VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

Modelado de un sistema de refrigeración miniatura usando una arquitectura de red neuronal KAN

Modeling of a Miniature Refrigeration System Using a Kolmogorov-Arnold Network (KAN) Neural Architecture

Luisa Fernanda Paredes Acevedo[1], Uriel Arredondo Gutiérrez[1], Juan Manuel Belman Flores[1]
[1]Departamento de Ingeniería Mecánica, Universidad de Guanajuato-DICIS, Comunidad de Palo Blanco Salamanca, Guanajuato, 36885, México.
lf.paredesacevedo@ugto.mx, u.arredondogutierrez@ugto.mx, jfbelman@ugto.mx

Resumen

La optimización de sistemas de refrigeración por compresión de vapor es un tema de interés debido a su elevado consumo energético y su impacto ambiental. En este trabajo se desarrolló un modelo predictivo basado en una arquitectura de red neuronal Kolmogorov-Arnold Network (KAN) para estimar el coeficiente de desempeño (COP) de un sistema de refrigeración miniatura operando con los refrigerantes R134a, R515B y R516A. Se empleó un banco experimental de baja capacidad frigorífica, considerando como variables de entrada el tipo de refrigerante, la masa de refrigerante, la velocidad del compresor y la velocidad del ventilador. El entrenamiento y validación del modelo se realizaron mediante la técnica Leave-One-Out Cross Validation (LOOCV). Los resultados demuestran el potencial de las redes KAN como herramienta para el modelado y análisis de sistemas de refrigeración bajo diferentes condiciones de operación.

Palabras clave: Red neuronal KAN, refrigeración por compresión de vapor, coeficiente de desempeño, inteligencia artificial, entrenamiento.

Introducción

Los sistemas de refrigeración por compresión de vapor son una de las tecnologías más utilizadas en aplicaciones domésticas, comerciales e industriales debido a su capacidad para proporcionar altos niveles de eficiencia y confiabilidad operativa (Dossat & Horan, 2002). Gracias a estas ventajas, estos sistemas se utilizan en diversas aplicaciones como la conservación de alimentos, el acondicionamiento de espacios interiores y varios procesos industriales donde es necesario mantener un control adecuado de la temperatura para garantizar un funcionamiento eficiente y seguro.

Sin embargo, el crecimiento de la demanda de equipos de refrigeración ha incrementado considerablemente el consumo energético asociado a estos sistemas, convirtiéndolos en un área de interés para la investigación y el desarrollo de nuevas estrategias de optimización. De acuerdo con la Agencia Internacional de Energía (IEA), las tecnologías de enfriamiento representan cerca del 20% de la electricidad consumida en edificios a nivel mundial, y se espera que la demanda de enfriamiento continúe aumentando durante las próximas décadas debido al crecimiento poblacional, la urbanización y el incremento de las temperaturas globales (International Energy Agency [IEA], s. f.).

Además de la energía que consumen durante su operación, los sistemas de refrigeración por compresión de vapor también generan preocupaciones ambientales relacionadas con el uso de refrigerantes y las emisiones indirectas asociadas a la producción de electricidad. Se estima que cerca del 10% de las emisiones globales de gases de efecto invernadero (GEI) provienen de las actividades relacionadas con la refrigeración y el transporte de alimentos (Cámara Nacional de la Industria de Conservas Alimenticias [CANAINCA], s. f.). Esto se debe principalmente al uso de la energía en los sistemas de refrigeración y al empleo de refrigerantes con alto potencial de calentamiento global (PCG).

En un contexto donde la eficiencia energética, la reducción de costos y la sostenibilidad son prioridades, la inteligencia artificial surge como una herramienta poderosa para simular, evaluar y optimizar el rendimiento de los sistemas de refrigeración. Adoptar estas tecnologías es clave para asegurar que los equipos funcionen de manera inteligente, previendo fallas, ahorrando energía y mejorando la calidad de los procesos (Pérez-Gomariz et al., 2023).

Entre las arquitecturas existentes de la inteligencia artificial destaca la Kolmogorov-Arnold Network (KAN), propuesta como una alternativa a las redes neuronales tradicionales. A diferencia de las redes multicapa convencionales y las redes neuronales de perceptrón multicapa (MLP), las KAN sustituyen los pesos lineales por funciones entrenables basadas en el teorema de representación de Kolmogorov-Arnold, lo que les permite capturar relaciones altamente no lineales con una mayor interpretabilidad y eficiencia en determinadas aplicaciones (Liu et al., 2024).

Con esto se demuestra el potencial de las KAN en problemas de matemáticas, física y modelado científico, concluyendo que esta arquitectura representa una alternativa prometedora para tareas donde se requieren modelos precisos, eficientes y fácilmente interpretables. Así, en este trabajo se propone el uso de la arquitectura KAN para simular el desempeño de un sistema de refrigeración de pequeña capacidad frigorífica.

Banco experimental

El banco experimental empleado en este estudio corresponde a un sistema de refrigeración por compresión de vapor de baja capacidad frigorífica (por debajo de los 1000 W), diseñado para evaluar el comportamiento térmico de refrigerantes alternativos de bajo potencial de calentamiento global (PCG), bajo distintas condiciones de operación.

El sistema está integrado por un mini compresor, un condensador (micro canal) enfriado por un ventilador, un filtro secador, un tubo capilar y un evaporador tipo placas, todos conectados mediante tuberías de cobre para formar un circuito cerrado de refrigeración, tal y como se indica en la figura 1.

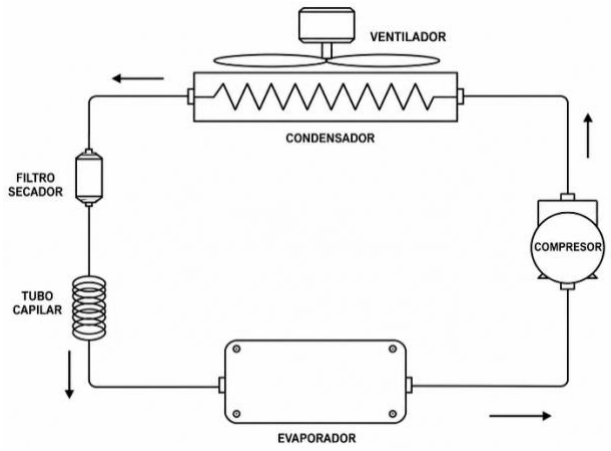


Figura 1. Esquema del banco experimental de refrigeración por compresión de vapor.

El ciclo de refrigeración inicia en el compresor, donde el refrigerante en estado de vapor y baja presión es comprimido, incrementando su presión y temperatura. Posteriormente, el refrigerante fluye hacia el condensador, donde cede calor al ambiente impulsado por el ventilador y experimenta un cambio de fase de vapor a líquido a alta presión.

A continuación, el refrigerante atraviesa el filtro secador, cuya función es retener partículas sólidas y absorber la humedad presente en el circuito, evitando daños en los componentes y posibles obstrucciones en el tubo capilar.

Posteriormente, el refrigerante circula a través del tubo capilar, donde ocurre una reducción significativa de presión debido al estrangulamiento del flujo. Como consecuencia, disminuyen la presión y la temperatura del refrigerante antes de ingresar al evaporador.

Finalmente, en el evaporador el refrigerante absorbe calor del entorno y se evapora, produciendo el efecto de enfriamiento. Una vez completado este proceso, el refrigerante retorna al compresor en estado de vapor y baja presión, cerrando así el ciclo de refrigeración.

En la figura 2 se muestra una imagen del banco experimental. Se encuentra totalmente instrumentado para medir la temperatura a la entrada y salida de los componentes principales, así como las presiones de trabajo. Los datos usados en este trabajo fueron obtenidos de un estudio previo (Silva-Romero et al., 2026).

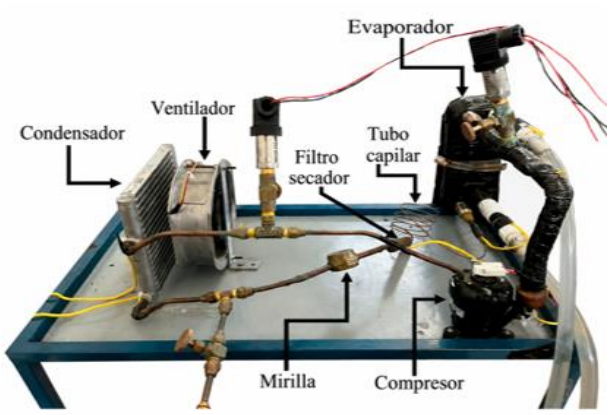


Figura 2. Banco experimental.

Red Neuronal Kolmogorov-Arnold (KAN)

Las redes neuronales Kolmogorov-Arnold Network (KAN) son una arquitectura de aprendizaje profundo desarrollada como una alternativa a las redes neuronales de perceptrón multicapa (MLP).

Su fundamento teórico se basa en el teorema de representación de Kolmogorov-Arnold, el cual establece que una función multivariable puede expresarse mediante la composición de funciones unidimensionales entrenables. A partir de este principio, las KAN reemplazan los pesos lineales convencionales por funciones de activación entrenables ubicadas en las conexiones entre neuronas, permitiendo una representación más flexible de relaciones no lineales complejas (Liu et al., 2024).

A diferencia de las redes neuronales tradicionales, donde las funciones de activación se aplican únicamente en los nodos, las KAN incorporan funciones unidimensionales parametrizadas mediante B-splines en cada conexión de la red. Esta característica permite que el modelo aprenda directamente la forma funcional de las relaciones entre las variables de entrada y salida, mejorando la capacidad de aproximación y facilitando la interpretación de los resultados obtenidos (Liu et al., 2024).

Otra ventaja importante de esta arquitectura es su capacidad de interpretabilidad. Las KAN pueden emplearse para identificar expresiones simbólicas aproximadas a partir de los datos, proporcionando una mayor comprensión de las relaciones existentes entre las variables analizadas.

En el presente trabajo, la arquitectura KAN se empleó para modelar el comportamiento de un sistema de refrigeración por compresión de vapor operando con diferentes refrigerantes y condiciones de funcionamiento. La selección de esta arquitectura se debe a su capacidad para capturar relaciones no lineales entre las variables operativas y el desempeño energético del sistema (Liu et al., 2024).

Resultados

El parámetro de interés en el sistema de refrigeración es el coeficiente de desempeño, COP, el cual es calculado mediante la ecuación 1, implicando la capacidad frigorífica con relación a la potencia del compresor.

$$\mathrm{COP} = \frac{\dot{Q}_{\mathrm{evap}}}{\dot{W}_{\mathrm{comp}}} \tag{1}$$

La base de datos estuvo conformada por 81 muestras experimentales obtenidas del banco experimental [(Silva-Romero et al., 2026). Para garantizar la reproducibilidad del entrenamiento, se estableció una semilla aleatoria (seed) con valor de 54. Las funciones de activación fueron configuradas con un tamaño de cuadrícula (grid) igual a 3. El entrenamiento fue llevado a cabo durante 17 ciclos de entrenamiento con el objetivo de evitar el sobreentrenamiento utilizando el algoritmo de optimización Limited-memory Broyden-Fletcher-Goldfarb-Shanno (L-BFGS), un método empleado para minimizar la función de pérdida durante el entrenamiento del modelo. Como función de pérdida se utilizó el Error Cuadrático Medio (MSE).

Con el objetivo de evaluar la capacidad predictiva de la arquitectura Kolmogorov-Arnold Network (KAN), se realizó un proceso de validación mediante la técnica Leave-One-Out Cross Validation (LOOCV). Los resultados obtenidos permitieron analizar el rendimiento del modelo en el coeficiente de desempeño (COP) del sistema de refrigeración bajo diferentes condiciones de operación.

La arquitectura KAN empleada para este estudio está conformada por una capa de entrada de 6 neuronas, correspondientes a las variables operativas del sistema, seguida de dos capas ocultas con 6 y 3 neuronas, respectivamente, y una capa de salida compuesta por una sola neurona encargada del valor del COP como se muestra en la figura 3.

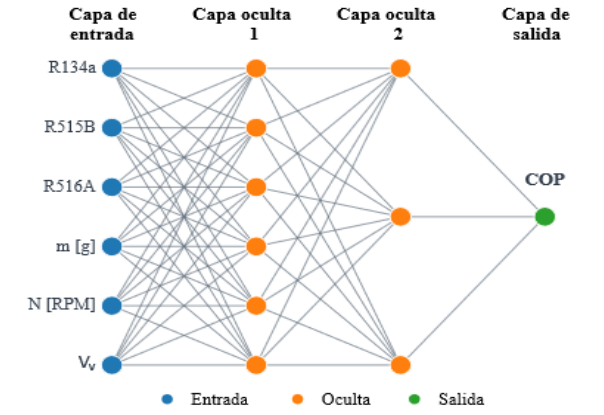


Figura 3. Estructura de la red KAN.

Las variables de entrada consideradas para el entrenamiento de la red KAN fueron el tipo de refrigerante, R134a como el fluido convencional y R515B y R516A como fluidos alternos; la masa de refrigerante (m), la velocidad de giro del compresor (N) y la velocidad del ventilador (V_v) acoplado al condensador. La masa de refrigerante se expresó en gramos (g), mientras que la velocidad del compresor se registró en revoluciones por minuto (rpm).

Para facilitar el procesamiento de los datos, la velocidad del ventilador se codificó de forma categórica, asignando los valores -1, 0 y 1 a las velocidades baja, media y alta, respectivamente. Por su parte, la velocidad del compresor se representó mediante la variable N, cuyos niveles experimentales fueron 3000, 4500 y 6000 rpm, mientras que la masa de refrigerante tomó valores de 70, 90 y 110 g.

Con ello se obtuvieron las métricas globales que mostraron un coeficiente de determinación de 0.968, un error absoluto medio (MAE) de 0.179 y un error cuadrático medio (MSE) de 0.064, lo que indica una alta capacidad del modelo para predecir el comportamiento experimental del sistema.

La figura 4 muestra la comparación entre los valores reales del COP y los valores predichos por la red neuronal KAN durante la validación para los tres refrigerantes. Se observa que la mayoría de los puntos se encuentran próximos a la línea de tendencia central, indicando una alta concordancia entre las predicciones del modelo y los datos experimentales dentro de un máximo error relativo del ±10%. En la figura también se observa una mayor fluctuación de puntos para el R515B fuera del error relativo, lo que se puede atribuir quizá a algunos errores de medición.

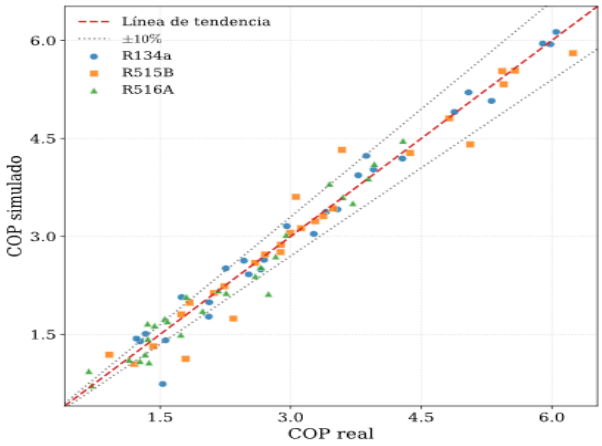


Figura 4. COP simulado vs COP real.

Una vez validado el modelo desarrollado, este puede ser usado para la simulación del sistema de refrigeración miniatura. En este sentido, la figura 5 muestra la variación del COP en función de la masa de refrigerante, donde se mantiene constante la velocidad del compresor en 3000 rpm, así como una velocidad media del ventilador. Se observa que el comportamiento depende de la cantidad de masa de refrigerante, así como del tipo del fluido. Sin embargo, el banco experimental deberá operar a una masa determinada, desde el punto de vista experimental será aquella que represente menor consumo de energía.

El comportamiento de la figura 5 está relacionado con las diferencias en las propiedades termofísicas de cada refrigerante. El refrigerante R516A presenta una menor densidad del líquido saturado (1077.8 kg/m³) en comparación con el R134a (1206.7 kg/m³) y el R515B (1185.6 kg/m³), por lo que los incrementos en la masa de refrigerante generan menos variaciones en el desempeño del sistema.

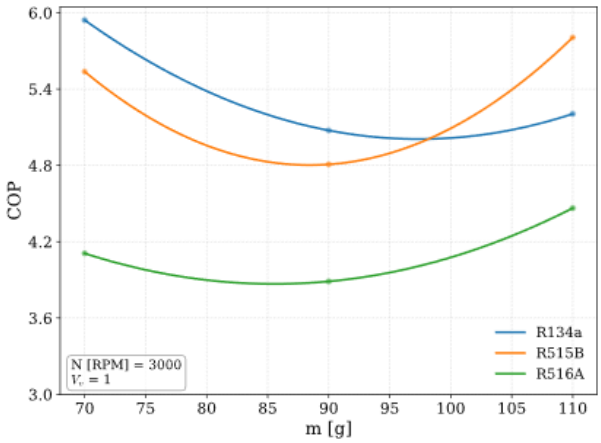


Figura 5. COP vs masa de refrigerante.

En la figura 6 se muestra el comportamiento de la velocidad de giro del ventilador sobre el COP, para una masa constante de 90 gramos y una velocidad de giro del compresor de 3000 rpm. Se observa una tendencia creciente del COP para los tres refrigerantes evaluados, indicando que el incremento del flujo de aire favorece la transferencia de calor en el condensador, por lo que mejora el desempeño global del sistema.

El refrigerante R134a presenta los valores más elevados del COP en todo el rango analizado, seguido por el R515B, mientras que el R516A presenta los valores más bajos. Este comportamiento confirma la importancia de la velocidad del ventilador como variable operativa para maximizar la eficiencia energética del sistema de refrigeración.

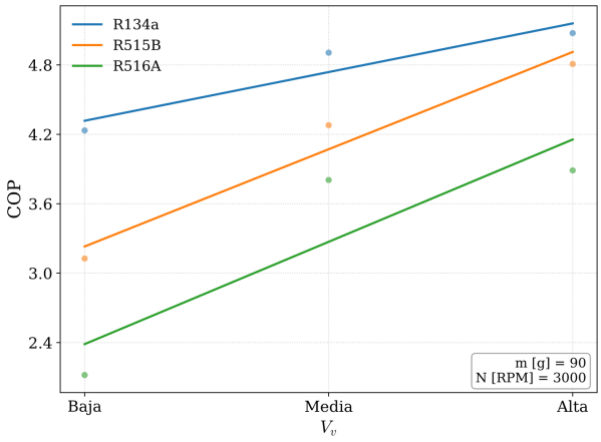


Figura 6. COP vs V_v.

La figura 7 muestra la relación entre el COP y la velocidad de rotación del compresor para una masa de refrigerante fija y una velocidad media del ventilador. Se observa una disminución del COP al aumentar la velocidad del compresor para los tres refrigerantes analizados.

Este comportamiento puede explicarse porque, al incrementar la velocidad del compresor, el sistema consume más energía, pero el aumento en la capacidad de enfriamiento no es proporcional, lo que ocasiona una reducción en el COP. Entre los refrigerantes evaluados, el R134a presenta los mayores valores de COP a bajas velocidades de compresor, mientras que el R516A mantiene los valores más bajos. Se confirma que las propiedades termodinámicas del R134a favorecen a un mayor desempeño por arriba de las mezclas alternas.

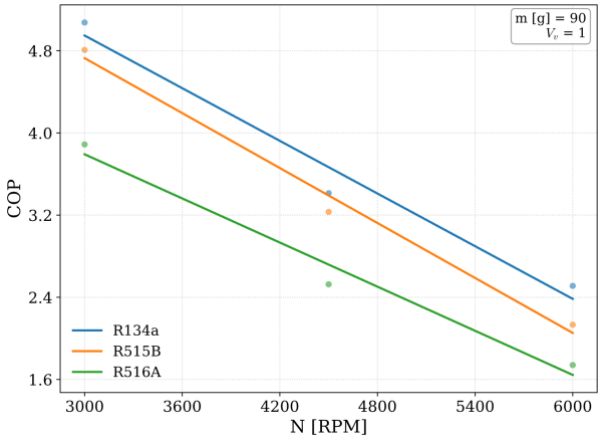


Figura 7. COP vs N.

La figura 8 presenta la distribución de los valores del COP para cada refrigerante mediante diagramas de caja, los cuales permiten identificar la variación de los datos y comparar el comportamiento de cada refrigerante. Se observa que el R134a y el R515B presentan medianas y valores promedio muy similares, así como una dispersión relativamente amplia de los datos, reflejando una mayor variabilidad del desempeño bajo las diferentes condiciones de operación evaluadas.

Por otro lado, el R516A muestra una mediana inferior y una distribución concentrada hacia valores más bajos de COP. Estos resultados indican que, dentro del conjunto de datos analizados, los refrigerantes R134a y R515B ofrecen un desempeño energético superior respecto al R516A, aunque con una variabilidad ligeramente mayor.

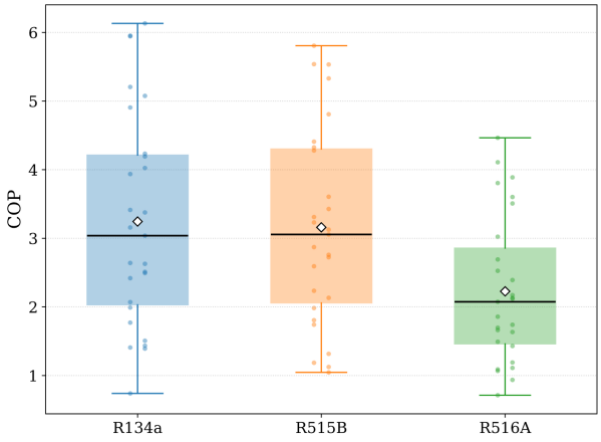


Figura 8. Distribución del COP para cada refrigerante

Por último, la figura 9 muestra la importancia relativa de las variables de entrada sobre la predicción del COP. Se observa que la velocidad del compresor (N) es la variable más influyente, con una contribución del 48.8%.

Por su parte, el tipo de refrigerante presenta una importancia del 20.5% y la velocidad del ventilador un valor del 20.2%, mientras que la masa de refrigerante registra la menor influencia, con un 10.4%. Además, la importancia acumulada indica que las tres primeras variables explican aproximadamente el 89.6% del comportamiento del COP estimado por el modelo.

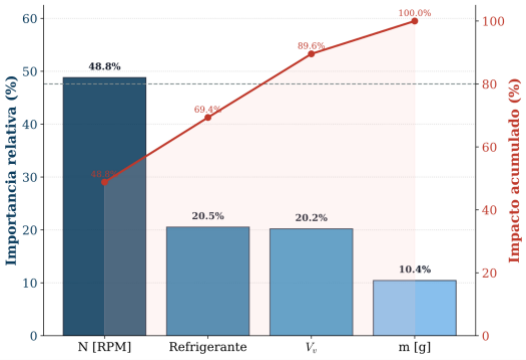


Figura 9. Importancia relativa de las variables de entrada sobre el COP.

Como resultado del entrenamiento del modelo, la arquitectura KAN permitió obtener una expresión simbólica que relaciona las variables de entrada con el coeficiente de desempeño (COP). A diferencia de las redes neuronales convencionales, esta arquitectura ofrece la posibilidad de representar el conocimiento aprendido mediante una ecuación matemática interpretable. Para facilitar su lectura, la expresión se presenta redondeada a cuatro decimales.

$$\begin{aligned}\text{COP} = &-0.0266 \cdot \text{Masa} + 0.6531 \cdot \text{R134a} + 0.9784 \cdot \text{R515B} - 0.4271 \cdot \text{R516A} - 0.0007 \cdot \text{RPM} + 0.5570 \cdot \\ &\text{Vv} + 1.3312 \cdot \exp(0.9519 \cdot \text{R134a} - 0.0004 \cdot \text{RPM}) + 0.0402 \cdot \exp(0.0298 \cdot \text{Masa} + 1.2661 \cdot \text{R516A} - \\ &0.0003 \cdot \text{RPM}) + 7.2524 + 1.9319 \cdot \exp(-1.2884 \cdot \exp(0.0204 \cdot \text{Masa} + 0.8651 \cdot \text{R516A} - 0.0002 \cdot \\ &\text{RPM}))\end{aligned} \quad (2)$$

Conclusiones

En este trabajo se desarrolló un modelo predictivo basado en una arquitectura Kolmogorov-Arnold Network (KAN) para estimar el coeficiente de desempeño (COP) de un sistema de refrigeración por compresión de vapor de baja capacidad que opera con los refrigerantes R134a, R515B y R516A. Para ello, se emplearon 81 datos experimentales obtenidos bajo diferentes condiciones de operación, utilizando como variables de entrada el tipo de refrigerante, la masa de refrigerante, la velocidad del compresor y la velocidad del ventilador. Entre las principales conclusiones se pueden citar las siguientes:

El modelo KAN presentó un desempeño satisfactorio para la predicción del COP, obteniendo un coeficiente de determinación (R^2) de 0.968, un MAE de 0.179 y un MSE de 0.064, teniendo una alta concordancia entre los valores experimentales y los estimados. La velocidad del compresor fue la variable con mayor influencia sobre el COP, con una contribución del 48.8%, seguida por el tipo de refrigerante y la velocidad del ventilador, mientras que la masa de refrigerante presentó la menor influencia.

Entre los refrigerantes evaluados, el R134a presentó los mayores valores de COP con respecto a las mezclas alternas bajo las condiciones operativas evaluadas en el sistema de refrigeración.

En general, los resultados obtenidos demuestran que las redes KAN son una herramienta eficaz para el modelado de sistemas de refrigeración, permitiendo usarlas para la predicción con una precisión adecuada en el desempeño energético del sistema bajo diferentes condiciones de operación.

Bibliografía/Referencias

Cámara Nacional de la Industria de Conservas Alimenticias. (s. f.). Cómo la innovación en la cadena de frío de alimentos frescos combate los efectos del cambio climático. https://www.canainca.org/index.php/es/la-industria/noticias-recientes/252-como-la-innovacion-en-la-cadena-de-frio-de-alimentos-frescos-combate-los-efectos-del-cambio-climatico

Dossat, R. J., & Horan, T. J. (2002). Principles of refrigeration (5th ed.). Prentice Hall.

International Energy Agency. (s. f.). The future of cooling. https://www.iea.org/reports/the-future-of-cooling

Liu, Z., Wang, Y., Vaidya, S., Ruehle, F., Halverson, J., Soljačić, M., Hou, T. Y., & Tegmark, M. (2024). KAN: Kolmogorov-Arnold networks (Version 5). arXiv. https://doi.org/10.48550/arXiv.2404.19756

Pérez-Gomariz, M., López-Gómez, A., & Cerdán-Cartagena, F. (2023). Artificial neural networks as artificial intelligence technique for energy saving in refrigeration systems—A review. Clean Technologies, 5(1), 116–136. https://doi.org/10.3390/cleantechnol5010007

Silva-Romero, J. C., Rodríguez-Muñoz, J. L., Demesa-López, F. N., Hernández-Fusilier, D., Pérez-García, V., & Belman-Flores, J. M. (2026). Experimental investigation of a miniature refrigeration system using R134a and a low-GWP blend R515B. Thermo, 6, 36.