

# Redes Neuronales: La clave para entender tus electrodomésticos

## Resumen

En el presente artículo se analiza y se divulgan en un lenguaje apropiado para todo público la definición y utilización de redes neuronales artificiales (ANN) como un recurso fundamental para mejorar la eficiencia energética en las viviendas, con la finalidad de promover la sostenibilidad y el uso eficiente de la energía. El foco de la investigación se encuentra en la identificación y clasificación de los patrones de consumo de dos electrodomésticos de alta demanda energética, específicamente refrigeradores y hornos de microondas. Se llevó a cabo el entrenamiento de una red neuronal mediante un modelo *feed-forward* en *Matlab*, utilizando datos recopilados de sensores de corriente, potencia y factor de potencia. En la metodología se llevó a cabo la limpieza y normalización de los datos con el fin de mejorar el desempeño del algoritmo. En el análisis de los datos, se observó que la identificación de electrodomésticos alcanzó una tasa de precisión del 98.7%, demostrando una destacada capacidad de generalización al ser evaluados datos no previamente analizados. El presente estudio evidencia la capacidad de las Redes Neuronales Artificiales (ANN, por sus siglas en inglés) para disminuir el derroche de energía y ofrecer soluciones eficientes en la administración energética residencial. Las palabras clave de este estudio: neuronales artificiales, optimización energética en electrodomésticos, eficiencia energética y sostenibilidad.

## 1.- Introducción

En el mundo actual, que se enfrenta a los apremiantes problemas del cambio climático, la necesidad de adoptar soluciones energéticas es más crucial que nunca. El continuo aumento de las temperaturas, provocado en parte por nuestra dependencia energética de los combustibles fósiles, pone de manifiesto la urgente necesidad de cambiar la forma en que producimos, distribuimos y utilizamos la energía (Lu, et al. 2022.) Los hábitos de la población en el uso de la energía llevan años estancados por lo que existe un inmenso potencial sin explotar para mejorar la eficiencia y reducir las emisiones de carbono, como el uso de la inteligencia artificial (IA), pero eso lo iremos desenrollando poco a poco a largo de este artículo. En la búsqueda de la sostenibilidad, la gestión de la energía en los

Abraham Efraím  
Rodríguez-Mata ,  
Jesús A. Medrano-  
Hermosillo , Gerardo  
Arno Sonk

Tecnológico  
Nacional de México/  
Instituto Tecnológico  
de Chihuahua

Recibido:  
4 de octubre de 2024  
Aceptado:  
5 de noviembre de  
2024

hogares emerge como un área de interés, el reto no consiste en reducir el consumo de energía, sino en optimizar su utilización para aprovechar al máximo los recursos renovables y reducir al mínimo la dependencia de fuentes de energía convencionales perjudiciales para el medio ambiente, la clave está en la optimización. Este intrincado planteamiento de la gestión de la energía requiere herramientas de análisis y adaptación a patrones de consumo complejos, tarea ideal para las redes neuronales. Pero antes de adentrarnos a la definición formal, que son y para que de estos pequeños algoritmos maravillosos llamadas Redes Neuronales Artificiales (RNA) será bueno definir por qué y cómo es necesario optimizar la energía en los hogares de la población (Cui, et al. 2019).

Aunque las industrias consumen más energía que las zonas residenciales en términos absolutos, son las viviendas de todo el mundo las que tienen un gran potencial para mejorar la eficiencia energética y detectar fugas. A la vista, la diferencia puede parecer sorprendente; las industrias, con sus grandes máquinas y operaciones continuas, sin duda consumen enormes cantidades de energía (El Alaoui & Rougui, 2024). Sin embargo, al considerar el consumo energético combinado de los hogares cada uno equipado con varios aparatos y sistemas de calefacción y enfriamiento hay una oportunidad especial para aumentar la eficiencia. La clave reside en reconocer y corregir las pequeñas ineficiencias y fugas de energía dentro de estos entornos residenciales. Al abordar estas cuestiones no se pueden lograr ahorros sustanciales en energía a mayor escala, pero los propietarios de viviendas también pueden beneficiarse de facturas de servicios públicos más bajas que contribuyen al objetivo general de la sostenibilidad medioambiental.

Identificar las fugas de energía dentro de una casa implica examinar factores tales como los patrones de uso de energía, el consumo de energía en espera y los aumentos inesperados de la demanda de energía. Los enfoques tradicionales a esta tarea han implicado principalmente inspecciones o herramientas básicas de vigilancia digital que ofrecen algunas perspectivas pero que pueden no profundizar en los problemas que causan el desperdicio de energía. Estos métodos carecen de la complejidad necesaria para analizar los datos de manera eficaz e identificar las sutiles ineficiencias que, colectivamente, resultan en desechos energéticos significativos.

Los métodos tradicionales se enfrentan a un desafío, no solo consumen tiempo, sino que también luchan para seguir adelante con los patrones cada vez más cambiantes de uso de la energía de los hogares. Esto pone de relieve la necesidad de

soluciones automatizadas avanzadas.

Las redes neuronales de la IA entran en el centro de atención y prometen un avance significativo en la optimización del consumo de energía residencial. Las redes neuronales poseen la capacidad de analizar grandes cantidades de datos y descubrir patrones que pueden eludir a los analistas humanos. Cuando se aplican a los datos de uso de energía, estos modelos de IA pueden diferenciar entre tendencias y problemas potenciales con una precisión y velocidad notables que los métodos tradicionales no pueden coincidir. Además, utilizando el análisis de datos en tiempo real, las redes neuronales no identifican, sino que también predicen posibles ineficiencias energéticas que permiten la aplicación de medidas proactivas. Esta transición de la gestión energética a la reactiva supone un gran paso adelante, en la mejora de la forma en que utilizamos y conservamos la energía en los hogares, como se ilustra de manera abstracta en la figura 1.

Las redes neuronales juegan un papel en este progreso ofreciendo más que sólo capacidades analíticas: representan una nueva perspectiva sobre cómo pensamos y gestionamos la energía. Con su capacidad para aprender y ajustar las redes neuronales pueden procesar datos de sistemas energéticos para identificar patrones y detectar anomalías que pueden pasar desapercibidas por los analistas (Bui, et al. 2020). La valiosa asistencia proporcionada por las redes neuronales es esencial en la lucha contra el cambio climático, ayudándonos a tomar decisiones bien informadas sobre el uso de la energía y facilitando la adopción de métodos de conservación más eficaces. Además, la naturaleza flexible de las redes permite que los conocimientos derivados de dicha investigación se apliquen en diversos entornos geográficos y socioeconómicos, aumentando así su influencia (Gupta & Koppad, 2020).

Este estudio tiene como objetivo introducir la optimización energética con su aplicación práctica en hogares, promoviendo la sostenibilidad, el ahorro económico y una mejor calidad de vida. Al centrarse en el análisis de los hábitos de consumo y aspectos clave como el uso y la eficiencia energética a través



**Figura 1.-Optimización del consumo de energía en el hogar utilizando redes neuronales (elaboración propia).**

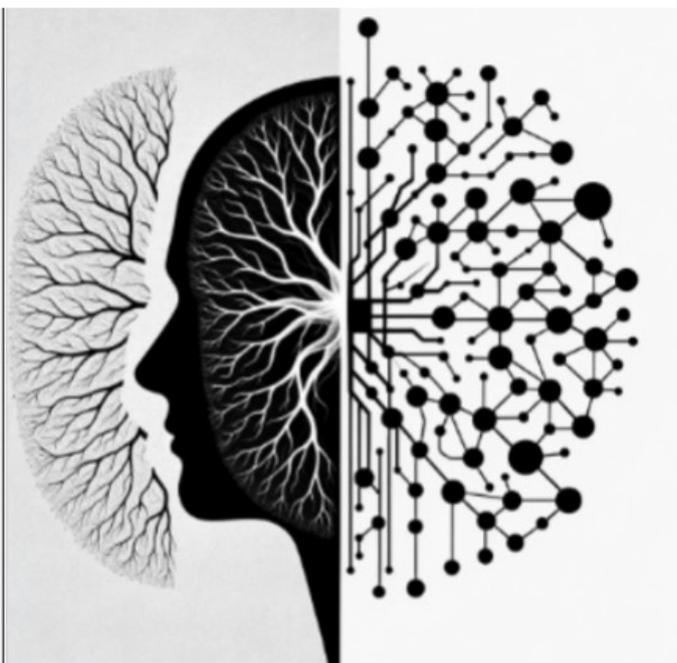
de redes neuronales artificiales (ANN), se descubre cómo estas herramientas pueden proporcionar ideas para estrategias personalizadas de ahorro energético, superando las limitaciones de los métodos tradicionales.

Pero ¿Qué son las Redes Neuronales Artificiales (ANN)? Imaginemos la organización de una gran fiesta sorpresa. Se tiene una lista de cosas por hacer: decoraciones, música, comida y la lista de invitados. Al principio, es posible que se sienta un poco abrumado sin saber por dónde empezar; quizás se coloquen los globos en lugares poco visibles o se elija una música que no a todos les guste. Sin embargo, a medida que se reciben comentarios de los amigos (“me encanta esta canción”, “los globos lucirían mejor en la entrada”), se ajustan las decisiones para mejorar la experiencia. Este proceso iterativo de aprendizaje basado en retroalimentación es similar a cómo funcionan las redes neuronales artificiales, que están inspiradas en las células nerviosas.

Las ANN pueden ser comparadas con una orquesta sinfónica, donde cada instrumento (neurona) tiene su propia partitura (datos de entrada) única que contribuye a la sinfonía final (tarea de procesamiento). Al principio, la orquesta puede tener algunos desajustes: los violines suenan muy fuerte, los vientos madera entran en el momento equivocado. Pero el director (algoritmo de aprendizaje) ajusta a cada músico, asegurándose de que, con cada ensayo, la armonía mejore. Las sinapsis serían las señales que el director utiliza para comunicarse con la orquesta, garantizando que cada nota llegue en el momento y volumen adecuados para crear una melodía coherente y hermosa. De la misma manera en que una orquesta aprende a interpretar una sinfonía de forma más refinada con la práctica, una ANN se “afina” a través del entrenamiento para llevar a cabo tareas complejas con gran precisión (Jiménez Betancourt et al., 2020).

Una ANN aprende de manera similar a cómo un niño aprende a clasificar bloques por forma y color. Inicialmente, el niño podría equivocarse y tratar de colocar un bloque redondo en un hueco cuadrado, sin embargo, con el tiempo y mediante prueba y error, el niño comienza a comprender qué bloques van en cada hueco. En este proceso, el cerebro del niño ajusta su comprensión y mejora su habilidad para resolver el problema.

**Figura 2.-Humanos y Máquinas: Paralelos Neuronales (elaboración propia).**



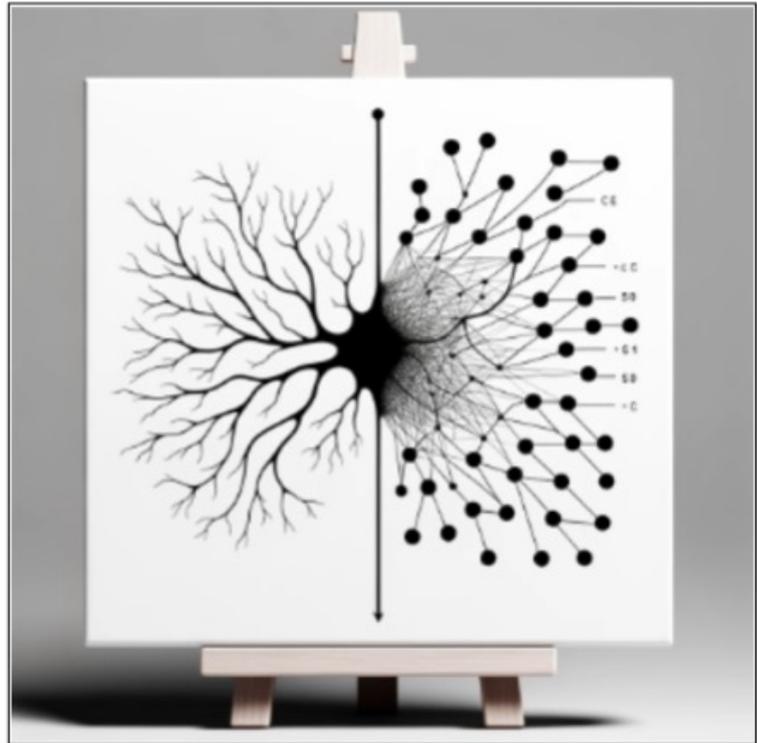
Como se muestra en la figura 2 las redes neuronales son similares a las redes neuronales naturales biológicas.

Las redes neuronales artificiales imitan este proceso de aprendizaje al ajustar sus conexiones internas, también conocidas como pesos, para mejorar en tareas específicas como la clasificación de imágenes o el procesamiento del lenguaje natural. Se basan en los “errores” cometidos para aprender de ellos y así desempeñar mejor la tarea en futuras ocasiones. Las redes multicapa están abiertamente extendidas en todos los seres vivos y ahora también en la tecnología esto como se muestra en la figura 3.

Las ANN son sistemas informáticos inspirados en la estructura y funcionamiento del cerebro humano. A través del aprendizaje y adaptación basados en datos, estas redes pueden llevar a cabo tareas complejas que van desde el reconocimiento de patrones hasta la toma autónoma de decisiones. Al entrenarse con ejemplos y ajustar sus conexiones internas, las ANN aprenden a mejorar su rendimiento en estas tareas, ofreciendo soluciones versátiles y potentes para una amplia variedad de aplicaciones prácticas.

Imagínate que estas diseñando un rascacielos elevado, donde la estabilidad y el conocimiento de cada piso son cruciales. Los pisos inferiores podrían simbolizar los fundamentos, mientras que las capas o pisos superiores incorporan datos y características precisas. En el reino de las redes neuronales artificiales, cada capa oculta dentro de una red de múltiples capas procesa diligentemente los datos, elevando gradualmente su complejidad. Este meticuloso proceso garantiza que la estructura final posea la notable capacidad de identificar y responder a patrones complicados, superando las capacidades de construcciones rudimentarias.

El aprendizaje profundo de las redes neuronales se puede comparar con el entrenamiento de un equipo olímpico. Alcanzar la grandeza requiere el dominio de múltiples áreas, mezclando sin problemas la natación, el ciclismo y las habilidades de carreras en el contexto de un triatlón, por ejemplo. Cada sesión de entrenamiento está cuidadosamente diseñada para ajustar



**Figura 3.-Redes Neuronales Multicapa en la Naturaleza y la Tecnología (elaboración propia).**

los músculos y el enfoque estratégico del atleta, asegurando que no sólo están listos para competir, sino que también son capaces de superar a sus rivales en circunstancias difíciles. Del mismo modo, el aprendizaje profundo capacita a la red en múltiples capas de procesamiento, optimizando sus pesos y prejuicios internos, para realizar tareas complejas con una precisión excepcional. En última instancia, los algoritmos de aprendizaje funcionan como entrenadores personales para estas redes. Consideremos el aprendizaje hacia atrás como un entrenador profesional, por ejemplo, que analiza meticulosamente cada acción tomada durante una sesión de entrenamiento, identificando errores y proporcionando orientación precisa para la mejora (Himeur, Alsalemi, et al, 2020). Esta retroalimentación permite ajustes precisos, garantizando que con cada iteración, la red mejore, se vuelva más eficiente y alcance una mayor precisión en su tarea. Este enfoque iterativo y basado en la retroalimentación asegura que, al igual que los atletas aprenden de cada carrera, las redes neuronales de múltiples capas aprendan de cada dato procesado, mejorando continuamente su rendimiento. En pocas palabras, las redes neuronales de múltiples capas proporcionan una solución poderosa y sofisticada para abordar problemas complejos, ya que se inspiran en las redes nerviosas del cerebro humano o se construyen mediante medios tecnológicos, es decir de alguna manera hacemos que las maquinas aprendan de la misma manera que lo hacemos nosotros (Owda et al., 2014).

En la siguiente sección, vamos a profundizar en los aspectos más técnicos de las redes neuronales aplicadas al ahorro de la energía, revelamos los secretos detrás de la capacitación de nuestros aprendices para realizar la identificación eléctrica. Profundizando en la complejidad de la introducción de datos en estas redes, las técnicas de entrenamiento que empleamos para optimizar su rendimiento, y los métodos que utilizamos para generar sus predicciones respecto de los aparatos eléctricos.

## **2.- Materiales y métodos**

Debido a su alta demanda energética en el hogar, elegimos concentrar el análisis en refrigeradores y hornos de microondas en nuestra metodología. Estos aparatos son comunes en la mayoría de los hogares y consumen una gran cantidad de energía, por lo que son objetivos importantes para la optimización energética. Decidimos no incluir minisplits o aires acondicionados en nuestro estudio inicial porque reconocemos que su uso varía ampliamente según la región geográfica. El clima

permite vivir confortablemente en muchas áreas de México sin la necesidad de refrigeración artificial constante, lo que limita la relevancia universal de estos sistemas en nuestro análisis de optimización de energía. Esta selección estratégica de electrodomésticos nos permite abordar las fuentes de consumo de energía más comunes y consistentes en los hogares, ofreciendo soluciones que se aplican a la mayoría de las casas (Pérez-Denicia et al., 2017).

Profundizando, hemos embarcado en un viaje similar al de enseñar a un aprendiz altamente perceptivo a identificar los patrones eléctricos distintivos de diferentes dispositivos domésticos (do Carmo & Castro, 2020). Este proceso, aunque complejo, inicia una interesante conversación entre la creatividad humana y la inteligencia artificial. Pensemos en la inmensa cantidad de datos que recopilan estos sensores, es como si nuestro aprendiz tuviera acceso a una enorme biblioteca, que contiene la información de cada dispositivo eléctrico de su hogar. Cada elemento de esta biblioteca se somete a un análisis cuidadoso, ya que la red neuronal se hace capaz de distinguir el suave ruido de un refrigerador del vibrante sonido de una microondas. Esta tarea puede parecer abrumadora al principio, pero puede hacerse más accesible utilizando el aprendizaje automático y las técnicas de aprendizaje profundo (Moradzadeh et al., 2020). Estas poderosas herramientas equipan a nuestro detective digital con los recursos necesarios para completar con éxito el trabajo.

Para entrenar a una red neuronal, nuestro aprendiz digital, para reconocer las firmas energéticas de los electrodomésticos, comenzamos recogiendo una sinfonía de datos de sensores. Tratamos cuidadosamente estos datos, eliminando todas las notas discordantes antes de que la red neural pudiera comenzar su viaje de aprendizaje. El enfoque utilizado para resolver esta cuestión implicó la recopilación de mediciones de corriente, potencia y factor de potencia de refrigeradores y hornos de microondas a través de un sensor PZEM-004t, como se muestra en la figura 4. Los paneles de desarrollo ESP32 y

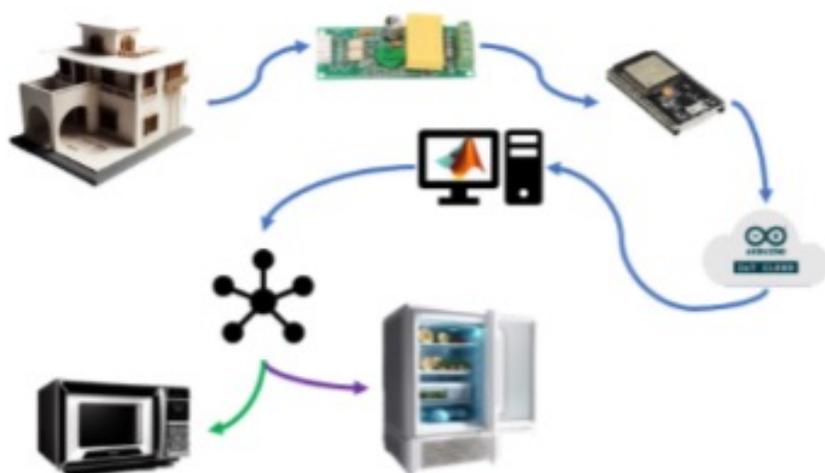


Figura 4.-Estructura metodológica de este trabajo (elaboración propia).

la nube ARDUINO IoT se utilizaron para permitir la vigilancia remota y la adquisición de estos datos. Después de esto, la red *neural feedforward* se sometió a limpieza de datos, capacitación y generalización usando Matlab. La información recogida fue cuidadosamente tratada y examinada para distinguir diferencias notables en estas métricas, determinando cuáles eran las más sugestivas de las diferentes funciones del aparato. Para asegurar que la red neural se entrenara con sólo los atributos más pertinentes, esta fase del proceso de perfeccionamiento del conjunto de datos era esencial. Mediante el uso de técnicas de normalización y eliminación de los extremos, el preprocesamiento limpió los datos para prepararlos para la tarea más compleja de identificación de aparatos.

Para entrenar la red neural, utilizamos una arquitectura de alimentación avanzada diseñada para distinguir entre aparatos particulares, como microondas y refrigeradores. La optimización iterativa del diseño de la red resultó en una configuración con varios nodos de entrada que coincidían con los parámetros clave identificados y múltiples capas ocultas para procesar estos datos de manera eficiente. La precisión del aprendizaje de la red y la clasificación de los datos eléctricos se mejoró aún más mediante la aplicación de funciones de rendimiento y activación (Balakrishnan, et al. 2023).

### **3.- Resultados**

Durante esta breve investigación, la red neural demostró ser no sólo un aprendiz excepcional, sino también un destacado intérprete, de igual manera demostró una increíble capacidad para minimizar errores, alcanzando un error cuadrado promedio de menos de 0,02 en tan solo 218 épocas; una época se refiere a una iteración completa del conjunto de datos de entrenamiento a través de la red neuronal durante el proceso de aprendizaje. Es decir, cada vez que todos los datos disponibles se utilizan para entrenar y ajustar los parámetros de la red (como los pesos de las conexiones entre las neuronas), se completa una época.

Examinando la capacidad de la red de distinguir entre las distintas firmas eléctricas de los refrigeradores y los microondas, los hallazgos fueron fascinantes. Al principio, la red afirmó una asombrosa tasa de precisión del 98,7%, que es comparable a un observador enérgico capaz de diferenciar entre tonos de color casi idénticos. Su tasa mínima de caída del 0,5%, que mostraba una rara confusión entre los dos aparatos, fue indicativa de esta exactitud. Era asombroso lo exacto que identificaba los refrigeradores el 97,9% de las veces- y lo raro que los clasificaba

incorrectamente- su especificidad para las microondas alcanzaba un impresionante 99,5%.

Cuando la red fue probada contra datos frescos y no probados durante la fase de generalización, siguió funcionando brillantemente, alcanzando una precisión del 94%. Incluso con una tarea ligeramente más difícil -las tasas de caída y falta crecían hasta el 6% y el 8,4%, respectivamente la red siguió siendo capaz de identificar de manera fiable los microondas el 92% del tiempo y los refrigeradores con una fuerte tasa de recuperación del 96,2%.

#### 4.- Discusión

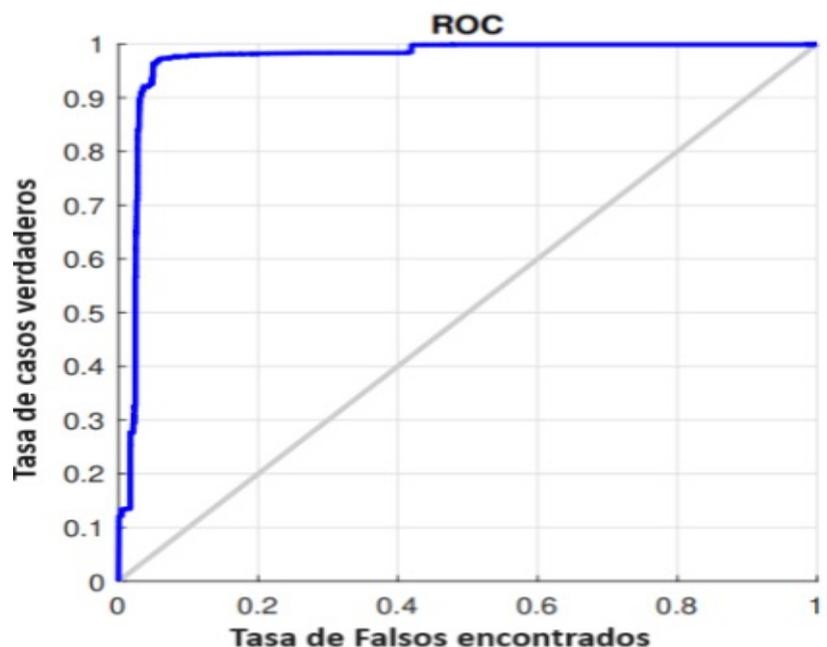
La sofisticada capacidad de la red para distinguir entre los aparatos se demuestra por la curva de ROC (*Receiver Operating Characteristic*) y el valor de AUC (*Area Under the Curve*) de 0.9692, que juntos presentan una imagen de un modelo que no sólo es eficiente, sino que también es notablemente preciso en su trabajo, como se muestra en la figura 5.

La capacidad del sistema para identificar ciertos dispositivos, como refrigeradores y hornos de microondas, demuestra su capacidad para analizar en profundidad los patrones de consumo de energía. Esto permite la implementación de sistemas inteligentes de conservación de energía que pueden ajustar la cantidad de energía consumida en tiempo real al reconocer los dispositivos que se utilizan y cómo se pueden utilizar de manera más eficiente. Para ejemplo, una red neuronal podría detectar refrigeradores que consumen más energía que lo habitual, determinar cuándo se requiere mantenimiento y la hora ideal de funcionamiento utilizando las tarifas eléctricas fluctuantes durante el día. Usando las habilidades predictivas y analíticas de las redes neurológicas, se puede optimizar la utilización de energía tanto a nivel familiar como en sistemas de gestión de energía inteligentes.

#### 5.- Conclusiones

Este artículo de divulgación demostró cómo la inteligencia artificial, más concretamente, las redes neuronales, pueden ir más allá de las técnicas convencionales de gestión de la energía. Nuestra automatización de la detección y clasificación del uso de los aparatos eléctricos

Figura 6.-Curva característica de operación del receptor (ROC) en la fase de generalización



no sólo simplifica el análisis del consumo de energía, sino que también abre la puerta a sistemas de energía más inteligentes y receptivos. Este trabajo añade al cuerpo creciente de la investigación sobre aplicaciones de IA en la eficiencia energética proporcionando conocimientos prácticos de la implementación de redes neuronales para los problemas del mundo real.

## Referencias

- Balakrishnan, R., Geetha, V., Kumar, M. R., & Leung, M. F. (2023). Reduction in residential electricity bill and carbon dioxide emission through renewable energy integration using an adaptive feed-forward neural network system and MPPT technique. *Sustainability*, 15(19), 14088.
- Bui, D. K., Nguyen, T. N., Ngo, T. D., & Nguyen-Xuan, H. (2020). An artificial neural network (ANN) expert system enhanced with the electromagnetism-based firefly algorithm (EFA) for predicting the energy consumption in buildings. *Energy*, 190, 116370.
- Cui, G., Liu, B., & Luan, W. (2019). Neural network with extended input for estimating electricity consumption using background-based data generation. *Energy Procedia*, 158, 2683-2688.
- do Carmo Correa, S. D. J., & Castro, A. R. (2020). Automated non-intrusive load monitoring system using stacked neural networks and numerical integration. *IEEE Access*, 8, 210566-210581.
- El Alaoui, M., & Rougui, M. (2024). Examining the application of artificial neural networks (ANNs) for advancing energy efficiency in building: A comprehensive review. *Journal of Sustainability Research*, 6(1).
- Gupta, J., & Koppad, D. (2020). Artificial neural network hardware implementation: Recent trends and applications. *Computational Vision and Bio-Inspired Computing: ICCVBIC 2019*, 345-354.
- Himeur, Y., Alsalemi, A., Bensaali, F., & Amira, A. (2020). A novel approach for detecting anomalous energy consumption based on micro-moments and deep neural networks. *Cognitive Computation*, 12(6), 1381-1401.
- Jiménez Betancourt, R. O., González López, J. M., Barocio Espejo, E., Concha Sánchez, A., Villalvazo Laureano, E., Sandoval Pérez, S., & Contreras Aguilar, L. (2020). IoT-based electricity bill for domestic applications. *Sensors*, 20(21), 6178.
- Lu, C., Li, S., & Lu, Z. (2022). Building energy prediction using artificial neural networks: A literature survey. *Energy and Buildings*, 262, 111718.
- Moradzadeh, A., Sadeghian, O., Pourhossein, K., Mohammadi-Ivatloo, B., & Anvari-Moghaddam, A. (2020). Improving residential load disaggregation for sustainable development of energy via principal component analysis. *Sustainability*, 12(8), 3158.
- Owda, H. M., Omoniwa, B., Shahid, A. R., & Ziauddin, S. (2014). Using artificial neural network techniques for prediction of electric energy consumption. *arXiv preprint arXiv:1412.2186*.
- Pérez-Denicia, E., Fernández-Luqueño, F., Vilariño-Ayala, D., Montaña-Zetina, L. M., & Maldonado-López, L. A. (2017). Renewable energy sources for electricity generation in Mexico: A review. *Renewable and Sustainable Energy Reviews*, 78, 597-613.