

Jornadas de Automática

Modelado dinámico de enfriadoras por absorción mediante LSTM y CNN-LSTM

Zuliet Medina Rodríguez^{a,*}, Juana López Redondo^a, María del Mar Castilla Nieto^b, José Domingo Álvarez Hervás^b

^aDepartamento de Informática, Grupo TIC-146 - Supercomputación – algoritmos. Ctra. Sacramento s/n, La Cañada de San Urbano, Universidad de Almería, 04120, Almería, España.

^bDepartamento de Informática, Grupo TEP197 - Automática, Robótica y Mecatrónica, CIESOL—ceiA3. Ctra. Sacramento s/n, La Cañada de San Urbano, Universidad de Almería, 04120, Almería, España.

To cite this article: Medina, Z, López, J, Castilla, MM, Álvarez, JD. 2026. Dynamic modeling of absorption chillers using LSTM and CNN-LSTM. *Jornadas de Automática*, 47. <https://doi.org/10.17979/ja-cea.2026.47.13696>

Resumen

La siguiente investigación presenta el desarrollo de modelos de “caja negra” para la caracterización dinámica de una enfriadora por absorción Yazaki WFC SC20. A diferencia de estudios previos basados en software propietario, esta investigación utiliza tecnologías de software libre como Python y PyTorch para mejorar la replicabilidad y escalabilidad del modelado. Se diseñaron y compararon dos arquitecturas de redes neuronales profundas: una red de memoria a corto y largo plazo (LSTM) y un modelo híbrido convolucional-recurrente (CNN-LSTM). Para optimizar el rendimiento, se empleó el *framework* Optuna, permitiendo una búsqueda inteligente de hiperparámetros y la selección de las variables de entrada. Los modelos fueron entrenados y validados con datos reales de la instalación solar térmica del centro CIESOL correspondientes a los años 2014 y 2015. Los resultados demuestran que la arquitectura que mejor describe el comportamiento de la máquina es la CNN-LSTM.

Palabras clave: Modelo LSTM, Modelo Híbrido CNN-LSTM, Enfriadora por absorción, Software Libre

Dynamic modeling of absorption chillers using LSTM and CNN-LSTM.

Abstract

The following research presents the development of “black box” models for the dynamic characterization of a Yazaki WFC SC20 absorption chiller. Unlike previous studies based on proprietary software, this research uses open-source software technologies such as Python and PyTorch to improve the reproducibility and scalability of the modeling. Two deep neural network architectures were designed and compared: a Long Short-Term Memory (LSTM) network and a hybrid convolutional-recurrent model (CNN-LSTM). To optimize performance, the Optuna framework was used, enabling intelligent hyperparameter search and input variable selection. The models were trained and validated with real data from the CIESOL center’s solar thermal installation from 2014 and 2015. The results demonstrate that the architecture that best describes the absorption chiller is the CNN-LSTM.

Keywords: LSTM Model, CNN-LSTM Hybrid Model, Absorption Machine, Free Software

1. Introducción

Alrededor de un tercio de la energía total consumida en el mundo se atribuye a los edificios residenciales y al sector terciario (IEA (2022)). Aproximadamente el 38 % del consumo de estos se debe al sistema de calefacción, ventilación y

aire acondicionado. Para mitigar este impacto y avanzar hacia los Edificios de Emisiones Casi Nulas (ZEB del inglés *Zero Energy Building*), resulta fundamental sustituir los sistemas convencionales, basados en ciclos de compresión de vapor de alto consumo eléctrico, por alternativas que puedan ser alimentadas con fuentes limpias y sostenibles.

*Autor para correspondencia: zmr262@inlumine.ual.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

En este contexto, y como parte de las estrategias trazadas para el cuidado del medio ambiente, ha existido un aumento del uso de las energías renovables en diferentes sectores. Este impulso se encuentra respaldado a nivel nacional por objetivos como los del Plan Nacional Integrado de Energía y Clima (PNIEC) 2023-2030 que buscan alcanzar una cuota del 48 % de energía renovables en el consumo final (Gobierno de España (2023)).

Como parte de este escenario de transición energética, las enfriadoras por absorción surgen como una alternativa prometedora. Estos pueden ser alimentados por calor procedente de fuentes de energía renovables, como energía solar, biomasa u otros. Además, cuentan con fuentes convencionales para apoyar el funcionamiento cuando la energía renovable no está disponible.

Sin embargo, el control de estos equipos es complejo debido a la necesidad de conmutar entre diferentes fuentes de energía según las condiciones climáticas dinámicas. La literatura científica indica que la mayoría de los modelos existentes se basan en condiciones estacionarias, ignorando los fenómenos dinámicos inherentes a las renovables. Para solucionar esta problemática, debido a su alta capacidad para modelar la naturaleza no lineal de estos sistemas, las herramientas basadas en el aprendizaje automático y el aprendizaje profundo han ganado un gran protagonismo en los últimos años.

Un ejemplo de lo anterior es (Hosseini (2022)), donde los autores comparan técnicas de Redes Neuronales Artificiales (ANN), Máquinas de Vectores de Soporte (SVM) y programación genética para predecir el rendimiento de enfriadoras de absorción de simple efecto. Este estudio demostró que las redes neuronales ofrecen la mayor precisión en la estimación del coeficiente de rendimiento (*COP*) y la carga térmica. Lo que concluye que los modelos de aprendizaje automático (*Machine Learning*) pueden reemplazar de forma efectiva a las simulaciones termodinámicas complejas, garantizando una alta exactitud con un bajo coste de cómputo.

Asimismo, la transición hacia modelos predictivos más complejos ha consolidado el uso de arquitecturas de aprendizaje profundo (*Deep Learning*). En la investigación (Panahizadeh et al. (2021)), se emplearon redes neuronales profundas para modelar una enfriadora por absorción alimentada por calor residual. Dicho modelo logró predecir la capacidad frigorífica y la eficiencia energética con tasas de error extremadamente bajas, destacando la viabilidad de integrar energías renovables y *Deep Learning* en aplicaciones sostenibles de climatización y aire acondicionado bajo condiciones operacionales dinámicas.

Tomando como referencia este ecosistema de soluciones basadas en datos, a nivel local se han desarrollado esfuerzos previos para caracterizar sistemas específicos. En particular, el trabajo de Ferre et al. (2023) abordó la modelación mediante “caja negra” de la enfriadora por absorción Yazaki WFC SC20 instalada en el centro CIESOL, ubicado en el campus de la Universidad de Almería (UAL). Para tal fin, los autores emplearon una arquitectura de red neuronal No Lineal Autorregresiva con Entradas Exógenas (NARX, del inglés *Nonlinear Autoregressive with Exogenous input*) implementada en MATLAB, logrando caracterizar fielmente la respuesta dinámica de dicho sistema.

La presente investigación propone ampliar dicho trabajo

utilizando tecnologías de software libre como Python y Jupyter para mejorar la escalabilidad y replicabilidad del modelo desarrollado. Además de realizar un análisis de sensibilidad y una comparativa con otras arquitecturas buscando optimizar el modelo para su futura integración en sistemas de control avanzado o dentro de una arquitectura software para que sirva como gemelo digital del sistema.

Para ello el siguiente documento ha sido estructurado en las siguientes secciones. En la sección 2 se describe la enfriadora por absorción del centro CIESOL objeto de este trabajo. La metodología desarrollada para calcular los modelos del sistema se enumera en la sección 3, mientras que, los resultados obtenidos a partir de dichos modelos se comentan en la sección 4. Finalmente, la sección 5 enumera las principales conclusiones de este trabajo y futuras líneas de investigación derivadas del mismo.

2. Descripción del sistema real

El sistema objeto de estudio se centra en una enfriadora por absorción de la marca YAZAKI WFC SC20 (70.3 kW) alimentada por una instalación solar térmica de 160 m². El equipo está alimentada por un campo de colectores solares planos compuesto por 80 colectores con una inclinación de 30° y orientación sur. Para garantizar la estabilidad operativa el edificio durante los transitorios de nubes, dispone de un sistema de acumulación de 10000 litros (dos depósitos de 5000 l) que actúa como almacenamiento térmico frente a las variaciones de radiación, apoyado adicionalmente por una caldera de gas de ciclo combinado, ver figura 1.




Figura 1: Esquema general de la instalación de frío solar.

Como se muestra en la figura 2, la enfriadora dispone de un conjunto de señales para monitorizar las entradas y salidas del sistema. Entre las variables que se registran se puede destacar como señales de entrada al sistema: i) el flujo al generador (señal Q5 del sistema de monitorización), ii) la temperatura del agua procedente del campo solar o de la caldera de apoyo (señal s11), iii) la temperatura del agua de retorno del edificio (señal s18) y, iv) la temperatura del agua de refrigeración proveniente de la torre (señal s20). En el otro lado, como salidas del sistema se tiene: i) la temperatura de retorno hacia el campo solar (señal s12), ii) la temperatura del agua fría enviada a las estancias del edificio (señal s19) y, iii) la temperatura del agua hacia la enfriadora por absorción (señal s21).




Figura 2: Esquema de funcionamiento de la enfriadora por absorción Yazaki WFC SC20.

3. Metodología

Para el desarrollo del modelado matemático que describe el comportamiento del sistema se propone el uso de tecnologías de software libre como son el lenguaje de programación Python y el entorno interactivo Jupyter Notebook. Esta elección tecnológica permite garantizar la transparencia y reproducibilidad de la investigación. Además, asegura la escalabilidad del modelo para su integración en sistemas de control avanzado sin restricciones de licencias propietarias. Asimismo, facilita su incorporación en la plataforma de supervisión del edificio para operar como un gemelo digital de la enfriadora.

3.1. Selección de variables de entrada y optimización

Para lograr el menor error en la salida de los modelos se ha utilizado el framework Optuna, que es una biblioteca de Python, de código abierto, diseñada para la optimización automática de hiperparámetros en modelos de *Machine Learning* y *Deep Learning*. Su uso permite una búsqueda inteligente de los parámetros mediante el algoritmo *Tree-structured Parzen Estimator* (TPE), optimizando la función objetivo basada en el error cuadrático medio (MSE del inglés *Mean Squared Error*) (Akiba et al. (2019)).

Entre los hiperparámetros que se desean analizar se encuentra el determinar qué combinación de entradas al modelo (señales Q5, s11, s18 y s20) aporta mayor capacidad predictiva. Lo que elimina variables redundantes o que introduzcan ruido al sistema. Además de establecer los hiperparámetros críticos necesarios para el entrenamiento del modelo como son el número de capas ocultas y tamaño de las mismas, la longitud de la secuencia y el porcentaje de neuronas a apagar durante el entrenamiento, entre otras características específicas de cada modelo objeto de estudio.

3.2. Selección de arquitecturas

Para capturar la dinámica térmica y temporal de la enfriadora por absorción, se han diseñado y comparado dos arquitecturas de redes neuronales profundas. Ambas arquitecturas han sido implementadas en PyTorch y están diseñadas para procesar secuencias temporales multivariantes provenientes de los sensores del sistema. A continuación se expone una breve descripción de cada uno de los modelos de caja negra probados.

3.2.1. Modelos de memoria larga a corto plazo

Los modelos de memoria larga a corto plazo (LSTM del inglés *long short-term memory*) se encuentran diseñados para procesar secuencias de vectores a lo largo del tiempo. Su arquitectura permite retener la información relevante en una celda de memoria durante periodos prolongados. La persistencia de datos se gestiona a través de un estado de celda. Este componente funciona como un canal de transporte de información que atraviesa la secuencia de forma lineal, permitiendo que el conocimiento crítico persista con mínimas alteraciones. Además, cuenta con estructuras neuronales basadas en funciones de activación no lineales que regulan dinámicamente el flujo de datos llamados puertas (*gates*).

3.2.2. Modelo híbrido convolucional-recurrente (CNN-LSTM)

Esta arquitectura combina redes neuronales convolucionales (CNN del inglés *ConvNet*) con redes LSTM lo que permite mejorar la tasa de extracción de características no lineales y capturar dependencias (Rodríguez-Ramos et al. (2026)). Las capas convolucionales actúan como extractores automáticos de características de alto nivel. Al aplicar filtros espaciales permite identificar patrones morfológicos y estructuras locales dentro de los datos de entrada. Por otra parte, las capas recurrentes se encargan de la interpretación de la dinámica secuencial.

4. Resultados

En esta sección se presentan los resultados obtenidos tras los procesos de optimización, entrenamiento y pruebas de las arquitecturas propuestas. Para llevar a cabo el desarrollo y ajuste de los modelos, se utilizaron los datos reales de la instalación correspondientes al mes de junio de los años 2014 y 2015, periodos en los que la máquina se encuentra en funcionamiento efectivo.

El tratamiento de los datos brutos se estructuró en tres fases secuenciales para asegurar la estabilidad del entrenamiento. En primer lugar, se aplicó un filtro digital de paso bajo para reducir el ruido de alta frecuencia inherente a la monitorización de variables térmicas. En segundo lugar, se llevó a cabo el relleno de los registros faltantes (*gaps*) en las series temporales para dar continuidad a las secuencias dinámicas. Por último, para optimizar la convergencia de las arquitecturas recurrentes y convolucionales, se realizó una normalización Min-Max. Mediante este método, tanto el conjunto de características indexadas de entrada como las variables objetivo de salida se escalan de manera independiente hacia un rango acotado de $[-1; 1]$. Los valores límite reales utilizados para dicha transformación correspondieron a los rangos experimentales del sistema; para las entradas: Q5 $[-0,01; 12,38]$ m³/h, s11 $[28,71; 82,10]$ °C, s18 $[9,00; 32,60]$ °C y s20 $[24,70; 33,80]$ °C; y para las salidas: s12 $[30,80; 85,10]$ °C, s19 $[7,50; 32,80]$ °C y s21 $[24,80; 34,20]$ °C.

Una vez acondicionado el conjunto de datos mediante este flujo de preprocesamiento, se procedió a su partición estructural. Con el objetivo de garantizar una correcta evaluación del aprendizaje y evitar el sesgo de anticipación, el conjunto de datos se dividió en tres fases independientes. Los datos de junio de 2014 se destinaron cronológicamente a las etapas de

ajuste inicial: un 75 % de este periodo se utilizó para el entrenamiento y optimización de hiperparámetros, mientras que el 25 % restante se reservó para la validación interna del modelo (figura 3). Por otra parte, los datos del mes de junio de 2015 se aislaron por completo para actuar como un conjunto de pruebas (*testeo*) dinámicas. Lo que permite verificar la capacidad de generalización y robustez de las redes ante escenarios temporales totalmente nuevos.




Figura 3: Distribución de los datos de entrenamiento y validación correspondientes a junio de 2014

4.1. Optimización mediante Optuna

Como se mencionó con anterioridad para la optimización de los modelos se utilizó el framework Optuna. A lo largo del estudio se ejecutaron más de dos mil iteraciones de la función objetivo, para cada una de las arquitecturas, utilizando el algoritmo TPE, que es un método avanzado de Optimización Bayesiana, para minimizar el MSE. El proceso de búsqueda se gestionó a través de archivos de persistencia (.pkl y .json), permitiendo identificar los hiperparámetros que reducen el error a la hora de caracterizar la dinámica de la máquina Yazaki WFC SC20. Además se implementó en el código el uso de una semilla fija que permite garantizar la reproducibilidad de los resultados.

4.1.1. Modelo LSTM

En el modelo puramente recurrente, la optimización se centró en la profundidad y capacidad de memoria de la red. El estudio evaluó la relevancia de Q_5 , s_{11} , s_{18} y s_{20} como variables exógenas, integradas con la realimentación de las salidas previas (s_{12} , s_{19} y s_{21}). El espacio de hiperparámetros abarcó de 1 a 4 capas ocultas con 32 a 256 neuronas cada una. Asimismo, la ventana de observación (n_{steps}) se ajustó entre 10 y 60 pasos temporales para capturar la inercia térmica del sistema. Por último, la tasa de abandono (*dropout*) se optimizó entre 0.0 y 0.4 como mecanismo de regularización para asegurar la generalización ante datos no vistos.

Los resultados de la optimización identificaron que para el modelo LSTM la configuración más robusta para capturar la inercia térmica del sistema consiste en una arquitectura de una sola capa con 128 neuronas. Esta configuración emplea una función de activación LeakyReLU en su etapa de salida

y un n_{steps} de 5 pasos temporales. Para favorecer la generalización del modelo, se estableció un dropout de 0.10. Asimismo, los análisis de sensibilidad determinaron que la variable s_{18} (temperatura de retorno del edificio) posee la mayor capacidad predictiva para definir el comportamiento de las variables de salida del sistema. Por consiguiente, para este modelo en particular, el espacio de entrada exógena se redujo única y exclusivamente a dicha variable (s_{18}), prescindiendo deliberadamente de las demás variables físicas disponibles en la enfriadora con el fin de simplificar la estructura y mitigar el riesgo de sobreajuste.

4.1.2. Modelo CNN-LSTM

Para la arquitectura híbrida, además de los parámetros anteriores, se añadieron dimensiones de búsqueda específicas para el procesamiento espacial y la extracción de características. Por un lado, respecto a los parámetros convolucionales, se optimizó el número de filtros (32, 64 o 128) junto con el tamaño del kernel (3 o 5), permitiendo que la red identificara patrones morfológicos locales en las señales. Por otro lado, en cuanto a la arquitectura de la red y a diferencia del modelo LSTM simple, Optuna ajustó el equilibrio entre la extracción de características de alto nivel en las capas *Conv1d* y la interpretación de la dinámica secuencial en la etapa recurrente.

Luego del proceso de optimización la configuración maestra para el modelo CNN-LSTM integró una etapa convolucional con un tamaño de kernel de 3 y 128 filtros. Además, cuenta con una capa con 96 neuronas, 35 pasos temporales y un *dropout* de 8.54×10^{-5} . En lo que respecta al espacio de características de entrada, y a pesar de que la instalación experimental monitoriza un espectro más amplio de señales, el vector de variables exógenas de este modelo se restringió de forma exclusiva al caudal al generador (Q_5) y a la temperatura del agua de retorno del edificio (s_{18}), descartando por completo el resto de las variables de la máquina al no aportar una mejora significativa en el ajuste predictivo.

4.2. Análisis de modelos con datos de entrenamiento (junio 2014)

Para el entrenamiento y caracterización inicial de la máquina Yazaki WFC SC20, se utilizaron los datos correspondientes a junio del año 2014. El conjunto de datos se dividió cronológicamente, destinando un 75 % para el entrenamiento y el 25 % restante para la validación, como se mencionó con anterioridad. Con el fin de garantizar la integridad causal y evitar el sesgo de anticipación (*data leakage*), se implementó un preprocesamiento mediante ventanas deslizantes no centradas y una división temporal, asegurando que el modelo prediga estados futuros basándose exclusivamente en información histórica.

Para evaluar cuantitativamente el desempeño de las arquitecturas propuestas, se emplearon diversos índices de rendimiento implementados mediante la librería Scikit-Learn: el Error Cuadrático Medio (*MSE*), el Error Absoluto Medio (*MAE*), el Coeficiente de Correlación (*N*), el Error Relativo Medio (*MRE*) y el Error Absoluto Medio Normalizado (*NMAE*). Cabe destacar que, a pesar de que las redes neuronales se entrenaron utilizando los datos acotados en el rango

$[-1, 1]$, todas las métricas reportadas se calcularon tras revertir dicha transformación mediante un proceso de desnormalización (*inverse transform*). De este modo, los valores presentados reflejan el error físico real sobre el comportamiento dinámico de la enfriadora.

4.2.1. Desempeño del modelo LSTM

La arquitectura LSTM fue configurada con los resultados obtenidos en el apartado anterior y luego de un proceso de entrenamiento más profundo que el realizado con Optuna se obtuvieron los resultados que se pueden apreciar en la figura 4




Figura 4: Resultados del modelo LSTM con los datos de junio del año 2014

Como se observa en la tabla 1, el modelo presenta un desempeño sólido con N cercanos a la unidad para los tres sensores. No obstante, el MSE en el sensor $s12$ (la temperatura de retorno hacia el campo solar) es superior al de los demás, lo que sugiere una mayor dificultad de la arquitectura LSTM pura para capturar la dinámica específica de esta variable de salida.

Tabla 1: Resultados del modelo LSTM con los datos de junio del año 2014

Parámetro	s12	s19	s21
MSE	$0.0375 \text{ }^{\circ}\text{C}^2$	$0.0076 \text{ }^{\circ}\text{C}^2$	$0.0018 \text{ }^{\circ}\text{C}^2$
N	0.9993	0.9999	0.9994
MAE	$0.1361 \text{ }^{\circ}\text{C}$	$0.0671 \text{ }^{\circ}\text{C}$	$0.0273 \text{ }^{\circ}\text{C}$
MRE	0.0021	0.0050	0.0010
$NMAE$	0.0073	0.0038	0.0042

4.2.2. Desempeño del modelo híbrido CNN-LSTM

Al igual que en el apartado anterior, la arquitectura híbrida CNN-LSTM se configuró con los parámetros obtenidos del proceso de optimización y se realizó un entrenamiento más profundo. Los resultados de este se pueden observar en la figura 5 y los valores estadísticos que determinan su rendimiento en la tabla 2.

Como se aprecia, los resultados del modelo híbrido CNN-LSTM muestran una mejora respecto a la arquitectura anterior. Específicamente, el MSE para el sensor $s12$ se redujo en aproximadamente un 63 %, pasando de 0.0375 a 0.0138. Esta disminución del error, sumada a una correlación casi perfecta en el sensor $s19$ ($N=1.0000$), demuestra que la combinación de capas convolucionales para la extracción de características y capas recurrentes para la dependencia temporal es superior para modelar la máquina de absorción.




Figura 5: Resultados del modelo CNN-LSTM con los datos de junio del año 2014

Tabla 2: Resultados del modelo CNN-LSTM con los datos de junio del año 2014

Parámetro	s12	s19	s21
MSE	$0.0138 \text{ }^{\circ}\text{C}^2$	$0.0030 \text{ }^{\circ}\text{C}^2$	$0.0007 \text{ }^{\circ}\text{C}^2$
N	0.9997	1.0000	0.9998
MAE	$0.0805 \text{ }^{\circ}\text{C}$	$0.0364 \text{ }^{\circ}\text{C}$	$0.0179 \text{ }^{\circ}\text{C}$
MRE	0.0012	0.0029	0.0006
$NMAE$	0.0043	0.0021	0.0027

4.3. Pruebas con datos dinámicos (junio 2015)

Con el fin de verificar la robustez y escalabilidad de los modelos obtenidos, se realizaron pruebas de validación utilizando datos correspondientes a junio del año 2015, los cuales representan escenarios temporales no vistos durante la fase de entrenamiento. Como se puede apreciar en la figura 6 y la tabla 3, se confirma que ambas arquitecturas mantienen una alta capacidad de generalización ante condiciones dinámicas reales. No obstante, la superioridad del modelo híbrido CNN-LSTM es notable, logrando reducir el MSE en el sensor $s19$ en casi un orden de magnitud respecto a la LSTM convencional. Estos resultados validan la efectividad de integrar capas convolucionales para la extracción de patrones espaciales y capas recurrentes para el modelado de la dinámica temporal.




Figura 6: Comparativa de los resultados de los modelos LSTM y CNN-LSTM con los datos de junio del año 2015

Tabla 3: Índices estadísticos de los modelos LSTM y CNN-LSTM con los datos de junio del año 2015

Parámetro	LSTM			CNN-LSTM		
	s12	s19	s21	s12	s19	s21
<i>MSE</i>	0.2409473 °C ²	0.0777327 °C ²	0.0051761 °C ²	0.1563292 °C ²	0.0075801 °C ²	0.0024015 °C ²
<i>N</i>	0.9990	0.9995	0.9996	0.9990	0.9999	0.9998
<i>MAE</i>	0.34010 °C	0.17148 °C	0.04983 °C	0.22236 °C	0.05619 °C	0.03327 °C
<i>MRE</i>	0.0053	0.0078	0.0017	0.0035	0.0032	0.0011
<i>NMAE</i>	0.00627	0.00685	0.00545	0.00410	0.00224	0.00364

5. Conclusiones

La presente investigación permitió validar la eficacia de los modelos de caja negra para la caracterización dinámica de la enfriadora por absorción Yazaki WFC SC20 perteneciente al sistema de refrigeración por frío solar del centro CIE-SOL ubicado en la UAL. Para ello, se desarrollaron dos tipos de modelos basados en aprendizaje automático, un modelo LSTM y un modelo híbrido CNN-LSTM.

Con base a los resultados obtenidos se puede concluir que la combinación de capas convolucionales para la extracción de patrones morfológicos y capas de memoria a corto y largo plazo para la interpretación de la dinámica secuencial logró capturar con alta precisión la inercia térmica del sistema. Además, los resultados de validación con datos del año 2015 demostraron la robustez del modelo híbrido CNN-LSTM frente a los modelos recurrentes tradicionales. Por lo tanto en futuros trabajos sería recomendable utilizar este tipo de modelo.

Además, el uso del framework Optuna resultó fundamental para alcanzar los niveles de precisión. Permitiendo una optimización inteligente de hiperparámetros y una selección de las variables de entrada a través de más de dos mil iteraciones. Asimismo, este proceso permitió determinar, mediante análisis de sensibilidad, que la temperatura de retorno del edificio, señal s18, es la variable con mayor peso en el comportamiento de las salidas del sistema, ya que está presente en las métricas de ambas arquitecturas objeto de estudio.

El desarrollo de esta investigación bajo tecnologías de software libre como Python y PyTorch garantiza la transparencia, escalabilidad y reproducibilidad de los resultados por parte de la comunidad científica. La capacidad de estos modelos para integrarse como un gemelo digital dentro del sistema de monitorización y supervisión del edificio o para desarrollar sistemas de control avanzados a partir de ellos, representa un paso significativo hacia la gestión energética de edificios con este tipo de sistemas alimentados por energía solar para reducir sus emisiones de manera significativa.

Agradecimientos

Este trabajo ha recibido apoyo financiero del proyecto PID2024-155521OB-I00 (financiado por MCI-

N/AEI/10.13039/501100011033/FEDER “Una forma de hacer Europa”). Por otra parte, la doctoranda Zuliet Medina Rodríguez agradece el apoyo del Grupo La Rábida, a través de su programa de becas de movilidad internacional del año 2026. Los autores expresan su gratitud por la ayuda concedida, la cual facilitó la estancia de investigación necesaria para el desarrollo y validación de los modelos presentados en este estudio.

Referencias

- Akiba, T., Sano, S., Yanase, T., Ohta, T., Koyama, M., 2019. Optuna: A next-generation hyperparameter optimization framework. In: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. KDD '19. Association for Computing Machinery, New York, NY, USA, p. 2623–2631.
URL: <https://doi.org/10.1145/3292500.3330701>
DOI: 10.1145/3292500.3330701
- Ferre, A., Castilla, M., Carballo, J. A., Álvarez, J. D., 2023. Characterization of an absorption machine using artificial neural networks. In: Maglogianis, I., Iliadis, L., MacIntyre, J., Dominguez, M. (Eds.), Artificial Intelligence Applications and Innovations. Springer Nature Switzerland, Cham, pp. 279–291.
- Gobierno de España, 2023. Plan nacional integrado de energía y clima 2023-2030 (pniec). Documento oficial.
- Hosseini, P., 2022. Deep-learning neural network prediction of a solar-based absorption chiller cooling system performance using waste heat. Sustainable Energy Technologies and Assessments 53, 102683.
URL: <https://www.sciencedirect.com/science/article/pii/S2213138822007329>
DOI: <https://doi.org/10.1016/j.seta.2022.102683>
- IEA, 2022. International energy agency- key world energy statistics 2021. Tech. rep.
URL: <https://www.iea.org/reports/key-world-energy-statistics-2021>
- Panahizadeh, F., Hamzehei, M., Farzaneh-Gord, M., Villa, A. A. O., 2021. Evaluation of machine learning-based applications in forecasting the performance of single effect absorption chiller network. Thermal Science and Engineering Progress 26, 101087.
URL: <https://www.sciencedirect.com/science/article/pii/S2451904921002481>
DOI: <https://doi.org/10.1016/j.tsep.2021.101087>
- Rodríguez-Ramos, A., Ma, L., Verde, C., Silva Neto, A. J., Llanes-Santiago, O., 2026. An optimized deep learning framework for fault and cyber-attack detection in chemical process monitoring. Chemical Engineering Science 320, 122608.
URL: <https://www.sciencedirect.com/science/article/pii/S0009250925014290>
DOI: <https://doi.org/10.1016/j.ces.2025.122608>