

Asignación jerárquica de caudal en plantas termosolares de gran escala basada en subasta con inteligencia artificial

Ruiz-Moreno, Sara^{a,*}, Gallego, Antonio J.^a, Camacho, Eduardo F.^b

^aDepto. de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos sin número, 41092, Sevilla, España

^bAICIA - 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. Hierarchical, auction-based flow allocation in large-scale thermal solar plants with artificial intelligence. XX Simposio CEA de Control Inteligente, Huelva (Spain), 2025.

Resumen

Este artículo presenta un método para optimizar el equilibrio térmico en plantas de colectores cilindro-parabólicos. Utiliza un sistema basado en una estrategia de mercado para distribuir el flujo entre los lazos, combinado con una red neuronal para reducir el coste computacional. Este enfoque consiste en subastar el caudal entre los diferentes lazos adaptándose a las variaciones en las pérdidas térmicas y la eficiencia de los colectores. Además, el método sigue una estructura jerárquica, dividiendo los diferentes lazos en grupos y repartiendo el caudal entre los distintos sectores de la planta. El método se ha validado en simulación bajo diferentes condiciones, consiguiendo mejoras en la potencia térmica y los factores de intercepción en comparación con un sistema sin asignación de flujo.

Palabras clave: Energías renovables, Redes neuronales, Inteligencia artificial, Estrategia de mercado

Auction-based hierarchical flow allocation in large-scale solar thermal power plants with artificial intelligence

Abstract

This article presents a method to optimize thermal balance in parabolic trough collector plants. It uses a market-based system to distribute the flow among the loops, combined with a neural network to reduce computational cost. This auction-based approach adapts to variations in thermal losses and collector efficiency. Additionally, the method follows a hierarchical structure, dividing the different loops into groups and distributing the flow among the various sectors of the plant. The method has been validated through simulations under different conditions, showing improvement in thermal power and interception factors compared to a system without flow allocation.

Keywords: Solar energy, Neural networks, Artificial intelligence, Market-based strategy

1. Introducción

El Sol es la fuente primaria de energía, y sustenta casi todas las demás formas de energía, tanto de origen fósil como renovable (Şen, 2004). Su potencial para generar energía y sus características sostenibles desde el punto de vista medioambiental la posicionan como una solución muy atractiva para satisfacer la creciente demanda energética mundial (Rakhshani et al., 2019).

La energía solar se aprovecha comúnmente a través sistemas fotovoltaicos (PV, por sus siglas en inglés, *PhotoVoltaics*)

o energía solar de concentración (CSP, *Concentrating Solar Power*). Entre las diferentes tecnologías CSP, los colectores cilindro-parabólicos (PTC, *Parabolic-Trough Collectors*) destacan por su alta eficiencia, bajo impacto ambiental y facilidad de integración y escalabilidad (Ahmad et al., 2023).

En estas plantas, la reflectividad varía entre los lazos debido a factores como la acumulación de polvo o roturas, lo que provoca desequilibrios en el campo. Para mitigar estos efectos, las plantas comerciales emplean mecanismos como el desenfoque para proteger el sistema de sobrecalentamientos y manipular las

*Autor para correspondencia: srmoreno@us.es




Figura 1: Esquema de una planta PTC. A la derecha: campo solar. A la izquierda: 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 .

válvulas de entrada con el fin de mejorar el equilibrio térmico y reducir pérdidas (Song et al., 2024).

Varios estudios han abordado la distribución de flujo entre lazos para lograr el equilibrio térmico, por ejemplo mediante algoritmos de optimización ajustando las válvulas de entrada a los lazos (Sánchez et al., 2019) y agrupando lazos con eficiencias similares (Gallego et al., 2023). Otras estrategias para reducir el tiempo de cálculo y manipular las válvulas de cada lazo se basan en control predictivo distribuido (Frejo and Camacho, 2020), métodos de *clustering* (Palacio et al., 2023) y en control coalicional (Sánchez-Amores et al., 2023) para desacoplar el control de algunos lazos.

Otra forma de reducir el coste computacional es mediante el uso de Inteligencia Artificial (IA), que puede aplicarse a distintos componentes del sistema de control, desde el modelado (Schimperna et al., 2024) hasta la determinación directa de acciones de control (Hose et al., 2023). En el contexto de las plantas termosolares, existen diversas implementaciones como la combinación de redes inversas con optimización por enjambre de partículas (Cervantes-Bobadilla et al., 2021), algoritmos genéticos (Goel et al., 2022), métodos basados en lógica difusa (Tilahun, 2024) o Redes Neuronales Artificiales (RNAs) entrenadas para aproximar el problema de optimización de un control coalicional (Masero et al., 2022).

El inconveniente de esta última metodología es que depende de información que normalmente no está disponible, como la distribución espacial de la irradiancia, la temperatura del metal y el coeficiente de pérdidas térmicas. Por esta razón, las plantas PTC comerciales suelen contar con uno o un pequeño conjunto de lazos totalmente instrumentalizados que cuentan con más sensores que el resto de la planta. En estos lazos, todas las mediciones de temperatura, eficiencia óptica y pérdidas térmicas son conocidas o estimadas y se extrapolan al resto de la planta.

Para aplicar estas estrategias en plantas comerciales, sería esencial utilizar únicamente datos de sensores disponibles en planta, como se propone en este artículo. La metodología se basa en un sistema de mercado en el cual cada lazo ajusta su caudal en función de un precio de subasta. Además, se emplea una RNA para reducir el coste computacional y permitir su aplicación en sistemas reales de gran escala y con varios sectores. El método, además, fue adaptado a una planta real de 50 MW. Las principales contribuciones son:

- Distribución del flujo entre los lazos utilizando únicamente la información disponible en la planta.
- Mecanismo de subasta con un precio de mercado determinado por la potencia térmica.
- RNA que aprende la distribución del flujo e imita la metodología basada en subastas por grupos de lazos.
- Estructura jerárquica para plantas de gran escala agrupando lazos según su temperatura y diferenciando el control de válvulas y bomba.

El artículo está organizado de la siguiente manera: la Sección 2 describe el sistema utilizado, la Sección 3 presenta la metodología propuesta y el mecanismo de desenfoque, la Sección 4 expone los resultados obtenidos y la Sección 5 proporciona unas conclusiones y sugiere líneas de desarrollo futuro.

2. Descripción del Sistema

Una planta PTC es un sistema compuesto por lazos de espejos parabólicos que concentran la luz solar sobre una línea focal. Un fluido fluye a través de una tubería ubicada a lo largo de esta línea, donde se calienta para generar energía térmica. El fluido se dirige normalmente a un generador de vapor para impulsar una turbina y producir energía eléctrica (Figura 1).

Las simulaciones se realizaron en un modelo de 90 lazos de una planta con características similares a las de Mojave (Gallego et al., 2019). Cada lazo tiene 4 colectores orientados nort-sur, con una sección activa de 593 m que recibe radiación y una longitud total de 620 m. Los lazos están divididos en dos sectores de 40 y 50 lazos. El fluido utilizado es Therminol VP-1, con una temperatura nominal de unos 390–393 °C y densidad y capacidad calorífica específicas dadas por las Ecuaciones (1) y (2), con la notación de la Tabla 2 siendo los subíndices a ambiente, f fluido, m metal ent entrada y sal salida (Gallego et al., 2022).

$$\rho_f = 1061,5 - 0,5787T_f - 9,0242 \cdot 10^{-4}T_f^2 \quad (1)$$

$$C_f = 1552,049 + 2,38501T_f + 0,0010558T_f^2 \quad (2)$$

Tabla 1: Parámetros y variables.

Símbolo	Descripción	Unidades
A	Área transversal	m^2
$\rho(t)$	Densidad	kg/m^3
$C(t)$	Capacidad calorífica específica	$J/(kg \cdot ^\circ C)$
G	Apertura del colector	m
L	Longitud de la tubería	m
$T(t)$	Temperatura	$^\circ C$
$q(t)$	Caudal	m^3/h
$I(t)$	Irradiancia	W/m^2
K_{opt}	Eficiencia óptica	—
$n_o(t)$	Eficiencia geométrica	—
$H_l(t)$	Coef. de pérdidas térmicas	$W/(m^2 \cdot ^\circ C)$
$H_t(t)$	Coef. de transmisión de calor metal-fluido	$W/(m^2 \cdot ^\circ C)$

La eficiencia geométrica se determina mediante la Ecuación (3) (Österholm and Pålsson, 2014), donde ϕ es la latitud, δ_s es la declinación y ω_s es el ángulo horario:

$$n_o = \left((\sin(\phi) \sin(\delta_s) + \cos^2(\delta_s) \sin^2(\omega_s) + \cos(\phi) \cos(\delta_s) \cos(\omega_s))^2 \right)^{\frac{1}{2}} \quad (3)$$

El método se diseñó para un modelo de parámetros concentrados con una estrategia simple de desenfoque para permitir una implementación rápida y entrenar las RNAs. Luego, las redes se aplicaron al modelo de parámetros distribuidos para evaluar la robustez en un sistema más complejo y realista.

2.1. Modelo de Parámetros Concentrados

Las primeras pruebas se realizaron sobre la versión estática del modelo de parámetros concentrados (Ecuación (4)) (Camacho et al., 2012) donde q es la variable manipulable.

$$T_{sal} = \frac{1}{qP_{cp} + 0,4H_l} \left(\alpha_{K_{opt}} n_o K_{opt} IS - 0,8 (0,5T_{ent} - t_a) (2 - \alpha_{H_l}) + qT_{ent} P_{cp} \right) \quad (4)$$

donde $S = 3415,5 m^2$, $C_{lazo} = L_{lazo} \rho_f C_f A_f$, $P_{cp} = \rho_f C_f$ y H_l , está definido por la Ecuación (5).

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

2.2. Modelo de Parámetros Distribuidos

El modelo de parámetros distribuidos describe los balances de energía en el metal y el fluido con variables distribuidas espacialmente (Camacho et al., 2012). El lazo se discretiza longitudinalmente en 151 segmentos, cada uno de 3.213 m, y los cálculos se realizan con un paso de integración de 0.25 s. El modelo viene dado por las Ecuaciones (6) y (7).

$$\rho_m C_m A_m \frac{\partial T_m}{\partial t} = n_o G K_{opt} I + H_l G (T_a - T_m) + L H_t (T_f - T_m) \quad (6)$$

$$\rho_f C_f A_f \frac{\partial T_f}{\partial t} + q \rho_f C_f \frac{\partial T_f}{\partial x} = -L H_t (T_f - T_m) \quad (7)$$

donde $A_m = 2,1677 \cdot 10^{-4} m^2$, $G = 5,75 m$, $L = 0,2136$ y $A_f = 0,0036 m^2$.

Por último, el coeficiente de transferencia de calor convectivo del tubo interior se calcula como (Camacho et al., 2012).

$$H_t = \left(\frac{q}{3600} \right)^{0,8} \left(-7,182817 \cdot 10^{-7} T_f^4 - 1,356114 \cdot 10^3 T_f^3 + 2,679214 \cdot 10^{-1} T_f^2 + 479,1142 T_f + 5,011334 \cdot 10^3 \right) \quad (8)$$

2.3. Potencia Térmica

La potencia térmica neta (Ecuación 9) se calcula sumando las contribuciones de potencia térmica de cada lazo restando un término de penalización proporcional al caudal, escalado por un factor $k = 3000$. Este valor fue determinado heurísticamente para evitar ajustes excesivos en las posiciones de las válvulas.

$$P_{th} = \sum_i q_i \rho_{f,i} C_{f,i} (T_{sal,i} - T_{ent,i}) - k q_i \quad (9)$$

3. Metodología Propuesta

3.1. Mecanismo de Desenfoque y Factor de Intercepción

En ciertas situaciones, las plantas comerciales necesitan desenfoque algunos colectores modificando sus ángulos para reducir la energía captada. Esto es necesario cuando la temperatura de salida supera el límite máximo permitido, y no es posible aumentar el flujo de aceite debido a restricciones en la bomba o el generador de vapor. La eficiencia y el ángulo de desenfoque se relacionan mediante la curva de la Figura 2 y la relación entre la energía captada y la reflejada viene dada por el factor de intercepción (IF, *Intercept Factor*) (Manikandan et al., 2019).




Figura 2: Curva eficiencia-ángulo de desenfoque (Sánchez et al., 2020).

En el modelo estático, el desenfoque consiste en saturar T_{sal} cuando excede los $392^\circ C$. El IF se calcula como un multiplicador de la irradiancia y se reduce iterativamente hasta que la T_{sal} baja de $392^\circ C$. Para el modelo dinámico, se aplica el método propuesto en (Sánchez et al., 2018) para cada colector y el IF se obtiene como la eficiencia de desenfoque. Los límites máximos de temperatura se definen como: $T_1^{max} = 323^\circ C$, $T_2^{max} = 348^\circ C$, $T_3^{max} = 373^\circ C$, y $T_4^{max} = 390^\circ C$.

3.2. Metodología Basada en Subasta

El objetivo es maximizar la potencia térmica de la planta teniendo en cuenta discrepancias desconocidas entre los lazos. Para ello, se propone una metodología para distribuir el flujo de forma jerárquica: primero, por sectores, después, por grupos de lazos dentro de cada sector, y después para cada lazo. Dentro de cada grupo de lazos, las válvulas se ajustan localmente mediante una metodología basada en subastas para optimizar la potencia térmica global. En primer lugar, esta metodología se aplicó en 10 lazos del modelo estático.

La subasta se ejecuta de forma iterativa durante N_{it} iteraciones en las que se realizan tres simulaciones para cada lazo: una con el caudal actual q_i y dos con mayor y menor caudal $q_i^\pm = q_i \pm \Delta q$. El valor mínimo de q_i^- se satura a $10^{-6} \text{ m}^3/\text{s}$.

Después, se predicen las potencias térmicas como $P_{th,i}$ utilizando q_i y $P_{th,i}^\pm$ utilizando $q_i^\pm$, que se emplean para obtener las potencias de demanda y oferta según:

$$\begin{aligned} P_{dema,i} &= P_{th,i}^+ - P_{th,i} \\ P_{ofer,i} &= P_{th,i}^- - P_{th,i} \end{aligned} \quad (10)$$

Estas potencias se usan para calcular los precios de oferta y demanda que se utilizarán en la subasta dados por:

$$\begin{aligned} C_{dema,i} &= \frac{1}{\Delta q} P_{dema,i} \\ C_{ofer,i} &= \frac{1}{\Delta q} P_{ofer,i} \end{aligned} \quad (11)$$

Finalmente, se selecciona un precio de subasta C_{au} que guía la decisión de cada lazo sobre si debe demandar, ofrecer o mantener el caudal. Éste se calcula como el promedio de todas las potencias de oferta y demanda, según la Ecuación (12):

$$C_{au} = \frac{1}{2N_{lazos}\Delta q} \left(\sum_i P_{dema,i} + \sum_i P_{ofer,i} \right) \quad (12)$$

Durante las negociaciones, para aumentar/disminuir el caudal, el precio de demanda/oferta debe ser mayor que el precio de subasta, y la potencia tras el aumento/disminución debe ser mayor que la obtenida al disminuir/aumentar o mantener el caudal. En los demás casos, el caudal se mantiene sin cambios.

La actualización del caudal es proporcional a la diferencia entre las potencias de oferta o demanda y el precio de subasta y, después, todos los caudales se reescalan como $q_i := q_i \frac{Q}{\sum_j q_j}$ para asegurar que el caudal total del grupo sea igual a la suma de caudales individuales.

Aunque el algoritmo calcula los caudales locales, las variables manipuladas son las aperturas de las válvulas v_i , por lo que se debe realizar una transformación en cada instante de muestreo. Dada una apertura de válvula, el caudal se obtiene como $q_i = v_i \sum_j q_j / \sum_j v_j$.

Este algoritmo se aplica de forma escalonada: en primer lugar, se aplica una vez para repartir el caudal entre los sectores. Después, se agrupan los lazos de cada sector en grupos de 10 y se divide el caudal para cada grupo. Finalmente, se aplica el algoritmo para dividir el caudal entre los lazos de cada grupo y obtener las aperturas de las válvulas como en la Figura 3. La selección de grupos se realiza cada 15 minutos y consiste en agrupar los caudales con mayor y menor temperatura para favorecer el intercambio de caudal.




Figura 3: Esquema de la metodología completa

El problema de obtener las aperturas de las válvulas dado el caudal local es un sistema subdeterminado. Se requiere un proceso iterativo que actualice las aperturas y calcule los caudales hasta converger, durante un número de iteraciones $N_{it,v}$. Una de las válvulas se fija al 100 % y las demás se actualizan con un término proporcional a la diferencia entre el caudal deseado q_i y el calculado en cada iteración $\tilde{q}_i$, como se indica en la Ecuación (13).

$$\Delta v = K_v(q_i - \tilde{q}_i) \quad (13)$$

3.3. Redes Neuronales

Para evitar que el algoritmo iterativo se ejecute en cada instante de muestreo, se emplea una RNA que reparte el caudal entre los lazos de cada grupo replicando el método descrito. La red utilizada es un perceptrón multicapa (MLP, *MultiLayer Perceptron*), una RNA compuesta por una capa de entrada, una o más capas ocultas y una capa de salida. Cada capa oculta contiene un número variable de neuronas con funciones de activación no lineales.

En este estudio, se utilizaron funciones de activación sigmoide tangente hiperbólica en las capas ocultas, mientras que en la capa de salida se empleó una función lineal, escalando los datos en el rango $[-1, 1]$. Los pesos de la red se entrenaron mediante el algoritmo de retropropagación de Levenberg-Marquardt (Lillicrap et al., 2020) y la estructura de la red se definió mediante un proceso de prueba y error.

El vector de entrada a la RNA es $X(k) = (T_{ent}(k), T_{sal,1}(k), T_{sal,2}(k), \dots, T_{sal,N_{lazos}}(k), T_a(k), I(k)n_o(k), IF_1(k), IF_2(k), \dots, IF_{N_{lazos}}(k), \bar{T}_{sal}(k), IF(k), v_1(k), v_2(k), \dots, v_{N_{lazos}}(k))$ y el de salida es $Y(k) = (v_1(k+1), v_2(k+1), \dots, v_{N_{lazos}}(k+1))$, donde v_i es la apertura de la válvula del lazo i .

Se realizaron 135 simulaciones con el modelo estático, 27 perfiles reales de irradiancia y diferentes valores de pérdidas térmicas y eficiencias ópticas, obteniendo 26400 datos que fueron aleatorizados y divididos en subconjuntos de entrenamiento (70 %), validación (15 %) y prueba (15 %).

4. Resultados

En esta sección se presentan los resultados obtenidos al aplicar el método mediante simulación con el modelo de parámetros distribuidos de una planta de 90 lazos divididos en dos sectores de 40 y 50 lazos. Los factores de interceptación fueron filtrados mediante un filtro paso bajo con una constante de tiempo de 10 minutos. Todos los cálculos fueron realizados en MATLAB R2024b sobre un procesador Intel® Core™ i7-9700F a 3 GHz con 16 GB de memoria RAM.

Los controladores de distribución de flujo se ejecutan con un tiempo de muestreo de 10 minutos y el control externo de caudal se aplica cada 30 segundos. Para la capa de distribución por lazos, en lugar de establecer un criterio de convergencia, se establecen 10 iteraciones de control y 150 de apertura de válvulas, mientras que, por simplicidad, los controladores de las otras dos capas usan una iteración. El resto de parámetros son $\Delta q = 1 \text{ m}^3/\text{s}$, $K = 10^{-5}$, $K_v = 0,25$.

Los hiperparámetros seleccionados para entrenar las redes neuronales son los siguientes: factor de amortiguamiento inicial $\mu_0 = 10^{-3}$ con ratios de incremento y decremento de 10 y 10^{-1} y valor máximo de 10^{10} , un máximo de $4 \cdot 10^3$ épocas, gradiente mínimo de 10^{-7} y máximo de 6 validaciones. Se entrenaron diferentes RNAs y se seleccionó una con tres capas ocultas de 50, 25 y 10 neuronas con los resultados de la Tabla 2. El tiempo total de entrenamiento fue de 14,5612 horas.

Tabla 2: Error Cuadrático Medio (ECM) y coeficiente de correlación R de la red seleccionada en los subconjuntos

	Entrenamiento	Validación	Prueba
ECM	$7,59 \cdot 10^{-6}$	$9,57 \cdot 10^{-6}$	$1,75 \cdot 10^{-5}$
R	99,96 %	99,95 %	99,94 %

Además, se utilizaron tres perfiles extra para comparar los métodos: un día nublado, uno soleado y uno parcialmente nublado. La Tabla 3 compara los IF, potencias térmicas y la correlación de las T_{sal} sin asignación (distribuyendo el caudal de manera equitativa entre todos los lazos) y con el método propuesto bajo las mismas condiciones. Además, se muestra una media ponderada basada en el porcentaje promedio de días soleados (57.5 %), parcialmente nublados (42.28 %) y nublados (0.22 %) en Gila Bend. En la Tabla 4 se muestran los resultados obtenidos al aplicar la RNA en un campo compuesto por diez lazos. Ambas tablas demuestran una mejora de las potencias y los factores de intercepción, indicando un mejor reparto de caudal, una mayor producción, una menor necesidad de desenfoco y una mayor homogeneización de las temperaturas. El tiempo medio de cálculo con el método base en 10 lazos fue 85.814 s, mientras que con la RNA fue $1.352 \cdot 10^{-4}$ s.

Tabla 3: IF (MW) y potencias térmicas y correlación de T_{sal} (%) obtenidos en la planta con y sin asignación de caudal.

Método	Media			Media Ponderada		
	P	IF	ρT	P	IF	ρT
Sin	102.21	94.22	94.70	106.04	92.26	91.84
Con	102.55	94.40	94.80	106.54	92.81	92.32

Tabla 4: IF (MW) y potencias térmicas y correlación de T_{sal} (%) obtenidos en diez lazos con y sin asignación de caudal.

Método	Media			Media Ponderada		
	P	IF	ρT	P	IF	ρT
Sin	10.78	94.52	91.01	11.51	93.12	91.02
Con	10.85	94.85	94.14	11.60	93.67	94.67

Las Figuras 4 a 7 muestran las temperaturas, caudales, factores de intercepción y potencias térmicas obtenidas al simular el sistema completo. Estas simulaciones demuestran la adaptabilidad de los controladores neuronales a un sistema más complejo compuesto por una gran cantidad de lazos. Se observa el

paso de un único caudal para todos los lazos a una gran variedad de caudales, que da lugar a una mayor condensación de las temperaturas (más similares entre sí) y mayor potencia producida.




Figura 4: Temperaturas de salida con y sin asignación de caudales.




Figura 5: Caudales con y sin asignación de caudales.




Figura 6: Factores de intercepción con y sin asignación de caudales.




Figura 7: Potencias térmicas con y sin asignación de caudales.

Se ha probado un controlador basado en los algoritmos anteriores y adaptado al sistema de control distribuido de plantas reales. Concretamente, se ha aplicado en 13 de las plantas PTC de 50 MW de Atlantica Sustainable Infrastructure Ltd (Ruiz-Moreno et al., 2025).

5. Conclusiones

Este artículo presenta una metodología para optimizar el reparto de caudal en plantas solares PTC mediante un sistema basado en el mercado de subastas. Este mecanismo se ha combinado con una RNA para reducir el coste computacional y la cantidad de datos necesarios, lo que permite aplicarlo en una planta real, donde no es posible resolver problemas de optimización o algoritmos complejos. La metodología fue probada bajo diversas condiciones, mostrando resultados prometedores.

El método propuesto basado en subastas selecciona eficazmente el reparto de caudal y la apertura de válvula de los diferentes lazos, incluso cuando estos presentan pérdidas térmicas y eficiencias variables. La metodología fue evaluada con días soleados, parcialmente nublados y nublados y superó consistentemente el caso en el que el caudal se repartía uniformemente en términos de potencia y factores de intercepción. Además, la adaptación del modelo de parámetros concentrados al de parámetros distribuidos resalta la generalizabilidad del método.

La reducción de la información necesaria para la asignación de flujo lograda mediante la RNA hace que este enfoque sea escalable e implementable en escenarios reales, lo que potencialmente conduce a mejoras significativas en la eficiencia operativa de plantas solares térmicas a gran escala.

Trabajo futuro se enfocará en desarrollar técnicas para agrupar los lazos y aplicar las redes neuronales a la planta completa para mejorar el rendimiento y disminuir en mayor medida la necesidad de realizar operaciones complejas en 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) y de la Unión Europea (Proof of Concept Lump Sum Grant, acuerdo No ERC-2022-PoC1).

Referencias

- Ahmad, A., Prakash, O., Kuasher, R., Kumar, G., Pandey, S., Hasnain, S. M. M., 2023. Parabolic trough solar collectors: A sustainable and efficient energy source. *Materials Science for Energy Technologies*. DOI: 10.1016/j.mset.2023.08.002
- Camacho, E. F., Berenguel, M., Rubio, F. R., Martínez, D., 1 2012. *Control of solar energy systems*. Springer-Verlag.
- Cervantes-Bobadilla, M., Hernández-Pérez, J. A., Juárez-Romero, D., Bassam, A., García-Morales, J., Huicochea, A., Jaramillo, O. A., 2021. Control scheme formulation for a parabolic trough collector using inverse artificial neural networks and particle swarm optimization. *JBSMSE* 43, 1–14. DOI: 10.1007/s40430-021-02862-4
- 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., Camacho, E. F., 2019. Mathematical modeling of the {Mojave} solar plants. *Energies* 12, 4197. DOI: doi.org/10.3390/en12214197
- Gallego, A. J., Macías, M., de Castilla, F., Sánchez, A. J., Camacho, E. F., 2022. Model predictive control of the {Mojave} solar trough plants. *Control Engineering Practice* 123, 105140. DOI: 10.1016/j.conengprac.2022.105140
- 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. pp. 1807–1812. DOI: 10.23919/ACC55779.2023.10156440
- Goel, A., Verma, O. P., Manik, G., 2022. Flow rate optimization of a parabolic trough solar collector using multi-objective genetic algorithm.
- Hose, H., Köhler, J., Zeilinger, M. N., Trimpe, S., 2023. Approximate nonlinear model predictive control with safety-augmented neural networks. *arXiv preprint*. DOI: 10.48550/arXiv.2304.09575
- Lillicrap, T. P., Santoro, A., Marris, L., Akerman, C. J., Hinton, G., 2020. Back-propagation and the brain. *Nature Reviews Neuroscience* 21, 335–346. DOI: 10.1038/s41583-020-0277-3
- Manikandan, G. K., Iniyar, S., Goic, R., 2019. Enhancing the optical and thermal efficiency of a parabolic trough collector – a review. *Applied Energy* 235, 1524–1540. DOI: 10.1016/j.apenergy.2018.11.048
- Masero, E., Maestre, J. M., Camacho, E. F., 2022. Market-based clustering of model predictive controllers for maximizing collected energy by parabolic-trough solar collector fields. *Applied Energy* 306, 117936. DOI: 10.1016/j.apenergy.2021.117936
- Palacio, P. C., Maestre, J. M., Gallego, A. J., Annaswamy, A., Camacho, E. F., 2023. Clustering-based model predictive control of solar parabolic trough plants. *Renewable Energy*. DOI: 10.1016/j.renene.2023.118978
- 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
- Ruiz-Moreno, S., Gallego, A. J., Macías, M., Camacho, E. F., 2025. Market-oriented flow allocation for thermal solar plants: An auction-based methodology with artificial intelligence. *arXiv preprint arXiv:2504.01652*.
- Schimperna, I., Galuppi, G., Magni, L., 2024. Recurrent neural network based mpc for systems with input and incremental input constraints. *IEEE Control Systems Letters*. DOI: 10.1109/LCSYS.2024.3404332
- Song, Y., Wang, J., Zhang, J., Li, Y., 2024. Temperature homogenization control of parabolic trough solar collector field based on hydraulic calculation and extended kalman filter. *Renewable Energy*, 120346. DOI: 10.1016/j.renene.2024.120346
- 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, A. J., Gallego, A. J., Escaño, J. M., Camacho, E. F., 2020. Parabolic trough collector defocusing analysis: Two control stages vs four control stages. *Solar Energy* 209, 30–41. DOI: 10.1016/j.solener.2020.09.001
- Sánchez-Amores, A., Martínez-Piauelo, J., Maestre, J. M., Ocampo-Martínez, C., Camacho, E. F., Quijano, N., 2023. Population-dynamics-assisted coalition model predictive control for parabolic-trough solar plants. *IFAC* 56, 7710–7715. DOI: 10.1016/j.ifacol.2023.10.1174
- Tilahun, F. B., 2024. Fuzzy-based predictive deep reinforcement learning for robust and constrained optimal control of industrial solar thermal plants. *Applied Soft Computing* 159, 111432. DOI: 10.1016/j.asoc.2024.111432
- Österholm, R., Pålsson, J., 2014. Dynamic modelling of a parabolic trough solar power plant. pp. 409–418. DOI: 10.3384/ecp140961057
- Şen, Z., 2004. Solar energy in progress and future research trends. *Progress in Energy and Combustion Science* 30, 367–416. DOI: j.pecs.2004.02.004