

Optimización del Consumo Energético en el Hogar mediante Redes Neuronales Recurrentes en el contexto del Caribe Colombiano

Optimization of Household Energy Consumption through Recurrent Neural Networks in the Context of the Colombian Caribbean

DOI: <https://doi.org/10.17981/cesta.05.01.2024.03>

Artículo de investigación científica. Fecha de recepción: 3 de marzo de 2024, Fecha de aceptación: 30 mayo de 2024

Zurisaddai Severiche-Maury 

Universidad de Sucre. Sincelejo, (Colombia)
Zurisaddai.severiche@unisucrvirtual.edu.co

Alejandro Guerrero-Hernández 

Universidad de Sucre. Sincelejo, (Colombia)
Alejandro.guerrero@unisucru.edu.co

Javier E. Sierra 

Universidad de Sucre. Sincelejo, (Colombia)
Javier.sierra@unisucru.edu.co

José López-Prado 

Universidad de Sucre. Sincelejo, (Colombia)
Jose.lopez@unisucru.edu.co

Cómo citar:

Z. Severiche-Maury, A. Guerrero Hernández, Javier Sierra, José López Prado “Optimización del Consumo Energético en el Hogar mediante Redes Neuronales Recurrentes en el contexto del Caribe Colombiano”, *J. Comput. Electron. Sci.: Theory Appl.*, vol. 5 no. 1, pp. 25-33, 2024. DOI: <https://doi.org/10.17981/cesta.05.01.2024.03>

Resumen

En un contexto global donde la eficiencia energética es una prioridad, la gestión inteligente del consumo de energía en el hogar se ha vuelto indispensable para reducir el impacto ambiental y optimizar el uso de recursos. Este estudio tiene como objetivo evaluar la efectividad de un modelo de red neuronal recurrente (RNN) del tipo Long Short-Term Memory (LSTM) para predecir la conexión de dispositivos eléctricos y estimar su consumo energético. El modelo fue entrenado y probado utilizando datos de consumo de cinco dispositivos domésticos, recolectados en intervalos de 15 minutos a lo largo de 180 días. Los resultados indican que el modelo LSTM logró una precisión del 87,47% en la clasificación de la conexión de dispositivos y una estimación precisa del consumo de energía. Estas conclusiones muestran el potencial del modelo para mejorar la eficiencia energética en los hogares, proporcionando a los usuarios herramientas para tomar decisiones informadas y reducir su consumo energético.

Palabras clave — Consumo de energía; Gestión energética en el hogar; Red neuronal recurrente (RNN); Eficiencia energética; Inteligencia artificial (IA).

Abstract

In a global context where energy efficiency is a priority, smart management of energy consumption at home has become indispensable to reduce environmental impact and optimize resource use. This study aims to evaluate the effectiveness of a Long Short-Term Memory (LSTM) recurrent neural network (RNN) model to predict the connection of electrical devices and estimate their energy consumption. The model was trained and tested using consumption data from five household devices, collected at 15-minute intervals over 180 days. The results indicate that the LSTM model achieved an accuracy of 87.47% in classifying device connection and accurately estimating energy consumption. These findings show the potential of the model to improve energy efficiency in homes, providing users with tools to make informed decisions and reduce their energy consumption.

Keywords— Energy consumption; Home energy management; Recurrent neural network (RNN); Energy efficiency; Artificial intelligence (AI).



I. INTRODUCCIÓN

En un escenario donde el consumo energético global continúa su tendencia ascendente, las proyecciones de la Agencia Internacional de Energía [1] y el informe de la Unidad de Planeación Minero - Energética (UPME) sobre la demanda de energéticos en Colombia destacan un crecimiento proyectado significativo. Este aumento proyectado en el consumo energético plantea desafíos ambientales considerables, especialmente en términos de emisiones de CO₂ y sostenibilidad. A lo largo del tiempo, se han implementado esfuerzos globales para abordar estos desafíos.

En este contexto de creciente demanda y preocupaciones ambientales, la necesidad de soluciones innovadoras para gestionar eficientemente la energía se vuelve cada vez más urgente. A nivel doméstico, los sistemas de gestión de energía en el hogar (HEMS) han surgido como una respuesta efectiva a estos desafíos. Estos sistemas aprovechan tecnologías de Inteligencia Artificial (IA) para reducir el consumo de energía y mejorar su rendimiento, lo que los convierte en una herramienta para aumentar la eficiencia energética en los hogares [2].

Las Redes Neuronales Recurrentes (RNN) han demostrado ser herramientas poderosas en la predicción de secuencias temporales, siendo ampliamente utilizadas en aplicaciones que requieren el manejo de datos secuenciales como el reconocimiento de voz y la traducción automática. En el ámbito de la gestión energética en el hogar, las RNN, especialmente las variantes como Long Short-Term Memory (LSTM), han sido empleadas con éxito para predecir el consumo energético y optimizar la eficiencia en entornos residenciales [3].

En este artículo, exploraremos en detalle el desarrollo y la implementación de un modelo de RNN del tipo LSTM para la administración inteligente de energía en el hogar. A través de un enfoque basado en datos y técnicas avanzadas de IA, este modelo ofrece la capacidad de predecir la conexión de dispositivos y estimar su consumo de energía, lo que proporciona una base sólida para la optimización del consumo energético en el hogar. Mediante la combinación de la teoría con la práctica, este trabajo busca contribuir al avance en la eficiencia energética residencial y alinearse con los esfuerzos globales para abordar los desafíos energéticos y ambientales actuales.

El resto del documento se organiza de la siguiente manera: en la sección de **Trabajos Relacionados**, se revisan investigaciones previas sobre el uso de la inteligencia artificial en la gestión energética; en **Materiales y Métodos**, se describen los procedimientos y herramientas utilizadas; la sección **Contribuciones y Resultados** presenta los hallazgos clave del estudio; finalmente, en **Conclusiones**, se discuten las implicaciones de los resultados y se sugieren futuras líneas de investigación.

II. TRABAJOS RELACIONADOS

La investigación sobre el uso de algoritmos de inteligencia artificial (IA) en el sector energético ha sido extensa y diversa. Varios autores han explorado diferentes enfoques para mejorar la eficiencia energética y proporcionar soluciones innovadoras para la gestión del consumo de energía en los hogares. La Tabla 1 resume los autores y el trabajo que han desarrollado.

Tabla I. Trabajos Relacionados

Autor	Descripción del trabajo
[4]	Uso de algoritmos de IA en el sector energético. Mejora de procesos de generación, distribución y comercialización de energía. Analiza varios algoritmos dentro de los cuales se encuentra LSTM.
[5]	Técnicas de optimización en microrredes. Importancia de algoritmos precisos, como DE, CRO, TLBO, PSO.
[6]	Uso de IA para mejorar eficiencia energética en Sudáfrica. Destaca ANN y SVM. Sugiere DRL para gestión de energía en hogares.
[7]	Modelos de predicción de consumo energético. Enfoque en algoritmos de aprendizaje profundo. Se enfoca en el uso de los algoritmos RNN, ANN, DNN y SVM.
[17]	Aplicación de IA en programación de sistemas energéticos. Resalta relevancia de algoritmos como la evolución diferencial y redes neuronales. Analizando principalmente los algoritmos ANN, RBF y BP.
[8]	Analizan las aplicaciones de las técnicas de optimización de consumo basadas en IA para sistemas de gestión de energía del hogar (HEMS) y sus ventajas sobre las técnicas tradicionales.
[10]	Ofrecen una visión general del aprendizaje por refuerzo (RL) y su aplicación en HEMS, destacando el uso de modelos de redes neuronales profundas (DNN) en RL.
[11]	Presentan un sistema de hogar inteligente que utiliza inteligencia artificial e Internet de las cosas para gestionar cargas de iluminación y sistemas de climatización.
[12]	Presentan un sistema de hogar inteligente basado en inteligencia artificial con tasa de aprendizaje variable para gestionar el consumo de energía en los hogares.

Autor	Descripción del trabajo
[13]	Proponen un sistema de gestión de energía para el hogar basado en un algoritmo genético para la programación de cargas, optimizando el uso de energía en los hogares.
[14]	Propone un modelo para reconocer patrones de consumo de energía en los electrodomésticos utilizando una plataforma de IoT y técnicas de aprendizaje automático.
[15]	Propone un algoritmo de aprendizaje automático para una respuesta a la demanda consciente de la actividad en edificios residenciales, considerando el ahorro de energía y los requisitos de confort.
[16]	Propone un algoritmo de optimización ligero llamado FastInformer-HEMS para sistemas de gestión de energía domésticos (HEMS) con una unidad de almacenamiento fotovoltaico.

En el análisis de los artículos revisados, se destaca el uso de redes neuronales profundas, particularmente redes recurrentes, para abordar la predicción del consumo de energía en el hogar. En [11], [14] emplean redes neuronales artificiales con retropropagación para predecir y regular el uso de equipos eléctricos, basándose en datos ambientales y comportamentales. Además, en [8] exploran el potencial de las técnicas de aprendizaje por refuerzo profundo (DRL) para optimizar aún más los sistemas de gestión de energía en el hogar (HEMS), aprendiendo del comportamiento del usuario y los patrones de consumo de energía. Esta tendencia hacia el uso de redes neuronales profundas y recurrentes muestra su efectividad en la predicción y gestión del consumo de energía en entornos residenciales, señalando un área de investigación clave para futuros trabajos en el campo de la inteligencia artificial aplicada a la gestión energética domiciliar; destacándose el uso de redes LSTM para la predicción del consumo por los buenos resultados que arrojan.

III. MATERIALES Y MÉTODOS

Para llevar a cabo este estudio, se siguieron los siguientes pasos metodológicos:

1. **Instalación de Medidores de Consumo Energético:** Se instalaron medidores de consumo energético en cinco dispositivos comunes de uso en el hogar: televisor, ventilador, computador, aire acondicionado y lámpara, como se observa en la figura 1. Estos medidores se colocaron con el fin de registrar el consumo de energía de cada dispositivo de manera continua durante un período de 180 días. Los datos recolectados se almacenaron en la nube, permitiendo su accesibilidad y posterior análisis [20], [17].



Figura 1. Medidor en toma de variables eléctricas

2. **Preparación del Dataset:** Los datos obtenidos, registrados en intervalos de 15 minutos, se organizaron en un archivo en formato tabular. Este archivo contenía los registros de consumo de energía para cada uno de los dispositivos. Antes de proceder al modelado, los datos fueron preprocesados [21], [22], lo cual incluyó la normalización para asegurar que los valores estuvieran en un rango adecuado para el análisis. Este preprocesamiento garantiza que el modelo pueda interpretar los datos de manera efectiva.
3. **División del Conjunto de Datos:** El conjunto de datos preprocesado se dividió en dos subconjuntos: uno para el entrenamiento del modelo y otro para su prueba. Esta división permite evaluar la capacidad del modelo para generalizar a datos no vistos durante el entrenamiento. La proporción de esta división fue establecida para asegurar una representación adecuada de ambos conjuntos [23].

4. **Desarrollo del Modelo:** Se diseñó un modelo de red neuronal recurrente (RNN) utilizando la arquitectura Long Short-Term Memory (LSTM). La estructura del modelo incluyó capas de entrada, capas LSTM para capturar las dependencias temporales en los datos, y capas de salida para la clasificación y estimación del consumo energético. Cada capa del modelo fue cuidadosamente configurada para optimizar el rendimiento en la tarea de predicción [24].
5. **Entrenamiento y Evaluación del Modelo:** El modelo LSTM se entrenó utilizando el conjunto de datos de entrenamiento. Durante el proceso del entrenamiento, se ajustaron los parámetros del modelo para minimizar el error de predicción. Una vez entrenado, el modelo se evaluó utilizando el conjunto de datos de prueba. Se emplearon métricas estándar, como precisión y error de clasificación, para medir el desempeño del modelo en la tarea de clasificación y estimación de consumo energético [18], [19].
6. **Implementación y Resultados:** La implementación del modelo se realizó en Python utilizando herramientas especializadas, como TensorFlow, a través de la plataforma Google Colaboratory. Esta elección de herramientas se alinea con el uso creciente de tecnologías avanzadas para el desarrollo de sistemas de gestión energética, como se observa en la literatura reciente. En [25], se destaca que la integración de tecnologías como la inteligencia artificial en sistemas de gestión de energía en hogares inteligentes permite una optimización más eficiente del consumo eléctrico. De manera similar, es [26] resalta la importancia de sistemas de supervisión que emplean redes de sensores y plataformas integradas para el control y la estimación del consumo energético, enfatizando la capacidad de estos sistemas para ajustarse a las necesidades del usuario y promover el ahorro energético. Los resultados obtenidos fueron analizados para validar la eficacia del modelo en la clasificación de conexión y la estimación del consumo energético en el contexto de sistemas de gestión de energía en el hogar (HEMS). La precisión en la predicción y la capacidad de adaptación del modelo reflejan una mejora significativa en la gestión de la energía doméstica, proporcionando una herramienta útil para la optimización del consumo y la reducción de costos energéticos. La integración de estos sistemas con tecnologías existentes y su adaptación a dispositivos de diferentes fabricantes subraya su relevancia en el avance hacia un hogar más inteligente y eficiente en términos de consumo energético.

IV. CONTRIBUCIONES Y RESULTADOS

Para evaluar la eficacia del modelo de red neuronal recurrente tipo Long Short-Term Memory (LSTM) en la gestión energética en el hogar, se siguieron los pasos detallados a continuación:

1. **Implementación del Modelo:** El modelo LSTM desarrollado tiene dos salidas principales. La primera salida proporciona una clasificación binaria que indica si un dispositivo está conectado o no en un momento dado. La segunda salida estima el consumo de energía del dispositivo activo. La figura 3 ilustra la estructura del modelo, mostrando las capas de entrada, LSTM y salida.

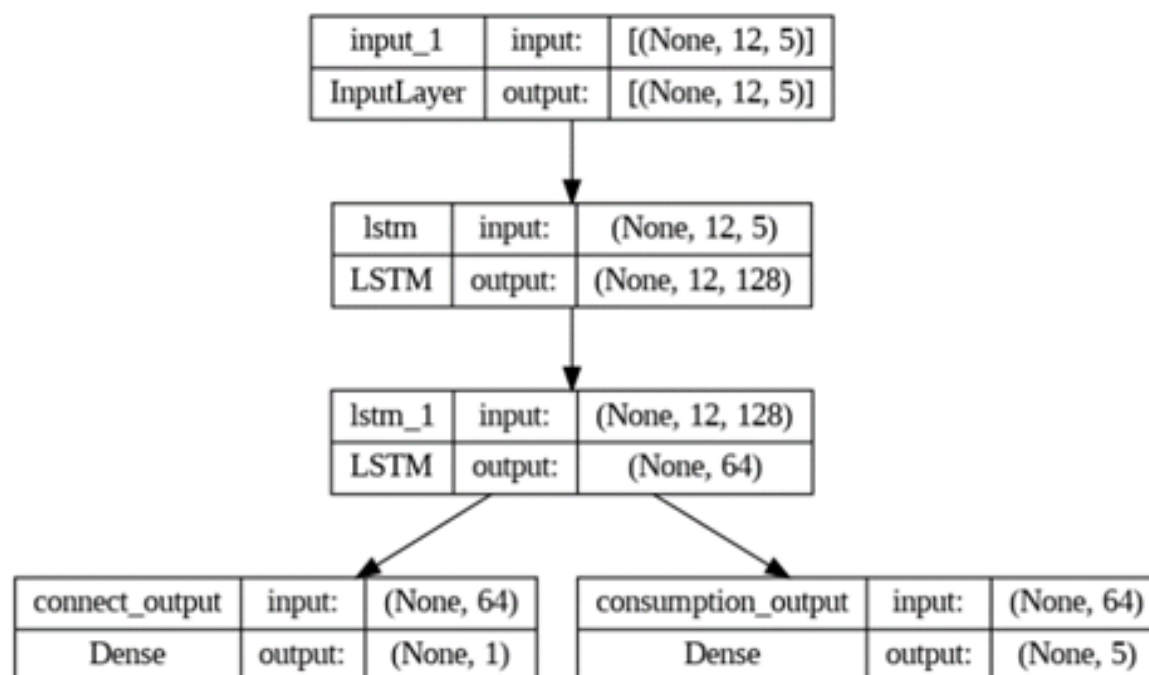


Figura 3. Estructura del modelo

2. **Evaluación de la Precisión:** Para medir el desempeño del modelo, se evaluó la precisión en el conjunto de datos de prueba. El modelo alcanzó una precisión del 87.47% en la clasificación de la conexión de dispositivos. La figura 4 presenta el gráfico de precisión del modelo, mostrando la efectividad en la identificación de dispositivos conectados correctamente.

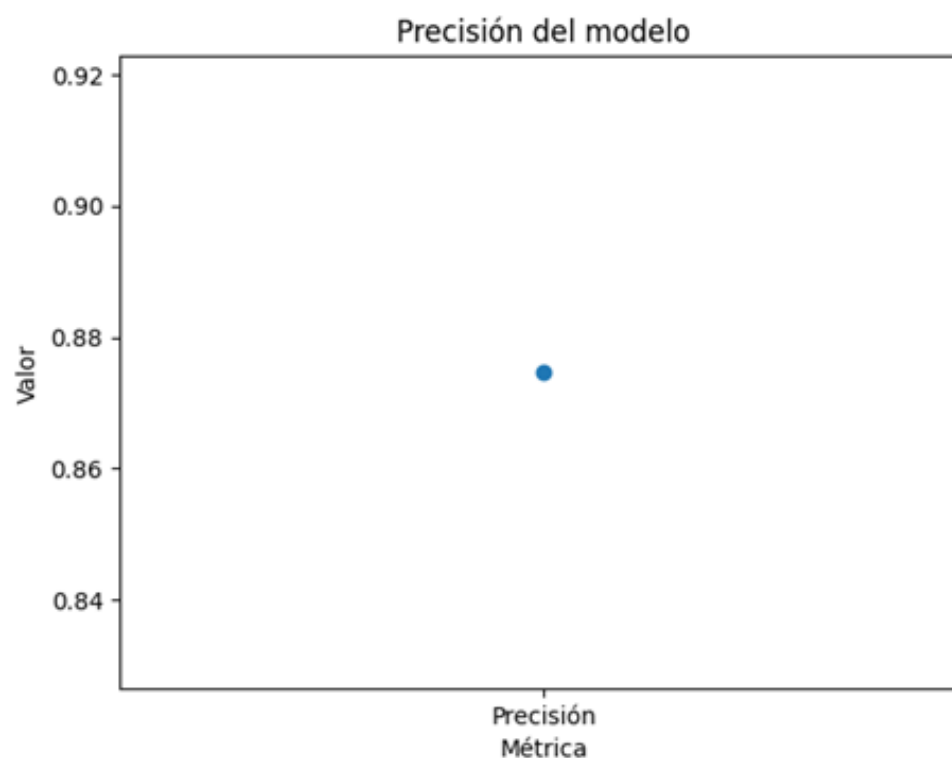


Figura 4. Gráfico de precisión del modelo

3. **Cálculo del Error de Clasificación:** Se calculó el error de clasificación, que resultó ser 0.13. Este valor indica el porcentaje de predicciones incorrectas respecto al total de predicciones realizadas. La figura 5 muestra un gráfico comparativo entre la precisión y el error de clasificación, permitiendo una visualización clara de los resultados.

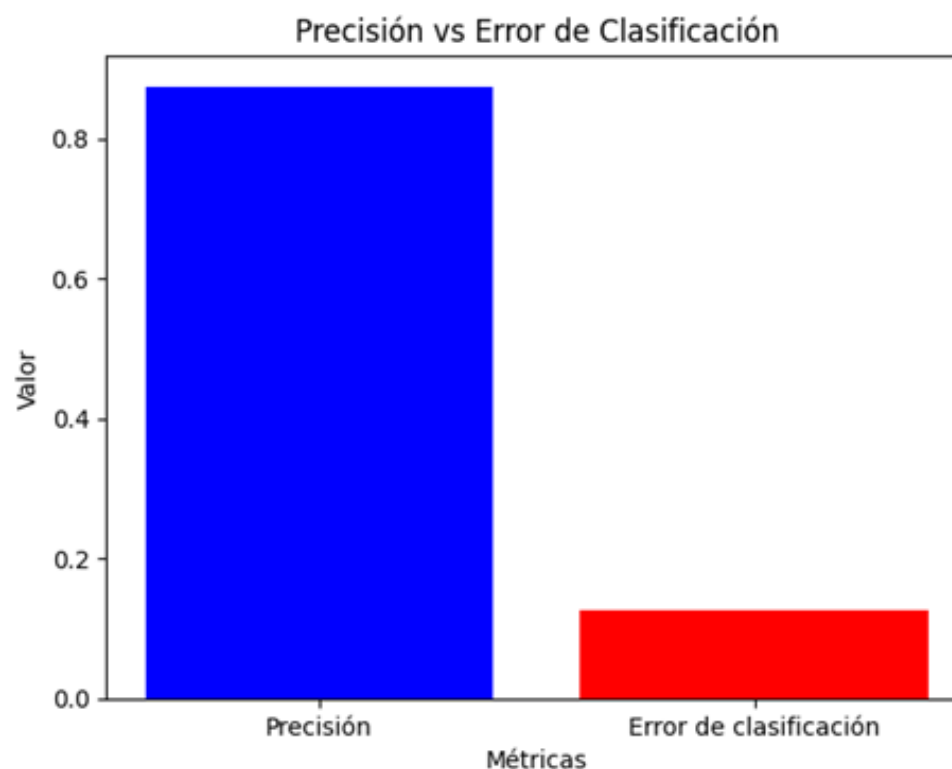


Figura 5. Precisión y error de clasificación

4. **Análisis del Consumo de Energía:** Para cada dispositivo activo identificado en el último paso de tiempo, se calculó su consumo estimado. El modelo permitió identificar el dispositivo con el mayor consumo en ese momento. La figura 6 muestra un gráfico de barras que representa el consumo estimado de cada dispositivo. Las barras en rojo indican los dispositivos que están activos en ese momento.

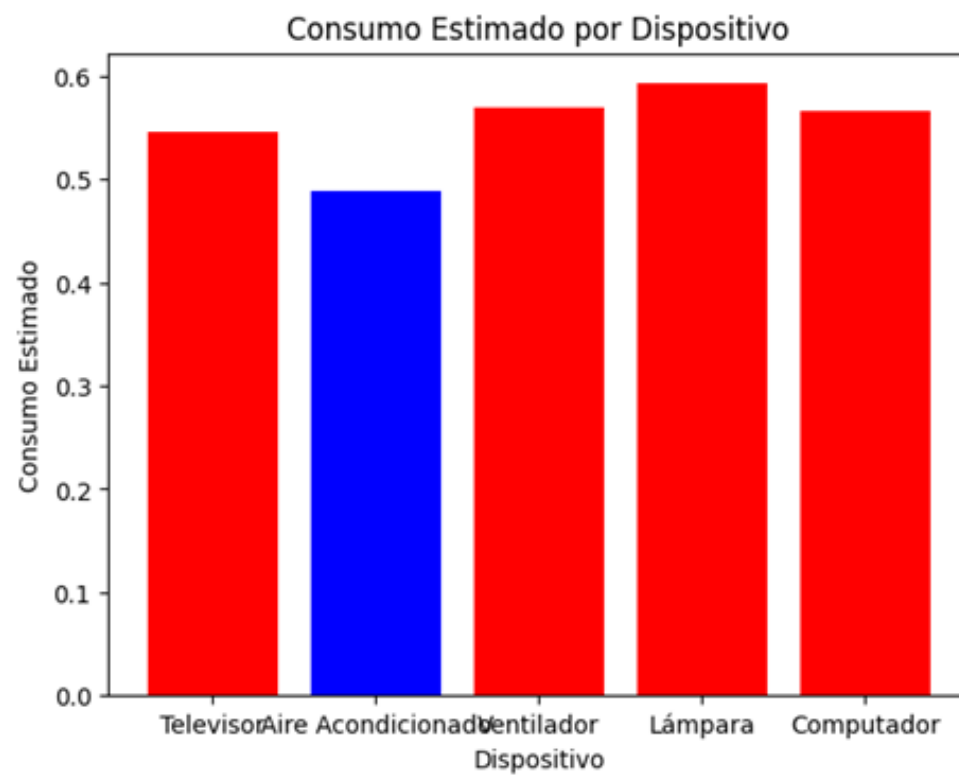


Figura 6. Dispositivos activos

5. **Frecuencia de Conexión de Dispositivos:** Se contó la frecuencia de conexión de cada dispositivo durante el período de estudio. Los resultados se graficaron en un gráfico de barras, donde el eje X representa los dispositivos y el eje Y la frecuencia de conexión. La figura 7 presenta este gráfico, ilustrando qué dispositivos fueron más frecuentemente conectados.

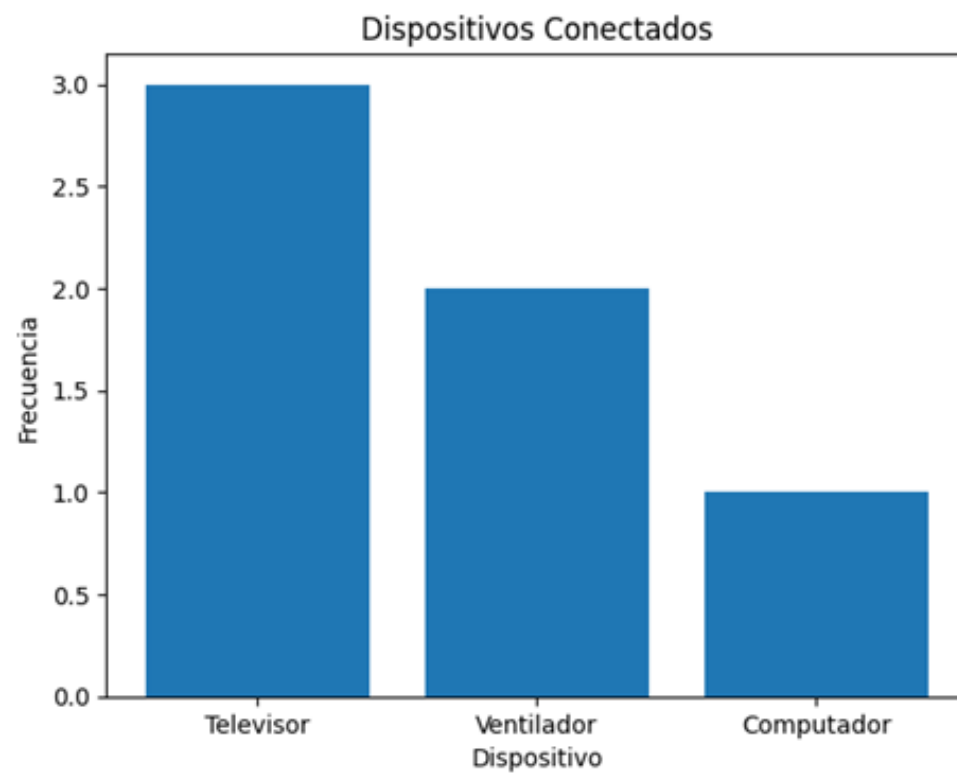


Figura 7. Dispositivos conectados

6. **Detección del Dispositivo con Mayor Consumo:** El modelo permitió identificar el dispositivo activo con el mayor consumo de energía en cada instante. Este análisis fue fundamental para evaluar qué dispositivos contribuyen más al consumo total de energía. La figura 8 muestra un gráfico de barras con el consumo estimado de cada dispositivo activo, destacando en rojo los dispositivos en funcionamiento.

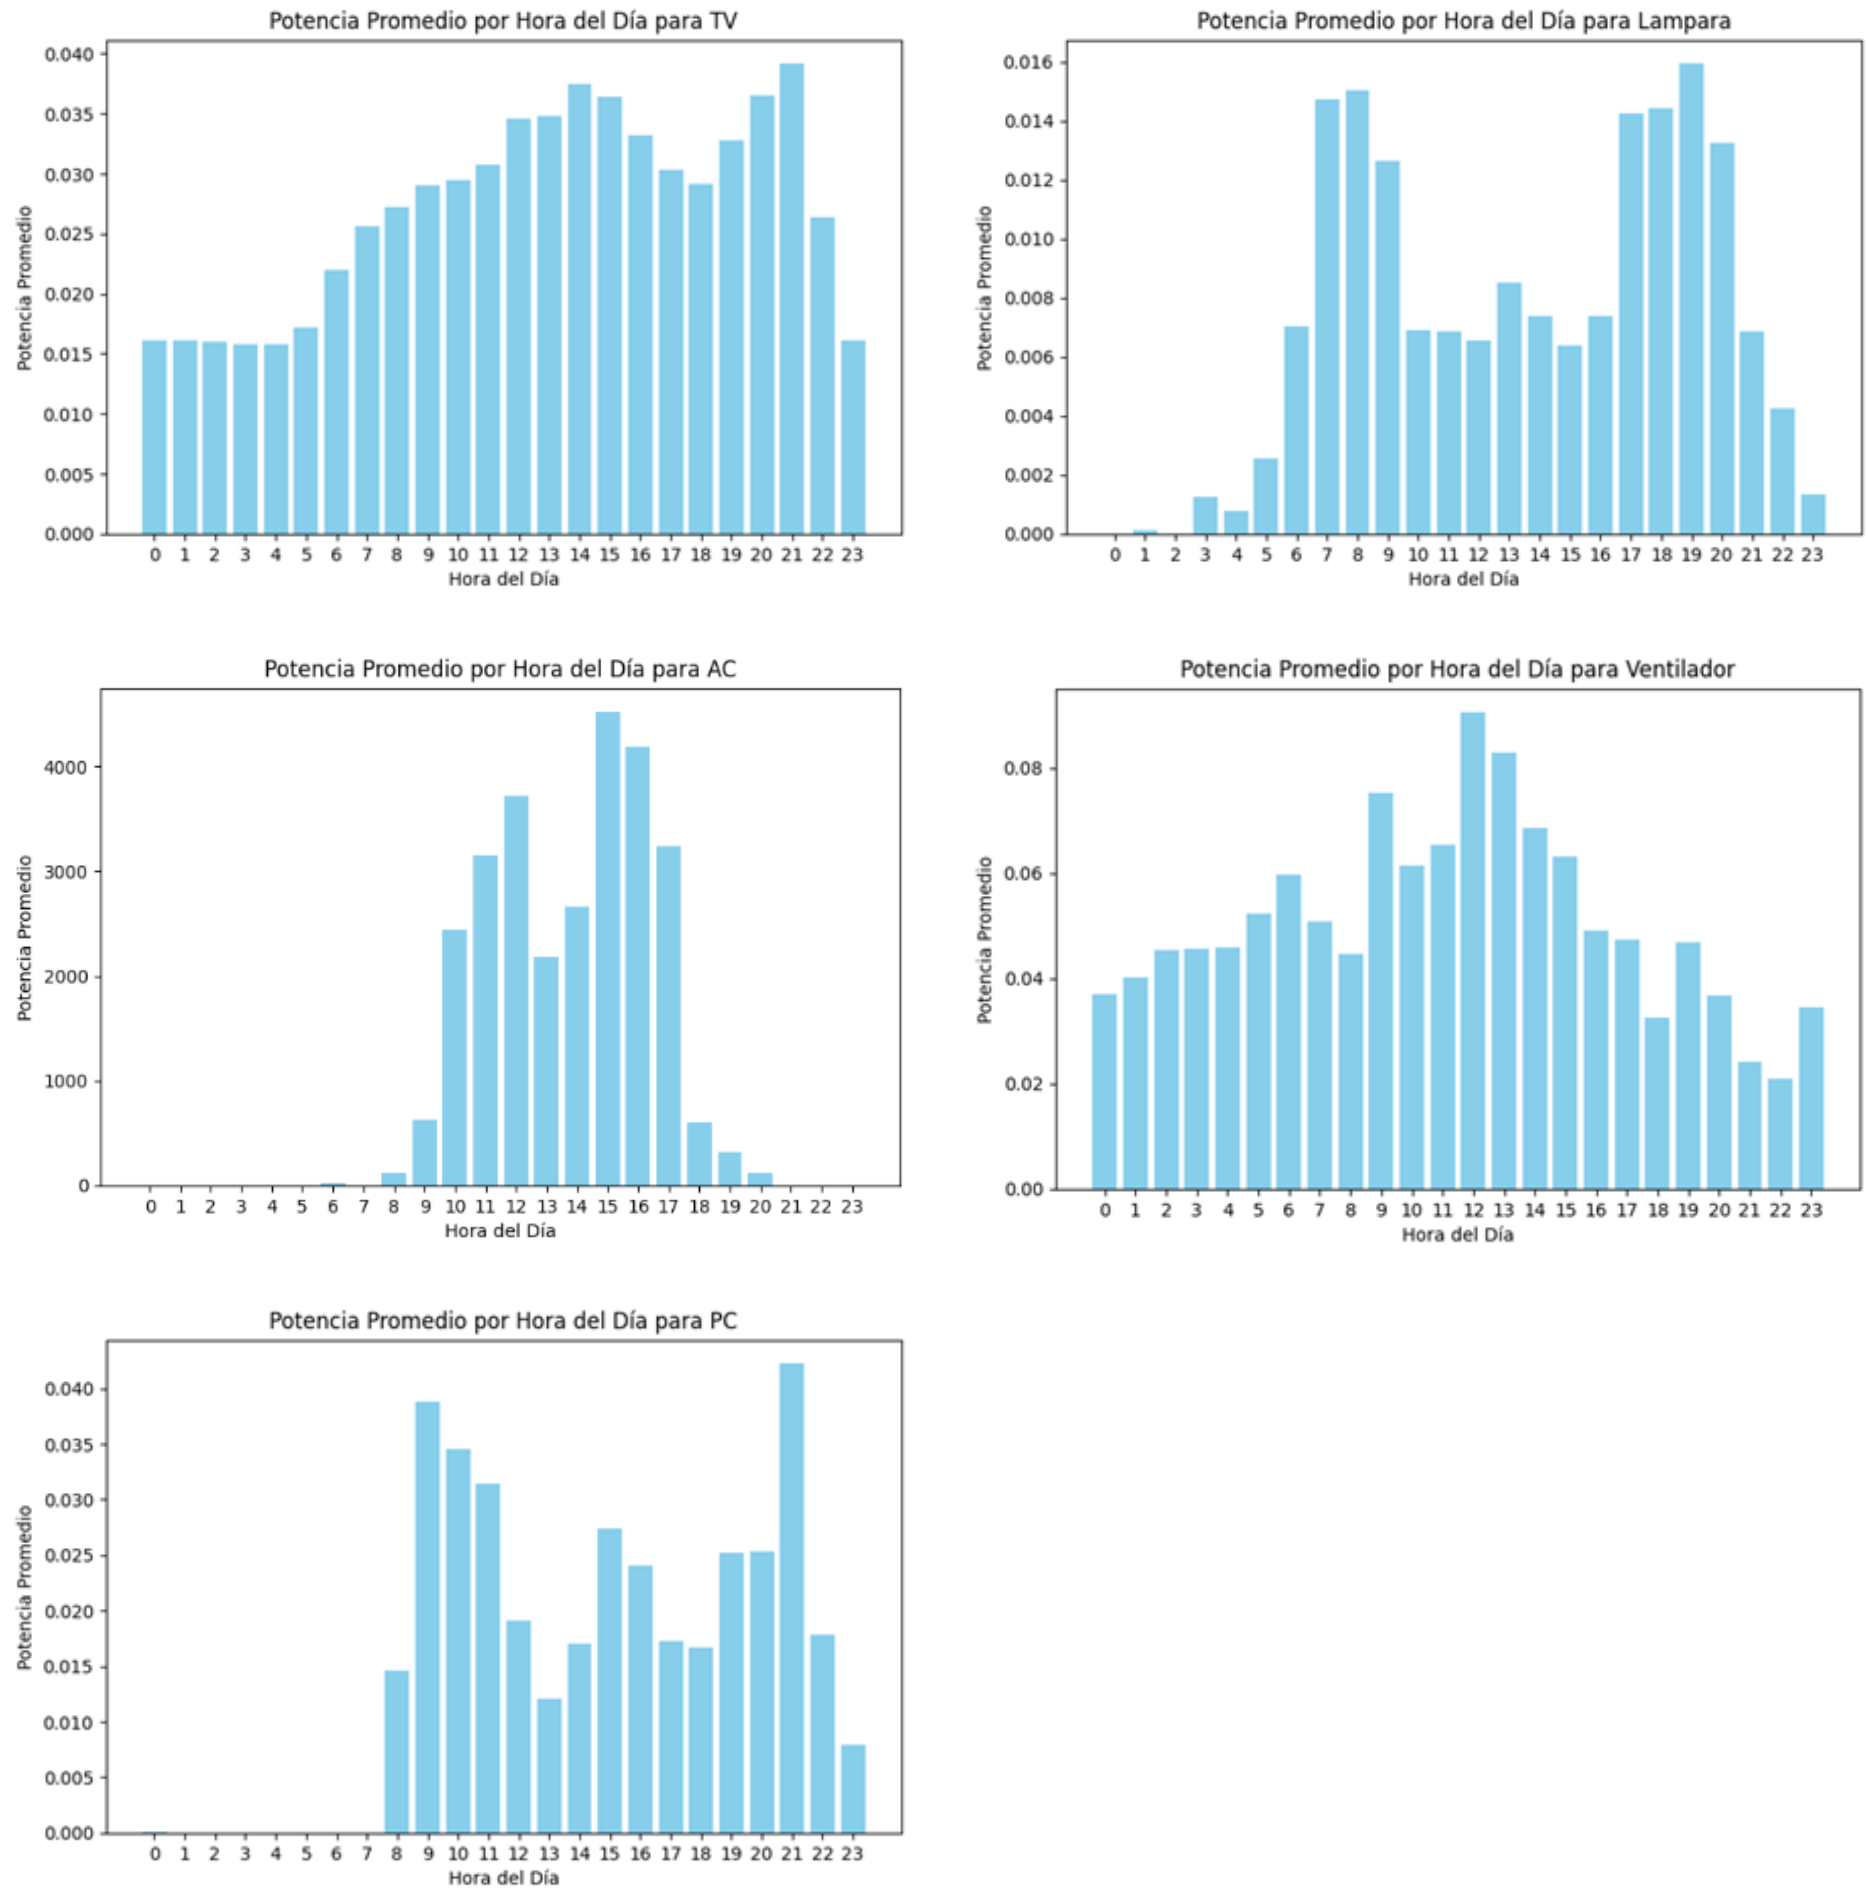


Figura 8. Consumo estimado de dispositivos activos

Los resultados indican que el modelo LSTM proporciona una alta precisión en la clasificación de la conexión de dispositivos y una estimación precisa del consumo de energía. Estos hallazgos demuestran la eficacia del modelo en la gestión de energía, permitiendo una optimización significativa del consumo energético en el hogar. La información obtenida sobre los patrones de consumo de energía puede ayudar a los usuarios a tomar decisiones informadas para mejorar la eficiencia energética y reducir el consumo innecesario. Principio del formulario

V. CONCLUSIONES

En este estudio, se ha explorado y evaluado el uso de un modelo de red neuronal recurrente (RNN) del tipo Long Short-Term Memory (LSTM) para la gestión energética en el hogar (HEMS). Los resultados obtenidos muestran que el enfoque propuesto tiene el potencial de mejorar significativamente la eficiencia energética en los hogares al permitir una mejor identificación y gestión del consumo de energía de los dispositivos.

Una de las principales conclusiones es que el modelo LSTM demostró ser eficaz en la clasificación de la conexión de dispositivos y la estimación de su consumo de energía, logrando una precisión satisfactoria en las pruebas realizadas. Esto sugiere que la utilización de técnicas de inteligencia artificial, puede ser una estrategia efectiva para optimizar la gestión energética en los hogares.

Además, se observó que el modelo proporciona insights útiles sobre los patrones de consumo de energía. Estos insights incluyen la identificación de los dispositivos que consumen más energía en diferentes momentos del día, así como la frecuencia de conexión de cada dispositivo. Esta información permite a los usuarios detectar patrones de uso que pueden ser optimizados para reducir el consumo energético. Por ejemplo, se pueden ajustar los horarios de uso de ciertos dispositivos o implementar medidas para reducir el consumo de los dispositivos que se usan con mayor frecuencia. Estos hallazgos resaltan la importancia de la implementación de sistemas de gestión energética basados en inteligencia artificial, que no solo mejoran la precisión en la predicción del consumo energético, sino que también brindan recomendaciones prácticas para optimizar el rendimiento de los dispositivos y mejorar la sostenibilidad en el uso de la energía. La capacidad del modelo para proporcionar tales recomendaciones demuestra su valor en la mejora de la eficiencia energética en el hogar.

Este estudio refleja el potencial del enfoque propuesto para mejorar la gestión energética en el hogar, lo que puede contribuir a la reducción del consumo energético y las emisiones de carbono a nivel doméstico y, en última instancia, a nivel global.

Es posible resaltar, que el modelo puede integrarse eficazmente con los sistemas de gestión energética existentes, proporcionando una capa adicional de inteligencia que optimiza el control y la supervisión del consumo energético. Su adaptabilidad permite la integración con dispositivos domésticos de diferentes fabricantes, facilitando la interoperabilidad entre distintos sistemas y tecnologías.

Para integrar el modelo con sistemas de gestión energética existentes, se podría implementar una interfaz de programación de aplicaciones (API) que permita al modelo comunicarse con plataformas de gestión de energía ya instaladas en el hogar. Esta integración permitiría que el modelo proporcione recomendaciones en tiempo real sobre el uso de energía y ajuste automáticamente la configuración de los dispositivos conectados para optimizar el consumo.

En cuanto a la interoperabilidad con dispositivos domésticos de diferentes fabricantes, el modelo podría ser adaptado para interactuar con protocolos de comunicación estándar, como Zigbee o Z-Wave, que son comúnmente utilizados en sistemas de automatización del hogar. La adaptación del modelo a estos protocolos permitiría su integración con una amplia variedad de dispositivos, independientemente del fabricante, facilitando la gestión centralizada y la optimización del consumo energético en un entorno doméstico heterogéneo.

Sin embargo, se reconoce que aún existen áreas de mejora y se sugiere continuar investigando y desarrollando modelos y técnicas avanzadas de inteligencia artificial para una gestión energética aún más eficiente y sostenible en el futuro.

FINANCIACIÓN

Este trabajo fue financiado por la Universidad de Sucre, Sincelejo – Colombia.

CONTRIBUCIÓN DE LOS AUTORES

Los autores confirman su contribución al artículo de la siguiente forma: Investigación: Zurisaddai de la Cruz Severiche Maury, preparación del manuscrito: Zurisaddai de la Cruz Severiche Maury, revisión y edición: Alejandro Guerrero, metodología: Zurisaddai de la Cruz Severiche Maury y Javier Emilio Sierra Carrillo, tratamiento de datos y preparación del manuscrito: Zurisaddai de la Cruz Severiche Maury y Alejandro Guerrero, supervisión: Alejandro Guerrero y Javier Emilio Sierra Carrillo.

Todos los autores revisaron los resultados y aprobaron la versión final del manuscrito.

CONFLICTO DE INTERESES

Los autores declaran que no existen conflictos de intereses relacionados con la presentación de este estudio.

AGRADECIMIENTOS

Los autores agradecen al Programa de Investigación “Eficiencia Energética 2030: Transición a la Construcción Sostenible”, con código 1216-938-106387, financiado por el Ministerio de Ciencia, Tecnología e Innovación (Min-ciencias) del Gobierno de Colombia a través de la convocatoria “938-2023 Ecosistemas en Energía Sostenible, Eficiente y Asequible” con contrato No. 395-2023

REFERENCIAS

- [1] Agencia Internacional de Energía. (n.d.). *Acerca de la AIE*. 2023. Disponible: <https://www.iea.org/about>
- [2] Unidad de Planeación Minero-Energética (UPME). *Ley 1715 de 2014*. Disponible: <http://www.upme.gov.co/normatividad/nacional/2014/IForootan>, M. M., Larki, I., Zahedi, R., &
- [3] Nugaliyadde, A., Somaratne, U., & Wong, K. W. (2019). Predicting electricity consumption using deep recurrent neural networks. *arXiv preprint arXiv:1909.08182*.
- [4] H. Szczepaniuk y E. K. Szczepaniuk. (2022). “Applications of Artificial Intelligence Algorithms in the Energy Sector,” *Energies*, 16(1), 347. doi: 10.3390/en16010347
- [5] G. S. Thirunavukkarasu, M. Seyedmahmoudian, E. Jamei, B. Horan, S. Mekhilef, & A. Stojcevski. (2022). “Role of optimization techniques in microgrid energy management systems—A review,” *Energy Strategy Reviews*, 43. doi:10.1016/j.esr.2022.100899
- [6] L. D. Mashapu, P. S. P. Eboule, y H. C. J. Pretorius. (2022). “La necesidad de inteligencia artificial para la gestión de la eficiencia energética: una revisión,” en *8.ª Conferencia internacional sobre eficiencia energética e ingeniería agrícola (EE&AE) de 2022*, Ruse, Bulgaria, pp. 1-6. doi: 10.1109/EEAE53789.2022.9831359
- [7] T. C. Brito y M. A. Brito. (2022). “Previsión del consumo de energía: métodos de inteligencia artificial,” en *17.ª Conferencia Ibérica sobre Sistemas y Tecnologías de la Información (CISTI) 2022*, Madrid, España, pp. 1-4. doi: 10.23919/CISTI54924.2022.9820078
- [8] M. Nutakki y S. Mandava. (2023). “Review on optimization techniques and role of artificial intelligence in home energy management systems,” *Engineering Applications of Artificial Intelligence*, 119. doi:10.1016/j.engappai.2022.105721
- [9] J. Pecas Lopes, J. Moreira Claro, y J. M. Yusta. (2011). “Microgrids: Experiences, barriers and success factors,” *Proceedings of the IEEE*, 99(6), 1020-1031.
- [10] O. Al-Ani y S. Das. (2022). “Aprendizaje por refuerzo: teoría y aplicaciones en HEMS,” *Energías*, 15(17), 1-37. 6392. MDPI AG. Disponible: <http://dx.doi.org/10.3390/en15176392>
- [11] A. T. Souza, L. N. Canha, R. G. Milbradt, C. L. Lemos, C. Michels, y T. A. S. Santana. (2020). “Un sistema de hogar inteligente que utiliza inteligencia artificial e integración con almacenamiento de energía y microgeneración,” en *Conferencia de tecnologías innovadoras de redes inteligentes (ISGT) de IEEE Power & Energy Society 2020*, Washington, DC, EE. UU., pp. 1-5. doi: 10.1109/ISGT45199.2020.9087749
- [12] I. A. Akhinov y M. R. A. Cahyono. (2021). “Desarrollo de un sistema doméstico inteligente basado en inteligencia artificial con tasa de aprendizaje variable para gestionar el consumo de energía en el hogar,” en *Conferencia internacional sobre sistemas de inteligencia artificial y mecatrónica (AIMS) de 2021*, Bandung, Indonesia, pp. 1-6. doi: 10.1109/AIMS52415.2021.9466064
- [13] R. El Makroum, A. Khallaayoun, R. Lghoul, K. Mehta, y W. Zörner. (2023). “Home Energy Management System Based on Genetic Algorithm for Load Scheduling: A Case Study Based on Real Life Consumption Data,” *Energies*, 16(6), 2698. MDPI AG. Disponible: <http://dx.doi.org/10.3390/en16062698>
- [14] F. Ulloa-Vásquez, L. García-Santander, D. Carrizo, y V. Heredia-Figueroa. (2022). “Intelligent Electrical Pattern Recognition of Appliances Consumption for Home Energy Management using High Resolution Measurement,” *IEEE Latin America Transactions*, 20(2), 326-334. doi: 10.1109/TLA.2022.9661473
- [15] H. Zhang, X. Liu, y Y. Li. (2021). “Energy Management Systems for Microgrids Using Artificial Intelligence: A Review,” *Energy Conversion and Management*, 224, 113307.
- [16] X. Chen y D. Ning. (2023). “FastInformer-HEMS: A Lightweight Optimization Algorithm for Home Energy Management Systems,” *Energies*, 16(9), 3897. MDPI AG. Disponible: <http://dx.doi.org/10.3390/en16093897>
- [17] X. Chen y J. Liu. (2021). “Smart home energy management system using deep learning techniques,” *Energy Reports*, 7, 1234-1245. <https://doi.org/10.1016/j.egvr.2021.03.018>
- [18] D. Lee, S. Park, y J. Kim. (2023). “Predictive analytics for home energy management systems using recurrent neural networks,” *Applied Energy*, 307, 118152. <https://doi.org/10.1016/j.apenergy.2022.118152>
- [19] H. Li, Y. Wang, y Z. Huang. (2022). “A deep learning approach for household energy consumption prediction,” *Journal of Energy Storage*, 50, 104188. <https://doi.org/10.1016/j.est.2022.104188>
- [20] A. Smith, B. Brown, y C. Johnson. (2020). “Energy consumption forecasting in smart homes with LSTM neural networks,” *IEEE Transactions on Smart Grid*, 11(2), 320-329. <https://doi.org/10.1109/TSG.2020.2994874>

- [21] T. Zhang, S. Liu, y Q. Xu. (2019). "A comparative study of LSTM and GRU for predicting energy consumption," *Energy Procedia*, 158, 2345-2350. <https://doi.org/10.1016/j.egypro.2019.01.273>
- [22] J. Zhao, X. Wang, y L. Liu. (2021). "Home energy management based on long short-term memory neural network," *Renewable Energy*, 178, 792-800. <https://doi.org/10.1016/j.renene.2021.06.063>
- [23] M. Choi, D. Lee, y J. Kim. (2021). "Energy consumption prediction for home energy management systems using LSTM neural networks," *Energy and Buildings*, 235, 110708. <https://doi.org/10.1016/j.enbuild.2021.110708>
- [24] S. Ryu, S. Han, y H. Yoon. (2020). "Deep learning for energy management in smart homes," *IEEE Access*, 8, 183680-183688. <https://doi.org/10.1109/ACCESS.2020.3029065>
- [25] Gallardo, J. A. (2023). Análisis Exhaustivo de los Sistemas de Gestión de la Energía en Hogares Inteligentes. *CESTA*, 4(2).
- [26] De La Hoz, J., Guerrero, B., & Beleño, K. (2021). Dispositivo de Monitoreo de Consumo para el Ahorro de Energía en el Hogar. *CESTA*, 2(1), 1-18.

Zurisaddai Severiche-Maury, es miembro del grupo de Investigación e Innovación en Electrónica (GINELECT), y profesor de la Facultad de Ingenierías en el Programa de Ingeniería Electrónica de la Universidad de Sucre.

Alejandro Guerrero-Hernández, es Ingeniero Electrónico, Especialista y Magíster en Controles Industriales de la Universidad de Pamplona. El ingeniero Alejandro realizó su estudio Doctorales en Automatización y Sistema en la Universidad Tecnológica Federal de Paraná (UTFPR) en Brasil. Trabaja como docente- Investigador en el programa de Ingeniería Electrónica en la Universidad de Sucre.

Javier E. Sierra, es Doctor y Magister en ingeniería de la Universidad Pontificia Bolivariana. Actualmente, docente de la facultad de ingenierías de la Universidad de Sucre. Es Investigador en áreas como redes inteligentes, telecomunicaciones y redes ópticas.

José López-Prado, es ingeniero electrónico y Máster en Controles Industriales, y Doctor en Ingeniería Industrial y profesor del Departamento de Ingeniería Electrónica en la Universidad de Sucre.