

UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS

INSTITUTO DE INVESTIGACIÓN EN CIENCIAS BÁSICAS Y APLICADAS

CENTRO DE INVESTIGACIÓN EN INGENIERÍA Y CIENCIAS APLICADAS

OPTIMIZACIÓN DEL CONTROL TÉRMICO EN EDIFICACIONES
UTILIZANDO REDES NEURONALES CONFORMABLES INVERSAS
PARA SISTEMAS DE CALEFACCIÓN RADIANTE

TESIS PROFESIONAL PARA OBTENER EL GRADO DE:
DOCTORADO EN INGENIERÍA Y CIENCIAS APLICADAS

PRESENTA:

ALEXIA IRAIS MATA PÉREZ

DIRECTOR: DR. JOSÉ ALFREDO HERNÁNDEZ PÉREZ

CO-DIRECTORA: DRA. ARIANNA PARRALES BAHENA

SINODALES:

DR. ALBERTO ALVAREZ GALLEGOS

DR. ARMANDO HUICOCHEA

DR. JOSE ALFREDO RODRIGUEZ RAMIREZ

DR. JESUS EMMANUEL SOLIS PEREZ

DR. DARIO COLORADO GARRIDO

RESUMEN

Este estudio presenta una metodología innovadora que integra redes neuronales inversas conformables (*CANNi*) con algoritmos genéticos (*GA*) y algoritmo de optimización por enjambre de partículas (*PSO*) para optimizar el confort térmico en edificios. Haciendo hincapié en la eficacia de las funciones de transferencia conformables dentro de las *CANNi*, la investigación se basa en un amplio conjunto de datos para predecir la transferencia de calor en diversos climas. En particular, la metodología destaca por su meticuloso proceso de selección de modelos, en el que se emplean pruebas de pendiente-intercepto para garantizar una predictibilidad sólida (99%) y una fuerte correlación entre las variables de entrada y de salida. El modelo seleccionado presenta un equilibrio óptimo entre precisión predictiva y eficiencia computacional, con un valor R de 0.9992 y bajos $RMSE$ (0.0078) y $MAPE$ (2.1099). Este rendimiento permite calibrar con precisión la RFH para mejorar el confort y supone un gran paso adelante hacia la mejora de la eficiencia energética y la sostenibilidad en el sector de la construcción. Estos resultados abogan por una utilización más eficiente de los recursos energéticos en los edificios, adaptándose hábilmente a las fluctuaciones climáticas y mejorando la calidad de vida de los habitantes.

ABSTRACT

This study introduces an innovative methodology that integrates Inverse Conformable Artificial Neural Networks (*CANNi*) with Genetic Algorithms (*GA*) or Particle Swarm Optimization (*PSO*) to optimize thermal comfort in buildings. Emphasizing the efficacy of conformable transfer functions within *CANNi*, the research relies on a comprehensive dataset to forecast heat transfer across diverse climates. Notably, the methodology stands out for its meticulous model selection process, employing slope-intercept tests to ensure robust predictability (99%) and strong correlation between input and output variables. The selected model exhibits an optimal equilibrium between predictive precision and computational efficiency, reaching an R – value of 0.9992 with low $RMSE$ (0.0078) and $MAPE$ (2.1099). Such performance enables precise calibration of Radiant Floor Heating Systems (*RFH*) for enhanced comfort and marks a significant stride toward bolstering energy efficiency and sustainability within the construction sector. These

findings advocate for more efficient utilization of energy resources in buildings, adeptly accommodating climatic fluctuations and enhancing the inhabitants' quality of life.

AGRADECIMIENTOS.

Este trabajo fue realizado con el apoyo del **Centro de Investigación en Ingeniería y Ciencias Aplicadas (CIICAp)**. Los autores agradecen especialmente a la **Secretaría de Educación, Ciencia, Innovación y Tecnología (SECIHTI)** por el financiamiento otorgado, el cual fue fundamental para el cumplimiento de los objetivos de esta investigación.

A mis padres Victoria y Víctor, por ser el impulso constante en mi vida y por estar siempre, sin importar la distancia o el desafío. Gracias por creer en mí y por darme las herramientas para llegar hasta aquí.

A mi hermana Denisse, por su apoyo incondicional y por esa insistencia constante que me llevó a emprender este doctorado; sin tus palabras de aliento y tus empujones en el momento justo, este camino no habría comenzado.

A mi esposo, Jordan, por todo lo que ya sabes. Gracias por ser mi pilar, por tu paciencia infinita y por sostenerme en cada etapa de este proceso. Este logro es tan tuyo como mío.

Mi más profundo agradecimiento a los doctores **Alfredo y Arianna**. Gracias por guiarme y apoyarme de manera incondicional, por sus valiosos consejos y por ser mentores que me enseñaron el verdadero valor de la investigación. Su guía fue la brújula necesaria para llegar al final de este proceso.

DEDICATORIA.

Al maestro Gustavo Espinosa Barreda, quien siempre me impulsó a superar mis propios límites. Aunque su partida le impidió ser testigo de este logro, su mentoría y constante aliento han sido fundamentales en mi formación. Honro su legado con este trabajo, esperando que, dondequiera que esté, sea consciente del impacto transformador que tuvo en mi vida. GRACIAS INFINITAS. Descanse en paz

Índice

1. Marco teórico	10
2. Configuración experimental	18
3. Metodología	22
3.1. Preprocesamiento.....	22
3.2. División de datos.....	23
3.3. Arquitectura de la Red Neuronal Artificial	24
3.3.1. Capa de entrada	24
3.3.2. Capa oculta.....	24
3.4. Funciones de transferencia conformables	25
3.5. Validación estadística.....	29
3.6. Estrategia de control con Redes Neuronales Artificiales Inversas (ANNi)	29
3.6.1. Consideraciones del escenario de prueba.....	33
4. Resultados y discusión.	36
5. Conclusiones.....	53
6. Referencias.....	55
7. Anexo 1: Productos científicos obtenidos.	63

LISTA DE TABLAS

Tabla 1. Características del sistema de suelo radiante (RFH).....	20
Tabla 2. Rangos operacionales en la literatura	20
Tabla 3. Valores para cada escenario	36
Tabla 4 Resultados de los modelos clásicos.	37
Tabla 5. Resultados de los modelos conformables	39

LISTA DE FIGURAS

Figura 1. Demanda de electricidad por sector [1].....	11
Figura 2. Estructura típica de un sistema de suelo radiante.....	19
Figura 4. Metodología ANN	22
Figura 5. Comportamiento de las funciones conformables	28
Figura 6. Rendimiento R de los modelos con diferente número de neuronas en la capa oculta.....	40
Figura 7. Rendimiento MAPE de los modelos.....	41
Figura 8. Rendimiento RMSE de los modelos.....	42
Figura 9. Regresión obtenida del modelo CTANSIG 4:3:1	43
Figura 10. Proceso CANNi	45
Figura 11. Calor total vs Temperatura en Múnich	46
Figura 12. Calor total vs Temperatura en Vancouver	46
Figura 13. Calor total vs Temperatura en Murmansk.....	47
Figura 14. Optimización de la temperatura media del fluido en Múnich	48
Figura 15. Optimización de la temperatura media del fluido en Vancouver.....	49
Figura 16. Optimización de la temperatura media del fluido en Murmansk.....	49
Figura 17. Comparativa entre Temperatura Operativa y Temperatura Media del Fluido vs Temperatura del suelo en Múnich	50
Figura 18. Comparativa entre Temperatura Operativa y Temperatura Media del Fluido vs Temperatura del suelo en Vancouver	50
Figura 19. Comparativa entre Temperatura Operativa y Temperatura Media del Fluido vs Temperatura del suelo en Murmansk	51
Figura 20. Errores de la optimización por hora entre GA y PSO para Múnich	52
Figura 21. Errores de la optimización por hora entre GA y PSO para Vancouver	52

Figura 22. Errores de la optimización por hora entre GA y PSO para Murmansk 53

1. Marco teórico

La crisis energética mundial, agravada por la invasión de Ucrania por parte de Rusia principios de 2022 [1], ha provocado una volatilidad sin precedentes y fuertes caídas en los precios de la energía, especialmente en el mercado del gas natural.

El gas natural representa más del 23% de la generación mundial de electricidad [2], lo que pone de relieve una dependencia significativa que, a raíz de los recientes conflictos geopolíticos, ha provocado un resurgimiento del uso del carbón en el sector energético. Este cambio reactivo ha respondido a las necesidades energéticas inmediatas y ha contribuido al aumento de las emisiones de gases de efecto invernadero, agravando aún más los retos medioambientales a los que se enfrenta nuestro mundo [3,4].

Un análisis desagregado de esta demanda residencial revela que el principal motor del consumo energético en los hogares es la necesidad de climatización de espacios (calefacción y refrigeración). Tradicionalmente, la gestión de estos sistemas se vuelve altamente ineficiente debido a la naturaleza estocástica de las variables climáticas exógenas y la elevada inercia térmica inherente a los materiales de construcción de las edificaciones. Como se ilustra en la Figura 1. Crecimiento de la demanda de electricidad histórico y proyectado por sector [1], los escenarios proyectados por la Agencia Internacional de la Energía (IEA) para el periodo 2021–2030 —tanto bajo las Políticas Declaradas (STEPS) como bajo los Compromisos Anunciados (APS)— demuestran que el enfriamiento de espacios experimentará el crecimiento de demanda más agresivo del sector energético global, aproximándose a la frontera de los 3,000 TWh. Este incremento no solo supera la evolución histórica observada entre 2010 y 2021, sino que eclipsa las demandas proyectadas para sectores industriales intensivos como el aluminio, los productos químicos o la producción de hidrógeno, consolidando al confort térmico estival como la mayor presión sobre las redes eléctricas del siglo XXI.

El cambio climático ha aumentado la necesidad de climatización de espacios, y las previsiones actuales no apuntan a una inversión de esta tendencia [7-9]. Esta situación se traduce en elevados costes operativos y un gran impacto medioambiental, lo que hace

necesaria una reevaluación exhaustiva de las tecnologías y los enfoques empleados para la gestión térmica residencial.




Figura 1. Crecimiento de la demanda de electricidad histórico y proyectado por sector [1]

La superioridad de los sistemas RFH frente a los métodos de convección forzada radica en la distribución del gradiente térmico. Mientras que los sistemas de aire acondicionado tienden a concentrar el aire caliente en la parte superior de las habitaciones —lejos de la zona de ocupación humana—, el suelo radiante emite calor de manera uniforme por radiación. Este fenómeno permite alcanzar la sensación de confort a temperaturas operativas ligeramente inferiores, lo que se traduce en un ahorro energético directo de entre el 10% y el 20% en comparación con sistemas tradicionales [17]

Los sistemas de calefacción por suelo radiante (RFH por sus siglas en inglés) se están convirtiendo en una opción prometedora entre las alternativas emergentes debido a su eficiencia energética y capacidad para proporcionar confort térmico. Estos sistemas utilizan el suelo como fuente térmica y suelen implicar la circulación de un líquido refrigerante (comúnmente agua) a través de tubos empotrados en la estructura del suelo [10]. Para optimizar el diseño de los RFH, es fundamental comprender la eficiencia con la que se transfiere el calor a través de las superficies dentro de estos sistemas.

El flujo de calor es crucial para cuantificar la eficacia con la que se transfiere el calor a través de diferentes medios. Este parámetro es esencial para diseñar sistemas térmicos eficientes y predecir la distribución de la temperatura en diversos procesos industriales y sistemas físicos. Ayuda a los ingenieros y diseñadores a tomar decisiones informadas sobre cómo mejorar el rendimiento de dichos sistemas.

El flujo de calor de los sistemas RFH puede verse influido por diversos factores, entre ellos la radiación solar, el suministro de calor, la ubicación de la habitación, la temperatura exterior y las condiciones de calefacción del entorno [11,12]. Cada uno de estos elementos tiene el potencial de influir en la eficiencia con la que el sistema de suelo radiante gestiona el calor. Es fundamental evaluar de forma exhaustiva estos factores para optimizar el rendimiento del sistema y abordar de manera eficaz los retos energéticos, así como medioambientales.

A lo largo de los años, se han realizado numerosos estudios para evaluar la capacidad de transferencia de calor de los sistemas RFH y desarrollar métodos para mejorarla. Sin embargo, un análisis más detallado revela que, aunque estos estudios han realizado importantes contribuciones, también presentan limitaciones metodológicas que dejan margen para la mejora. Por ejemplo, Jing et al. [13] desarrollaron modelos numéricos para diferentes estructuras de calefacción radiante utilizando una matriz de microtubos. Aunque estos modelos proporcionaron información valiosa sobre la distribución de la temperatura y el proceso de transferencia de calor, su enfoque experimental limitado deja dudas sobre su aplicabilidad a diferentes configuraciones de RFH.

Xu et al. [14] utilizaron el método de volúmenes finitos para investigar el flujo de calor que implica el cambio de fase, optimizando la temperatura del suministro de agua y estableciendo directrices para la variación de la temperatura superficial. Aunque este trabajo contribuye al diseño de sistemas RFH eficientes en modo intermitente, su enfoque en la optimización de un único parámetro puede limitar su aplicabilidad en escenarios más complejos.

Wang et al. [15] propusieron un modelo de cálculo para determinar el flujo de calor total (q_t) en RFH. Si bien el modelo mostró un rendimiento superior en comparación con la fórmula estándar ISO, reduciendo significativamente las desviaciones estándar y

mejorando la precisión de los cálculos de q_t , su dependencia de las variaciones de temperatura a lo largo de parámetros específicos plantea dudas sobre su solidez en condiciones cambiantes.

La introducción de redes neuronales artificiales (ANN por sus siglas en inglés) en el campo del flujo de calor ha abierto nuevas posibilidades para mejorar la precisión de las predicciones. Acikgoz et al. [16] desarrollaron un modelo ANN para predecir los coeficientes de transferencia de calor en un sistema de suelo radiante utilizando una arquitectura de retropropagación con la función de transferencia TANSIG. Este modelo logró una alta precisión en la predicción del flujo de calor en RFH, con un coeficiente de correlación de 0,99955. Sin embargo, la estructura relativamente simple del modelo puede no captar completamente las complejas interacciones térmicas en RFH más avanzados.

Verma et al. [17] propusieron un modelo ANN para predecir el flujo de calor en un sistema de calefacción y refrigeración por suelo radiante (RFH), utilizando cuatro variables para obtener el calor total (q_t): resistencia calórica del material (R_s), flujo masico (m_f), temperatura media del fluido refrigerante (T_{wm}) y temperatura operativa (T_{op}). A pesar de su alta precisión, con un R^2 de 0.9984 y un MSE de 0.00055, el uso exclusivo de funciones de transferencia convencionales como *TANSIG* y *Purelin* podría limitar su generalización a contextos desconocidos, más modernos y funciones flexibles. La bibliografía sobre modelización matemática y aprendizaje profundo destaca la importancia de seleccionar funciones de transferencia óptimas. Aunque *TANSIG* (ec. (1)) se ha utilizado comúnmente, otras opciones, como *LOGSIG* (ec. (2)), *SOFTPLUS* (ec. (3)), *SWISH* (ec. (4)) y *ELU* (ec. (5)), están ganando relevancia para abordar retos específicos como la degradación del gradiente, la mejora de la convergencia del modelo y la generalización a diversas aplicaciones.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1, \quad -1 < f(x) < 1$$

(1)

$$f(x) = \frac{1}{1 + e^{-x}}, \quad 0 < f(x) < 1$$
(2)

$$f(x) = \ln(1 + e^{-x})$$
(3)

$$f(x) = \frac{x}{1 + e^{-\beta x}}$$
(4)

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^{-x} - 1), & x < 0 \end{cases}$$
(5)

A pesar de la versatilidad de las funciones de transferencia mencionadas (ec. 1 a 5), la modelación de sistemas con una inercia térmica elevada, como los suelos radiantes, presenta un desafío adicional: la memoria del sistema. Las redes neuronales de orden entero asumen que la respuesta del sistema depende únicamente del estado actual, ignorando el historial térmico que influye en la transferencia de calor por radiación y conducción en la estructura del edificio.

Para mitigar esta limitación, surge el concepto de Funciones de Transferencia Conformables. A diferencia de las funciones tradicionales que operan en un espacio euclidiano rígido, las funciones conformables introducen un parámetro de control λ derivado del cálculo fraccionario. Este parámetro permite que la 'pendiente' y la 'curvatura' de la activación neuronal se ajusten dinámicamente, capturando fenómenos de memoria y no linealidades que las funciones enteras suavizan excesivamente. Así, el tránsito hacia las CANN no es solo una búsqueda de precisión estadística, sino una necesidad de fidelidad física con el fenómeno de histéresis térmica.

La elección de la función de transferencia puede afectar sustancialmente al rendimiento de las redes neuronales en diversas aplicaciones [18-21]. Sin embargo, estas investigaciones no abordan adecuadamente la implementación de nuevas funciones conformables derivadas del cálculo fraccionario, las cuales ofrecen ventajas en términos

de simplificación del modelo y robustez frente al ruido. Solís-Pérez et al. [22] demostraron la superioridad de estas arquitecturas (*CANN*) al aplicarlas con éxito en tres escenarios de alta complejidad técnica: (1) la predicción de la fracción de vacío en intercambiadores de calor helicoidales, donde la función conformable capturó mejor la dinámica del flujo bifásico; (2) la estimación del coeficiente de desempeño (COP) en sistemas de refrigeración por absorción, logrando una mayor precisión con arquitecturas más compactas; y (3) el modelado de cinéticas en procesos de fermentación, demostrando una alta capacidad de generalización frente a datos experimentales ruidosos [22].

A pesar de estos resultados prometedores en procesos térmicos y biotecnológicos, su aplicabilidad en la gestión dinámica y optimización inversa de sistemas de calefacción radiante (RFH) complejos, los cuales presentan una inercia térmica significativa y una dependencia crítica de las variables climáticas, aún no se ha explorado por completo. Esto justifica el desarrollo de un modelo inverso basado en funciones de transferencia conformables de Khalil [23] para este sector.

Un antecedente crítico en esta línea de investigación es el uso de redes neuronales inversas (*ANNi* por sus siglas en inglés) para la optimización de procesos térmicos. Hernández [24] desarrolló una metodología pionera donde se invirtió una red neuronal de orden entero para encontrar las condiciones óptimas de operación en el secado de alimentos, demostrando que es posible determinar parámetros desconocidos a partir de condiciones requeridas mediante métodos de optimización numérica.

Una vez establecida la arquitectura de la red (directa), el siguiente reto técnico es su aplicabilidad práctica. El modelado convencional solo permite predecir el flujo de calor (salida) a partir de variables operativas (entrada). Sin embargo, en la ingeniería de control, el interés real radica en el diseño funcional. Siguiendo la metodología de Hernández [24], quien demostró que es posible invertir una red neuronal para encontrar condiciones óptimas de operación en procesos de secado, esta tesis propone aplicar dicho enfoque de inversión (*ANNi*) pero potenciado por la flexibilidad de las funciones conformables.

Este salto técnico es fundamental: pasamos de una herramienta que 'observa' el fenómeno a una herramienta que 'diseña' la operación del sistema RFH, permitiendo que

el usuario defina el confort deseado y el algoritmo entregue los parámetros de flujo y temperatura necesarios.

Los sistemas de optimización orientados al control, como las redes neuronales artificiales inversas (*ANNi*), han demostrado ser herramientas valiosas para mejorar la eficiencia de los sistemas térmicos. García-Morales et al. [25] aplicaron un modelo *ANNi* para controlar la temperatura de salida en un intercambiador de calor de doble tubo, logrando un seguimiento de referencia superior con un *RMSE* bajo de 0,2025. Sin embargo, este enfoque aún no se ha probado en aplicaciones más dinámicas y complejas, como los sistemas *RFH*.

Ajbar et al. [26] mejoraron la eficiencia térmica de un colector parabólico utilizando *ANNi* en combinación con algoritmos genéticos (*GA*) y algoritmo de optimización de enjambres de partículas (*PSO*). Este enfoque demostró ser eficaz, ya que alcanzó un alto coeficiente de correlación de 0,9511 y un bajo MSE de 0,0193. Sin embargo, la integración de estas técnicas en el contexto de los sistemas *RFH* sigue siendo un área poco explorada, lo que pone de relieve la necesidad de seguir investigando.

La integración de las Redes Neuronales Artificiales Conformables (*CANN*) con el modelo inverso (*ANNi*) da lugar a un área prometedora, que conduce al desarrollo de redes neuronales artificiales conformables inversas (*CANNi* por sus siglas en inglés). Esta combinación aprovecha los puntos fuertes de ambos enfoques: *CANN* destaca en la captura de relaciones de datos complejas y es resistente al ruido, mientras que *ANNi* modela los sistemas a la inversa, transformando las salidas en entradas. Esta integración tiene un gran potencial para abordar diversos problemas de aplicación, ya que ofrece un enfoque potente y versátil.

Este trabajo de investigación explora la aplicación de *CANNi* como un enfoque novedoso para mejorar y acelerar los modelos de predicción del flujo de calor en *RFH*. La metodología consiste en utilizar ANN con diversas funciones de activación, incluidas las tradicionales como LOGSIG y TANSIG, y funciones modernas como SOFTPLUS, SWISH y ELU, junto con sus equivalentes conformables. El objetivo es capturar eficazmente las intrincadas relaciones entre los datos en la construcción. Además, el estudio introduce el

concepto de sistemas de optimización orientados al control, concretamente *CANNi*, que aprovechan el aprendizaje profundo de CANN para el control del sistema. Este innovador enfoque tiene como objetivo optimizar el rendimiento de las RFH y mejorar su eficiencia energética. Este estudio mejora y perfecciona un modelo establecido anteriormente para calcular el flujo de calor en las RFH. Investiga cómo el uso de *CANNi* puede optimizar y controlar el modelo.

Bajo este esquema, la integración de funciones de activación avanzadas y sus contrapartes conformables no solo busca una mayor precisión en el modelo directo, sino que establece una base matemática robusta para la fase de inversión. No obstante, la transformación de estas redes en un sistema de optimización orientado al control (*CANNi*) presenta un desafío computacional significativo: al invertir la red neuronal, el espacio de búsqueda de los parámetros de entrada adquiere una naturaleza no convexa, caracterizada por la presencia de múltiples mínimos locales y regiones de estancamiento. En estas condiciones, los métodos de optimización tradicionales basados en el gradiente suelen ser insuficientes, ya que tienden a quedar atrapados en soluciones locales que no representan el óptimo global del sistema térmico.

Para superar esta limitación, la presente investigación justifica la selección de algoritmos de optimización bio-inspirados, específicamente Algoritmos Genéticos (GA) y Optimización por Enjambre de Partículas (PSO). Estas técnicas metaheurísticas permiten una exploración estocástica y global del espacio de soluciones, asegurando que los parámetros operativos encontrados para el sistema RFH —tales como el flujo masico y la temperatura del fluido— sean los más eficientes desde una perspectiva sistémica. De este modo, la *CANNi* se consolida no solo como un modelo predictivo, sino como una herramienta de diseño funcional capaz de adaptarse a las exigencias energéticas de las edificaciones modernas.

A partir de este enfoque integral, las principales contribuciones de esta investigación se detallan a continuación:

- Aplicación de ANN para mejorar los parámetros de la red, de modo que sea posible aplicar ANNi.

- Aplicación pionera de *CANNi* en la optimización de sistemas RFH, mejorando la predicción de parámetros.
- Optimización y simplificación del modelo de predicción del flujo de calor para RFH.
- Control del modelo de predicción del flujo de calor para RFH mediante un enfoque de inversión.
- Innovación en la gestión de datos, adaptándose a las condiciones cambiantes en entornos reales.

2. Configuración experimental

La Figura 2 ilustra un sistema de suelo radiante que es objeto de investigación en este estudio. Este sistema consta de cuatro capas estructurales: una capa de recubrimiento superior, una capa de solado, una capa de relleno, una capa aislante y una tubería intercambiadora de calor. Varias características operativas vitales definen el comportamiento del sistema radiante, incluyendo el caudal másico (m_f), la resistencia térmica (R_s), la temperatura media del fluido de transferencia de calor (T_{wm}) que circula dentro del tubo radiante y la temperatura operativa (T_{op}). Por último, el flujo de calor del sistema radiante (q_t) correspondiente a los parámetros operativos especificados se selecciona como medida de rendimiento. Estas variables clave, también ilustradas en la Figura 2, desempeñan un papel crucial en la determinación del rendimiento del sistema.

Es importante señalar que la Figura 2 es una representación esquemática de un sistema RFH típico. Los datos utilizados en este estudio no se generaron mediante simulaciones, sino que fueron recopilados y comunicados por Verma et al. [17], quienes recopilaron datos experimentales de diversos estudios publicados que realizaron experimentos en el mundo real. La tabla 1 presenta los parámetros del sistema y los rangos de funcionamiento derivados de la bibliografía [17]. Por otro lado, la tabla 2 presenta una comparación de los rangos de funcionamiento entre los estudios citados en la bibliografía, tal y como se describe en la fuente [17].




Figura 2. Estructura típica de un sistema de suelo radiante

La configuración multicapa descrita en la Figura 2 no es meramente estructural, sino que determina la resistencia térmica total del sistema. Cada interfaz entre el recubrimiento superior y el aislante genera una caída de temperatura que debe ser compensada por el flujo másico (m_f). La inclusión de la resistencia térmica (R_s) como variable de entrada es crítica, ya que engloba las propiedades conductivas de materiales tan diversos como el concreto, mortero o acabados cerámicos, los cuales presentan diferentes capacidades de almacenamiento térmico. Esta inercia térmica es la que justifica el empleo de funciones conformables, ya que los modelos de orden entero suelen subestimar el tiempo de retardo en la transferencia de calor desde la tubería hasta la superficie del solado.

Tabla 1. Características del sistema de suelo radiante (RFH)

Parámetros	Rango de operación	Unidades
Flujo de masa (m_f)	0.0017 – 1.994	$\frac{Kg}{s}$
Resistencia al calor (R_s)	0.0241 – 0.648	$\frac{m^2 K}{W}$
Temperatura media (T_{wm})	8.3 – 59.9	$^{\circ}C$
Temperatura operativa (T_{op})	17.3 – 35.65	$^{\circ}C$
Flujo de calor (q_t)	8.1 – 193.9	$\frac{W}{m^2}$

Tabla 2. Rangos operacionales en la literatura

Fuente	Tipo de sistema	$T_{wm}(^{\circ}C)$	$m_f\left(\frac{Kg}{s}\right)$	$R_s\left(\frac{m^2 K}{W}\right)$	$T_{op}(^{\circ}C)$
Karakoyun et al. [27]	Calentamiento	35 – 45	0.01 – 0.04	0.03 – 0.1	18 – 25
Wu et al. [28]	Calentamiento/ Enfriamiento	10 – 35	0.01 – 0.08	0.03 – 0.07	20 – 27
Jin et al. [29]	Enfriamiento	15 – 20	0.01 – 0.05	0.04 – 0.1	24 – 26
Li et al. [30]	Enfriamiento	8 – 40	0.02 – 0.06	0.03 – 0.08	23 – 25
Cholewa et al. [31]	Calentamiento/ Enfriamiento	8 – 35	0.02 – 0.05	0.02 – 0.06	19 – 28
Verma et al. 2023 [17]	Calentamiento/ Enfriamiento	8.3 – 59.9	0.0017 – 1.994	0.0241 – 0.648	17.3 – 35.65

Al observar la comparativa de la Tabla 2, se hace evidente que el conjunto de datos recopilado por Verma et al. [17] presenta una amplitud significativamente mayor en comparación con los estudios individuales citados. Por ejemplo, mientras que Li et al. [30] se limitan a un rango de temperatura operativa (T_{op}) de 23 a 25 $^{\circ}C$ para enfriamiento,

la base de datos global abarca desde los 17.3 °C hasta los 35.65 °C. Esta disparidad en los rangos operativos (que cubren tanto calefacción como enfriamiento) introduce una alta no-linealidad en el espacio de búsqueda. Para una red neuronal tradicional, esta varianza extrema puede conducir a problemas de sobreajuste o a una pobre generalización en los límites del rango (extrapolación), lo que refuerza la necesidad de utilizar optimizadores robustos como PSO y funciones de transferencia que no se saturen fácilmente.

El flujo de calor (q_t), seleccionado como la medida de rendimiento principal, se expresa en W/m^2 y representa la densidad de energía transferida por unidad de área. En el contexto de edificios inteligentes, predecir con exactitud este valor es el primer paso para el diseño de sistemas de control de lazo cerrado. Un error en la estimación de q_t , especialmente en el rango superior observado en la Tabla 1 (hasta $193.9 \frac{W}{m^2}$), resultaría en un consumo energético innecesario o en una incapacidad del sistema para alcanzar el punto de consigna de confort térmico en condiciones climáticas extremas.

3. Metodología

Como se mencionó anteriormente, una ANN es un marco de neuronas interconectadas capaces de procesar y transmitir información para generar respuestas específicas. El modelado con ANN implica cuatro etapas principales: preprocesamiento de datos, diseño de la arquitectura de la red, entrenamiento de la red y análisis del rendimiento de la red. El diseño de la arquitectura de la red, el entrenamiento y el análisis del rendimiento son componentes vitales. La Figura 3 ofrece una representación visual de la secuencia de estos pasos.




Figura 3. Metodología ANN

3.1. Preprocesamiento

La limpieza de datos implica la eliminación de datos inexactos, duplicados o incompletos. La normalización de datos convierte los atributos numéricos a una escala estandarizada, lo que evita que las variables con magnitudes más altas eclipsen a las que tienen magnitudes más bajas durante el entrenamiento. La ec. (6) ilustra un método de normalización de datos utilizado con frecuencia [32].

$$x_n = (y_{max} - y_{min}) * \frac{x_{exp} - x_{min}}{x_{max} - x_{min}} + y_{min}$$

x_n es la variable normalizada, x_{exp} es la variable experimental que se va a normalizar, x_{min} y x_{max} son el mínimo y el máximo de la variable de entrada, y y_{min} y y_{max} representan el rango de normalización.

La decisión de escalar los datos específicamente al rango de [0.1, 0.9] responde a una necesidad crítica de la dinámica de entrenamiento de las redes neuronales. Al utilizar funciones de activación de tipo sigmoideal (como LOGSIG y TANSIG), los valores de entrada muy cercanos a 0 o 1 (o fuera de estos rangos) provocan que la derivada de la función de activación sea extremadamente pequeña. Este fenómeno, conocido como saturación del gradiente, impide que los pesos se actualicen de manera efectiva durante el proceso de retropropagación (backpropagation), deteniendo el aprendizaje del modelo. Al mantener los datos en el rango intermedio, se asegura que la red opere en la zona de máxima sensibilidad de la función de transferencia, facilitando una convergencia más rápida y estable del algoritmo Levenberg-Marquardt.

La normalización se aplicó tanto a las variables de entrada como a las de salida, escalándolas para que quedaran dentro del rango de 0,1 a 0,9, tal y como se define en la ec. (6). Este procedimiento de estandarización fue esencial para garantizar la uniformidad de los datos y facilitar el proceso de entrenamiento de la ANN.

3.2. División de datos

La partición de datos implica dividir el conjunto de datos en subconjuntos, normalmente denominados conjuntos de entrenamiento, validación y prueba. El conjunto de entrenamiento se utiliza para ajustar los parámetros de la ANN mediante un algoritmo de optimización.

El conjunto de prueba selecciona el mejor modelo entre varios candidatos basándose en criterios como el coeficiente de correlación (R). El conjunto de pruebas es crucial para estimar el rendimiento real del modelo elegido cuando se aplica a nuevos datos. Esta estrategia de división deliberada nos permite entrenar el modelo, optimizar sus parámetros y evaluar su rendimiento en datos no vistos, lo que garantiza su solidez y precisión [33].

3.3. Arquitectura de la Red Neuronal Artificial

La modelización ANN implica analizar y reconocer la mejor configuración entre datos de entrada, neuronas ocultas y datos de salida, con el objetivo de que los datos de salida modelados reflejen los datos reales de la forma más cercana a la realidad posible.

La arquitectura general de una ANN se divide normalmente en tres secciones: la capa de entrada, las capas ocultas y la capa de salida.

3.3.1. Capa de entrada

La capa de entrada está formada por neuronas y variables que representan los datos de entrada. Su función principal es capturar y transmitir los datos de entrada a las capas posteriores. En esta sección, los datos ya ingresan normalizados.

3.3.2. Capa oculta

La capa oculta contiene un número variable de neuronas, determinado mediante un proceso iterativo guiado por el rendimiento del modelo. Dentro de una neurona de la capa oculta de la red neuronal, se calcula una combinación lineal de las entradas ponderadas por sus respectivos pesos, lo que da como resultado una suma. Este proceso se muestra en la Ec. (7).

$$y = \sum_{n=1}^N (W_{i(n,s)} P_n + b_{1(s)})$$

(7)

Donde y representa la suma ponderada de la matriz de pesos (W_i) por las entradas (P) más el sesgo b_1 . Las letras n y s representan el tamaño de las matrices y vectores, donde n es el número de entradas y s es el número de neuronas.

Esta suma se procesa posteriormente a través de una función de transferencia no lineal para capturar las intrincadas relaciones entre las variables de entrada y salida [34].

En la capa oculta, las funciones de transferencia producen transformaciones no lineales, lo que les permite abordar problemas de alta complejidad de manera eficaz. Las funciones de transferencia desempeñan un papel crucial en el procesamiento y la transmisión de información a través de las capas de una ANN, lo que influye en su rendimiento [35]. Dos funciones clásicas, LOGSIG (sigmoide logarítmica) (ec. (2)) y TANSIG (sigmoide tangente hiperbólica) (ec. (1)), han prevalecido en la literatura debido a sus propiedades deseables, incluida su capacidad para introducir no linealidades en el modelo [26]. En la búsqueda continua de mejorar el rendimiento y la estabilidad del entrenamiento, han surgido funciones alternativas como SOFTPLUS (ec. (3)), SWISH (ec.(4)) y ELU (ec.(5)).

Estas funciones son muy valiosas para problemas de regresión o clasificación multiclase, ya que pueden representar eficazmente valores positivos y negativos. Aunque han recibido relativamente menos atención, han demostrado su eficacia en contextos específicos al ofrecer gradientes más estables y mejorar la convergencia en el entrenamiento profundo [36-43].

El diseño de la capa oculta es quizás el paso más empírico y fundamental del modelado. Esta investigación se apoya en el Teorema de Aproximación Universal, el cual establece que una red neuronal con una sola capa oculta y una cantidad finita de neuronas puede aproximar cualquier función continua en subconjuntos compactos de R^n , siempre que la función de activación sea no lineal y acotada. En el caso de los sistemas RFH, donde las interacciones entre la temperatura operativa y el flujo masico son altamente no lineales y dependen de la inercia térmica de los materiales, una sola capa oculta con funciones de transferencia robustas es suficiente para capturar la complejidad del fenómeno sin incurrir en un costo computacional excesivo que dificultaría la posterior fase de inversión.

3.4. Funciones de transferencia conformables

La incorporación del cálculo fraccionario en las funciones de transferencia ha dado lugar recientemente a mejoras significativas en el rendimiento y la simplificación de los modelos predictivos. Aunque el concepto de implementar el cálculo fraccionario ya se había considerado anteriormente, no fue hasta que Khalil introdujo su definición de

derivada fraccionaria [44] cuando esta implementación se hizo viable. En consecuencia, esta definición de cálculo fraccionario satisface las propiedades fundamentales de la diferenciación, incluyendo la derivada de una constante, la regla del producto, la regla del cociente y la regla de la cadena. Esto allana el camino para la posible generalización del cálculo a órdenes no enteros.

La viabilidad de estas funciones radica en la elegancia matemática de la definición de Khalil. A diferencia de otras definiciones de cálculo fraccionario (como Caputo o Riemann-Liouville), la derivada conformable preserva las propiedades clásicas del cálculo diferencial, lo que permite su integración directa en el entrenamiento de redes neuronales. La derivada conformable de orden α para una función f se define como:

$$T_{\alpha}(f)(t) = \lim_{\epsilon \rightarrow 0} \frac{f(t + \epsilon t^{1-\alpha}) - f(t)}{\epsilon}$$

(8)

Esta definición permite que el parámetro α (denotado como λ y ξ en este estudio) actúe como un modulador de la 'memoria' del sistema. En términos físicos, esto significa que la red neuronal puede ajustar la forma en que el historial térmico del edificio influye en la predicción actual, proporcionando una flexibilidad que las funciones de orden entero simplemente no poseen. Esto es vital para modelar la histéresis térmica presente en los sistemas de calefacción por suelo radiante.

Este énfasis condujo a la creación de funciones de transferencia conformables, que incorporan características del cálculo fractal en las funciones de transferencia tradicionales [22]. Las funciones conformables como CLOGSIG (ec. (9)), CTANSIG (Ec. (10)), CSOFTPLUS (ec. (11)), CSWISH (ec. (12)) y CELU (ec. (13)) ofrecen ventajas potenciales sobre sus homólogas convencionales, especialmente en lo que respecta a la adaptabilidad y el rendimiento en contextos específicos. Hay varios factores que determinan los criterios de selección para su aplicación.

$$f^{\xi}(x) = \frac{1}{1 + e\left(\lambda \frac{(-x)^{\xi}}{\xi}\right)}$$

(9)

$$f^{\xi}(x) = \frac{2}{1 + e\left(\lambda \frac{(-2x)^{\xi}}{\xi}\right)} - 1$$

(10)

$$f^{\xi}(x) = \ln\left(1 + e\left(\lambda \frac{(x)^{\xi}}{\xi}\right)\right)$$

(11)

$$f^{\xi}(x) = \frac{x}{1 + e\left(\lambda \frac{(-\beta x)^{\xi}}{\xi}\right)}$$

(12)

$$f^{\xi}(x) = \begin{cases} x, & x \geq 0, \\ \alpha \cdot \left(e\left(\lambda \frac{(x)^{\xi}}{\xi}\right) - 1\right), & x < 0. \end{cases}$$

(13)

La Figura 4 ilustra el comportamiento de las funciones de transferencia conformables cuando los parámetros λ y ξ se eligen arbitrariamente. Las funciones de transferencia convencionales se obtienen cuando $\lambda = 1$ y $\xi = 1$.

La capa de salida representa la respuesta variable. La configuración de esta capa depende de la naturaleza del problema en cuestión. Supongamos que el problema es una regresión, cuyo objetivo es predecir un valor continuo. En ese caso, la capa de salida puede consistir en una sola neurona que emplea una función lineal o de identidad para generar la predicción constante. Por último, la ecuación (14) muestra la función objetivo de la ANN con una capa oculta.




Figura 4. Comportamiento de las funciones conformables

$$Output = f_o \left[\sum_{n=1}^N \left[W_{o(o,n)} \left(f_h \left(\sum_{r=1}^R (W_{i(n,r)} P_{(r)} + b_{1(n)}) \right) \right) \right] + b_{2o} \right]$$

(14)

f_o es la función de transferencia aplicada a la capa de salida, W_o son los pesos asociados con la capa oculta, f_h es la función de transferencia aplicada a la capa oculta, W_i son los pesos asociados con la capa de entrada, P son las entradas de la ANN, b_1 y b_2 son los sesgos de la capa oculta y de salida.

3.5. Validación estadística

La validación estadística constituye la etapa final y crítica del modelado directo, permitiendo cuantificar la capacidad de generalización de la red neuronal antes de proceder a su inversión. Dado que las CANN operan con parámetros conformables que ajustan la curvatura de la función de activación, es imperativo utilizar métricas que evalúen el error desde distintas perspectivas: linealidad, magnitud absoluta y dispersión relativa.

3.5.1. Coeficiente de Correlación (R)

El coeficiente de correlación de Pearson evalúa la fuerza y la dirección de la relación lineal entre los valores reales de flujo de calor (q_t) y las predicciones del modelo (q_{tpred}). Su valor oscila entre -1 y 1, donde un valor cercano a la unidad indica una concordancia casi perfecta. En esta tesis, el R es fundamental para verificar que la introducción del parámetro conformable α no distorsione la linealidad esperada del fenómeno físico en rangos de operación estables. Se calcula mediante la ecuación:

$$R = \frac{\sum_{i=1}^n (q_{t,exp} - \overline{q_{t,exp}})(q_{t,pred} - \overline{q_{t,pred}})}{\sqrt{\sum_{i=1}^n (q_{t,exp} - \overline{q_{t,exp}})^2 \sum_{i=1}^n (q_{t,pred} - \overline{q_{t,pred}})^2}}$$

(15)

3.5.2. Error Cuadrático Medio *RMSE*

El *RMSE* es la métrica de costo principal durante el entrenamiento con el algoritmo Levenberg-Marquardt. Al elevar los errores al cuadrado, esta métrica penaliza de manera más severa las desviaciones grandes (outliers). Para el sistema RFH, un *RMSE* bajo es indicativo de que el modelo es capaz de manejar los picos de flujo de calor sin generar desviaciones peligrosas que podrían derivar en un sobrecalentamiento de la estructura o en un cálculo erróneo del confort.

$$RMSE = \frac{1}{n} \sum_{i=1}^n (q_{t,exp} - q_{t,pred})^2$$

(16)

3.5.3. Error Porcentual Absoluto Medio (*MAPE*)

A diferencia del *RMSE*, el *MAPE* expresa el error en términos relativos (porcentaje), lo que facilita su interpretación para los ingenieros y diseñadores de sistemas térmicos. Esta métrica es especialmente valiosa en esta investigación porque permite comparar la precisión del modelo en diferentes escalas de flujo de calor (desde 8.1 hasta 193.9 W/m^2) de manera equitativa, proporcionando una visión clara de la fiabilidad del sistema en condiciones de baja y alta demanda energética.

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^n \left| \frac{q_{t,exp} - q_{t,pred}}{q_{t,exp}} \right| \right) \times 100$$

(17)

3.6. Estrategia de control con Redes Neuronales Artificiales Inversas (ANNi)

El desarrollo de modelos ANN representa un enfoque potente para optimizar diversos aspectos, como el tiempo, el coste y el error, en la representación de fenómenos complejos utilizando variables operativas. Los modelos ANNi introducen un enfoque de inversión innovador al transformar las variables objetivo en entradas del modelo. Esta

inversión permite al modelo recibir las variables objetivo y generar las variables operativas necesarias para lograr ese resultado. Al aprovechar los modelos ANN, los investigadores pueden mejorar su capacidad para manipular y controlar los sistemas de manera eficiente para lograr los resultados específicos deseados [25,26,48-50].

Para lograr la aplicación óptima de los modelos ANNi, es esencial tener en cuenta los siguientes puntos clave:

- Desarrollar una ecuación que represente fielmente el fenómeno subyacente.
- Identificar y mantener las variables específicas del contexto a lo largo del análisis.
- Elaborar una estrategia de inversión del modelo.
- Optimizar las variables de salida para mejorar el rendimiento y la precisión.
- Simular el modelo mediante la generación de escenarios.

Comenzamos formulando meticulosamente la ecuación para delinear el fenómeno cautivador. Esta ecuación se obtiene incorporando la función de transferencia, los pesos y los sesgos adquiridos durante el entrenamiento CANN en la función objetivo (ec. (14)). Esto establece una base sólida para el modelo, lo que permite una representación precisa de la dinámica subyacente. A continuación, es crucial identificar y mantener constantes las variables específicas del contexto, que, aunque importantes, deben ser más generalizables. Esto simplifica el análisis sin comprometer la validez del enfoque. Esta estrategia dirige los esfuerzos de optimización hacia factores operativos manipulables que son críticos para la mejora del sistema.

El proceso de inversión comienza estableciendo la ecuación del modelo en cero en relación con las variables operativas manipulables, un paso crucial para identificar los puntos operativos óptimos. Este procedimiento permite una intervención directa y eficaz en estas variables, guiándolas hacia los objetivos de optimización deseados. Posteriormente, estas y las variables objetivas se separan del modelo general y se convierten en entradas en el nuevo modelo ANNi. Este enfoque fomenta una estructura clara y organizada, agilizando las simulaciones y simplificando las tareas de optimización.

Durante la fase de optimización, se emplean algoritmos genéticos (GA) y la optimización por enjambre de partículas (PSO) debido a su notable capacidad para navegar por espacios de búsqueda complejos y converger en soluciones óptimas [51-56]. Los AG simulan la evolución de los organismos vivos, en la que los individuos más aptos dominan sobre los menos aptos, asemejándose a los mecanismos de evolución biológica como la selección natural, el cruce y la mutación [57]. La PSO se inspira en el comportamiento colectivo de las aves o los pelícanos. Su objetivo es descubrir la solución óptima para un problema ajustando continuamente las posiciones y velocidades de las partículas dentro de una matriz [58].

La elección de GA y PSO sobre métodos deterministas (como el método de Newton o el Descenso de Gradiente) para la inversión del modelo CANN se basa en el equilibrio entre **exploración y explotación**. Debido a que la función objetivo resultante de la inversión de una red conformable es altamente no convexa y puede presentar múltiples mínimos locales, un método basado en el gradiente se estancaría prematuramente. Los Algoritmos Genéticos, mediante sus operadores de mutación, aseguran una **exploración** global del espacio de parámetros del sistema RFH. Por otro lado, la Optimización por Enjambre de Partículas (PSO) destaca en la **explotación** de las mejores soluciones encontradas por el grupo, acelerando la convergencia hacia los valores óptimos de flujo masico y temperatura del fluido. Esta combinación asegura que el diseño funcional del control térmico sea no solo preciso, sino globalmente eficiente.

La inspiración detrás de los optimizadores bioinspirados les permite explorar a fondo los espacios de soluciones, manteniendo la diversidad y evitando la convergencia prematura hacia soluciones subóptimas. Esta capacidad de exploración indiscriminada, su versatilidad y su capacidad de ejecución paralela los posicionan como herramientas eficientes para optimizar los modelos ANNi. En última instancia, el rendimiento de los optimizadores se yuxtapone con el fenómeno que se examina.

El proceso de simulación del modelo *CANNi* culmina en la generación de escenarios, una tarea que exige el cumplimiento de las prácticas convencionales que deben estar en consonancia con las normas y reglamentos aplicables. El cumplimiento de las normas establecidas garantiza la credibilidad y la pertinencia de los escenarios generados

3.6.1. Consideraciones del escenario de prueba

El cumplimiento del estándar Passive House es fundamental para garantizar que el modelo sea aplicable a la edificación sustentable de vanguardia. La selección de climas polar, frío y templado no es arbitraria; busca estresar el modelo *CANNi* ante condiciones de diseño extremas. En el clima polar, el sistema debe demostrar su capacidad de carga máxima, mientras que, en el templado, debe mostrar su precisión ante fluctuaciones rápidas entre el día y la noche. Las ecuaciones de balance térmico (14 y 15) actúan como el 'vínculo de realidad' de la tesis: la Ec. (14) cuantifica la fuga de energía a través de la envolvente (muros y ventanas), mientras que la Ec. (15) dicta cuánta energía debe inyectar el sistema hidráulico para compensarla. Al resolver este balance mediante el modelo inverso, la tesis pasa de una predicción teórica a una herramienta de ingeniería de control dinámico en tiempo real.

1. Siguiendo las normas establecidas por Passive House [58], se seleccionaron tres ciudades para representar diferentes condiciones climáticas: polar, fría y templada. Basándose en estas clasificaciones, se establecieron los valores estándar de transmitancia térmica (U) para cada zona. Utilizando la herramienta POWER de la NASA [60], se determinó el día más frío de 2021 en cada ciudad, organizando los datos en la Tabla 3.

Se recopilaron datos de temperatura por hora de cada ciudad para analizar la respuesta del sistema de control a fluctuaciones significativas de temperatura. Esta metodología nos permite evaluar la eficiencia del sistema en diversas condiciones climáticas y optimizar su rendimiento para mejorar la eficiencia energética y el confort.

2. Las dimensiones consideradas para la habitación son las siguientes:
3. Anchura: cuatro metros.
4. Longitud: cinco metros.
5. Altura: dos metros y medio.
6. Durante las pruebas, se identificaron variables específicas relacionadas con los materiales utilizados en el sistema de calefacción radiante:

- a. $Flujo\ Másico(m_f) = 0.0323 \frac{kg}{s}$

b. Resistencia al calor (R_s) = $0.241 \frac{m^2 K}{W}$

Adicionalmente, se establecieron constantes para asegurar condiciones de muestra optimas:

c. Temperatura de confort térmico (T_{comf}) = $20 ^\circ C$

d. Area total de las paredes del cuarto = $85m^2$

e. Area total de la instalación del sistema = $20m^2$

f. Ganancias de calor $\left(\begin{array}{c} \text{Calor total generado por personas y} \\ \text{dispositivos electrónicos} \end{array} \right) = 300W$

7. Utilizando las variables y constantes definidas, se utilizaron ecuaciones básicas de balance térmico:

a. Transferencia de calor a través de la envolvente del edificio:

$$\bar{Q} = U * (A_t - A_{rf}) * (T_{comf} - \overline{T_{hr}})$$

(18)

$$Q = \text{Calor transferido promedio (W)}$$

$$U = \text{Coeficiente de transferencia termica total} \left(\frac{W}{m^2 K} \right)$$

$$A_t = \text{Area total de las paredes que transfieren calor}(m^2)$$

$$A_{rf} = \text{Area total de la instalación del sistema}(m^2)$$

$$T_{comf} = \text{Temperatura de confort térmico}(K)$$

$$T_{hr} = \text{Temperatura registrada por hora}(K)$$

b. Flujo de calor a través de la instalación del sistema:

$$q_t = \frac{Q - Q_{gain}}{A_{rf}}$$

(19)

$$q_t = \text{Tasa de flujo de calor del sistema} \left(\frac{W}{m^2} \right)$$

$$Q = \text{Calor transferido}(W)$$

$$Q_{gain} = \text{Ganancias de calor}(W)$$

Utilizando las ecuaciones (18) y (19), se calculó la tasa de transferencia de calor requerida por el sistema RFH para mantener la habitación a la temperatura de confort establecida de 20 °C. Posteriormente, aprovechando el flujo de calor (m_f), la resistencia térmica (R_s) y la tasa de flujo de calor (q_t) identificados previamente, se llevó a cabo una optimización utilizando la ecuación del modelo de red neuronal artificial con mejor rendimiento. Esta optimización tenía como objetivo determinar los valores óptimos para la temperatura de funcionamiento (T_{op}) y la temperatura media del fluido (T_{wm}), con el fin de garantizar la máxima eficiencia y el confort térmico dentro de la habitación.

La temperatura de funcionamiento es una medida importante que refleja la percepción térmica de una persona en un espacio determinado. Por este motivo, se eligió como parámetro para analizar la precisión del modelo en términos de detección térmica real dentro del edificio. Para realizar este análisis, se calculó la media del vector de temperaturas operativas obtenidas y se analizó para ver si los valores resultantes, obtenidos mediante algoritmos de optimización, reflejan con precisión la realidad térmica experimentada por los ocupantes del edificio. Este enfoque garantiza que el sistema de calefacción radiante no solo cumpla los requisitos técnicos, sino que también proporcione el confort térmico deseado.

Se calculó la temperatura superficial para evaluar la eficacia del modelo en cuanto al confort térmico en la superficie del sistema de calefacción por suelo radiante (RFH). Este análisis se realizó utilizando la ecuación (20) [17], que facilita una estimación precisa de la temperatura superficial y su influencia en el confort de los ocupantes. Esta metodología garantiza que la superficie del RFH funcione dentro de los parámetros óptimos para el bienestar del usuario, proporcionando una perspectiva completa de la capacidad del sistema para mantener un ambiente confortable.

$$q_t = \frac{T_{wall} - T_{op}}{R_s} \rightarrow T_{wall} = q_t * R_s + T_{op}$$

(20)

$$q_t = \text{Tasa de flujo de calor del sistema} \left(\frac{W}{m^2} \right)$$

$$R_s = \text{Resistencia al calor} \left(\frac{m^2 K}{W} \right)$$

$$T_{wall} = \text{Temperatura de la pared} (K)$$

$$T_{op} = \text{Temperatura operativa} (K)$$

Tabla 3. Valores para cada escenario

Ciudad	Tipo de clima	Transmitancia térmica $U \left(\frac{W}{m^2 K} \right)$	Día seleccionado
Múnich, Alemania	Templado frío	0.35	13 de febrero de 2021
Vancouver, Canadá	Frío	0.30	21 de diciembre de 2021
Murmansk, Rusia	Polar	0.25	11 de enero de 2021

4. Resultados y discusión.

En esta sección se presentan y analizan los resultados de los experimentos realizados con diferentes arquitecturas de ANN para modelar el problema. Para el modelado de la ANN se utilizó el software MATLAB® versión 2021b, concretamente la caja de herramientas de optimización integrada en el software. En el proceso de desarrollo del modelo se llevaron a cabo varios pasos cruciales, siendo uno de los más importantes el preprocesamiento de los datos. La arquitectura fundamental de la ANN comprendía cuatro neuronas en la capa de entrada (representadas por m_f , R_s , T_{wm} , T_{op}) y una en la capa de salida (q_t), y el número de neuronas en la capa oculta se determinó mediante ajustes empíricos durante el proceso de desarrollo del modelo.

El conjunto inicial de modelos exploró el impacto de variar el número de neuronas en la capa oculta de 1 a 5. Estos modelos emplearon funciones de transferencia convencionales como LOGSIG, TANSIG, SOFTPLUS, SWISH y ELU. El límite máximo

de cinco neuronas en la capa oculta se seleccionó basándose en investigaciones previas en el campo [17].

El segundo grupo de modelos se centró en funciones de transferencia conformables (CLOGSIG, CTANSIG, CSOFTPLUS, CSWISH, CELU), con un número de neuronas en la capa oculta que oscilaba entre 1 y 5. El objetivo de esta investigación era evaluar el rendimiento de estas funciones de transferencia más recientes a la hora de abordar el problema de modelización.

Se realizaron diez mil simulaciones para cada uno de los 50 modelos generados. El entrenamiento de los modelos ANN utilizó el algoritmo de optimización Levenberg-Marquardt. Se aplicó un filtro inicial utilizando una prueba de pendiente-intercepción con un nivel de confianza del 99 %. Este filtro identificó los modelos con métricas de rendimiento robustas (R , $RMSE$, $MAPE$) y aquellos que representaban con precisión las relaciones lineales entre las variables. De los 50 modelos creados, 44 superaron con éxito la prueba de pendiente-intercepción, 19 de ellos utilizando funciones de transferencia tradicionales y 25 utilizando funciones de transferencia conformables. Las tablas 4 y 5 muestran los resultados obtenidos de los modelos clásicos y conformables, respectivamente. Estas tablas incluyen las métricas $b_{Superior}$ y $b_{Inferior}$, que representan los enfoques superior e inferior de la intersección, y $m_{Superior}$ y $m_{Inferior}$, que indican los enfoques de pendiente superior e inferior. Las figuras 5, 6 y 7 proporcionan información sobre el rendimiento de cada modelo en términos de las métricas evaluadas, a saber, R , $MAPE$ y $RMSE$.

Tabla 4 Resultados de los modelos clásicos.

Función	Arquitectura	R	MAPE	RMSE	Intercepto ($I \pm 0$)		Pendiente ($S \pm 1$)	
					$b_{Superior}$	$b_{Inferior}$	$m_{Superior}$	$m_{Inferior}$
TANSIG	4:1:1	0.93067	20.22276	0.07197	0.08578	0.00418	0.96482	0.74704
TANSIG	4:2:1	0.99060	8.08018	0.02697	0.02527	-0.00725	1.01461	0.92782
TANSIG	4:3:1	0.99606	5.34176	0.01744	0.01325	-0.00819	1.02193	0.96471

TANSIG	4:4:1	0.99872	2.24290	0.01008	0.01009	-0.00207	1.00695	0.97448
TANSIG	4:5:1	0.99674	4.23825	0.01668	0.01987	0.00059	1.00855	0.95709
LOGSIG	4:1:1	0.93051	20.30231	0.07271	0.09223	0.01379	0.92644	0.71709
LOGSIG	4:2:1	0.99039	7.92894	0.02719	0.02343	-0.00970	1.02280	0.93436
LOGSIG	4:3:1	0.99738	3.50351	0.01458	0.01630	-0.00099	1.00618	0.96003
LOGSIG	4:4:1	0.99928	1.67172	0.00760	0.00800	-0.00111	1.00472	0.98041
LOGSIG	4:5:1	0.99908	2.03641	0.00850	0.00568	-0.00475	1.01510	0.98726
SOFTPLUS	4:1:1	0.92945	19.82693	0.07265	0.08621	0.00443	0.95869	0.74041
SOFTPLUS	4:2:1	0.98896	6.17565	0.02938	0.02984	-0.00501	1.00560	0.91259
SOFTPLUS	4:3:1	0.99732	4.10409	0.01445	0.01164	-0.00607	1.01915	0.97187
SOFTPLUS	4:4:1	0.99852	1.94753	0.01082	0.01043	-0.00263	1.00651	0.97164
SOFTPLUS	4:5:1	0.99893	2.32957	0.00915	0.00504	-0.00621	1.01470	0.98468
SWISH	4:1:1	0.93571	19.75337	0.06948	0.08264	0.00416	0.96315	0.75367
SWISH	4:2:1	0.98729	9.26987	0.03158	0.02586	-0.01279	1.04167	0.93850
SWISH	4:3:1	0.99699	3.58373	0.01551	0.01550	-0.00297	1.00407	0.95478
SWISH	4:4:1	0.99890	2.73726	0.00929	0.00831	-0.00302	1.00960	0.97935
SWISH	4:5:1	0.99950	1.27538	0.00631	0.00364	-0.00398	1.00713	0.98680
ELU	4:1:1	0.94364	18.48479	0.06517	0.07853	0.00411	0.97440	0.77574
ELU	4:2:1	0.99626	4.56331	0.01700	0.01243	-0.00842	1.01923	0.96359
ELU	4:3:1	0.99778	3.35102	0.01317	0.01102	-0.00498	1.01016	0.96745
ELU	4:4:1	0.99764	3.69789	0.01366	0.01332	-0.00321	1.01173	0.96763
ELU	4:5:1	0.99795	3.33417	0.01278	0.00961	-0.00595	1.02131	0.97978

Tabla 5. Resultados de los modelos conformables

Función	Arquitectura	R	MAPE	RMSE	Intercepto ($l \pm 0$)		Pendiente ($S \pm 1$)	
					$b_{Superior}$	$b_{Inferior}$	$m_{Superior}$	$m_{Inferior}$
CTANSIG	4:1:1	0.9459	15.94178	0.06383	0.06625	-0.00914	1.00733	0.80610
CTANSIG	4:2:1	0.9973	3.50128	0.01445	0.01174	-0.00596	1.01571	0.96845
CTANSIG	4:3:1	0.9992	2.10998	0.00780	0.00568	-0.00370	1.00592	0.98086
CTANSIG	4:4:1	0.9991	2.44344	0.00837	0.00672	-0.00355	1.00985	0.98244
CTANSIG	4:5:1	0.9995	1.85441	0.00622	0.00370	-0.00378	1.00633	0.98637
CLOGSIG	4:1:1	0.9459	15.90834	0.06383	0.06668	-0.00850	1.00440	0.80372
CLOGSIG	4:2:1	0.9973	3.50179	0.01445	0.01174	-0.00597	1.01572	0.96846
CLOGSIG	4:3:1	0.9989	1.47395	0.00927	0.00943	-0.00165	1.00315	0.97358
CLOGSIG	4:4:1	0.9993	1.94817	0.00748	0.00362	-0.00544	1.01073	0.98654
CLOGSIG	4:5:1	0.9996	1.10455	0.00547	0.00564	-0.00087	1.00137	0.98399
CSOFTPLUS	4:1:1	0.9473	17.38426	0.06298	0.07213	-0.00080	0.98704	0.79239
CSOFTPLUS	4:2:1	0.9967	4.35567	0.01586	0.01344	-0.00595	1.01874	0.96697
CSOFTPLUS	4:3:1	0.9992	1.60950	0.00794	0.00734	-0.00219	1.00358	0.97814
CSOFTPLUS	4:4:1	0.9993	1.89783	0.00743	0.00446	-0.00463	1.00977	0.98553
CSOFTPLUS	4:5:1	0.9994	1.53243	0.00630	0.00535	-0.00236	1.00684	0.98627
CSWISH	4:1:1	0.9476	17.08337	0.06300	0.06250	-0.01288	1.02273	0.82155
CSWISH	4:2:1	0.9944	4.25775	0.02085	0.01711	-0.00792	1.01191	0.94510
CSWISH	4:3:1	0.9985	2.06907	0.01092	0.00669	-0.00642	1.01056	0.97557
CSWISH	4:4:1	0.9995	1.44287	0.00561	0.00420	-0.00269	1.00675	0.98835
CSWISH	4:5:1	0.9995	1.02773	0.00574	0.00577	-0.00114	1.00285	0.98442
CELU	4:1:1	0.9507	15.82668	0.06098	0.06767	-0.00401	1.00252	0.81118

CELU	4:2:1	0.9959	6.33137	0.01761	0.01358	-0.00803	1.02012	0.96243
CELU	4:3:1	0.9980	2.66372	0.01243	0.01035	-0.00476	1.00985	0.96950
CELU	4:4:1	0.9980	3.25638	0.01232	0.00941	-0.00565	1.01935	0.97916
CELU	4:5:1	0.9980	3.27397	0.01243	0.01269	-0.00220	1.00536	0.96559




Figura 5. Rendimiento R de los modelos con diferente número de neuronas en la capa oculta




Figura 6. Rendimiento MAPE de los modelos

Se analizó el rendimiento de los modelos ANN en relación con las características térmicas del sistema RFH. Los modelos conformables demostraron una capacidad superior para predecir el rendimiento del RFH, lo que se refleja en la capacidad de estos modelos para ajustar con precisión los parámetros operativos necesarios para mantener una temperatura agradable. CLOGSIG 4:5:1 y CSWISH 4:5:1 superan constantemente a otros modelos, independientemente del número de neuronas.




Figura 7. Rendimiento RMSE de los modelos

Teniendo en cuenta el número de neuronas en la selección del modelo, CTANSIG 4:3:1 se perfila como la opción más equilibrada.

Este modelo cumple los criterios de alta correlación y precisión de predicción y ofrece ventajas de eficiencia computacional gracias a su estructura simplificada. La reducción del número de neuronas disminuye los recursos computacionales necesarios para el entrenamiento y la inferencia, así como el riesgo de sobreajuste, lo que conduce a una generalización más robusta de los nuevos datos.

Partiendo de nuestro mejor modelo, derivamos una ecuación que describe su comportamiento sustituyendo la función de transferencia, los pesos y los sesgos obtenidos durante el entrenamiento CANN en la función objetivo Ec. (14). A continuación, la simplificamos mediante factorización algebraica para proporcionar una representación más concisa, como se muestra en la Ec. (21). La Figura 8 ilustra la eficacia de la capacidad predictiva del modelo resultante, destacando cómo puede predecir con precisión las condiciones óptimas de funcionamiento del sistema RFH.




Figura 8. Regresión obtenida del modelo CTANSIG 4:3:1

$$q_t = \begin{pmatrix} \frac{0.0946}{\left(1 + e^{1.9082 * ((-2) * (0.6535 * m_f - 0.0731 * R_s - 0.1819 * T_m + 1.6947 * T_{op} - 0.4413))^{0.5756}}\right)} + \\ \frac{0.1089}{\left(1 + e^{2.6793 * ((-2) * (-0.0453 * m_f - 0.0017 * R_s + 0.8740 * T_m - 0.3297 * T_{op} + 0.5309))^{0.4702}}\right)} + \\ \frac{0.2767}{\left(1 + e^{2.8626 * ((-2) * (-0.0302 * m_f - 1.1244 * R_s + 0.6397 * T_m - 0.3449 * T_{op} + 0.3215))^{0.5506}}\right)} + \\ 0.1636 \end{pmatrix} \quad (21)$$

Dada la variabilidad de m_f y R_s en diferentes emplazamientos, se decidió mantenerlos constantes. Por lo tanto, el modelo CINN queda en función de T_{wm} y T_{op} , como se muestra en la Ec. (22). Posteriormente, estas variables, junto con q_t , se separan del modelo general y se convierten en entradas del nuevo modelo CINN. La reconfiguración del modelo condujo a una simplificación significativa del proceso de optimización, permitiendo la aplicación directa del GA para determinar los valores óptimos de T_{wm} y T_{op} .

$$f(T_m, T_{op}) = \begin{pmatrix} \frac{0.0946}{\left(1 + e^{1.9082 * ((-2) * (0.6535 * m_f - 0.0731 * R_s - 0.1819 * T_m + 1.6947 * T_{op} - 0.4413))^{0.5756}}\right)} + \\ \frac{0.1089}{\left(1 + e^{2.6793 * ((-2) * (-0.0453 * m_f - 0.0017 * R_s + 0.8740 * T_m - 0.3297 * T_{op} + 0.5309))^{0.4702}}\right)} + \\ \frac{0.2767}{\left(1 + e^{2.8626 * ((-2) * (-0.0302 * m_f - 1.1244 * R_s + 0.6397 * T_m - 0.3449 * T_{op} + 0.3215))^{0.5506}}\right)} + \\ 0.1636 \end{pmatrix} - q_{t_{desired}} \quad (22)$$




Figura 9. Proceso CANNi

La Figura 9 ilustra el diagrama conceptual del *CANNi*, haciendo hincapié en la interacción entre las variables de entrada (T_{wm} , T_{op} y q_t) y el proceso de optimización facilitado por GA y PSO, lo que conduce a la predicción de las condiciones operativas óptimas. Este diagrama no solo delinea el marco interno del modelo *CANNi*, sino que también aclara el enfoque empleado para optimizar las variables clave dentro de las restricciones definidas. Muestra cómo estas optimizaciones pueden mejorar significativamente el rendimiento térmico del sistema RFH en diversos escenarios climáticos.

CANNi se simuló creando escenarios que reflejan la implementación típica de RFH en diversas zonas climáticas. Las consideraciones para el desarrollo de escenarios se explicaron en la sección de metodología.

La Figura 10, Figura 11 y Figura 12 presentan gráficos importantes para Múnich, Vancouver y Murmansk. El gráfico «a» ilustra la temperatura real registrada en el día más frío en estas ciudades, mientras que el gráfico «b» indica la cantidad necesaria para mantener una temperatura agradable de 20 °C. Este análisis constituye la base para comprender el uso de la energía en climas fríos, lo cual es esencial para evaluar la eficacia de las técnicas de optimización. Este conocimiento nos permite discernir la energía necesaria para mantener unas condiciones interiores confortables y cómo estas demandas fluctúan en respuesta a condiciones exteriores extremas.




Figura 10. Calor total vs Temperatura en Múnich

La carga máxima de calefacción requerida para cada ciudad, indicada por el valor máximo de q_t , corresponde a la temperatura exterior más baja registrada durante el año. La tabla 6 compara los valores típicos de carga de calefacción para cada tipo de clima, según la ASHRAE [61], con los obtenidos en este estudio.




Figura 11. Calor total vs Temperatura en Vancouver




Figura 12. Calor total vs Temperatura en Murmansk

La carga máxima de calefacción está sujeta a varios factores interrelacionados, que no se exploran exhaustivamente en este análisis. Por lo general, las cargas máximas de calefacción se observan entre las 5 y las 6 de la mañana, coincidiendo con las temperaturas exteriores más bajas. Sin embargo, en nuestro estudio, el momento en que se produce la carga máxima de calefacción puede desviarse de esta norma. Esta desviación se debe a que nuestro análisis se centra en cómo el sistema de calefacción por suelo radiante (RFH) responde a los datos de temperatura optimizados proporcionados por la herramienta POWER, en lugar de adherirse a las tendencias horarias típicas de descenso de las temperaturas exteriores.

La Figura 13, Figura 14 y Figura 15 presentan datos sobre el rendimiento de GA y PSO al ajustar T_{wm} . Aunque las temperaturas del fluido pueden parecer algo bajas, esto contrasta con las Figura 16, Figura 17 y Figura 18 que muestran que los ajustes de la temperatura de funcionamiento se acercan al valor propuesto de 20 °C, considerado como la temperatura de confort térmico, y la temperatura de la pared T_{wall} se alcanza con los valores T_{wm} . En el escenario de Múnich (véase la Figura 16), GA mantiene de forma constante una temperatura de funcionamiento más cercana al objetivo de confort

de 20 °C (21,5 °C) que PSO (19,9 °C). Además, la temperatura de la superficie de la pared T_{wall} se mantiene dentro del rango confortable de 20 °C a 30 °C.

Esta observación sugiere que GA destaca en el ajuste fino de las condiciones para lograr un entorno térmico óptimo. De manera similar, en el escenario de Vancouver (véase la Figura 17), el GA mantiene una temperatura de funcionamiento media ligeramente superior (21,4 °C) a la del PSO (19,9 °C), manteniendo el T_{wall} en el mismo rango de temperatura de confort deseado, lo que indica que el GA es más fiable a la hora de garantizar el confort térmico, especialmente en climas más cálidos. En el escenario de Murmansk (véase la Figura 18), GA alcanza una temperatura media de funcionamiento notablemente más alta (21,7 °C) que PSO (20 °C), lo que demuestra su capacidad para adaptarse y responder de manera eficiente a condiciones climáticas más severas.




Figura 13. Optimización de la temperatura media del fluido en Múnich




Figura 14. Optimización de la temperatura media del fluido en Vancouver




Figura 15. Optimización de la temperatura media del fluido en Murmansk




Figura 16. Comparativa entre Temperatura Operativa y Temperatura Media del Fluido vs Temperatura del suelo en Múnich




Figura 17. Comparativa entre Temperatura Operativa y Temperatura Media del Fluido vs Temperatura del suelo en Vancouver




Figura 18. Comparativa entre Temperatura Operativa y Temperatura Media del Fluido vs Temperatura del suelo en Murmansk

La Figura 19, Figura 20 y Figura 21 comparan directamente los errores asociados con la tarea de cada optimizador de ajustar los parámetros necesarios para alcanzar el confort térmico. En el escenario de Múnich (véase la Figura 19), el GA muestra de forma constante errores más bajos a lo largo del día que el PSO, lo que implica una mayor precisión en los ajustes de los parámetros para mantener el confort térmico. De manera similar, en el escenario de Vancouver (véase la Figura 20), se observan patrones de error similares a los observados en Múnich. El GA muestra sistemáticamente errores más bajos, lo que subraya su mayor eficiencia y fiabilidad en el ajuste de las condiciones de confort térmico. A pesar de las gélidas condiciones climáticas de Murmansk (véase la Figura 21), el GA mantiene una tasa de error más baja que el PSO, lo que demuestra su resistencia y capacidad para realizar ajustes precisos incluso en entornos exigentes.




Figura 19. Errores de la optimización por hora entre GA y PSO para Múnich




Figura 20. Errores de la optimización por hora entre GA y PSO para Vancouver




Figura 21. Errores de la optimización por hora entre GA y PSO para Murmansk

Las figuras 10 a 21 ilustran la superioridad constante del GA sobre el PSO en diferentes contextos climáticos. El GA mantiene constantemente temperaturas operativas más cercanas o superiores al umbral deseado y presenta menos errores en su ejecución, lo que se traduce en una mayor precisión y eficiencia. Estos hallazgos subrayan la importancia de seleccionar el optimizador adecuado para las aplicaciones de transferencia de calor y confort térmico en edificios, especialmente cuando se abordan variaciones climáticas sustanciales.

5. Conclusiones

El estudio muestra la eficacia de los modelos conformables al destacar su notable capacidad para establecer correlaciones y reducir errores. Estos atributos subrayan la sólida capacidad de los modelos para abordar las complejidades del confort térmico. La identificación de CTANSIG 4:3:1 como el modelo óptimo subraya un equilibrio armonioso entre precisión y eficiencia computacional, lo que pone de relieve su utilidad pragmática en la modelización de entornos con temperatura controlada. En este contexto, la

integración de algoritmos de optimización (como GA y PSO) en el marco de *CANNi* se ha convertido en una potente estrategia para identificar las condiciones térmicas óptimas. Este enfoque facilita una exploración exhaustiva dentro del espacio de soluciones, lo que pone de manifiesto la adaptabilidad y capacidad de respuesta de estas herramientas a los parámetros de entrada en constante evolución. La fusión de los modelos *CANNi* con técnicas de optimización avanzadas representa una vía innovadora para mejorar el diseño y el rendimiento de RFH.

La adaptabilidad y solidez del modelo quedan patentes en su simulación en diversas zonas climáticas, incluidas las regiones polares, frías y de temperaturas bajas. El ajuste del modelo para adaptarse a condiciones extremas en lugares como Murmansk, Vancouver y Múnich subraya su eficacia a la hora de ofrecer soluciones térmicas óptimas en diferentes contextos climáticos. Esta versatilidad pone de relieve la utilidad pragmática del modelo para optimizar la RFH y mejorar el confort térmico.

Este estudio representa un avance sustancial en ingeniería térmica y construcción sostenible al ofrecer una metodología y herramientas para el diseño y la optimización eficientes de RFH. La integración de *CANNi* con técnicas de optimización aborda de manera eficaz los retos contemporáneos en la regulación del confort térmico.

6. Referencias

- [1] IEA. World Energy Outlook 2022 / The global energy crisis. <https://www.iea.org/reports/world-energy-outlook-2022/the-global-energy-crisis?language=es>. (Accessed 23 April 2024).
- [2] IEA. World electricity generation mix by fuel, 1971-2019. <https://www.iea.org/data-and-statistics/charts/world-electricity-generation-mix-by-fuel-1971-2019>. (Accessed 23 April 2024).
- [3] IEA. Coal. <https://www.iea.org/energy-system/fossil-fuels/coal#tracking>. (Accessed 23 April 2024).
- [4] IEA. Annual change in generation and CO2 emissions from unabated coal-fired power plants in the Net Zero Scenario, 2015-2030. <https://www.iea.org/data-and-statistics/charts/annual-change-in-generation-and-co2-emissions-from-unabated-coal-fired-power-plants-in-the-net-zero-scenario-2015-2030>. (Accessed 23 April 2024).
- [5] IEA. Energy Statistics Data Browser. <https://www.iea.org/data-and-statistics/datatools/energy-statistics-data-browser?country=WORLD&energy=Electricity&year=2020>. (Accessed 23 April 2024).
- [6] IEA. Shares of residential energy consumption by end use in selected IEA countries, 2019. <https://www.iea.org/data-and-statistics/charts/shares-of-residential-energy-consumption-by-end-use-in-selected-iea-countries-2019>. (Accessed 23 April 2024).
- [7] IEA. Residential space heating and water heating consumption covered by minimum energy performance standards, 2000-2022. <https://www.iea.org/data-and-statistics/charts/residential-space-heating-and-water-heating-consumption-covered-by-minimum-energy-performance-standards-2000-2022>. (Accessed 23 April 2024).
- [8] IEA. Residential space cooling consumption covered by minimum energy performance standards by region, 2000-2022. <https://www.iea.org/data->

andstatistics/charts/residential-space-cooling-consumption-covered-by-minimumenergy-performance-standards-by-region-2000-2022. (Accessed 23 April 2024).

[9] IEA. World Energy Outlook 2022 / Outlook for electricity. <https://www.iea.org/reports/world-energy-outlook-2022/outlook-for-electricity?language=es>. (Accessed 23 April 2024).

[10] W. Chen, Y. Liu, X. Liang, F. Luo, T. Liao, S. Wang, X. Gao, Z. Zhang, Y. Fang, Experimental and numerical investigations on radiant floor heating system integrated with macro-encapsulated phase change material, *Energy* 282 (2023) 128375, <https://doi.org/10.1016/j.energy.2023.128375>.

[11] J. Zheng, T. Yu, B. Lei, C. Chen, Experimental study on the thermal performance of radiant floor heating system with the influence of solar radiation on the local floor surface, *Indoor Built Environ.* 1420326X221148729 (2023), <https://doi.org/10.1177/1420326X22114872>.

[12] O. Babaharra, K. Choukairy, S. Hamdaoui, K. Khallaki, S.H. Mounir, Thermal behavior evaluation of a radiant floor heating system incorporates a microencapsulated phase change material, *Constr. Build. Mater.* 330 (2022) 127293, <https://doi.org/10.1016/j.conbuildmat.2022.127293>.

[13] Jing, H., Quan, Z., Dong, R., Hao, L., Liu, Y., & Zhao, Y. (2022). Performance simulation and optimization of new radiant floor heating based on micro heat pipe array. In *Building Simulation* (pp. 1-14). Tsinghua University Press. DOI: 10.1007/s12273-021-0834-3.

[14] Y. Xu, B.B. Sun, L.J. Liu, X.Y. Liu, The numerical simulation of radiant floor cooling and heating system with double phase change energy storage and the thermal performance, *J. Storage Mater.* 40 (2021) 102635, <https://doi.org/10.1016/j.est.2021.102635>.

[15] M. Wang, P. Li, W. Liu, Generic mathematical formulation of the total heat transfer coefficients between heated radiant floor surfaces and rooms, *Build. Environ.* 211(2022) 108701, <https://doi.org/10.1016/j.buildenv.2021.108701>.

- [16] O. Acikgoz, A.B. Çolak, M. Camci, Y. Karakoyun, A.S. Dalkilic, Machine learning approach to predict the heat transfer coefficients pertaining to a radiant cooling system coupled with mixed and forced convection, *Int. J. Therm. Sci.* 178 (2022) 107624, <https://doi.org/10.1016/j.ijthermalsci.2022.107624>.
- [17] V. Verma, R. Nath, R. Tarodiya, Heat transfer prediction for radiant floor heating/cooling systems using artificial neural network (ANN), *Heat Transfer* 52 (4) (2023) 3135–3152, <https://doi.org/10.1002/htj.22820>.
- [18] L.S. Saoud, H. AlMarzouqi, Forecasting Solar Irradiance using Hybrid Stationary Wavelet Transform-Quaternion Valued Neural Network with a Softplus AMSGrad Learning Algorithm, *IEEE International Conference on Power Systems Technology* 1–6 (2022), <https://doi.org/10.1109/POWERCON53406.2022.9929612>.
- [19] Z. Zhang, J. Liu, G. Liu, J. Wang, J. Zhang, Robustness verification of swish neural networks embedded in autonomous driving systems, *IEEE Trans. Comput. Social Syst.* (2022), <https://doi.org/10.1109/TCSS.2022.3179659>.
- [20] R.R. Devaram, D. Beraldo, R. De Benedictis, M. Mongiovì, A. Cesta, LEMON: a lightweight facial emotion recognition system for assistive robotics based on dilated residual convolutional neural networks, *Sensors* 22 (9) (2022) 3366, <https://doi.org/10.3390/s22093366>.
- [21] Y. Lockner, C. Hopmann, W. Zhao, Transfer learning with artificial neural networks between injection molding processes and different polymer materials, *J. Manuf. Process.* 73 (2022) 395–408, <https://doi.org/10.1016/j.jmapro.2021.11.014>.
- [22] J.E. Solís-Pérez, J.A. Hernandez, A. Parrales, J.F. Gomez-Aguilar, A. Huicochea, Artificial neural networks with conformable transfer function for improving the performance in thermal and environmental processes, *Neural Netw.* 152 (2022) 44–56, <https://doi.org/10.1016/j.neunet.2022.04.016>.
- [23] R. Khalil, M. Al Horani, A. Yousef, M. Sababheh, A new definition of fractional derivative, *J. Comput. Appl. Math.* 264 (2014) 65–70, <https://doi.org/10.1016/j.cam.2014.01.002>.

- [24] Hernández, J. A. "Optimum operating conditions for heat and mass transfer in foodstuffs drying by means of neural network inverse." *Food Control* 20.4 (2009): 435-438. <https://doi.org/10.1016/j.foodcont.2008.07.005>
- [25] J. García-Morales, M. Cervantes-Bobadilla, J.A. Hernandez-Pérez, Y.I. Saavedra Benítez, M. Adam-Medina, G.V. Guerrero-Ramírez, Inverse artificial neural network control design for a double tube heat exchanger, *Case Studies in Thermal Engineering* 34 (2022) 102075, <https://doi.org/10.1016/j.csite.2022.102075>.
- [26] W. Ajbar, A. Parrales, U. Cruz-Jacobo, R.A. Conde-Gutiérrez, A. Bassam, O. A. Jaramillo, J.A. Hernandez, The multivariable inverse artificial neural network combined with GA and PSO to improve the performance of solar parabolic trough collector, *Appl. Therm. Eng.* 189 (2021) 116651, <https://doi.org/10.1016/j.applthermaleng.2021.116651>.
- [27] Y. Karakoyun, O. Acikgoz, A. Çebi, A. Koca, G. Çetin, A.S. Dalkilic, S. Wongwises, A comprehensive approach to analyze the discrepancies in heat transfer characteristics pertaining to radiant ceiling heating system, *Appl. Therm. Eng.* 187 (2021) 116517, <https://doi.org/10.1016/j.applthermaleng.2020.116517>.
- [28] X. Wu, J. Zhao, B.W. Olesen, L. Fang, F. Wang, A new simplified model to calculate surface temperature and heat transfer of radiant floor heating and cooling systems, *Energ. Buildings* 105 (2015) 285–293, <https://doi.org/10.1016/j.enbuild.2015.07.056>.
- [29] X. Jin, X. Zhang, Y. Luo, R. Cao, Numerical simulation of radiant floor cooling system: The effects of thermal resistance of pipe and water velocity on the performance, *Build. Environ.* 45 (11) (2010) 2545–2552, <https://doi.org/10.1016/j.buildenv.2010.05.016>.
- [30] Q.Q. Li, C. Chen, Y. Zhang, J. Lin, H.S. Ling, Simplified thermal calculation method for floor structure in radiant floor cooling system, *Energ. Buildings* 74 (2014) 182–190, <https://doi.org/10.1016/j.enbuild.2014.01.032>.
- [31] T. Cholewa, M. Rosinski, Z. Spik, M.R. Dudzinska, A. Siuta-Olcha, On the heat transfer coefficients between heated/cooled radiant floor and room, *Energ. Buildings* 66 (2013) 599–606, <https://doi.org/10.1016/j.enbuild.2013.07.065>.

- [32] E.D. Reyes-T´ellez, A. Parrales, G.E. Ram´ırez-Ramos, J.A. Hernandez, G. Urquiza, M.I. Heredia, F.Z. Sierra, Analysis of transfer functions and normalizations in an ANN model that predicts the transport of energy in a parabolic trough solar collector, *Desalin. Water Treat* 200 (2020) 23–41, <https://doi.org/10.5004/dwt.2020.26063>.
- [33] P. Stawicki, I. Volosyak, cVEP Training Data Validation—Towards Optimal Training Set Composition from Multi-Day Data, *Brain Sci.* 12 (2) (2022) 234, <https://doi.org/10.3390/brainsci12020234>.
- [34] R. Bousmaha, R.M. Hamou, A. Amine, Automatic selection of hidden neurons and weights in neural networks for data classification using hybrid particle swarm optimization, multi-verse optimization based on L´evy flight, *Evol. Intel.* 15 (3) (2022) 1695–1714, <https://doi.org/10.1007/s12065-021-00579-w>.
- [35] Yogitha, R., & Mathivanan, G. (2018). Performance analysis of transfer functions in an artificial neural network. In 2018 International Conference on Communication and Signal Processing (ICCSP) (pp. 0393-0397). IEEE. DOI: 10.1109/ICCSP.2018.8524387.
- [36] Wiemann, P. F., Kneib, T., & Hambuckers, J. (2021). Using the softplus function to construct alternative link functions in generalized linear models and beyond. *arXiv preprint arXiv:2111.14207*. DOI: 10.48550/arXiv.2111.14207.
- [37] Meili, S. (2021). Softplus Penalty Functions for Constrained Optimization. *arXiv preprint arXiv:2107.04541*. DOI: 10.48550/arXiv.2107.04541.
- [38] Iida, M., Takeishi, Y., & Takeuchi, J. I. (2022). On Fisher Information Matrix for Simple Neural Networks with Softplus Activation. In 2022 IEEE International Symposium on Information Theory (ISIT) (pp. 3001-3006). IEEE. DOI: 10.1109/ISIT50566.2022.9834516.
- [39] S. Sagheb, F.W. Liu, A. Bahremand, A. Kidane, R. LiKamWa, SWISH: A shiftingweight interface of simulated hydrodynamics for haptic perception of virtual fluid vessels, in: In Proceedings of the 32nd Annual ACM Symposium on User Interface Software and Technology, 2019, pp. 751–761, <https://doi.org/10.1145/3332165.3347870>.

- [40] Fatima, A., & Pethe, A. (2021). NVM device-based deep inference architecture using self-gated activation functions (Swish). In *Machine Vision and Augmented Intelligence—Theory and Applications: Select Proceedings of MAI 2021* (pp. 33-44). Springer Singapore. DOI: 10.1007/978-981-16-5078-9_4.
- [41] S. Sagheb, A. Bahreman, R. LiKamWa, B. Lahey, Swish: Shifting weight-based interfaces for simulated hydrodynamics in mixed-reality fluid vessels, in: *In Proceedings of the Thirteenth International Conference on Tangible, Embedded, and Embodied Interaction*, 2019, pp. 213–221, <https://doi.org/10.1145/3294109.3300988>.
- [42] B. Olimov, S. Karshiev, E. Jang, S. Din, A. Paul, J. Kim, Weight initialization based rectified linear unit activation function to improve the performance of a convolutional neural network model, *Concurrency and Computation: Practice and Experience* 33 (22) (2021) e6143.
- [43] Y.D. Zhang, S.C. Satapathy, D. Wu, D.S. Guttery, J.M. Gorriz, S.H. Wang, Improving ductal carcinoma in situ classification by convolutional neural network with exponential linear unit and rank-based weighted pooling, *Complex & Intelligent Systems* 7 (2021) 1295–1310, <https://doi.org/10.1007/s40747-020-00218-4>.
- [44] D. Zhao, M. Luo, General conformable fractional derivative and its physical interpretation, *Calcolo* 54 (2017) 903–917, <https://doi.org/10.1007/s10092-017-0213-8>.
- [45] S. Verma, *Estadística básica para el manejo de datos experimentales: aplicación en la geoquímica: (geoquimiometría)*, Universidad Nacional Autónoma de México, 2005.
- [46] Kumar, K., Khatkar, M., Sharma, K., Bhakhar, R., Chaudhary, P., Sateesh, N., Ramesh, G., Chhabra, S. & Maithili, K. (2023). Optimizations of Process Parameter for Erosion Wear Using Sustainable Machine Learning Approach. In *E3S Web of Conferences* (Vol. 430, p. 01178). EDP Sciences. DOI: 10.1051/e3sconf/202343001178.
- [47] D. Fitrianto, C. Sari, Rancang Bangun Alat Ukur Suhu Dan Kelembaban Tanah Menggunakan Arduino Uno Dengan Perhitungan Mape (Mean Absolute Percentage

Error), Pada Lahan Perkebunan. *ELECTRA: Electrical Engineering Articles* 3 (01) (2022) 19–27. <http://doi.org/10.25273/electra.v3i01.13642>.

[48] Cruz-Jacobo, U., Conde-Gutiérrez, R. A., Hernandez, J. A., Silva-Martínez, S., Colorado, D., Juárez-Romero, D., & Alvarez-Gallegos, A. (2022). Optimization strategy to improve the removal efficiency of commercial herbicides using a multivariable inverse artificial neural network adapted with particle swarm optimization. DOI: 10.5004/dwt.2022.28972.

[49] M. Cervantes-Bobadilla, J. García-Morales, R.F. Escobar-Jiménez, J.A. Hernandez Perez, J.F. Gomez-Aguilar, V.H. Olivares-Peregrino, Experimental implementation of a new control approach using an inverse neural network to on-demand hydrogen production, *Control Eng. Pract.* 105 (2020) 104631, <https://doi.org/10.1007/s40430-021-02862-4>.

[50] M. Cervantes-Bobadilla, J.A. Hernandez-Perez, D. Juárez-Romero, A. Bassam, J. García-Morales, A. Huicochea, O.A. Jaramillo, Control scheme formulation for a parabolic trough collector using inverse artificial neural networks and particle swarm optimization, *J. Braz. Soc. Mech. Sci. Eng.* 43 (2021) 1–14, <https://doi.org/10.1016/j.conengprac.2020.104631>.

[51] R.A. Conde-Gutiérrez, U. Cruz-Jacobo, A. Huicochea, S.R. Casolco, J.A. Hernandez, Optimal multivariable conditions in the operation of an absorption heat transformer with energy recycling solved by the genetic algorithm in artificial neural network inverse, *Appl. Soft Comput.* 72 (2018) 218–234, <https://doi.org/10.1016/j.asoc.2018.08.008>.

[52] E.M. Novoa-del-Toro, E. Mezura-Montes, M. Vignes, M. Térézol, F. Magdinier, L. Tichit, A. Baudot, A multi-objective genetic algorithm to find active modules in multiplex biological networks, *PLoS Comput. Biol.* 17 (8) (2021) e1009263.

[53] G. Carmona-Arroyo, M. Quiroz-Castellanos, E. Mezura-Montes, Variable decomposition for large-scale constrained optimization problems using a grouping genetic algorithm, *Mathematical and Computational Applications* 27 (2) (2022) 23, <https://doi.org/10.3390/mca27020023>.

- [54] Arora, G., Chauhan, P., Asjad, M. I., Joshi, V., Emadifar, H., & Jarad, F. (2023). Particle swarm optimization for solving sine-gordan equation. DOI: 10.32604/csse.2023.032404.
- [55] M. Zhao, H. Zhao, M. Zhao, Particle swarm optimization algorithm with adaptive two-population strategy, IEEE Access (2023), <https://doi.org/10.1109/ACCESS.2023.3287859>.
- [56] Veeraiah, V., Khan, H., Kumar, A., Ahamad, S., Mahajan, A., & Gupta, A. (2022). Integration of PSO and deep learning for trend analysis of meta-verse. In 2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE) (pp. 713-718). IEEE. DOI: 10.1109/ICACITE53722.2022.9823883.
- [57] L. Scrucca, GA: A package for genetic algorithms in R, J. Stat. Softw. 53 (2013) 1–37, <https://doi.org/10.18637/jss.v053.i04>.
- [58] Samala, R. K. (2023). Particle Swarm Optimization. In Swarm Intelligence-Recent Advances and Current Applications. IntechOpen. DOI: 10.5772/intechopen.107156.
- [59] Passive House. (2022). Criteria and Algorithms for Certified Passive House Components: Opaque construction systems. https://passiv.de/downloads/03_certification_criteria_construction_systems_en.pdf.
- [60] NASA. POWER | DAVe 2021. <https://power.larc.nasa.gov/beta/data-accessviewer/>. (Accessed 23 April 2024).
- [61] American Society of Heating, Refrigerating and Air-Conditioning Engineers. (2021). ASHRAE Handbook—Fundamentals (SI Edition). American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc.

7. Anexo 1: Productos científicos obtenidos.

<i>Productos de la estancia de investigación</i>	
Artículo	Citas
Mata, A. I., Johnson, J. I., Parrales, A., Solís-Pérez, J. E., Huicochea, A., & Hernandez, J. A. (2024). Radiant heating systems control in buildings via Inverse Conformable Artificial Neural Networks and optimization techniques. <i>Energy and Buildings</i> , 325, 114968.	3
Mata, A. I., Johnson, J. I., Cha, S. H., Parrales, A., & Hernández, J. A. (2026). Oil agglomeration process optimization by inverse neural networks: An innovative approach with conformable transfer functions and bio-inspired optimization. <i>Fuel</i> , 408, 137595.	
Hernández, J. A., Solís-Pérez, J. E., Parrales, A., Mata, A., Colorado, D., Huicochea, A., & Gómez-Aguilar, J. F. (2023). A conformable artificial neural network model to improve the void fraction prediction in helical heat exchangers. <i>International Communications in Heat and Mass Transfer</i> , 148, 107035.	12
Johnson, J. I., Mata, A. I., Hernandez, J. A., Parrales, A., Rodriguez, J. A., Solis-Perez, J. E., ... & Jimenez-Cruz, F. (2025). Enhancing biodiesel cetane number prediction: Comparative study of neural network architectures with integer and conformable transfer functions. <i>Sustainable Energy Technologies and Assessments</i> , 75, 104241.	3
Rodríguez, J. A., Mata, A., Galindo, E., Johnson, J. I., & Hernández, J. A. (2025). Advancing Turbine Prediction: Harnessing Conformable Artificial Neural Networks for the Fracture Analysis. <i>Journal of Failure Analysis and Prevention</i> , 25(1), 357-369.	1
Johnson, J., Mata, A., Hernández, J. A., Parrales, A., Rodriguez, A., Solis-Perez, E., ... & Jimenez-Cruz, F. Enhancing Biodiesel Cetane Number Prediction Accuracy and Efficiency: A Comparative Study of Diverse Artificial Neural Network Architectures Using Integer and Conformable Transfer Functions. Available at SSRN 4859766.	



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS



INSTITUTO DE INVESTIGACIÓN EN CIENCIAS BÁSICAS Y APLICADAS

JEFATURA DE POSGRADO EN INGENIERÍA Y CIENCIAS APLICADAS



Cuernavaca, Morelos, a 12 de mayo de 2026.

DR. ARTURO MOLINA OCAMPO
COORDINADOR DEL POSGRADO EN
INGENIERÍA Y CIENCIAS APLICADAS
P R E S E N T E

Atendiendo a la solicitud para emitir DICTAMEN sobre la revisión de la TESIS titulada: OPTIMIZACIÓN DEL CONTROL TÉRMICO EN EDIFICACIONES UTILIZANDO REDES NEURONALES CONFORMABLES INVERSAS PARA SISTEMAS DE CALEFACCIÓN RADIANTE, que presenta la alumna **ALEXIA IRAIS MATA PÉREZ**, para obtener el título de **DOCTORADO EN INGENIERÍA Y CIENCIAS APLICADAS**.

Nos permitimos informarle que nuestro voto es **APROBATORIO**.

Atentamente

DR. ALBERTO ARMANDO ÁLVAREZ GALLEGOS

DR. JOSÉ ALFREDO RODRÍGUEZ RAMÍREZ

DR. ARMANDO HUICOCHEA RODRÍGUEZ

DR. DARIO COLORADO GARRIDO

DR. JESÚS EMMANUEL SOLÍS PÉREZ

DRA. ARIANNA PARRALES BAHENA

DR. JOSÉ ALFREDO HERNÁNDEZ PÉREZ

Se adiciona efirma UAEM



Av. Universidad 1001 Col. Chamilpa, Cuernavaca Morelos, México, 62209, Edificio 65,
Tel. 777 329 70 00 Ext. 6208 / ciicap.posgrado@uaem.mx

UAEM
RECTORÍA
2023-2029



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento con firma electrónica UAEM, soportada por el certificado vigente a la fecha de su elaboración y con efectos plenos de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS PUBLICADOS en el ÓRGANO INFORMATIVO UNIVERSITARIO "ADOLFO MENÉNDEZ SAMARÁ" número 117 de fecha 20 de abril de 2021.

Sello electrónico

JOSE ALFREDO HERNANDEZ PEREZ | Fecha:2026-06-01 09:20:25 | FIRMANTE

N2tZAtf/h1jGeSIHxwKQaaa4Sb5FFr8RXChTyzkld1omr8bf5B04OZMsUqQT0DDH/0/XC1dGDSyHovQcY/3kCoxPaGh1sJvBAMS1gOq1/HAKsWD/6/en2TKraa+tgFz8zMNKO+Uu
mhqg7iRWsyyJdlwe/t2GatcrpGwrq4b8nkOmfbvWzLa56EFFW6pT0pJ7BXi4cA9cXd6PB6uFhPniirykleDpaHxvqnqavzRaEb++uOu2PObeB8+gC9AcackeZIC+ngCTOv0OjGP7
UP9BYi0bmFjSrKpi7VHBFMxebfDFwhmnEeLglyv1NiEe4UXt3Zm+CJ09E4nTXoi7G4W9Q==

ARIANNA PARRALES BAHENA | Fecha:2026-06-01 10:06:15 | FIRMANTE

feo822kVeOgJPCT31zzE9lw4KmP47w1ASzugLUoDc/y54dH5Nqr4QzZW91rQ69W66THPI8iIv5A77zi2gGNoKAsg7lmsCzDnvp5TFkSM4XT7glcAsixbKxBuUrGXJA4ZTFmekZz7
XcmKKYsLHPIUPDGNcnZjVJ3dJEPXI+AeGpMsLb9kovWhYOL6kDjZm8uB7RuyxQEkiXCA+UliHdNI7KyluewwMJL96q5IRg3izE2CFFyV+qF44wjVxBHOuAX9Yn7sQw6zWKc
oXEPDWzghQBSbgsq1sXOK/cS0ii96WeE9WYh2vJfBGDM/DMHp4/a8eNXXdKG2xiEXU68+giQ==

DARIO COLORADO GARRIDO | Fecha:2026-06-01 15:07:44 | FIRMANTE

gAxm4n+uYwPzBzUqWxHfJm3vjpFAC8U7ldUeBcyq16NwptiXrZjevraqEPZYOhYsFLzUgkNAP07n40DucImQlimaj51IGdCawKAHTHVcOjRBDPjym1VOc397LJtqf1vxbqOW4nK
rRvb2wAC6gzaU+hFgHP1Pe87Vu88YBMq83uvYml3cJtnxZzKXbGceBg5vFjKnR5vmmqLfm1GCokviPuoqq0iBgC/mhRhstuL+X2xAdZwvB7z5n0x0A3pd103cx/ISw8n/bxV86wC
M34fEfUE3IAhgmVkv0DmGKbe9/fuAow9NpR7+57VLhQY0+p88cMuYXwiadv1a/n9gLLdw==

JOSE ALFREDO RODRIGUEZ RAMIREZ | Fecha:2026-06-02 10:27:14 | FIRMANTE

iooVEILayHqiTdfLLIX8R4uh9xelGvDnkr7gQaDAcvHXPIJvOfkwcx4q0glfm1tmTc6CgWvFWQsnaS81EMk8dXNzFvbQmbhmasuQEiW6M16nBECsZh9KZSmVaXZuFNMscYALbP
ui4QASyVCEPT2z4YFEijFUQd+Kj2J4vTdlDk1rKZqQrUueBFJvZQu/QgQ6H7vj1EhXu6vsvWIRbTtdgkVJUWMLTU8cirWXzbofmmvCQJXKAu5QqL8j56DkVPFOLSwbj4M4C32S
ZCg877XPQ46aArYg2WELV7ri+w3di1CYJPSfkBYuaF6l831gro/FSN58zW09ien9r6+tp+NQA==

ALBERTO ARMANDO ALVAREZ GALLEGOS | Fecha:2026-06-02 10:35:47 | FIRMANTE

gZociS+qFVvxSdDyG/6xe8Qnre/9jXhePDZv82WA+O5bg/7MBjFigtN8zBvrb6q3lrcCCdh3DB7Lzhf31N/u7JCz5MwxB1Sr2B2NPb9hHFJ9OoidYHywJiom5gA0C2XW7gzP9pv
Y+38gQGKQ9ey5c3yXfPWOla7FP0kk3TzoPl2slW4D/kG58L3CyxHGP6ba8Enr3+YEymTfYK4EbSldV9SNDRpKrELJptFOZ+cgW+DuCAZiqMj1nYZsnaF5BDUpU988rac5LfmVjK
E8UMXtDBA/+xq3Lh8ojPOZVkp2OvJaxtKSjV4Liipitd7No/Jeje2aX67LF1vFChLeZYA==

JESÚS EMMANUEL SOLIS PÉREZ | Fecha:2026-06-02 13:20:42 | FIRMANTE

Lsz+AaaN/Ej+MZI29OzSRkzKrxzRLNSBvt4isEWuPDPsNBWPP0xEkMKWH4AoFwQU9KFJEYgdqBvKSGTLzNo4meOdFNpMzKG9irP+bFe+aewSCyNYE/HwUsuuUAR7OxEzaV
xrPEQhaoNsJmzCxVhKAXAKsMJFxaD9aMPltg2DUQOvRliBZf4wQ6+pn/G4cq6EiNj4vYSh3t6tRWGVrVIRpEI3QE5LJ+jQgxODhWJzhuSzKy0ruNv0MbgJdKGS7lomQ2aV2c
LsOx7of0vyZWDwcofQFO5r23n4lqRAGB7B5CypAxbwOgtFFuK/Auwbp1dqTHIRS3tIsRJ7kaJCQQA==

ARMANDO HUICOCHEA RODRIGUEZ | Fecha:2026-06-04 13:30:19 | FIRMANTE

oVBDMNrdXO/02D61FAj1pvp8U/W2JO3n3Wgnr3hOY7wDKtlcW96g1V/WKxniJIP+meAf/+TD7PJCqoWk30eNKKQZpbULXb0HR6M406j016sLhn6hHgk7O+75vJkVc7vsO7LnpEd
YiToHR2OliG5K7abAq/P0P/gX6jc/5Yf5p5z23sfC40erWIDWBJPaW3jVFLWVrXc2OW+zg5oInUbWZyysWv2inp6cXYT+E9Avlygp3Xx8BS+uisPVJC2YZntUEo4uwzSb8zUBC+d5
9Wn68N/aDs4nl+fg8jO5BKrtmgOuxJNOFC5lo9x4noBNAsZ5RmL5Qbs5+HGT5fwpVTUDFQ==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



FSpwqyoCz

<https://efirma.uaem.mx/noRepudio/0hr97lnkrZKFg0gVVAz5JktVKqarlv7P>



UAEM
RECTORÍA
2023-2029