI: 10.1016/j.renene.2023.118978
- Frejo, J. R. D., Camacho, E. F., 7 2020. Centralized and distributed model predictive control for the maximization of the thermal power of solar parabolic-trough plants. *Solar Energy* 204, 190–199. DOI: 10.1016/j.solener.2020.04.033
- Gallego, A. J., Macías, M., de Castilla, F., Sánchez, A. J., Camacho, E. F., 2022a. Model predictive control of the Mojave solar trough plants. *Control Engineering Practice* 123, 105140. DOI: 10.1016/j.conengprac.2022.105140
- Gallego, A. J., Sánchez, A. J., Escaño, J. M., Camacho, E. F., 2022b. Non-linear model predictive control for thermal balance in solar trough plants. *European Journal of Control* 67, 100717. DOI: 10.1016/j.ejcon.2022.100717
- Gallego, A. J., Yebra, L. J., Pozo, A. J. S. D., Escaño, J. M., Camacho, E. F., 2023. Nonlinear mpc for thermal balancing of the TCP-100 parabolic trough collectors solar plant. In: *2023 American Control Conference (ACC)*, pp. 1807–1812. DOI: 10.23919/ACC55779.2023.10156440
- Jacob, J., Pandey, A. K., Rahim, N. A., Selvaraj, J., Samykano, M., Saidur, R., Tyagi, V. V., 2021. Concentrated photovoltaic thermal (CPVT) systems: Recent advancements in clean energy applications, thermal management and storage. *Journal of Energy Storage*, 103369. DOI: 10.1016/j.est.2021.103369
- Ma, L., Wang, Z., Lei, D., Xu, L., 2019. Establishment, validation, and application of a comprehensive thermal hydraulic model for a parabolic trough solar field. *Energies* 12, 1–24. DOI: 10.3390/en12163161
- Rakhshani, E., Rouzbehi, K., Sánchez, A. J., Tobar, A. C., Pouresmaeil, E., 2019. Integration of large scale PV-based generation into power systems: A survey. *Energies* 12, 1425. DOI: 10.3390/en12081425
- Sánchez, A. J., Gallego, A. J., Escaño, J. M., Camacho, E. F., 2018. Event-based MPC for defocusing and power production of a parabolic trough plant under power limitation. *Solar Energy* 174, 570–581. DOI: 10.1016/j.solener.2018.09.044
- Sánchez, A. J., Gallego, A. J., Escaño, J. M., Camacho, E. F., 2019. Thermal balance of large scale parabolic trough plants: A case study. *Solar Energy* 190, 69–81. DOI: 10.1016/j.solener.2019.08.001
- Sánchez-Amores, A., Martínez-Piazzuelo, J., Maestre, J. M., Ocampo-Martínez, C., Camacho, E. F., Quijano, N., 2023. Population-dynamics-assisted coalitional model predictive control for parabolic-trough solar plants. *IFAC-PapersOnLine* 56, 7710–7715. DOI: 10.1016/j.ifacol.2023.10.1174
- Teleszewski, T. J., Żukowski, M., Krawczyk, D. A., Rodero, A., 2021. Analysis of the applicability of the parabolic trough solar thermal power plants in the locations with a temperate climate. *Energies* 14. DOI: 10.3390/en14113003
- Şen, Z., 2004. Solar energy in progress and future research trends. *Progress in Energy and Combustion Science* 30, 367–416. DOI: 10.1016/j.pecs.2004.02.004