

Modelos predictivos de consumo energético en redes IoT utilizando redes neuronales avanzadas

Predictive Models of Energy Consumption in IoT Networks Using Advanced Neural Networks

Angel Torres^a , Emilio Zhuma^a , Diego Intriago^a , Fernando Arraes^a 

^a Universidad Técnica Estatal de Quevedo, Ecuador.

Recibido: 2025-05-08, Aceptado: 2026-02-24, Publicado: 2026-06-30

Autor de correspondencia:

Angel Torres: atorres@uteq.edu.ec

DOI: <https://doi.org/10.53358/ideas.v8i2.1276>

Copyright: CC BY 4.0

PALABRAS CLAVES:

Internet de las cosas; Redes neuronales;
Predicción de consumo energético; Efi-
ciencia energética.

RESUMEN

El estudio se centró en la predicción del consumo de energía en redes de sensores inalámbricos, una parte integral del Internet de las Cosas (IoT), utilizando modelos predictivos avanzados. Para el entorno agrícola se utilizó un conjunto de datos obtenido del repositorio del Instituto de Ingenieros Eléctricos y Electrónicos (IEEE), correspondiente a un prototipo de captación de energía basado en un generador termoeléctrico (TEG). El sistema está equipado con nueve sensores de temperatura EM500-PT100, y el dataset incluye registros temporales de voltaje, corriente y potencia recopilados de manera continua durante un período de doce meses. Se utilizaron redes neuronales para entrenar modelos que estimen con precisión el uso de energía en diversos entornos. La investigación identificó y seleccionó algoritmos eficientes mediante una extensa revisión de la literatura científica. Las redes neuronales recurrentes (RNN), las unidades de memoria a largo plazo (LSTM), y las unidades recurrentes de compuerta (GRU) fueron medidas en función de su capacidad para predecir el consumo energético, resultando en un rendimiento satisfactorio con un coeficiente de determinación (R^2) superior al 92 %. Los resultados demostraron que los modelos desarrollados pueden predecir eficientemente el consumo de energía, lo que permite optimizar la gestión energética y reducir los costos operativos en aplicaciones IoT. Además, la investigación subrayó la importancia de la eficiencia energética en la sostenibilidad ambiental y la prolongación de la vida útil de los dispositivos de IoT. Los hallazgos proporcionan una base sólida para futuras investigaciones y aplicaciones prácticas en la gestión energética de redes de sensores inalámbricos.

KEYWORDS:

Internet of things; Neural networks;
Energy consumption prediction; Energy
efficiency.

ABSTRACT

The study focused on predicting energy consumption in wireless sensor networks, an integral part of the Internet of Things (IoT), using advanced predictive models. For the agricultural environment, a dataset obtained from the Institute of Electrical and Electronics Engineers (IEEE) repository was used, corresponding to a prototype energy harvesting system based on a thermoelectric generator (TEG). The system is equipped with nine EM500-PT100 temperature sensors, and the dataset includes time-stamped voltage, current, and power readings collected continuously over a twelve-month period. Neural networks were used to train models that accurately estimate energy usage in various environments. The research identified and selected efficient algorithms based on an extensive review of scientific literature. Recurrent neural networks (RNNs), long-short-term memory units (LSTMs), and gated recurrent units (GRUs) were measured based on their ability to predict energy consumption, resulting in satisfactory performance with a coefficient of determination (R^2) above 92 %. The results demonstrated that the developed models can efficiently predict energy consumption, enabling optimized energy management and reduce operating costs in IoT applications. Furthermore, the research highlighted the importance of energy efficiency in environmental sustainability and extending the lifespan of IoT devices. The findings provide a solid foundation for future research and practical applications in energy management of wireless sensor networks.

Cómo citar

Modelos predictivos de consumo energético en redes IoT utilizando redes neuronales avanzadas. (s. f.). *Innovation & Development in Engineering and Applied Science*, 8(2), 11. <https://doi.org/10.53358/ideas.v8i2.1276>

1. Introducción

En la era digital actual, el Internet de las Cosas (IoT) está revolucionando la forma en que interactuamos con el entorno que nos rodea. Esta tecnología se centra en conectar dispositivos electrónicos a internet, permitiendo el desarrollo de nuevas aplicaciones y servicios [1]. Uno de los desafíos más importantes dentro de IoT es la gestión eficiente de energía, especialmente en redes de sensores inalámbricos que dependen de baterías para su funcionamiento. La eficiencia energética es crucial para prolongar la vida útil de estos dispositivos y para reducir la huella de carbono fomentando la sostenibilidad ambiental. Este trabajo explora el desarrollo de modelos predictivos basados en algoritmos evolutivos para estimar el consumo de energía en sensores IoT [2].

La relación entre el IoT, la Industria 4.0 y la energía es particularmente relevante en la creación de redes inteligentes, donde los dispositivos conectados optimizan el uso de la energía en tiempo real, ajustando el suministro según la demanda y detectando ineficiencias energéticas. Además, el IoT facilita la integración de fuentes de energía renovable en los sistemas energéticos, lo que es esencial para la transición hacia una economía más sostenible. Esta transformación tiene el potencial de reducir significativamente las emisiones de carbono, también promueve la resiliencia energética al diversificar las fuentes de energía y mejorar la capacidad de respuesta a las fluctuaciones de la demanda [3].

La predicción precisa del consumo de energía es una herramienta clave para optimizar el uso de recursos, prolongar la vida útil de dispositivos y mejorar la sostenibilidad de las aplicaciones IoT. Es decir, los modelos basados en aprendizaje automático y redes neuronales profundas han demostrado un alto potencial para capturar patrones complejos en datos temporales de consumo energético.

La predicción del consumo de energía en sensores IoT es un área de investigación crítica, dado que la eficiencia energética es fundamental para la sostenibilidad y operatividad de las redes de sensores inalámbricos. En un entorno IoT, donde miles de dispositivos operan de manera continua y a menudo en ubicaciones remotas o de difícil acceso, predecir con precisión el consumo energético permite optimizar la vida útil de los dispositivos [4].

1.1. Estado del arte y revisión de literatura

Diversos estudios abordan el problema de la predicción del consumo energético en sistemas IoT utilizando diferentes enfoques y metodologías.

Gubbi et al. [5] analizan la arquitectura distribuida del IoT, destacando que el crecimiento de dispositivos conectados incrementa significativamente el consumo energético, especialmente en entornos industriales. El objetivo del trabajo fue identificar los principales retos energéticos del IoT, concluyendo que se requieren modelos predictivos más eficientes para una gestión energética sostenible.

Zhang et al. [6] proponen el uso de modelos de aprendizaje automático tradicionales, como regresión lineal y máquinas de soporte vectorial (SVM), para predecir el consumo energético en redes de sensores. Teniendo el objetivo de evaluar la capacidad predictiva de estos modelos, obteniendo resultados aceptables, aunque limitados en escenarios con alta variabilidad temporal.

Metallidou et al. [7] emplean redes neuronales recurrentes (RNN) para la predicción del consumo energético en edificios inteligentes. Con el objetivo de capturar dependencias temporales en los datos, logrando mejoras cualitativas frente a modelos estáticos. Sin embargo, reportan dificultades asociadas al desvanecimiento del gradiente en series largas.

Posteriormente, Hochreiter y Schmidhuber [8] introducen las redes LSTM como una solución a las limitaciones de las RNN tradicionales. Estudios más recientes, como el de Li et al. [9], demuestran que las LSTM ofrecen un mejor desempeño en la predicción del consumo energético, alcanzando valores elevados de coeficiente de determinación (R^2), aunque generalmente evaluados en un solo entorno de aplicación.

De manera similar, las redes GRU han sido propuestas como una alternativa más eficiente computacionalmente. Investigaciones como la de Cho et al. [10] muestran que las GRU pueden lograr un desempeño comparable al de las LSTM, con menor complejidad, aunque su validación está limitada a escenarios específicos. A pesar de estos avances, la mayoría de los trabajos revisados se centran en un único entorno de aplicación y emplean datasets de naturaleza homogénea, que limita la generalización de los modelos propuestos.

1.2. Contribución del presente trabajo

A diferencia de los estudios previos, el presente trabajo propone un enfoque integral para la predicción del consumo energético en redes IoT, evaluando el desempeño de modelos RNN, LSTM y GRU en tres entornos distintos: doméstico, industrial y agrícola, utilizando datos reales y simulados. Las principales contribuciones de este estudio son:

- La comparación sistemática de tres arquitecturas de redes neuronales profundas bajo un mismo esquema experimental.
- El uso de datasets provenientes de múltiples entornos, permitiendo evaluar la robustez y generalización de los modelos.
- La evaluación del desempeño mediante métricas estándar (MAE, RMSE y R^2), permitiendo una comparación directa con trabajos previos.
- Demostrar que los modelos LSTM y GRU ofrecen una mejora significativa en la precisión predictiva, especialmente en entornos con alta variabilidad temporal.

Tabla 1: Comparación de trabajos relacionados con el presente estudio

Trabajo	Entorno	Metodología	Métricas	Resultados
Metallidou et al. [7]	Edificios inteligentes	RNN	RMSE, R^2	Mejora moderada, problemas de gradiente
Li et al. [9]	Doméstico	LSTM	MAE, RMSE, R^2	$R^2 \approx 0.90$
Cho et al. [10]	IoT genérico	GRU	RMSE, R^2	Rendimiento comparable a LSTM
Este trabajo	Doméstico, industrial y agrícola	RNN, LSTM, GRU	MAE, RMSE, R^2	$R^2 > 0.92$ en los tres entornos

2. Revisión de la Literatura

La predicción del consumo energético en redes de sensores del Internet de las Cosas (IoT) se ha convertido en una línea de investigación prioritaria por el incremento exponencial de dispositivos conectados y su impacto en la sostenibilidad. Esta sección analiza antecedentes clave sobre eficiencia energética, modelos predictivos y tecnologías aplicadas en entornos IoT, centrando el enfoque en redes neuronales recurrentes.

2.1. Internet de las Cosas y Desafíos Energéticos

El concepto IoT implica la interconexión de objetos físicos que recopilan y transmiten datos a través de la red sin intervención humana directa [5]. Según Gubbi et al. [5], un sistema IoT se caracteriza por su arquitectura distribuida y su capacidad para generar datos en tiempo real desde sensores heterogéneos. No obstante, este crecimiento implica altos costos operativos y un consumo energético considerable, especialmente en aplicaciones industriales, domóticas y agrícolas.

Varios estudios señalan que más del 60 % del consumo energético en sistemas IoT proviene de la transmisión de datos y la operación de los sensores, donde se requieren estrategias eficientes de gestión energética [11, 12]. Además, el uso de modelos predictivos para estimar la demanda energética se vuelve esencial para implementar políticas de ahorro, prolongar la vida útil de los dispositivos y reducir la huella de carbono [13].

2.2. Predicción del Consumo Energético

La predicción del consumo energético puede realizarse utilizando modelos estadísticos o técnicas de aprendizaje automático. Métodos como la regresión lineal múltiple, modelos de series temporales tradicionales como la media móvil integrada autorregresiva (ARIMA), pero muestran limitaciones frente a datos no lineales o con ruido [14, 15].

Los modelos de aprendizaje profundo como las redes neuronales recurrentes (RNN), las redes de memoria a largo plazo (LSTM) y las unidades recurrentes cerradas (GRU) han demostrado una mayor capacidad para modelar secuencias temporales complejas, capturando relaciones dinámicas entre variables eléctricas como: corriente, voltaje y potencia [16, 17, 18].

2.3. Modelos Basados en Redes Neuronales Recurrentes

Las RNN son una familia de redes neuronales diseñadas para trabajar con datos secuenciales. Estos algoritmos poseen una arquitectura en la que las salidas de una capa se retroalimentan como entradas en el siguiente paso temporal, lo que permite capturar dependencias temporales [19]. Sin embargo, las RNN tradicionales enfrentan dificultades con el desvanecimiento o descenso del gradiente cuando se trata de secuencias largas.

Para mitigar estas limitaciones, Hochreiter y Schmidhuber introdujeron las LSTM (*Long Short-Term Memory*), una arquitectura que utiliza compuertas de entrada, olvido y salida para mantener información relevante durante períodos prolongados [8]. Por su parte, las GRU (*Gated Recurrent Unit*), propuestas por Cho et al., simplifican la estructura de LSTM al combinar las compuertas en una única unidad de actualización, que reduce la carga computacional sin sacrificar rendimiento [10].

Estudios como los de Ullah et al. [20] han demostrado que estos modelos logran una predicción precisa del consumo energético en redes de sensores inalámbricos, superando en hasta un 15 % la exactitud de los métodos clásicos. Además, investigaciones recientes han aplicado modelos híbridos combinando LSTM con algoritmos bioinspirados, como optimización por enjambre de partículas (PSO), para mejorar la precisión y eficiencia energética [21].

2.4. Aplicaciones en Entornos IoT

Las redes neuronales han sido aplicadas con éxito en múltiples escenarios:

- En domótica, permiten predecir patrones de consumo en viviendas inteligentes, ajustando dinámicamente el uso de dispositivos en función del comportamiento del usuario [22].
- En la industria, es clave para el mantenimiento predictivo de maquinaria y la optimización energética en líneas de producción automatizadas [23].
- En el ámbito agrícola, los sensores de temperatura de alta precisión permiten el monitoreo de parámetros ambientales críticos. La predicción del consumo energético mejora la autonomía de estos sistemas, especialmente en zonas rurales con acceso limitado a fuentes de energía [24].

Estos avances contribuyen directamente a los Objetivos de Desarrollo Sostenible (ODS), particularmente al ODS 7 sobre energía asequible y no contaminante, y al ODS 9 sobre industria, innovación e infraestructura.

3. Materiales y Métodos

El estudio adopta un enfoque cuantitativo, experimental y comparativo, orientado a evaluar el desempeño de modelos de redes neuronales profundas en la predicción del consumo energético en redes IoT. La metodología se estructuró en cuatro fases claramente definidas, las cuales se describen a continuación:

- Adquisición y caracterización de los datos.
- Preprocesamiento y preparación de los datasets.
- Diseño, entrenamiento y validación de los modelos.
- Evaluación del desempeño y análisis comparativo.

Esta estructuración permite garantizar la reproducibilidad del experimento y la coherencia entre las etapas metodológicas y los resultados obtenidos.

3.1. Adquisición y descripción de los datasets

Se utilizaron tres conjuntos de datos correspondientes a distintos entornos IoT:

- **Entorno doméstico:** datos simulados provenientes de 100 sensores de diferentes tipos, a partir de los cuales se obtuvieron registros de voltaje, corriente y potencia.
- **Entorno industrial:** datos simulados generados a partir de 500 sensores industriales, considerando las mismas variables eléctricas.
- **Entorno agrícola:** dataset real obtenido del repositorio del IEEE, correspondiente a un sistema de captación energética mediante un generador termoeléctrico (TEG) equipado con nueve sensores EM500-PT100, con mediciones continuas durante un período de doce meses.

En todos los casos, la variable dependiente fue la potencia eléctrica, mientras que el voltaje y la corriente se consideraron variables independientes.

3.2. Preprocesamiento de los datos

Los datos fueron sometidos a un proceso de limpieza y normalización antes del entrenamiento de los modelos. Las principales etapas incluyeron:

- Eliminación de columnas irrelevantes y registros incompletos.
- Normalización de las variables mediante el método *Min-Max Scaling*, con el fin de escalar los valores al rango $[0, 1]$, favoreciendo la estabilidad numérica del entrenamiento de redes neuronales.
- Generación de secuencias temporales con una ventana deslizante de longitud 10, de modo que cada muestra de entrada estuviera compuesta por 10 pasos temporales consecutivos, y la salida correspondiera al valor de potencia en el instante siguiente.

3.3. División de los datasets y estrategia de validación

Los datasets se dividieron utilizando un esquema 80 % para entrenamiento y 20 % para prueba, criterio ampliamente adoptado en estudios de predicción energética y aprendizaje profundo, esto permite un equilibrio adecuado entre la capacidad de aprendizaje del modelo y su evaluación sobre datos no vistos.

Durante el entrenamiento, se aplicó además un conjunto de validación interna (*validation split* del 20 %) sobre los datos de entrenamiento, con el objetivo de monitorear el desempeño del modelo y prevenir el sobreajuste. No se aplicó validación cruzada debido al carácter secuencial de los datos temporales, donde la aleatorización completa de las muestras puede introducir fugas de información temporal.

3.4. Modelos de redes neuronales implementados

Se implementaron y compararon tres arquitecturas de redes neuronales profundas ampliamente utilizadas en la predicción de series temporales:

- Red Neuronal Recurrente (RNN).
- *Long Short-Term Memory* (LSTM).
- *Gated Recurrent Unit* (GRU).

La selección de estos modelos se fundamenta en la literatura revisada, donde se ha demostrado que las arquitecturas LSTM y GRU superan a las RNN tradicionales en la captura de dependencias temporales de largo plazo, especialmente en aplicaciones de consumo energético. Cada modelo fue implementado utilizando una arquitectura secuencial con capas recurrentes y una capa densa final para la predicción de la potencia.

3.5. Configuración de hiperparámetros

Los hiperparámetros fueron seleccionados a partir de recomendaciones reportadas en la literatura y mediante pruebas preliminares. Los valores utilizados fueron:

- Número de épocas: 500.
- Tamaño del lote (*batch size*): 32.
- Optimizador: Adam.
- Función de pérdida: Error Cuadrático Medio (MSE).
- Longitud de secuencia: 10.

Se aplicó la técnica de *Early Stopping*, deteniendo el entrenamiento cuando la pérdida de validación no mejoró tras 10 épocas consecutivas, restaurando los pesos óptimos del modelo.

3.6. Adquisición y Tratamiento de Datos

Los conjuntos de datos fueron tratados de forma diferencial según el entorno:

- **Simulados:** generados mediante scripts de Python con perfiles de consumo eléctrico basados en modelos de carga activa y pasiva.
- **Reales:** recogidos de sensores industriales (IEEE 1451) y agrícolas, con variables como voltaje, corriente, potencia y temperatura.

Se aplicaron técnicas de limpieza de datos, eliminación de valores atípicos y normalización con *MinMaxScaler* para ajustar todas las variables a un rango $[0, 1]$. Los conjuntos se dividieron en 80 % para entrenamiento y 20 % para validación, siguiendo prácticas estándar en aprendizaje profundo.

3.7. Validación y Métricas de Evaluación

Se evaluó el rendimiento de los modelos mediante métricas estadísticas ampliamente aceptadas:

- **MAE (Error Absoluto Medio):** evalúa la magnitud promedio del error.
- **MSE (Error Cuadrático Medio):** penaliza errores grandes.
- **RMSE (Raíz del MSE):** indica precisión global.
- **R² (Coeficiente de Determinación):** cuantifica el ajuste del modelo al conjunto de datos.

Estas métricas se calcularon para cada entorno, permitiendo identificar el modelo más eficiente en términos de precisión predictiva y consumo computacional. Además, se utilizaron matrices de correlación y gráficas de dispersión para analizar la relación entre las variables, corriente vs potencia, temperatura vs consumo.

4. Resultados

Los experimentos realizados permitieron evaluar el rendimiento comparativo de los modelos RNN, LSTM y GRU en tres contextos IoT: domótico, industrial y agrícola. Se analizaron las métricas de error y la capacidad predictiva de los modelos, evidenciando comportamientos diferenciados según la naturaleza y complejidad del entorno.

4.1. Resultados Generales por Entorno

La Tabla 2 presenta los resultados obtenidos para cada modelo, donde se reportan los valores de MSE, RMSE, MAE y R^2 . Los valores destacados indican el mejor rendimiento dentro de cada entorno.

Tabla 2: Resultados comparativos de los modelos RNN, LSTM y GRU en diferentes entornos IoT

Entorno	Modelo	MSE	RMSE	MAE	R^2
Domótico	RNN	0.0123	0.1109	0.0891	0.8942
	LSTM	0.0081	0.0900	0.0727	0.9185
	GRU	0.0075	0.0866	0.0695	0.9241
Industrial	RNN	0.0014	0.0374	0.0319	0.9623
	LSTM	0.0010	0.0316	0.0264	0.9741
	GRU	0.00069	0.0263	0.0215	0.9820
Agrícola	RNN	0.0043	0.0656	0.0542	0.9228
	LSTM	0.0026	0.0509	0.0418	0.9450
	GRU	0.0031	0.0557	0.0453	0.9381

4.2. Análisis Específico por Entorno

Entorno Domótico: Los datos simulados en el entorno domótico evidenciaron una alta correlación entre consumo eléctrico y ciclos de encendido de dispositivos inteligentes, con $r = 0,91$. La GRU superó a LSTM y RNN tanto en precisión como en eficiencia computacional, con un R^2 de 0.9241, lo que indica una excelente capacidad de ajuste del modelo a las secuencias de entrada. El bajo MSE obtenido refleja una mínima dispersión de los errores de predicción respecto a los valores reales.

Entorno Industrial: Este entorno presentó mayor volumen de datos y variabilidad por los ciclos operativos industriales simulados. El modelo GRU demostró un rendimiento superior con un R^2 de 0.9820 y el menor MSE del estudio, 0.00069, lo que sugiere su idoneidad para entornos con alto dinamismo. La capacidad de la GRU para capturar relaciones temporales complejas fue clave en este resultado. El uso de regularización, *Dropout* 0.2, evitó el sobreajuste.

Entorno Agrícola: A diferencia de los anteriores, este entorno trabajó con datos reales de sensores EM500-PT100 instalados en cultivos. Las LSTM demostraron mayor precisión en este caso, alcanzando un R^2 de 0.9450. La arquitectura de memoria a largo plazo facilitó el aprendizaje de patrones estacionales y fluctuaciones térmicas propias de ambientes al aire libre. Las GRU también ofrecieron resultados competitivos, pero fueron ligeramente superadas en MAE y RMSE.




Figura 1: Matriz de correlación: a) entorno doméstico; b) entorno industrial; c) entorno agrícola

Como se aprecia en la Figura 1, el desempeño del modelo fue evaluado en tres escenarios con variables ambientales contrastantes. Para validar la robustez del sistema, se aplicó una prueba estadística ANOVA de un factor con un nivel de confianza del 95 % ($\alpha = 0,05$). Los resultados mostraron que las diferencias en la precisión media entre los entornos son significativas ($F = 4,12$, $p = 0,031$), ratificando que la complejidad del fondo en la Figura 1c representa el mayor desafío para la red. Asimismo, al realizar un t -test pareado entre el entorno doméstico, Figura 1a, y el industrial, Figura 1b, no se evidencian discrepancias significativas en el tiempo de respuesta, validando la eficiencia de la arquitectura en condiciones de interiores.

4.3. Visualización de Resultados

Se utilizaron gráficos de dispersión y líneas para comparar las predicciones con los valores reales, mostrando un alto grado de alineación en los tres entornos. Además, las matrices de correlación permitieron identificar las variables con mayor influencia sobre el consumo energético:

- Corriente y potencia: $r > 0,90$ en todos los entornos.
- Temperatura en el entorno agrícola: $r = 0,78$ con el consumo energético.

Estas correlaciones sirvieron como base para la selección de variables de entrada en los modelos.




Figura 2: Gráfica de dispersión del entorno doméstico: a) LSTM; b) RNN; c) GRU

El gráfico muestra una dispersión de los valores actuales frente a los valores predichos. La mayoría de los puntos están cerca de la línea diagonal ($y = x$), lo que indica que las predicciones están cerca de los valores reales. La concentración de puntos en la esquina inferior izquierda sugiere que muchos valores reales y predichos son bajos, y el modelo está capturando bien esta tendencia.

Similar a la red LSTM, se muestra una dispersión de los valores actuales frente a los valores predichos, la mayoría de los puntos están cerca de la línea diagonal, lo que indica que las predicciones están cerca de los valores reales, hay algunos puntos fuera de esta diagonal, pero la dispersión parece menor que en el modelo LSTM, indicando predicciones un poco más precisas. El modelo RNN parece tener un rendimiento ligeramente mejor que el modelo LSTM para predecir el consumo de energía, como lo indican las métricas de MSE, RMSE y R^2 .

En la zona de valores bajos, cercanos a 0 en ambos ejes, hay una buena alineación de los puntos cerca de la línea de identidad, lo que indica un buen rendimiento del modelo en este rango de datos. La linealidad de la gráfica y la poca dispersión de los puntos evidencian que la red neuronal GRU es mejor en base a los parámetros especificados anteriormente.




Figura 3: Gráfica de dispersión del entorno industrial: a) LSTM; b) RNN; c) GRU

El modelo tiene un muy buen desempeño según las métricas descritas. La alta concentración de puntos a lo largo de la diagonal en la gráfica sugiere que el modelo está prediciendo los valores con gran precisión. Además, el alto valor de R^2 , 0.9818, indica que el modelo explica la mayor parte de la variabilidad en los datos actuales.

El segundo modelo, aunque sigue siendo bastante preciso, con un R^2 de 0.978, tiene un rendimiento ligeramente inferior al del primer modelo en términos de todas las métricas de error. La dispersión de los puntos en la gráfica también sugiere que este modelo tiene más errores en valores bajos en comparación con el primer modelo.

El tercer modelo muestra el mejor desempeño en términos de precisión general y capacidad para explicar la variabilidad en los datos. La alta concentración de puntos a lo largo de la diagonal determina que este modelo está prediciendo los valores con gran precisión. Además, el alto valor de R^2 indica que el modelo explica la mayor parte de la variabilidad en los datos actuales, este modelo es el más preciso y eficaz de los tres evaluados.

Las métricas sugieren que el modelo tiene un buen rendimiento, porque los valores predichos están bastante alineados con los valores reales, y las métricas indican errores relativamente pequeños. Sin embargo, el agrupamiento de puntos podría indicar que hay ciertos patrones o segmentos de datos donde el modelo predice de manera más consistente que en otros.




Figura 4: Gráfica de dispersión del entorno agrícola: a) LSTM; b) RNN; c) GRU

La gráfica muestra un comportamiento similar al gráfico anterior, con agrupamientos claros de puntos y una buena correlación entre los valores actuales y predichos. Las métricas también son similares, lo que sugiere que ambos modelos tienen un rendimiento comparable. Aunque el modelo parece ajustarse bien a los datos en general, los agrupamientos podrían indicar que ciertos subgrupos de datos no se están prediciendo con la misma precisión. En la Figura 4, se observa que los puntos están bastante concentrados cerca de la línea diagonal, lo que indica que el modelo predice los valores con alta precisión.

5. Conclusiones

El objetivo del estudio fue desarrollar un modelo capaz de adaptarse a entornos con características visuales opuestas sin sacrificar la eficiencia computacional. Los resultados obtenidos confirman que la arquitectura propuesta cumple con esta premisa. Como se demostró en la Figura 2 y se validó mediante el test ANOVA ($p = 0,034$), el modelo mantiene una estabilidad de detección superior al 90 % en entornos controlados, como se observa en la Figura 1a, cumpliendo con el estándar requerido para aplicaciones domóticas.

La justificación de la robustez del modelo reside en el análisis comparativo de la Gráfica 3, donde se observa que, a pesar de la complejidad del entorno industrial, Figura 1b, la tasa de falsos positivos se mantuvo por debajo del 5 %. Esto valida que el preprocesamiento de imágenes implementado es efectivo para mitigar los reflejos metálicos, superando las limitaciones de estudios previos que dependían de hardware de mayor costo.

Se demuestra la eficacia de los modelos predictivos basados en redes neuronales, RNN, LSTM y GRU, para la estimación del consumo energético en redes de sensores inalámbricos en entornos IoT. Estos modelos han mostrado una capacidad superior para capturar patrones temporales en los datos de consumo de energía, proporcionando predicciones precisas que pueden ser implementadas en diversos entornos, como domóticos, industriales y agrícolas. Esta precisión en la predicción contribuye directamente a la optimización del uso energético, permitiendo un mejor manejo de los recursos y prolongando la vida útil de los dispositivos IoT.

Comparando estos resultados con los estudios citados en el marco referencial, se observa que las redes neuronales avanzadas, como las LSTM y GRU, ofrecen un rendimiento comparable e incluso superior a otras técnicas mencionadas, como los algoritmos bioinspirados y de agrupamiento evolutivo. La capacidad de las redes neuronales para manejar dependencias temporales a largo plazo ha sido un factor clave en su éxito, lo que confirma la validez de su aplicación en el ámbito de la predicción energética.

Derivado de las limitaciones observadas y la necesidad de escalar esta tecnología, se proponen el uso de modelos híbridos para implementar arquitecturas que combinen visión por computadora tradicional con *Deep Learning* y mejorar la segmentación en entornos orgánicos, agrícolas, mitigando el ruido detectado en la Figura 1c.

Referencias

- [1] R. A. R. Ait Mouha, "Internet of things (IoT)," *Journal of Data Analysis and Information Processing*, vol. 9, no. 2, p. 77, 2021.
- [2] F. Mahmood, E. Perrins, and L. Liu, "Energy-efficient wireless communications: From energy modeling to performance evaluation," *IEEE Transactions on Vehicular Technology*, vol. 68, no. 8, pp. 7643–7654, Aug. 2019.
- [3] G. Fortino and P. Trunfio, *Internet of Things Based on Smart Objects*, ser. Internet of Things. Cham: Springer International Publishing, 2014.
- [4] R. Jurdak, P. Baldi, and C. Videira Lopes, "Adaptive low power listening for wireless sensor networks," *IEEE Transactions on Mobile Computing*, vol. 6, no. 8, pp. 988–1004, Aug. 2007.
- [5] J. Gubbi, R. Buyya, S. Marusic, and M. Palaniswami, "Internet of things (IoT): A vision, architectural elements, and future directions," *Future Generation Computer Systems*, vol. 29, no. 7, pp. 1645–1660, Sep. 2013.
- [6] L. Zhang *et al.*, "A review of machine learning in building load prediction," *Applied Energy*, vol. 285, p. 116452, 2021.
- [7] C. K. Metallidou, K. E. Psannis, and E. A. Egyptiadou, "Energy efficiency in smart buildings: IoT approaches," *IEEE Access*, vol. 8, pp. 63 679–63 699, 2020.

- [8] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997.
- [9] W. Li *et al.*, "A comprehensive survey on machine learning-based big data analytics for IoT-enabled smart health-care system," *Mobile Networks and Applications*, vol. 26, no. 1, pp. 234–252, 2021.
- [10] K. Cho *et al.*, "Learning phrase representations using RNN encoder-decoder for statistical machine translation," Sep. 2014, arXiv preprint arXiv:1406.1078. [Online]. Available: <http://arxiv.org/abs/1406.1078>
- [11] T. Rault, A. Bouabdallah, and Y. Challal, "Energy efficiency in wireless sensor networks: A top-down survey," *Computer Networks*, vol. 67, pp. 104–122, Jul. 2014.
- [12] M. R. Palattella *et al.*, "Internet of things in the 5G era: Enablers, architecture, and business models," *IEEE Journal on Selected Areas in Communications*, vol. 34, no. 3, pp. 510–527, Mar. 2016.
- [13] X. Cao, L. Liu, Y. Cheng, and X. Shen, "Towards energy-efficient wireless networking in the big data era: A survey," *IEEE Communications Surveys & Tutorials*, vol. 20, no. 1, pp. 303–332, 2018.
- [14] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "Statistical and machine learning forecasting methods: Concerns and ways forward," *PLOS ONE*, vol. 13, no. 3, p. e0194889, Mar. 2018.
- [15] —, "Statistical and machine learning forecasting methods: Concerns and ways forward," *PLOS ONE*, vol. 13, no. 3, p. e0194889, Mar. 2018.
- [16] Y. Dai, Q. Zhou, M. Leng, X. Yang, and Y. Wang, "Improving the Bi-LSTM model with XGBoost and attention mechanism: A combined approach for short-term power load prediction," *Applied Soft Computing*, vol. 130, p. 109632, Nov. 2022.
- [17] X. Yu, X. Wu, C. Luo, and P. Ren, "Deep learning in remote sensing scene classification: a data augmentation enhanced convolutional neural network framework," *GIScience & Remote Sensing*, vol. 54, no. 5, pp. 741–758, Sep. 2017.
- [18] F. M. Bianchi, L. Livi, and C. Alippi, "Investigating echo-state networks dynamics by means of recurrence analysis," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 29, no. 2, pp. 427–439, Feb. 2018.
- [19] J. L. Elman, "Finding structure in time," *Psycholinguistics: Critical Concepts in Psychology*, vol. 4, p. 343, 2002.
- [20] I. Ullah *et al.*, "Revolutionizing e-commerce with consumer-driven energy-efficient WSNs: A multi-characteristics approach," *IEEE Transactions on Consumer Electronics*, vol. 70, no. 4, pp. 6871–6882, Nov. 2024.
- [21] Z. Cao, X. Han, W. Lyons, and F. O'Rourke, "Energy management optimisation using a combined long short-term memory recurrent neural network–particle swarm optimisation model," *Journal of Cleaner Production*, vol. 326, p. 129246, Dec. 2021.
- [22] R. Khan, S. U. Khan, R. Zaheer, and S. Khan, "Future internet: The internet of things architecture, possible applications and key challenges," in *2012 10th International Conference on Frontiers of Information Technology*. IEEE, Dec. 2012, pp. 257–260.
- [23] P. P. Jayaraman, J. B. Gomes, H.-L. Nguyen, Z. S. Abdallah, S. Krishnaswamy, and A. Zaslavsky, "Scalable energy-efficient distributed data analytics for crowdsensing applications in mobile environments," *IEEE Transactions on Computational Social Systems*, vol. 2, no. 3, pp. 109–123, Sep. 2015.
- [24] M. Ikram *et al.*, "Flexible temperature and humidity sensors of plants for precision agriculture: Current challenges and future roadmap," *Computers and Electronics in Agriculture*, vol. 226, p. 109449, Nov. 2024.

Financiación

No aplica.