



**UNIVERSIDAD ESTATAL PENINSULA DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES
CARRERA DE ELECTRÓNICA Y AUTOMATIZACIÓN**

TRABAJO DE INTEGRACIÓN CURRICULAR

Previo a la obtención del título de:

INGENIERO EN ELECTRÓNICA Y AUTOMATIZACIÓN

**PRONÓSTICO DE CARGAS DE ENERGÍA ELÉCTRICA EN
HOGARES PARA LA PLANIFICACIÓN SOSTENIBLE DE LA
DEMANDA EN REDES INTELIGENTES.**

AUTOR:

DANNY PAÚL DEL PEZO TOMALÁ

DOCENTE TUTOR:

ING. MANUEL ASDRUAL MONTAÑO BLACIO, M.Sc.

LA LIBERTAD – ECUADOR

2024

AGRADECIMIENTOS

Agradezco sinceramente a Dios por su constante apoyo en cada etapa de mi vida, especialmente en este periodo con altibajos que está por concluir. Reconozco y agradezco el respaldo de las personas que Él ha puesto en mi camino, brindándome apoyo y sabiduría.

A mi madre, esencial en este momento crucial. Su lucha incansable, sabios consejos y amor incondicional son inspiradores. Aprecio los sacrificios realizados en mi nombre y su constante apoyo. Su determinación es un recordatorio valioso de la importancia de este logro, agradecido por su ejemplo inquebrantable de dedicación.

Agradezco a mi padre por su perseverancia y valiosa inspiración en mi formación. Su dedicación incansable para que alcancemos metas y nos convirtamos en individuos con valores sólidos es un reflejo del ser humano que aspiro ser. Su orientación ha sido fundamental en mi camino hacia la realización personal y profesional.

A mi querida esposa, mi compañera invaluable a lo largo de mi formación académica y la razón fundamental de alcanzar este importante objetivo. Su apoyo constante ha sido mi inspiración y fortaleza en este camino. Aprecio enormemente sus sacrificios y dedicación para lograr esta meta. Su inquebrantable contribución ha sido una fuente inigualable de inspiración, permitiéndonos brindar lo mejor a nuestras hijas. Este logro es el resultado de nuestra colaboración y complementariedad. Te amo tanto, mi Dayi.

A Mis hijas Samara y Sarahi que son la fuente de inspiración que me impulsaron a alcanzar este objetivo. Agradezco por las alegrías que me brindan y por el amor incondicional que comparten. Son la razón por la cual persisto en dar mi máximo esfuerzo y dedicación, ya que el logro que busco es para ustedes. Las amo demasiado mis princesas.

Agradezco a mis compañeros Byron, Carlos, Carmen, Cristhian, Julissa, Luis, Rodrigo y Ronny por brindarme su amistad, por los consejos y su apoyo para lograr esto, juntos pudimos dar lo mejor de nosotros para culminar este objetivo.

A mis docentes que me han forjado en este camino, En especial al Ing. Montañó por compartir su ayuda, consejo y dedicación para terminar este proceso. Gracias.

DEDICATORIA

Dedico este trabajo a mis padres, por ser siempre constante en que debo conseguir este objetivo, que debo mostrar todas mis experiencias y conocimiento a los demás. Por ser las personas que me han inculcado todo en esta vida, por el amor y ayuda que me han brindado. Pido a dios que siempre me acompañen en cada logro que el me permita realizar.

A mis hermanos que han estado para brindarme su cariño y ser constante en que como Hermano Mayor debo ser su fuente de inspiración.

A mi amada esposa, que ha dado todo de ella para que yo pueda completar este objetivo. Te amo tanto, eres la persona más leal, constante y amorosa que Dios me ha dado, este logro lo comparto contigo, haz estado día, tarde, noche incluso madrugadas ayudándome cuando ya quería renunciar, pero fuiste capaz de demostrarme ese amor que quiero en una persona que acompañará el resto de mi vida. Te amo 3 millones.

A mis princesas Samara y Sarahi, que siempre deben ser perseverante en alcanzar sus objetivos, que su padre siempre las va ayudar y dar lo mejor de sí para que ellas puedan tener lo mismo e incluso mejor vida que uno ha tenido. Las amo mucho, mis pequeñas.

A la familia de mi esposa que han estado presente y acompañado para poder culminar esta meta. Por las alegrías y tristeza que se vivió. Gracias.

A mi familia materna, paterna y amigos gracia por su apoyo incondicional y estar en los buenos y malos momentos.

En especial esta dedicatoria a mis queridos abuelitos, que incluso no estén presentes, ellos siempre me van a acompañar en cada logro que dios me permita realizar. Gracias por sus consejos y decirme que querían verme ya cumpliendo esta meta, este logro es para ustedes, celebrenlos allá arriba mi querida MamiLicha, PapiNapó y Mamibuela. Los amo y extraño tanto.

APROBACIÓN DEL TUTOR

En calidad de tutor del trabajo de titulación denominado: “**Pronóstico de Cargas de Energía Eléctrica en Hogares para la Planificación Sostenible de la Demanda en Redes Inteligentes.**”, elaborado por el estudiante Del Pezo Tomalá Danny Paúl, de la Carrera de Electrónica y Automatización de la Universidad Estatal Península de Santa Elena, me permito declarar que luego de haber orientado, estudiado y revisado, la apruebo en todas sus partes y autorizo al estudiante para que inicie los trámites legales correspondientes.

La Libertad, 15 de diciembre de 2023



Ing. Manuel Montaña Asdrual, M.Sc.

Docente Tutor

TRIBUNAL DE SUSTENTACIÓN



Ing. Ronald Rovira Jurado, Ph. D.
DIRECTOR DE LA CARRERA
ELECTRÓNICA Y AUTOMATIZACIÓN



Ing. Oscar Gómez Morales, Mgt
DOCENTE ESPECIALISTA



MANUEL ASDRUAL
MONTANO BLACIO

Ing. Manuel Asdrual Montano
Blacio, Mgt.
DOCENTE TUTOR



LUIS CHUQUIMARCA
JIMÉNEZ

Ing. Luis Chuquimarca Jiménez, Mgt.
DOCENTE GUÍA UIC



Ing. Corina Gonzabay De La A, Mgt.
SECRETARIA

RESUMEN

En el contexto actual, la gestión eficiente de la demanda eléctrica en hogares constituye un desafío estratégico fundamental para promover la eficiencia energética y la sostenibilidad. Este estudio se enfoca específicamente en la planificación sostenible de la demanda, subrayando la importancia de estrategias innovadoras, en particular, el empleo de redes neuronales, para perfeccionar la predicción de recursos y fomentar prácticas de consumo responsable.

El objetivo de esta investigación es implementar un sistema predictivo de cargas eléctricas a corto plazo en hogares mediante el uso de redes neuronales, contribuyendo así a la planificación sostenible de la demanda en redes inteligentes. La metodología se inicia con la creación de un sistema de monitoreo detallado del consumo eléctrico en hogares. Este sistema involucrará la instalación de dispositivos de medición y sensores para recopilar datos precisos y representativos del consumo eléctrico. Posteriormente, se procederá al procesamiento de estos datos y a la implementación de un modelo de aprendizaje automático en Python para la predicción de cargas eléctricas.

Después de la implementación de la metodología propuesta, se llevaron a cabo exhaustivas evaluaciones de los parámetros de entrada en relación con las variables de salida. Los resultados obtenidos revelaron una eficacia sorprendente del 98%, según las predicciones realizadas. Este alto nivel de concordancia entre los datos de entrada y los resultados previstos indica el éxito y la robustez de la propuesta, consolidando su validez y eficacia en el contexto evaluado.

Esta metodología no solo ha demostrado ser altamente precisa en sus predicciones, sino que también ofrece un enfoque innovador y sostenible para abordar los retos actuales en la gestión de la demanda eléctrica en hogares, promoviendo así prácticas de consumo responsables y avanzando hacia un futuro más eficiente y sostenible en términos energéticos.

Palabras Claves: Predicción, ESP32, IoT, RNA, LSTM, TagoIO.

ABSTRACT

In the current context, the efficient management of electrical demand in households represents a fundamental strategic challenge to promote energy efficiency and sustainability. This study specifically focuses on sustainable demand planning, emphasizing the importance of innovative strategies, particularly the use of neural networks, to refine resource prediction and encourage responsible consumption practices.

The objective of this research is to implement a short-term predictive system for electrical loads in households using neural networks, thereby contributing to sustainable demand planning in smart grids. The methodology begins with the creation of a detailed monitoring system for household electricity consumption. This system involves the installation of measurement devices and sensors to gather accurate and representative data on electricity consumption. Subsequently, the data is processed, and a machine learning model is implemented in Python for the prediction of electrical loads.

After the implementation of the proposed methodology, comprehensive evaluations of input parameters in relation to output variables were conducted. The results obtained revealed a remarkable efficacy of 98%, according to the predictions made. This high level of agreement between input data and anticipated results indicates the success and robustness of the proposal, consolidating its validity and effectiveness in the evaluated context.

Not only has this methodology proven to be highly accurate in its predictions, but it also offers an innovative and sustainable approach to address current challenges in household electrical demand management, thus promoting responsible consumption practices and advancing towards a more efficient and sustainable energy future.

Keywords: Prediction, ESP32, IoT, ANN, LSTM, TagoIO.

INDICE GENERAL

AGRADECIMIENTOS.....	I
DEDICATORIA.....	II
APROBACIÓN DEL TUTOR.....	III
TRIBUNAL DE SUSTENTACIÓN	IV
RESUMEN	V
ABSTRACT	VI
INTRODUCCIÓN.....	6
CAPITULO I.....	7
1.1 Antecedentes.....	7
1.2 Descripción del proyecto	9
1.3 Objetivos del proyecto.....	9
1.4 Justificación	9
1.5 Alcance de la propuesta	10
1.6 Metodología.....	11
CAPITULO II.....	13
2.1 MARCO CONTEXTUAL.....	13
2.2 MARCO CONCEPTUAL	14
2.2.1 El proceso del pronóstico.....	14
2.2.2 Factores que influyen en el pronóstico	15
2.2.3 Tipo de pronósticos según su horizonte.....	16
2.2.4 Clasificación de los métodos de pronósticos	18
2.2.5 Métodos aplicativos de pronósticos cuantitativos	20
2.2.6 Implementación, Entrenamiento y Validación de un Modelo de Aprendizaje Automático.....	25
2.2.7 Pronóstico en la energía eléctrica	29
2.2.8 Smart Grids y pronóstico de carga en la gestión de energía eléctrica	31
2.2.9 Arquitectura IoT en la gestión de la energía eléctrica	33
2.2.10 Protocolo de comunicación IoT para la gestión de la energía eléctrica.....	33
2.3 MARCO TEORICO	35
CAPITULO III	36
3.1 Componentes Físicos	36
3.1.1 Node MCU ESP32 Dev Kit-1	37
3.1.2 Sensor de corriente SCT03-013	39

3.1.3	Convertor ADS1115	40
3.1.4	Fuente de alimentación HLK-PM01	42
3.2	Componentes Lógicos.....	43
3.2.1	Python	43
3.2.2	TagoIO	44
3.3	Escenario de desarrollo de la propuesta.....	45
3.4	Diseño de la propuesta tecnológica	47
3.5	Desarrollo del Dispositivo de Monitoreo.	49
3.6	Arquitectura para la Adquisición de datos.....	51
3.6.1	Adquisición de datos en el sistema de monitoreo.	52
3.6.2	Calibración del Sensor de Corriente SCT03-013.....	54
3.7	Desarrollo del firmware de Monitoreo	57
3.7.1	Conexión Wifi ESP32	57
3.7.2	Creación de Canal en TagoIO	59
3.7.3	Comunicación por Protocolo MQTT	62
3.7.4	Envío de Datos a la plataforma de TagoIO	63
3.8	Gestión Eficiente de Cargas Eléctricas en la vivienda	67
3.9	Preparación de datos	69
3.10	Creación de red neuronal en Python	72
3.11	Entrenamiento y validación del modelo predictivo	74
3.12.	PRUEBAS Y RESULTADOS.....	74
3.12.1	Implementación del sistema de monitoreo.....	74
3.12.2	Pruebas de Adquisición de Datos sin calibrar el sensor de corriente.....	75
3.12.3	Pruebas de Adquisición de Datos con Sensores Calibrados	76
3.12.4	Comparación de Redes neuronales LSTM.....	79
3.12.5	Estructura de la red LSTM.....	81
3.12.6	Desempeño de la red Neuronal LSTM.....	82
3.12.7	Predicción de potencia real y predicha de los dispositivos	83
3.12.8	Muestreo de valores reales y predichos	84
3.12.9	Desempeño segundo entrenamiento del modelo LSTM	86
3.12.10	Predicción de la potencia tras el segundo entrenamiento.....	88
3.12.11	Aproximación de valores de potencia después de la predicción.....	91
3.12.12	Consumo Anual Predicho	91
3.12.13	Comparación de la predicción del consumo anual.....	94
3.12.14	Validez de la Red Neuronal	94

CAPITULO IV	95
4.1. CONCLUSIONES	95
4.2 RECOMENDACIONES.....	96
REFERENCIAS BIBLIOGRÁFICAS	98

ÍNDICE DE FIGURAS

Figura 1. Diagrama de flujo metodológico	12
Figura 2. Pasos del proceso de un pronóstico.	14
Figura 3. Factores que influyen en el Pronóstico	16
Figura 4. Relación entre una neurona biológica y una neurona artificial.....	23
Figura 5. Ejemplo de entrenamiento de una Red Neuronal	27
Figura 6. Representación del recorrido de la Energía Eléctrica.	29
Figura 7. Curva Típica de la demanda Diaria.	30
Figura 8. Estructura Smart Grids.....	31
Figura 9. Estructura del Internet de las Cosas	32
Figura 10. Distribución de pines en la placa NodeMCU ESP32 DevKit-1.	38
Figura 11. Estructura del Sensor de Corriente.	39
Figura 12. Identificación de pines del ADS1115.	41
Figura 13. Identificación de pines del HLK-PM01.	42
Figura 14. Modelo de aplicación con dispositivo IoT en la plataforma de TagoIO....	45
Figura 15. Modelado 3D de la Propuesta en Planta Baja.....	46
Figura 16. Modelado 3D de la Propuesta en Planta Alta.	46
Figura 17. Arquitectura de Red para el desarrollo de la Propuesta.	48
Figura 18. Diagrama de bloques para suministrar energía a los componentes.	49
Figura 19. Esquema del circuito eléctrico del sistema de monitoreo de energía	50
Figura 20. Esquema en 3D del sistema de monitoreo de energía.....	50
Figura 21. Arquitectura de Adquisición de Datos	51
Figura 22. Diagrama de flujo de adquisición de datos	53
Figura 23. Comparación de mediciones en luminarias	54
Figura 24. Comparacion de mediciones tomacorrientes	55
Figura 25. Comparación de valores del sensor calibrados vs. pinza amperimétrica...57	
Figura 26. Diagrama de flujo de la conexión WiFi.....	58
Figura 27. Integración de Dispositivo en la Plataforma de TagoIO.....	59
Figura 28. Selección de Protocolo de Comunicación a utilizar	59

Figura 29. Selección de formato de adquisición de datos	60
Figura 30. Descripción del Dispositivo del Tomacorriente en TagoIO	61
Figura 31. Descripción del Dispositivo de las luminarias en TagoIO.....	61
Figura 32. Diagrama de flujo de la Comunicación MQTT a TagoIO	63
Figura 33. Diagrama de Flujo envió de Datos a TagoIO	64
Figura 34. Conexión de Protocolo MQTT en la plataforma TagoIO.....	65
Figura 35. Descripción del mensaje en TagoIO para los valores de corriente.....	65
Figura 36. Recolección de Datos del Tomacorriente en la Plataforma TagoIO.....	65
Figura 37. Recolección de Datos de las luminarias en la Plataforma TagoIO	66
Figura 38. Dashboard de TagoIO para la corriente de las luminarias	66
Figura 39. Dashboard de TagoIO para la corriente del tomacorriente	67
Figura 40. Representación de valores Escalados.....	71
Figura 41. Diagrama de bloques Preparación de datos	72
Figura 42. Arquitectura LSTM.....	73
Figura 43. Instalación de los sistemas de monitoreo en el tablero principal.....	75
Figura 44. Prueba de Adquisición e interpretación de Datos de las luminarias	75
Figura 45. Prueba de Adquisición e interpretación de Datos del tomacorriente.....	76
Figura 46. Gráfica de corriente de las luminarias del 15 al 21 de octubre de 2023	77
Figura 47. Gráfica de corriente de tomacorrientes del 15 al 21 de octubre de 2023...	77
Figura 48. Gráfica de potencia de luminarias del 15 al 21 de octubre de 2023	78
Figura 49. Gráfica de potencia de tomacorrientes del 15 al 21 de octubre de 2023. ..	78
Figura 50. Comparación de predicciones de cada red LSTM con diferentes activaciones	80
Figura 51. Variables de entrada para la red neuronal.....	81
Figura 52. Estructura de la Red LSTM empleada	82
Figura 53. Desempeño de la red neuronal LSTM en las etapas de entrenamiento y validación	83
Figura 54. Predicción de carga vs. valores reales.....	83
Figura 55. Comparativa entre valores Reales y Predichos.....	84
Figura 56. Eficacia de la Red Neuronal LSTM.....	87
Figura 57. Desempeño de la Red Neuronal en las perdidas.....	87
Figura 58. Comparación de corriente real y predicha tras el segundo entrenamiento LSTM	88

Figura 59. Comparación de 50 muestras reales y predichas tras el segundo entrenamiento.	89
Figura 60. Aproximación de 50 muestras en comparación a los valores reales.....	91
Figura 61. Consumo anual de mi Residencia.....	92
Figura 62. Consumo de potencia consumida en el periodo octubre 2022 hasta septiembre 2023.....	93
Figura 63. Consumo anual junto con el valor predicho aplicando el modelo LSTM .	94
Figura 64. Planilla de Luz de mes de octubre y noviembre	95

ÍNDICE DE TABLAS

Tabla 1. Funciones de Activaciones de una red neuronal.	25
Tabla 2. Características del NodeMCU ESP32.	38
Tabla 3. Características del sensor de Corriente.....	39
Tabla 4. Características del Convertidor ADS1115.	41
Tabla 5. Librerías de Arduino para la conexión wifi de la ESP32	52
Tabla 6. Error absoluto y relativo entre el sistema de monitoreo y la pinza amperimétrica.	55
Tabla 7. Diferencias entre el sistema calibrado y la pinza amperimétrica	56
Tabla 8. Librerías de Arduino para la conexión wifi de la ESP32	58
Tabla 9. Librería de Arduino para la Comunicación MQTT con TagoIO	62
Tabla 10. Distribución de fase de cada electrodoméstico.	67
Tabla 11. Identificación de Corriente de cada electrodoméstico en el día.	69
Tabla 12. Identificación de Corriente de cada electrodoméstico en la noche.	69
Tabla 13. Librerías en Python para el Procesamiento de Datos	72
Tabla 14. Librerías en Python para la Creación de la Red Neuronal LSTM.....	73
Tabla 15. Datos de la Red neuronal.....	82
Tabla 16. Comparación de errores del modelo para las luminarias.....	84
Tabla 17. Comparación de errores del modelo para el tomacorriente.....	85
Tabla 18. Comparativa de Errores de Desempeño de la Red LSTM	86
Tabla 19. Datos Para el Segundo entrenamiento	86
Tabla 20. Comparación de errores de luminarias tras el segundo entrenamiento	89
Tabla 21. Comparación de errores de tomacorriente tras el segundo entrenamiento..	90
Tabla 22. Comparativa de Errores de Desempeño de la Red LSTM tras el segundo entrenamiento	90

INTRODUCCIÓN

En el escenario actual de crecimiento exponencial de la demanda eléctrica en hogares, la anticipación precisa de las cargas de energía se ha convertido en un desafío crítico. La falta de herramientas precisas y eficientes para pronosticar la demanda eléctrica compromete la estabilidad de los sistemas eléctricos residenciales, generando consecuencias económicas desfavorables y limitando la eficacia en la gestión de recursos energéticos.

En respuesta a esta problemática, se propone la implementación de avanzadas técnicas de pronóstico de cargas de energía eléctrica en hogares, orientadas hacia la planificación sostenible de la demanda en redes inteligentes. Esta propuesta se centra en la aplicación de tecnologías innovadoras, como la integración de redes neuronales, para mejorar la precisión y la eficiencia en la predicción de las cargas eléctricas.

Durante la propuesta se implica la creación de un sistema integral de monitoreo para garantizar la precisión y la calidad de los datos registrados. Se desarrollará una infraestructura de sensores inteligentes distribuidos estratégicamente en los hogares conectados a redes inteligentes. Estos sensores capturarán datos en tiempo real sobre el consumo eléctrico, teniendo en cuenta variables como la hora del día, y los patrones de uso históricos. Simultáneamente, se procederá a la implementación del aprendizaje automático, específicamente mediante el uso de una red neuronal, utilizando el lenguaje de programación Python. Se recopilarán conjuntos de datos extensos y representativos para entrenar la red neuronal, incluyendo información histórica de consumo, tiempo y patrones de comportamiento de la energía residencial.

La validación de este enfoque se llevará a cabo mediante comparaciones exhaustivas entre los pronósticos generados por la red neuronal y los datos reales de consumo eléctrico registrados por el sistema de monitoreo. Se evaluará la precisión de los pronósticos en diferentes condiciones y escenarios, garantizando así su robustez y confiabilidad en situaciones diversas.

CAPITULO I

1.1 Antecedentes

La ciudad de La Libertad ha tenido un aumento poblacional durante los últimos años, según el Instituto Nacional de Estadísticas y Censo (INEC) en el año 2001 tenía 77.646 habitantes [1]. Según el informe en 2010 ha aumentado a 95.942 habitantes [2], lo cual equivale al 23% de crecimiento poblacional hasta el 2010, lo que ha contribuido también un aumento a la demanda eléctrica en estos años.

La Corporación Nacional de Energía Eléctrica Unidad de Negocio Santa Elena, es la encargada de proveer la energía eléctrica en cada sector de la ciudad; no obstante, a pesar del crecimiento exponencial de la población y consecuentemente, de la demanda, a lo largo de los años no se ha evidenciado el uso de algún modelo predictivo de consumo energético que incremente la eficiencia en la distribución energética.

En la red eléctrica convencional, los usuarios de energía suelen no estar conscientes de sus hábitos de consumo, lo cual conduce a la pérdida innecesaria de energía y gastos económicos [3]. Esta situación es común en naciones en desarrollo, donde existe una significativa disparidad entre la oferta y la demanda de energía, ocasionando cortes de energía y reducciones de carga de forma recurrente.

En la actualidad, la tecnología tiene una presencia significativa en diversas áreas, y el sector de la energía eléctrica está incorporando un modelo de red inteligente con una gestión enfocada en la demanda. Este concepto se refiere a la capacidad de adaptar la demanda de energía mediante diversos enfoques [3]. La gestión de la demanda en el sistema de red inteligente busca aprovechar sistemas automatizados de gestión de energía basados en tecnologías avanzadas, como el Internet de las cosas y la computación en la nube [4]. Con el aumento anual de la demanda de energía, el pronóstico de carga destaca como un enfoque crucial para comprender con precisión la demanda antes del día, dividiéndose en pronósticos a corto, medio y largo plazo [5].

El pronóstico de carga a corto plazo en el contexto de una red inteligente puede abordarse de manera efectiva mediante dos enfoques principales: el uso de técnicas de inteligencia artificial o la aplicación de métodos estadísticos. Diversas revisiones, como las mencionadas en [6], han explorado el pronóstico de carga eléctrica, que abarca desde modelos basados en series de tiempo hasta enfoques basados en regresión, siendo estos

últimos de naturaleza estadística. En contraste, las técnicas de inteligencia artificial, como la inferencia difusa, sistemas de vectores, optimización de enjambre de partículas y algoritmos genéticos, se emplean principalmente con fines de optimización.

Uno de los primeros métodos evaluados para la predicción fue el planteamiento basado en series temporales, como se describe en [6]. Este método implica la construcción secuencial de modelos y exige una consideración minuciosa de factores como el orden de registro, la autocorrelación y la variabilidad de datos. Las series temporales, esenciales en la predicción de carga eléctrica, han sido fundamentales en campos como la economía y el procesamiento de señales digitales. Modelos destacados, como ARMA (Promedio Móvil Autorregresivo) y ARIMA (Promedio Móvil Integrado Autorregresivo), han sido claves en la predicción temporal, con ARMA aplicado a procesos estacionarios y ARIMA extendiendo su utilidad a procesos no estacionarios.

Con el avance de la Inteligencia Artificial, las Redes Neuronales Artificiales han sido incorporadas al Pronóstico de Carga a Corto Plazo. A diferencia de los modelos de regresión, estas redes construyen relaciones por sí mismas sin presuponer relaciones predefinidas entre los parámetros. En este enfoque, las redes neuronales se entrenan inicialmente, y el operador proporciona valores reales de entrada para obtener salidas estimadas. Park fue un pionero en este campo, proponiendo modelos de corto plazo basados en redes neuronales que utilizan una red neuronal artificial para prever la próxima hora, el pico y la carga diaria total. Este método ha demostrado ser altamente efectivo para mejorar la precisión de los pronósticos en comparación con los modelos tradicionales de regresión [7].

En los últimos años, el interés en este método ha experimentado un notable aumento debido a la capacidad de los modelos para aprender de manera autónoma, sin intervención humana. Diversos investigadores han buscado mejorar estos modelos, como lo ejemplifica SJ Kiartzis en [8], quien propuso un modelo para reducir errores de pronóstico utilizando perfiles de carga en las próximas 24 horas. Con la creciente implementación de redes neuronales artificiales en diversos proyectos, se ha creado un entorno propicio para revisar y evaluar críticamente estos sistemas. Ante este escenario, Steinhilber y Hippert llevó a cabo una exhaustiva revisión de modelos aplicados en proyectos basados en redes neuronales a corto plazo, según se describe en [9].

1.2 Descripción del proyecto

Este proyecto se enfoca en un sistema que analiza el consumo de cargas y utiliza el método de pronóstico a corto plazo para determinar el comportamiento futuro de la demanda energética, integrándolo en la planificación de la red inteligente.

El desarrollo del pronóstico implica la recepción de datos a través de un dispositivo que almacena las cargas para su registro en la nube. Estas cargas, distribuidas a lo largo del día, son analizadas para determinar el modelo predictivo con el menor error en las curvas de pronóstico residencial. La eficiencia del modelo se valida comparando sus registros con la demanda consumida.

Esta metodología permite anticipar y planificar de manera efectiva la demanda energética, optimizando así la gestión de la red inteligente.

1.3 Objetivos del proyecto

1.3.1 Objetivo General

- Implementar un sistema predictivo de cargas eléctricas a corto plazo mediante técnicas de Inteligencia Artificial para la planificación de la demanda de red.

1.3.2 Objetivos Específicos

- Realizar el Estado del Arte de los modelos de pronóstico de carga e interpretación de los factores que influyen en el proceso y las limitaciones propias de los modelos.
- Desarrollar una arquitectura IoT para la adquisición y almacenamiento de datos proveniente de los sensores.
- Implementar un modelo predictivo para la estimación de carga a corto plazo y la planificación de la demanda eléctrica.
- Evaluar experimentalmente el modelo predictivo mediante los errores de pronóstico con el fin de determinar la precisión de la demanda.

1.4 Justificación

Pronosticar el consumo energético en el sector público es crucial para anticipar el crecimiento de la demanda y proyectar diferentes escenarios. Dado que no se conoce exactamente cuándo se consumirá más o menos energía, la planificación debe considerar variaciones en las cargas. Los modelos de predicción, según Al-Awain y S.

Islam [10], buscan aumentar la eficiencia en los sistemas energéticos, permitiendo una planificación acertada. Además, Dong, Z. Zhang, y W.-C. Hong, en su trabajo [11], destacan la importancia de un enfoque híbrido para mejorar los pronósticos de carga eléctrica.

La información obtenida del estudio de pronóstico de demanda a corto plazo permite a los administradores de redes eléctricas tomar decisiones eficientes sobre flujos de carga, mantenimiento y seguridad operativa [12]. Aunque el consumo energético en la costa presenta una demanda mayor en comparación con otras regiones, esto se debe a condiciones climáticas que afectan significativamente el consumo. Además, el uso de equipos para contrarrestar el clima y hábitos de consumo que generan desperdicio agrava la situación. La implementación de una red inteligente, propuesta en este estudio, busca optimizar la distribución de energía, mejorando así la eficiencia en el uso de recursos eléctricos y contribuyendo a la sostenibilidad del sistema energético

El consumo de energía es vital para el progreso de un país. En Ecuador, según el CENACE, la demanda de energía aumentó un 4,57% en 2018. La eficiencia energética es cada vez más crucial. Los estudios de pronóstico permiten desarrollar modelos eficientes para la planificación de la demanda eléctrica, lo cual es fundamental en el sector eléctrico para la generación, transmisión y distribución de energía [13].

1.5 Alcance de la propuesta

El propósito principal de este proyecto es prever el consumo de energía en un horizonte de tiempo definido. Para lograrlo, se empleará un sistema remoto de gestión de cargas capaz de identificar desviaciones entre la demanda programada y la real. Esto posibilitará ajustes inmediatos y optimizaciones en el consumo.

El sistema de pronóstico se fundamenta en la recopilación de datos relacionados con la producción y distribución de energía. Aunque existen diversas herramientas disponibles para ajustar las cargas y mejorar la eficacia del pronóstico de consumo energético, destaca la utilidad del Internet de las cosas (IoT). Esta tecnología permite monitorear la carga de manera sencilla, conveniente y confiable, mejorando así la precisión del pronóstico y optimizando la gestión de la energía.

El análisis y estudio detallado llevado a cabo en el marco de este proyecto constituye una fuente rica de información valiosa para CNEL. Los datos recopilados y

los resultados obtenidos tienen el potencial de ser elementos clave en la planificación estratégica de los sistemas eléctricos de potencia de la entidad. Al proporcionar una visión profunda de los patrones de consumo, tendencias energéticas y comportamientos de carga, este proyecto ofrece conocimientos significativos que pueden guiar decisiones informadas en la asignación de recursos, el diseño de infraestructuras y la implementación de políticas energéticas eficientes.

La implementación exitosa de este proyecto no solo beneficiará a CNEL, sino que también podría tener un impacto significativo en la planificación energética a nivel local y nacional. Los resultados obtenidos permitirán una toma de decisiones más informada en cuanto a la distribución de recursos y la gestión de la demanda eléctrica. Además, al mejorar la eficiencia en el uso de la energía, se espera contribuir a la sostenibilidad ambiental y a la reducción de costos asociados al consumo energético.

1.6 Metodología

Para abordar la problemática de la gestión sostenible de la demanda eléctrica en hogares, se llevará a cabo una metodología integral, desde la investigación inicial hasta la implementación y validación práctica. Este enfoque, derivado de investigaciones previas [14] detallan una metodología por fases que se usará para esta propuesta. La metodología se centrará en desarrollar soluciones prácticas y sostenibles para optimizar la gestión de la demanda eléctrica, considerando la diversidad de patrones de consumo en los hogares y promoviendo la eficiencia energética de manera personalizada.

Adicionalmente, en la Figura 1 se presenta visualmente la metodología propuesta. Esta figura destaca las etapas clave del proyecto, desde la investigación inicial hasta la implementación práctica. La representación gráfica proporciona una visión general de cómo se estructurará y ejecutará la metodología, permitiendo una comprensión más clara del enfoque integral adoptado.

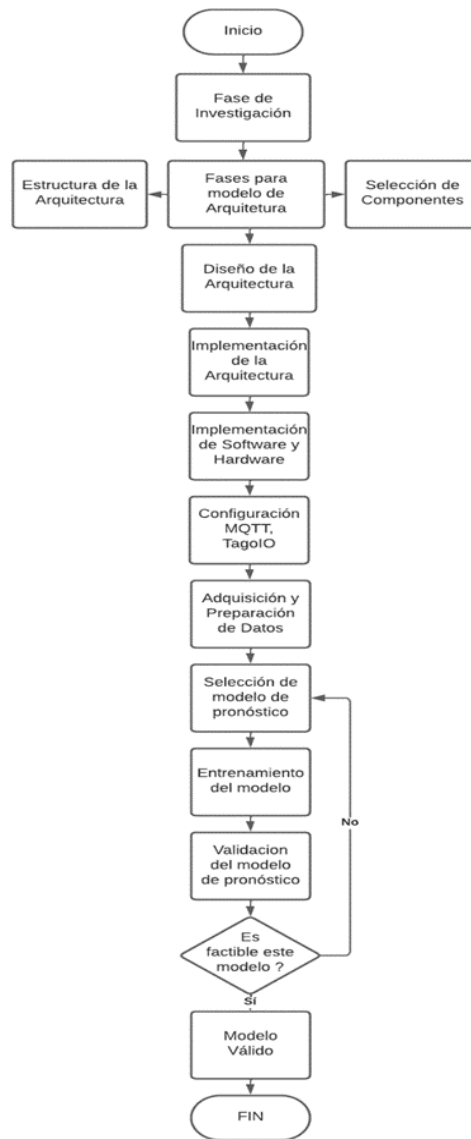


Figura 1. Diagrama de flujo metodológico

Fuente: El autor.

La metodología inicia con una fase de investigación, guiando el diseño del sistema mediante análisis literario. La etapa de modelado de arquitectura incluye estructuración, selección de componentes, diseño e implementación de hardware y software para establecer una base sólida. La adquisición y preparación de datos aseguran la disponibilidad y calidad de la información. La selección del modelo de pronóstico inicia un bucle de validación, implementando el modelo si es válido y repitiendo hasta alcanzar la eficacia deseada. La metodología concluye con la eficacia del modelo, abarcando desde la investigación inicial hasta la implementación continua y optimización, garantizando adaptabilidad y eficiencia en el pronóstico de carga en energía eléctrica.

CAPITULO II

2.1 MARCO CONTEXTUAL

En la Provincia de Santa Elena, la Corporación Nacional de Electricidad (CNEL EP) juega un papel crucial al gestionar la comercialización del servicio eléctrico y atender la creciente demanda energética de los hogares. Según los datos de la Unidad de Negocios Santa Elena, en el año 2019 se registró una cobertura eléctrica del 88,5%, con un consumo total de 430 GWh [15], indicando un aumento constante en la demanda energética de la región.

La CNEL EP se encuentra activamente comprometida en la mejora continua de la infraestructura eléctrica. Su enfoque incluye la expansión de la cobertura y la implementación de tecnologías avanzadas de medición y monitoreo. Estas iniciativas tienen como objetivo primordial optimizar la eficiencia en la distribución de energía, asegurando así la confiabilidad del suministro eléctrico para satisfacer las necesidades cambiantes de la comunidad.

El incremento constante en la demanda eléctrica y la expansión progresiva de las infraestructuras de redes han allanado el camino hacia la integración de tecnologías innovadoras, entre las cuales se destaca el Internet de las Cosas (IoT). Esta innovadora tecnología, enmarcada en la domótica, eleva la automatización y el control de dispositivos eléctricos en los hogares, transformando la gestión y el uso de la energía para contribuir a una vida diaria más eficiente y cómoda [16].

En este contexto, la implantación de un sistema de pronóstico de carga, orientado a la planificación de la demanda energética a corto plazo, se presenta como una medida esencial. Este sistema se basa en una plataforma computacional autónoma capaz de adquirir y analizar datos de forma automática, valiéndose de métodos avanzados en contraposición a enfoques estadísticos convencionales utilizados en trabajos anteriores [17].

Como parte integral de esta iniciativa, se lleva a cabo una exhaustiva investigación para abordar de manera más profunda el tema del pronóstico de cargas y sus diversas aplicaciones. El propósito es contribuir al proceso que conlleva la planificación de la demanda eléctrica, con un enfoque no solo orientado a nuestros hogares, sino con el objetivo más amplio de beneficiar a toda la provincia.

2.2 MARCO CONCEPTUAL

2.2.1 El proceso del pronóstico

El proceso de pronóstico suele seguir una guía para su desarrollo. La Figura 2 ofrece una representación visual de los pasos implicados en el pronóstico, destacando cómo se relacionan con los datos obtenidos de una base y cómo se ajustan al modelo. Estos pasos clave se presentan para guiar hacia una predicción efectiva [18].




Figura 2. Pasos del proceso de un pronóstico.

Fuente: El autor.

Paso 1. Formulación del problema y recolección de datos

Estos dos elementos son cruciales, ya que la naturaleza del problema define los datos necesarios. Sin datos apropiados, es necesario reconsiderar la formulación del problema o recurrir a métodos cualitativos para obtener la información requerida.

Paso 2. Manipulación y limpieza de datos

La cantidad de datos puede variar, y estos pueden contener elementos irrelevantes o desactualizados. Este paso implica la manipulación y limpieza de datos para obtener la información necesaria, eliminando cualquier ruido o información innecesaria.

Paso 3. Construcción y evaluación del modelo

Se utiliza un modelo de pronóstico apropiado que minimiza el error. Implica la aplicación de datos recopilados en un modelo que se evalúa meticulosamente para garantizar su eficacia.

Paso 4. Aplicación del modelo

Una vez recopilados y posiblemente reducidos a datos pertinentes, se generan los pronósticos reales del modelo. Este paso marca la aplicación práctica del modelo de pronóstico elegido.

Paso 5. Evaluación del pronóstico

Este paso implica la comparación de los valores pronosticados con los valores históricos reales, permitiendo ajustes para mejorar la precisión del modelo con el tiempo.

2.2.2 Factores que influyen en el pronóstico

El pronóstico de carga eléctrica, fundamental para una gestión eficiente de la energía, se encuentra ante desafíos como la variabilidad de datos históricos, eventos imprevistos, estacionalidad, cambios tecnológicos y crecimiento poblacional. La variabilidad estacional y diaria en la demanda de electricidad desempeña un papel crucial en asegurar un suministro eléctrico confiable. Estos cambios, que son predecibles a lo largo del año y siguen patrones regulares diarios, como los picos en la mañana, son fundamentales para comprender y prever las necesidades energéticas de la población.

Es esencial reconocer que, además de las variaciones estacionales, la introducción de tecnologías y fuentes de energía renovable introduce nuevas dinámicas en los patrones de consumo eléctrico. La capacidad de adaptarse a estos cambios es crucial para mantener la exactitud en los pronósticos y garantizar la continuidad del suministro eléctrico.

La anticipación de eventos imprevistos, como fenómenos climáticos extremos o situaciones de emergencia, se vuelve imperativa en un contexto donde la demanda eléctrica puede experimentar fluctuaciones inesperadas. La habilidad para adaptarse a cambios estacionales, comprender el impacto de las tecnologías emergentes y las energías renovables en el consumo, así como ajustar estrategias operativas en consecuencia, son elementos clave para asegurar la eficiencia y la confiabilidad del suministro eléctrico [19].

Para comprender con claridad cómo los distintos factores afectan la predicción del consumo eléctrico, la Figura 3 proporciona una representación visual de los elementos que deben ser considerados para anticipar de manera efectiva el consumo en diversos procesos. Esto ayuda a visualizar de manera coherente los desafíos y limitaciones que enfrenta el pronóstico, permitiendo una evaluación más completa y detallada de los procesos de anticipación de consumo eléctrico.




Figura 3. Factores que influyen en el Pronóstico

Fuente: El autor.

2.2.3 Tipo de pronósticos según su horizonte

La predicción de electricidad se fundamenta en gran medida en la consideración de distintos intervalos temporales, abarcando desde períodos horarios y diarios hasta semanales, mensuales y anuales. Por consiguiente, esta estimación se organiza y clasifica en tres categorías distintas, como se detalla a continuación [20]:

- Pronóstico de carga a corto plazo.
- Pronóstico de carga a mediano plazo.
- Pronóstico de carga a largo plazo.

2.2.3.1 Pronóstico de carga a corto plazo

El STLF, conocido como 'Short-Term Load Forecasting' (Predicción de Carga a Corto Plazo) en inglés, desempeña una función crucial en asegurar la seguridad y estabilidad de los sistemas de energía. Su importancia radica en controlar la generación de energía de manera coherente, equilibrar en tiempo real la oferta y la demanda de electricidad, y coordinar un programa de mantenimiento adecuado para los equipos eléctricos y otras operaciones asociadas [21].

En este caso de predicción, el intervalo de tiempo oscila entre una hora hasta una semana y se utiliza principalmente para la reducción de pérdidas, regulación de la tensión, para la operación y optimización del sistema energético. También se utiliza

para proporcionar datos importantes para la gestión del funcionamiento diario normal del sistema y el compromiso operativo [21].

Mejorar la precisión de STLF puede hacer una gran contribución a las operaciones confiables y económicas de los sistemas de energía. A medida que se desarrollan las redes inteligentes en todo el mundo, se proporcionan para el análisis datos multivariados y heterogéneos masivos de medidores inteligentes u otros dispositivos electrónicos avanzados [21] .

2.2.3.2 Pronóstico de carga a mediano plazo

La Predicción de Carga a Mediano Plazo (MTLF, por sus siglas en inglés, Medium-Term Load Forecasting) juega un papel vital en la planificación estratégica de la generación y distribución de energía. A pesar de los desafíos que enfrenta debido a la complejidad específica de la carga eléctrica en este periodo, el MTLF es esencial para anticipar y gestionar eficazmente las demandas energéticas.

Este proceso se ve especialmente afectado por la "maldición de la dimensionalidad", provocada por el elevado número de variables que intervienen en el MTLF. Superar este desafío requiere enfoques innovadores que puedan lidiar con la complejidad de la carga eléctrica, aprovechando la capacidad del aprendizaje múltiple para extraer características no lineales de los datos.

En el contexto de la MTLF, la implementación de métodos avanzados, como redes neuronales de memoria a corto plazo, destaca como una solución eficaz para construir modelos de pronóstico que ofrecen una mayor precisión. Estos enfoques no solo abordan los desafíos de la complejidad y dimensionalidad, sino que también contribuyen a la mejora continua de la planificación y operación de los sistemas energéticos a mediano plazo [22], [23] .

2.2.3.3 Pronóstico de carga a largo plazo

La Predicción de Carga a Largo Plazo (LTLF, por sus siglas en inglés, Long-Term Load Forecasting), que abarca horizontes de pronóstico que van desde uno hasta diez años y, en ocasiones, incluso varias décadas, proporciona estimaciones semanales y mensuales para los picos y valles de carga. Estos pronósticos son de vital importancia para la planificación y expansión de los sistemas de generación, transmisión y distribución eléctrica.

Seleccionar una técnica para el LTLF implica contar con un profundo conocimiento de la carga y de los diversos métodos de pronóstico disponibles, necesarios para modelar distintos tipos de carga. Dada la respuesta dispar de los distintos tipos de carga a los factores correspondientes y sus variados patrones de crecimiento o decrecimiento, se clasifican las cargas en residenciales, comerciales e industriales. Este enfoque estratégico en la predicción a largo plazo contribuye significativamente a la eficiencia y planificación sostenible de los sistemas eléctricos. [23].

2.2.4 Clasificación de los métodos de pronósticos

Los métodos de pronóstico se utilizan para predecir valores futuros o tendencias en función de datos históricos o patrones observados. Estos métodos se pueden clasificar en varias categorías según sus enfoques y características. Se dividen en 3 categorías las cuales son:

1. Método de Pronostico Cualitativo
2. Método de Pronostico Cuantitativo
3. Método de Pronostico Mixtos o Híbridos

2.2.3.1 Método de pronóstico cualitativo

En este método no se necesita datos históricos ni del área del conocimiento donde serán aplicados; se requiere la experiencia de quien elabora el pronóstico. El costo, cuya estimación es variable y compleja, se basa en la intuición y los conocimientos de lo que se pronostica. Estos métodos no especifican formalmente el procedimiento empleado para el pronóstico; por lo que se limitan en situaciones particulares de mediano y largo plazo.

2.2.3.2 Método de pronóstico cuantitativos

La aplicación del pronóstico cuantitativo, fundamental en la toma de decisiones estratégicas, se rige por tres condiciones esenciales que delinean su efectividad y precisión:

Datos Históricos

Un análisis detallado y exhaustivo de datos históricos relevantes es la base fundamental para cualquier pronóstico cuantitativo. Estos datos proporcionan una visión retrospectiva de los patrones y tendencias que guiarán las proyecciones futuras.

Organización y Cuantificación

La información recopilada debe ser organizada y cuantificada de manera numérica para facilitar su manipulación y análisis. La estructuración de datos en formatos numéricos permite la aplicación eficiente de modelos matemáticos y estadísticos.

Identificación de Patrones Repetitivos

La identificación de patrones repetitivos en los datos históricos es esencial para anticipar comportamientos futuros. Reconocer tendencias, ciclos y regularidades proporciona una base sólida para la formulación de pronósticos precisos.

Este método se distingue por sus características particulares que se consideran en un enfoque específico. Estas características se dividen en dos categorías principales: intuitiva y estadística.

La categoría intuitiva se centra en proyectar la experiencia de una aplicación a otra, buscando aplicar conocimientos previos de manera adaptativa. En este caso, la capacidad del pronosticador para transferir su experiencia resulta fundamental. Por otro lado, la categoría estadística, en contraste, no siempre requiere un profundo conocimiento por parte del pronosticador [24].

La categoría estadística dentro del Pronóstico Cuantitativo desempeña un papel crucial en la optimización de los procesos de planificación y toma de decisiones en la industria eléctrica. Al basarse en modelos matemáticos y estadísticos, esta categoría se divide en dos enfoques principales: deterministas y probabilísticos, también conocidos como aleatorios [24].

En el enfoque determinista, se busca establecer relaciones causales y predecir valores futuros de manera precisa y sin incertidumbre. Este método es valioso cuando se cuenta con información histórica confiable y patrones bien definidos. Por otro lado, el enfoque probabilístico aborda la naturaleza incierta y variable de muchos factores que influyen en la carga eléctrica. Utiliza la probabilidad para evaluar y pronosticar posibles escenarios, reconociendo la complejidad inherente a la dinámica eléctrica. [24].

2.2.5 Métodos aplicativos de pronósticos cuantitativos

2.2.5.1 Regresión Lineal

Entre las metodologías más comunes para la predicción de la demanda eléctrica, se destacan los modelos de regresión, los cuales se fundamentan en relaciones estadísticas entre la demanda eléctrica y diversas variables independientes, como la temperatura o el día de la semana.

Regresión Lineal Simple

Los modelos de Regresión Lineal se han destacado por su eficacia, especialmente en predicciones a corto plazo, como las proyecciones diarias o semanales. Estos modelos analizan la relación entre una variable Y y una variable X, con el objetivo de encontrar una línea recta que se ajuste de manera óptima a los datos históricos de carga eléctrica. Este análisis permite realizar proyecciones futuras de la carga eléctrica, tomando en consideración las variables independientes relevantes [25].

La Regresión Lineal Simple, como subconjunto de los modelos de regresión lineal, se centra en el análisis de la relación entre dos variables, siendo efectiva en escenarios donde se busca una comprensión más directa y simplificada de la influencia de una variable independiente en la demanda eléctrica.

El modelo de regresión lineal se puede expresar matemáticamente por la fórmula 1 que se detalla a continuación:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (1)$$

Donde:

- Y es la variable dependiente (carga eléctrica).
- β_0 es la intersección o término constante.
- $\beta_1, \beta_2, \dots, \beta_p$ son los coeficientes de regresión que representan la relación entre la carga eléctrica y las variables independientes X_1, X_2, \dots, X_p .
- ε es el término de error, que representa la variabilidad no explicada en la carga eléctrica.

El objetivo de la regresión lineal es estimar los valores óptimos de los coeficientes $\beta_0, \beta_1, \dots, \beta_p$ de manera que el modelo se ajuste de la mejor manera posible a los datos históricos de carga.

Regresión Lineal Múltiple

La regresión lineal múltiple cuya técnica estadística es utilizada para modelar la relación entre una variable dependiente (Y) y dos o más variables independientes ($X_1, X_2, X_3, \dots, X_n$) mediante una ecuación lineal. Esta técnica permite predecir la variable dependiente en función de las variables independientes a través de una combinación lineal de coeficientes [26], de acuerdo a la fórmula 2 es definida por la siguiente expresión matemática:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n + \varepsilon \quad (2)$$

Donde:

- Y es la variable dependiente que queremos predecir.
- β_0 es la intersección o término constante.
- $\beta_1, \beta_2, \beta_3, \dots, \beta_n$ son los coeficientes de regresión que representan la contribución de cada variable independiente a la variable dependiente.
- $X_1, X_2, X_3, \dots, X_n$ son las variables independientes.
- ε es el término de error, que representa la variabilidad no explicada en el modelo.

La regresión lineal múltiple busca estimar los valores más óptimos de los coeficientes ($\beta_0, \beta_1, \beta_2, \beta_3, \dots, \beta_n$) de manera que el modelo se ajuste mejor a los datos observados. Estos coeficientes se determinan utilizando métodos estadísticos, como el método de mínimos cuadrados, que minimiza la suma de los cuadrados de los errores (ε).

2.2.5.2 Series Temporales

Una serie temporal es una secuencia de datos observados, medidos o registrados en intervalos regulares de tiempo. En el contexto de pronósticos cualitativos, las series temporales se utilizan para analizar y prever patrones temporales en los datos, lo que permite tomar decisiones informadas sobre eventos futuros [27].

La representación general de una serie temporal Y_t en el tiempo t se expresa como en la fórmula 3:

$$Y_t = f(t) + S(t) + \varepsilon_t \quad (3)$$

Donde:

- $f(t)$ es la función de tendencia que describe la dirección general de los datos en el tiempo.
- $S(t)$ es la funcional estacional que modela patrones repetitivos o cíclicos.
- ε_t es el termino de error que captura la variación no sistemática o aleatoria.

Las series temporales, al ser secuencias cronológicas de observaciones, proporcionan una base valiosa para entender el comportamiento pasado y, por ende, anticipar el futuro. En este sentido, se introduce un paso crucial en el proceso de pronóstico: la implementación del modelo ARIMA.

La esencia del modelo ARIMA radica en su capacidad para representar relaciones entre observaciones temporales pasadas. La componente autorregresiva (AR) refleja la influencia de observaciones anteriores, la de medias móviles (MA) considera la relación con errores residuales de observaciones pasadas, y la diferenciación integrada (I) busca estacionarizar la serie temporal [28].

2.2.5.3 Redes Neuronales Artificiales

Los métodos de inteligencia artificial para predicciones son técnicas basadas en algoritmos avanzados que utilizan herramientas matemáticas sofisticadas para modelar y comprender cómo las variables dependientes se relacionan con las variables independientes. Lo que los distingue es su capacidad para abordar sistemas intrincados y desafiantes que exhiben comportamientos no lineales, permitiendo así el análisis y la predicción en entornos más complejos y realistas [29].

La aplicación de las redes neuronales al modelo de predicción de cargas eléctricas representa un avance significativo en la gestión eficiente de la energía eléctrica. En un mundo donde la demanda de electricidad es cada vez más dinámica y variable, contar con un sistema preciso de predicción de cargas se vuelve esencial para garantizar el suministro confiable y la utilización eficiente de los recursos energéticos. Las redes neuronales, inspiradas en el funcionamiento del cerebro humano, ofrecen una potente herramienta para abordar esta compleja tarea. Su capacidad para capturar relaciones no lineales y modelar patrones en datos históricos de consumo eléctrico las convierte en una opción atractiva para mejorar la precisión de las predicciones [30].

En la figura 4 se describe la interpretación de una red neuronal biológica a una red neuronal artificial donde implica la abstracción matemática de los principios fundamentales de las neuronas biológicas para crear modelos computacionales que puedan realizar tareas de procesamiento de información, aprendizaje y toma de decisiones en una amplia variedad de aplicaciones, desde el reconocimiento de patrones hasta la predicción de datos.




Figura 4. Relación entre una neurona biológica y una neurona artificial

Fuente: Imagen modificada por el Autor basada en *Redes neuronales* (Alarcon7a, 2021).

Las redes neuronales son sistemas compuestos por neuronas conectadas por sinapsis, con pesos que regulan la transmisión de señales. Cada neurona ajusta automáticamente sus pesos mediante algoritmos de aprendizaje, adaptándose a tareas específicas según su umbral de activación. Su estructura densamente interconectada permite un procesamiento altamente paralelo, siendo versátiles para aplicaciones en aprendizaje automático e inteligencia artificial [30].

En la configuración de una red neuronal, la elección de la arquitectura es crucial. Dos arquitecturas notables son las redes neuronales recurrentes (RNN) y las redes neuronales LSTM, diseñadas para manejar información secuencial de manera efectiva. Mientras que las RNN utilizan conexiones retroactivas, las LSTM son eficientes para abordar desafíos como el desvanecimiento del gradiente, permitiendo una mejor captura de dependencias a largo plazo. La elección entre estas arquitecturas depende de la tarea y los datos, destacando la importancia de seleccionar la estructura más apropiada [31].

2.2.5.4 Redes Neuronales Recurrentes

Las Redes Neuronales Recurrentes (RNN, por su denominación en inglés, Recurrent Neural Networks) constituyen un tipo específico de estructura en las redes neuronales artificiales, diseñadas con la finalidad de abordar el procesamiento de secuencias de datos. En contraste con las arquitecturas neuronales convencionales, las RNN incorporan conexiones retroactivas, permitiéndoles retener y emplear información previa en el transcurso de su procesamiento. Este atributo las posiciona de manera particularmente idónea para la manipulación de datos secuenciales, como es el caso de series temporales o contenido textual [32].

En esta aplicación de red neuronal, la información fluye no solo de una capa a otra, como en una red neuronal estándar, sino también a través de ciclos de retroalimentación. Esto permite a la red retener información sobre estados anteriores, lo que resulta especialmente útil para tareas que implican secuencias temporales, como el procesamiento de lenguaje natural [32].

En el contexto de las innovaciones tecnológicas en una de las áreas investigativas es el de agricultura, el sistema de monitoreo basado en Internet de las Cosas (IoT) para cultivos hidropónicos propuesto por Montaña-Blacio y colaboradores (2023) se presenta como un ejemplo destacado de la aplicación práctica de tecnologías avanzadas [33]. Este sistema utiliza las Redes Neuronales Recurrentes (RNN), que son fundamentales para tareas que implican secuencias temporales, como el procesamiento de lenguaje natural. El sistema IoT aborda la mejora de la eficiencia en la producción agrícola mediante la recopilación y análisis continuo de datos en tiempo real.

2.2.5.5 Red Neuronal LSTM

La Red Neuronal LSTM (Long Short-Term Memory) representa una variante avanzada de las Redes Neuronales Recurrentes (RNN), diseñada para abordar desafíos asociados con el desvanecimiento de gradientes y para manejar de manera eficaz secuencias temporales extensas. La principal innovación de las LSTM radica en su capacidad para retener información a largo plazo a través de unidades de memoria especializadas. Este mecanismo permite que la red capture y almacene patrones temporales significativos, facilitando así el procesamiento de secuencias de datos más extensas [34].

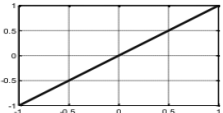
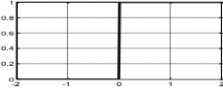

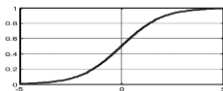
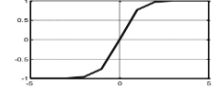

Las Redes Neuronales LSTM son particularmente efectivas en tareas que involucran procesamiento de lenguaje natural y secuencias largas. Su capacidad para mantener y utilizar información a largo plazo las hace idóneas para comprender contextos complejos y dependencias temporales en datos secuenciales. Este enfoque ha demostrado ser especialmente valioso en aplicaciones como la traducción automática, el análisis de sentimientos, la generación de texto y otras áreas donde la comprensión de la estructura temporal de los datos es esencial. [34].

2.2.6 Implementación, Entrenamiento y Validación de un Modelo de Aprendizaje Automático

La función de activación en una red neuronal, expresada matemáticamente, decide si una neurona debe activarse o permanecer inactiva, introduciendo elementos no lineales para aprender y reconocer patrones complejos en los datos [35].

En la Tabla 1 se enumeran diversas funciones de activación para la red neuronal, junto con sus ecuaciones correspondientes, ofreciendo así una visión detallada de las opciones disponibles para controlar la activación en diversos contextos y configuraciones de red.

Tabla 1. Funciones de Activaciones de una red neuronal.

Función	Ecuación	Gráfica
Lineal	$y(x) = x$	
Escalon	$y(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$	
Mixta o lineal a tramos	$y(x) = \begin{cases} -1, & x \leq -1 \\ x, & -1 < x < 1 \\ 1, & \text{si } x \geq 1 \end{cases}$	
Sigmoidal	$y(x) = \frac{1}{1 + e^{-x}}$	
Tangente hiperbólica	$y(x) = \tanh x$	
Gaussiana	$y(x) = Ae^{-Bx^2}$	

El entrenamiento de redes neuronales se caracteriza por ser un proceso iterativo y adaptativo que busca perfeccionar el rendimiento de la red. Este perfeccionamiento se logra mediante la exposición continuada a ejemplos representativos del conjunto de datos de entrenamiento, permitiendo a la red ajustar sus parámetros internos de manera precisa.

Durante el proceso de entrenamiento, se emplean algoritmos de optimización que buscan minimizar la diferencia entre las predicciones de la red y las respuestas deseadas. Este ajuste se realiza mediante la actualización de pesos y sesgos, influenciando directamente la capacidad de la red para modelar y comprender la complejidad presente en los datos [36].

La esencia del entrenamiento radica en la capacidad de la red para iterar sobre ejemplos de entrenamiento, permitiendo la asimilación progresiva de patrones y relaciones dentro de los datos. Esta mejora continua refleja la adaptabilidad inherente de las redes neuronales, que pueden ajustarse dinámicamente a medida que se exponen a información adicional [36], [37].

El objetivo último del entrenamiento es capacitar a la red para generalizar sus conocimientos y realizar predicciones precisas en situaciones nuevas. Sin embargo, este proceso no está exento de desafíos, como el sobreajuste, donde la red puede aprender demasiado específicamente los ejemplos de entrenamiento y no lograr una buena generalización en nuevos datos[36]

Durante el proceso de entrenamiento en una RNA de dos capas como se observa en la figura 5, la red consta de una capa de entrada (correspondiente a $l=0$, con dos neuronas), una capa intermedia oculta (correspondiente a $l=1$, con tres neuronas) y la capa de salida ($l=2$ y dos neuronas). El objetivo es calcular los pesos de la RNA, utilizando el algoritmo de retro propagación el cual se trata de un proceso iterativo en el que se parte de unos valores iniciales para los pesos y estos se van modificando mediante el método del gradiente descendiente [38].

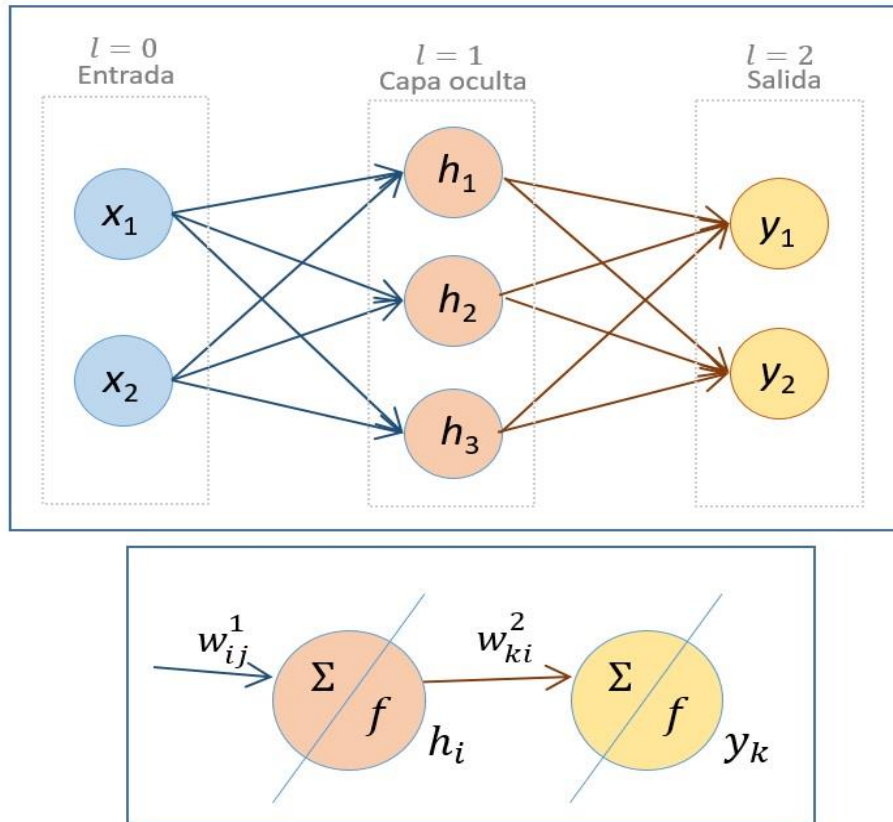


Figura 5. Ejemplo de entrenamiento de una Red Neuronal

Fuente: Entrenamiento de una red neuronal, Libretexts (2021)

Los criterios de validación y análisis se refieren a las métricas, estándares o criterios que se utilizan para evaluar y medir el rendimiento y la calidad de un modelo, sistema o proceso. Estos criterios son esenciales para determinar si un modelo o sistema cumple con los objetivos y requisitos establecidos.

Los criterios de validación y análisis se dividen en tres categorías principales:

Error cuadrático medio

El Error Cuadrático Medio o MSE por sus siglas en inglés (Mean Squared Error) es una métrica utilizada en estadísticas y aprendizaje automático para evaluar la calidad de un modelo de regresión. Se calcula como la media de los cuadrados de las diferencias entre las predicciones del modelo y los valores reales (etiquetas) en el conjunto de datos de prueba. El MSE cuantifica la magnitud de los errores cometidos por el modelo, dando más peso a los errores grandes debido a la elevación al cuadrado [39].

La expresión matemática del MSE se define como la suma de los cuadrados de las diferencias entre los valores predichos (Y_i) y los valores reales (Y_i'), dividida por el número total de observaciones (n).

La fórmula propuesta para el Error Cuadrático Medio está definida en la ecuación 4:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_i')^2 \quad (4)$$

Donde:

- n es el número total de observaciones.
- Y_i es el valor predicho por el modelo.
- Y_i' es el valor real u observado.

Error Absoluto Medio

El Error Absoluto Medio (MAE, por sus siglas en inglés, Mean Absolute Error), es una métrica utilizada para evaluar la precisión de un modelo de pronóstico o de regresión. Este indicador cuantifica la magnitud promedio de los errores absolutos entre los valores observados y los valores pronosticados [39].

Cuanto menor sea el MAE, mejor será la capacidad del modelo para realizar pronósticos precisos. Es una medida fácil de interpretar, ya que representa directamente el tamaño promedio de los errores absolutos en la escala de la variable que se está pronosticando.

La fórmula para el MAE viene definida por la ecuación 5:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (5)$$

Donde:

- n es el número total de observaciones.
- Y_i es el valor real u observado.
- \hat{Y}_i es el valor pronosticado por el modelo.

Error Cuadrático Medio de la Raíz

El Error Cuadrático Medio de la Raíz o RMSE (Root Mean Squared Error) en inglés, es otra medida ampliamente empleada para valorar la precisión de un modelo de pronóstico, lo que incluye evaluaciones relacionadas con pronósticos de carga eléctrica. Similar al MAE, el RMSE mide la discrepancia entre las predicciones y los valores reales; no obstante, destaca por penalizar de manera más notable los errores de mayor magnitud, ya que incorpora una operación de cuadratura en su cálculo [39].

La fórmula para calcular el RMSE se define por la ecuación 6:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (6)$$

Donde:

- n es el número total de observaciones.
- Y_i es el valor real u observado.
- \hat{Y}_i es el valor pronosticado por el modelo.

2.2.7 Pronóstico en la energía eléctrica

En el paradigma actual de la gestión energética, la electricidad emerge como una fuerza motriz esencial que impulsa una amplia variedad de sectores, desde la industria hasta los entornos residenciales y comerciales, como ilustra la figura 6 [40]. La creciente complejidad y la interconexión de estos sectores demandan sistemas integrados e inteligentes que permitan una administración eficiente de la energía a través de actividades cruciales como análisis, monitoreo, control y redirección de recursos eléctricos [41].




Figura 6. Representación del recorrido de la Energía Eléctrica.

Fuente: Imagen modificada por el Autor basada en *El viaje de la energía eléctrica y sus etapas: generación, transmisión, distribución y utilización* (SectorElectricidad, 2014)

Este enfoque, esencial para la eficiencia energética, se potencia mediante la integración de tecnologías avanzadas y enfoques de aprendizaje automático en la era de la gestión energética inteligente. La demanda eléctrica, influenciada por factores dinámicos como cambios en el comportamiento del consumidor y patrones estacionales [42], requiere estrategias avanzadas para anticipar y abordar sus variaciones. En este sentido, el desarrollo de modelos predictivos se posiciona como una herramienta estratégica para optimizar la planificación y asignación de recursos en la infraestructura eléctrica.

La integración de tecnologías avanzadas y enfoques de aprendizaje automático se revela como una necesidad imperante en la era de la gestión energética inteligente. La aplicación de modelos predictivos, respaldados por datos históricos de consumo eléctrico, no solo permite una mejor comprensión de la demanda futura, sino que también posibilita una gestión más eficiente y sostenible de la infraestructura eléctrica.

La figura 7, que ilustra la curva característica de la demanda diaria de energía, ofrece una visión reveladora de las variaciones a lo largo del día, evidenciando picos durante las horas de máxima actividad y valles en los períodos de menor consumo [43]. Esta representación gráfica no solo captura la dinámica diaria de la demanda eléctrica, sino que también subraya la necesidad crítica de estrategias avanzadas de pronóstico.

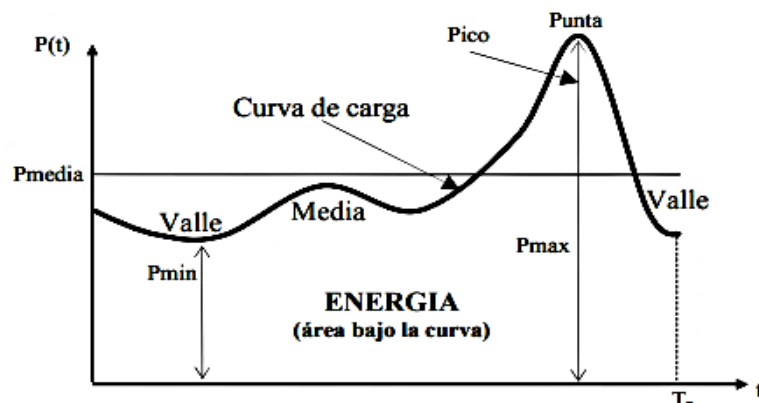


Figura 7. Curva Típica de la demanda Diaria.

Fuente: Pronóstico de Demanda de corto plazo en sistemas de suministro de energía eléctrica utilizando inteligencia artificial, V Hinojosa (2007).

El análisis detallado de esta curva revela patrones complejos y fluctuaciones que resultan fundamentales para la planificación y gestión efectiva de la red eléctrica. Anticipar las demandas máximas en momentos específicos del día se convierte en un desafío clave, y es aquí donde los modelos de pronóstico de carga desempeñan un papel crucial. Al aplicar técnicas avanzadas de aprendizaje automático, respaldadas por datos históricos, se busca no solo comprender la variabilidad diaria, sino también prever con precisión las demandas futuras.

2.2.8 Smart Grids y pronóstico de carga en la gestión de energía eléctrica

La incorporación del pronóstico de carga en la administración de la energía eléctrica adquiere una perspectiva renovada al contemplar la aplicación de Smart Grids (redes eléctricas inteligentes). Estos sistemas aprovechan los avances en tecnología de la información y comunicación para facilitar una gestión energética más eficaz y dinámica. Al integrar modelos de pronóstico de carga en Smart Grids, se refuerza la capacidad para anticipar y responder de manera ágil y precisa a las variaciones en la demanda eléctrica [44].

En la figura 8, se ilustra de manera gráfica la configuración de las Smart Grids, abarcando prácticamente todos los elementos de nuestro entorno. Este gráfico resalta la actividad y la interconexión de las redes eléctricas inteligentes en nuestras actividades diarias. Desde la generación hasta la distribución y el consumo de energía, las Smart Grids desempeñan un papel crucial en mejorar la eficiencia energética y gestionar de manera dinámica la demanda eléctrica [44].

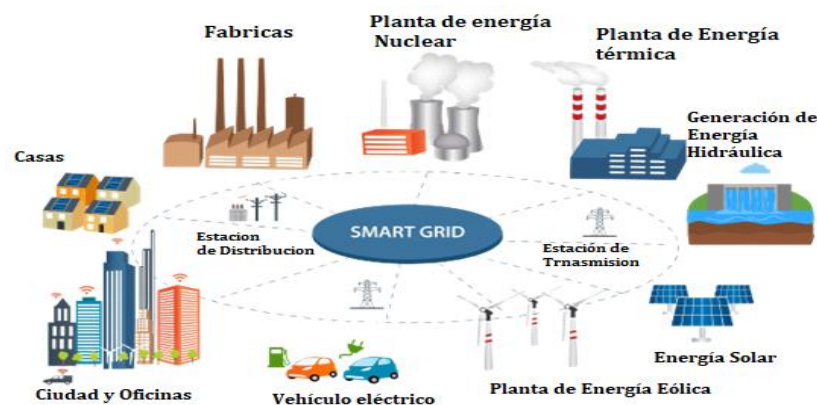


Figura 8. Estructura Smart Grids

Fuente: *Las Smart Grids, esenciales para el entorno que nos rodea, Fong, J. (2018)*

La incorporación del Internet de las cosas (IoT) a las Smart Grids emerge como un elemento esencial en la reconfiguración de la infraestructura eléctrica. El IoT, al facilitar la interconexión y comunicación fluida entre dispositivos, se posiciona como un catalizador determinante en el camino hacia sistemas eléctricos más avanzados y eficaces.

La entrada del IoT en las Smart Grids amplifica la capacidad de recopilación y transmisión de información, permitiendo una monitorización en tiempo real de diversos aspectos de la infraestructura eléctrica. Desde medidores inteligentes hasta sensores en puntos clave de la red, cada dispositivo IoT contribuye a la creación de un entorno eléctrico dinámico y adaptable. Este flujo continuo de datos enriquece la comprensión de la demanda, la generación y las condiciones de la red, posibilitando una gestión más precisa y eficiente [45].

La figura 9 ilustra de manera clara cómo esta fusión transforma la Smart Grid, infundiéndole una red de dispositivos interconectados que capturan y comparten datos en tiempo real.

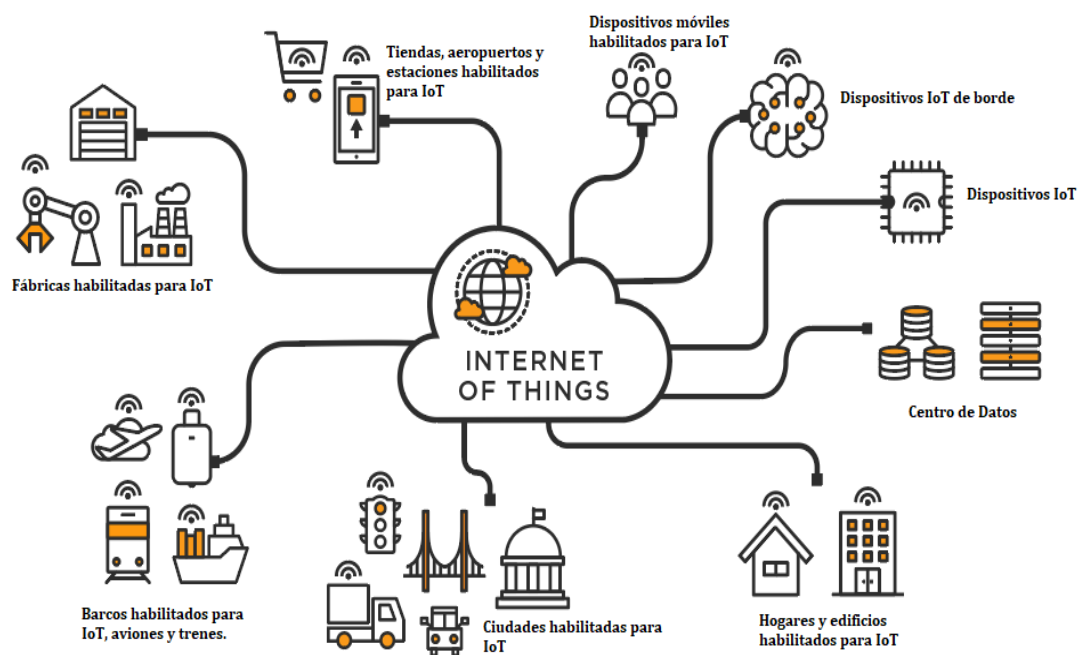


Figura 9. Estructura del Internet de las Cosas

Fuente: ¿Qué es el Internet de las cosas (IoT)?, Audisio, F. (2023)

2.2.9 Arquitectura IoT en la gestión de la energía eléctrica

La Arquitectura IoT con respecto a la Energía eléctrica conforma el diseño tecnológico que conecta dispositivos, sensores, redes y sistemas de control para mejorar el seguimiento, control y eficiencia de la generación, distribución y consumo de electricidad. Con la ayuda de estas arquitecturas se crean soluciones inteligentes que permiten una economía eléctrica más eficiente y económica. Hay distintos tipos que interactúan entre el IoT con la energía eléctrica del cual los principales son:

- Dispositivos IoT
- Conectividad
- Plataforma IoT
- Gestión de Datos
- Análisis y Control
- Monitorización en tiempo real

En el núcleo de esta infraestructura IoT, dispositivos como medidores y sensores conectados a la red eléctrica recopilan información crucial sobre consumo, calidad y estado de la red. Para la transmisión efectiva de datos, utilizan tecnologías como Wi-Fi, redes celulares o LPWAN. La plataforma de IoT funciona como epicentro, recibiendo y procesando datos para análisis en tiempo real y toma de decisiones informadas [46].

La gestión de datos involucra procesos de recopilación, almacenamiento y análisis histórico y en tiempo real en bases de datos seguras. Los datos se someten a algoritmos de análisis, como aprendizaje automático e inteligencia artificial, para lograr una predicción precisa de la demanda y optimización de la distribución de energía. La capacidad de monitoreo en tiempo real facilita la detección temprana de problemas y la adopción proactiva de medidas correctivas [46].

2.2.10 Protocolo de comunicación IoT para la gestión de la energía eléctrica

Los protocolos de comunicación IoT son conjuntos de reglas y estándares que permiten que dispositivos conectados en la Internet de las cosas se comuniquen entre sí y con sistemas externos de manera eficiente y efectiva. Estos protocolos son esenciales para la transmisión de datos, el control y la coordinación de dispositivos IoT en diversas aplicaciones, incluida la gestión de la energía eléctrica [47].

Dentro de los distintos protocolos de comunicación IoT que gozan de una amplia adopción en aplicaciones vinculadas en el ámbito de la gestión de energía eléctrica, se emplean, entre ellos MQTT, HTTP/HTTPS, MODBUS, DNP3, ZIGBEE, y LoRaWAN, como alternativas importantes.

2.2.10.1 Protocolo MQTT

En la trama del Internet de las cosas (IoT), el protocolo MQTT, abreviatura de 'Message Queuing Telemetry Transport', destaca como una solución diseñada para facilitar la comunicación eficiente entre dispositivos. Su principal enfoque reside en posibilitar la transmisión rápida y fiable de datos en redes con recursos limitados, como ancho de banda y energía. La versatilidad y escalabilidad del protocolo MQTT lo han convertido en una opción preferida en el ámbito del IoT, siendo especialmente adecuado para dispositivos con restricciones de energía y ancho de banda, como sensores y otros dispositivos IoT. Su capacidad para operar en redes con conexiones inestables lo hace ideal para diversas aplicaciones, desde la monitorización de dispositivos inteligentes hasta la gestión de flotas de vehículos y la agricultura de precisión, consolidándolo como una herramienta esencial en este campo tecnológico [48].

2.2.10. Protocolo HTTP y HTTPS

En el ámbito de la gestión de energía eléctrica, HTTP, conocido como Protocolo de Transferencia de Hipertexto, y su contraparte segura, HTTPS o Protocolo de Transferencia de Hipertexto Seguro, desempeñan un papel fundamental. Estos protocolos son esenciales para la transmisión eficiente de datos en tiempo real y para facilitar el monitoreo y control de sistemas eléctricos. Al permitir a los operadores de redes supervisar la demanda, calidad y estado de los dispositivos, así como controlar la distribución y responder a eventos, HTTP y HTTPS se posicionan como elementos clave en la infraestructura de gestión de energía. En particular, la seguridad mejorada proporcionada por HTTPS, gracias al cifrado de las comunicaciones, agrega un nivel crítico de protección a la infraestructura eléctrica, salvaguardando la integridad y la confidencialidad de los datos transmitidos [49].

2.3 MARCO TEORICO

En esta sección, se presentan los artículos y tesis relevantes que contribuyeron al desarrollo del presente trabajo de titulación.

En el trabajo de titulación "PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL ÓPTIMA", realizado en el Instituto Politécnico Nacional de México por Pablo Ortiz Mondragón en 2011, se expone una metodología destinada a mejorar la precisión del pronóstico de carga a corto plazo [50]. Este enfoque se basa en el uso de una red neuronal artificial, cuya arquitectura funcional contribuye significativamente a representar de manera más precisa el error, según el análisis efectuado en series de tiempo relacionadas con la demanda de carga.

En 2015, Miguel Eduardo Ortiz Alvarado, de la Universidad Politécnica Salesiana, presentó el artículo científico "PRONÓSTICO DE LA DEMANDA ELÉCTRICA RESIDENCIAL BASADO EN EL MODELO DE REGRESIÓN ADAPTATIVA MULTIVARIANTE SPLINE (MARS)" [51]. Este estudio aborda la complejidad de la demanda de energía en hogares, considerando variables no lineales como condiciones temporales, estacionales, demográficas y económicas. Su objetivo es mejorar la confiabilidad y la planificación del sistema eléctrico. El modelo MARS, siendo no paramétrico, utiliza una investigación detallada de la curva de carga diaria para planificar recursos y proponer una visión futura para la implementación de redes inteligentes. Esto mejora la gestión de la demanda y las operaciones de distribución al identificar patrones en datos históricos de consumo residencial.

En el año 2020, en la Universidad de las Fuerzas Armadas ESPE, Gonzalo Echeverría Simancas presentó su trabajo de titulación titulado "MODELOS HÍBRIDOS BASADOS EN DATOS PARA LA PREDICCIÓN DE CARGA ELÉCTRICA A CORTO Y MEDIANO PLAZO" [52]. Este estudio busca estrategias para mejorar la eficiencia energética mediante la implementación de modelos híbridos, que han demostrado abordar problemas de subestimación y sobreestimación. Se logró una mejora en la precisión del pronóstico, a pesar de un aumento en la complejidad computacional, al considerar y reducir errores porcentuales en la mayoría de los casos.

CAPITULO III

El desarrollo del próximo capítulo es proporcionar una visión detallada de los elementos fundamentales relacionados con el pronóstico de cargas de energía eléctrica en un entorno residencial. Esta sección se divide en tres partes cruciales para una comprensión exhaustiva de nuestra propuesta de pronóstico de cargas residencial.

En primer lugar, en la sección dedicada a los componentes físicos o hardware, se detallan los dispositivos y sensores seleccionados para recopilar datos relevantes para el pronóstico de cargas. Cada componente se analiza en términos de sus especificaciones técnicas, capacidades de medición y su ubicación estratégica en las instalaciones residenciales. Esta información es esencial para comprender cómo se adquieren los datos que alimentan nuestro sistema de pronóstico.

La segunda sección se centra en las herramientas informáticas o software utilizadas en la implementación del pronóstico de cargas. Aquí, se exploran en profundidad las aplicaciones y algoritmos específicos utilizados para procesar los datos recopilados y generar pronósticos precisos de la demanda eléctrica en hogares. Se resaltan las ventajas y limitaciones de cada software y cómo contribuyen a la optimización de la gestión de la energía.

Finalmente, en la sección de diseño de la propuesta, se establece una visión integral al describir la conexión estratégica entre el hardware y el software en el contexto del pronóstico de cargas. Se explican las estrategias de integración y las técnicas utilizadas para garantizar que los datos recopilados se traduzcan en pronósticos confiables y útiles para la planificación y gestión de la demanda eléctrica residencial.

3.1 Componentes Físicos

El proceso de pronóstico de cargas eléctricas en un sistema residencial implica una serie de componentes físicos críticos para la obtención de datos precisos y la generación de pronósticos confiables. Estos componentes desempeñan un papel esencial en la medición y el procesamiento de la información necesaria para la gestión eficiente de la demanda de energía eléctrica en hogares.

Un elemento fundamental es el sensor de corriente, que capta la señal eléctrica proveniente de la variable a medir, en este caso, la corriente eléctrica en AC. Estos sensores son esenciales para obtener mediciones en tiempo real de la demanda eléctrica.

Posteriormente, se realiza la conversión analógica/digital de la señal medida, a través del convertidor ADS1115, lo que permite que los datos sean procesados por una MCU (Microcontroller Unit). La MCU es el núcleo del sistema, encargada de recopilar y procesar los datos de corriente, además de ejecutar algoritmos que generan pronósticos de carga basados en patrones de consumo previos y otros factores relevantes.

La comunicación también es esencial, ya que se utilizan componentes para transmitir datos a sistemas de gestión centralizados o para su análisis y pronóstico en tiempo real. Además de los mencionados, cada componente está alimentado por una fuente de alimentación, en este caso, el HLK-PM01.

3.1.1 Node MCU ESP32 Dev Kit-1

El ESP32 es un microcontrolador de alto rendimiento y bajo consumo de energía que ha ganado popularidad en el mundo de la electrónica y la programación. Desarrollado por Espressif Systems, el ESP32 se destaca por su versatilidad y capacidad de conectividad. Este microcontrolador cuenta con dos núcleos de procesamiento de 32 bits y admite Wi-Fi y Bluetooth integrados. Su amplia gama de pines GPIO (General Purpose Input/Output), interfaces de comunicación como UART, SPI y I2C, y su capacidad para ejecutar sistemas operativos en tiempo real lo convierten en una opción ideal para una variedad de aplicaciones, desde proyectos de Internet de las cosas (IoT) y automatización del hogar hasta sistemas embebidos y dispositivos portátiles [53].

El ESP32 puede desempeñar un papel importante en la recopilación de datos de consumo de energía en tiempo real y su transmisión a sistemas de gestión centralizados o aplicaciones para su posterior análisis y pronóstico de cargas. Esto contribuye a una mejor comprensión de los patrones de consumo y a una gestión más eficiente de la energía eléctrica en hogares, edificios o instalaciones comerciales [53].

La disposición de pines en la placa de desarrollo ESP32 se muestra en la figura 10. En esta disposición, se identifican dos filas principales de pines a lo largo de los bordes de la placa. La mayoría de estos pines son GPIO, lo que permite su configuración como entradas o salidas digitales según las necesidades del proyecto. También se observan pines marcados como VCC y GND, utilizados para la alimentación eléctrica y la conexión a tierra, respectivamente.

En la tabla 2, se ofrecen detalles acerca de algunas características significativas del ESP32. Este microcontrolador, desarrollado por Espressif Systems, destaca por su rendimiento superior y su eficiencia energética.




Figura 10. Distribución de pines en la placa NodeMCU ESP32 DevKit-1.

Fuente: Espressif.

Tabla 2. Características del NodeMCU ESP32.

Características Técnicas	
Modelo de la placa de desarrollo	NodeMCU ESP32 DevKit-1
Microcontrolador	ESP WROOM 32
Cantidad de pines	38
CPU	2 núcleos, 240MHz
Memoria SRAM	520 KB
Tensión de alimentación	5 Vdc – 60mA
Voltaje en pines de salida	3.3 Vdc
Potencia	0.3W
Lenguaje de programación	Micropython, C++, C#
Puerto de transmisión	Micro USB

3.1.2 Sensor de corriente SCT03-013

El sensor de corriente SCT03-013 representa una solución innovadora para medir la corriente eléctrica de manera no invasiva en un conductor específico, sin necesidad de intervención física en el circuito. Este dispositivo es especialmente útil para el monitoreo preciso del consumo eléctrico en sistemas, sin interrupciones ni modificaciones físicas en los cables [54].

Funcionando mediante una bobina alrededor del conductor eléctrico, el sensor de corriente mide la corriente sin interrumpir el circuito. Detecta el campo magnético inducido por la corriente a través del principio de inducción electromagnética, generando una corriente proporcional en la bobina. Este diseño permite una monitorización precisa del flujo eléctrico sin interferencias en el funcionamiento del circuito original [54].

La figura 11 ilustra la estructura y el funcionamiento del sensor de corriente. Además, en la tabla 3 se detallan las características principales de este dispositivo.




Figura 11. Estructura del Sensor de Corriente.

Fuente: Naylamp Mechatronics

Tabla 3. Características del sensor de Corriente.

Características Técnicas	
Sensor	Sensor de Corriente
Modelo	SCT03-013
Señal	Analógica
Tensión de alimentación	3.3 V a 5V
Corriente Nominal	0 – 30 ^a
Exactitud	± 1%
Terminal	Tipo Jack 3.5mm

La relación fundamental que se utiliza en sensores de corriente como el SCT03-013, basados en la inducción electromagnética, está relacionada con la Ley de Faraday. La tensión inducida (V) en la bobina es proporcional a la tasa de cambio del flujo magnético (Φ) que atraviesa la bobina. Esto se expresa mediante la fórmula 7:

$$V = -N \frac{d\Phi}{dt} \quad (7)$$

Donde:

- V es la tensión inducida,
- N es el número de espiras en la bobina,
- Φ es el flujo magnético
- $\frac{d\Phi}{dt}$ es la tasa de cambio del flujo magnético respecto al tiempo.

Esta fórmula refleja cómo la variación de la corriente eléctrica en el conductor original induce un cambio en el flujo magnético a través de la bobina, generando así una señal de salida proporcional que se utiliza para medir la corriente eléctrica. Es importante tener en cuenta la relación lineal entre la corriente en el conductor original y la señal de salida del sensor. En algunos casos, esta relación se ajusta mediante calibración para garantizar mediciones precisas.

3.1.3 Conversor ADS1115

El ADS1115 se presenta como un convertidor analógico digital (ADC) de 16 bits, y se destaca por su utilidad en diversos proyectos que involucran dispositivos como Arduino y ESP32. Aunque las placas de Arduino suelen contar con un ADC integrado, el ADS1115 se diferencia al ofrecer mayores funcionalidades y una resolución más elevada. Con su capacidad de resolución de 16 bits, este convertidor puede representar hasta 65,536 niveles de voltaje. La comunicación entre el ADS1115 y dispositivos como Arduino o ESP32 se realiza a través de la interfaz I2C. Este componente resulta especialmente valioso en situaciones donde se requiere una mayor precisión en la medición de señales analógicas [55].

En la figura 12 se observan los pines del convertidor ADS1115 el cual tiene cuatro canales de entrada analógica, lo que significa que puede medir hasta cuatro señales analógicas diferentes. Además, el ADS1115 también tiene un amplificador

programable integrado (PGA) que puede aumentar la ganancia de la señal de entrada en un factor de hasta 16. Esto es especialmente útil cuando se trabaja con señales analógicas débiles o cuando se necesita una mayor precisión en la medición [55].




Figura 12. Identificación de pines del ADS1115.

Fuente: El autor

En la Tabla 4, se resumen las características del ADS1115, un convertidor analógico-digital (ADC) de 16 bits. Donde se destaca por su alta resolución, representando el rango de voltaje en 65,536 pasos discretos. Ofrece flexibilidad con 4 canales de entrada diferenciales o 2 canales singulares, permitiendo la programación del rango de voltaje ($\pm 6.144V$ a $\pm 0.512V$) y ajuste de la velocidad de muestreo (8 SPS a 860 SPS) para adaptarse a requisitos específicos [55].

Tabla 4. Características del Convertidor ADS1115.

Característica	Valor
Resolución	16 bits
Canales de Entrada	4 canales diferenciales o 2 canales singulares
Rango de Voltaje	$\pm 6.144V$, $\pm 4.096V$, $\pm 2.048V$, $\pm 1.024V$, $\pm 0.512V$
Programable	
Velocidad de Muestreo	8 SPS a 860 SPS (muestras por segundo)
Interfaz de Comunicación	I2C
Alarma Programable	Sí
Consumo de Energía	Bajo
Referencia Interna/Externa	2.048V (interna) / Externa seleccionable
Amplificador Programable	Sí
Disipador de Calor	Recomendado en aplicaciones de alta temperatura o alta velocidad de muestreo

3.1.4 Fuente de alimentación HLK-PM01

El HLK-PM01 de Hi-Link es un módulo de fuente de alimentación conmutada eficiente y regulada diseñado para dispositivos electrónicos. Con amplia tolerancia de voltaje de entrada (100-240V CA), proporciona una salida estable de 5V CC, siendo ideal para alimentar microcontroladores, sensores y otros componentes electrónicos. Reconocido por su eficiencia energética, aislamiento galvánico para seguridad y diseño compacto, este módulo es comúnmente utilizado en aplicaciones de electrónica y sistemas embebidos. Puede incorporar protecciones contra sobretensión, sobre corriente y cortocircuitos para asegurar la integridad de los dispositivos conectados [56].

En la figura 13, se proporciona un detallado esquema de los pines de entrada y salida de este transformador. En el proceso de transformación, los valores de entrada abarcan un rango de energía de 110 V a 220 V. Este dispositivo opera de manera eficiente para modular la energía de entrada, logrando que los valores de salida se sitúen en un rango establecido de 5 V.



Figura 13. Identificación de pines del HLK-PM01.

Fuente: El autor

La fuente de alimentación tiene la importante función de suministrar la tensión necesaria para la placa de diseño NodeMCU ESP32, que demanda una tensión de 5 Vcc.

Según las especificaciones del fabricante, se recomienda la inclusión de un condensador de 100 microfaradios en la salida de corriente continua (DC). Este condensador, que actúa como un filtro, se utiliza para suavizar la corriente eléctrica y mantener la estabilidad en la tensión de salida [56].

Su función principal es mitigar posibles picos de corriente que podrían afectar adversamente a dispositivos electrónicos dependientes de la alimentación suministrada. Esta medida de precaución es especialmente relevante al trabajar con componentes sensibles o sistemas susceptibles a cambios bruscos en la corriente, ya que un suministro

de energía más estable garantiza un rendimiento confiable y prolonga la vida útil de los dispositivos conectados [56].

3.2 Componentes Lógicos

El término "Componentes lógicos" engloba una variedad de plataformas y herramientas de desarrollo de código, junto con interfaces de visualización y sistemas de almacenamiento de datos, que resultan cruciales para posibilitar la comunicación y la ejecución de tareas específicas en el contexto de la predicción de cargas eléctricas. En el ámbito de los sistemas informáticos utilizados para este propósito, se encuentran tanto opciones de acceso gratuito, como el entorno de desarrollo integrado (IDE) de Arduino y Python, y de otras alternativas como TagoIO. A continuación, se detallarán minuciosamente los sistemas informáticos que desempeñan un rol esencial en el desarrollo de esta propuesta tecnológica, acompañados de una explicación de la lógica de programación implementada en cada fase del proyecto.

El entorno de desarrollo integrado (IDE) de Arduino simplifica la programación de microcontroladores, proporcionando una interfaz amigable y bibliotecas predefinidas para sensores y actuadores [57]. Los algoritmos de programación desempeñan un papel crucial en la medición y control de carga eléctrica, abarcando desde la adquisición precisa de datos hasta la implementación de lógica de control específica. La flexibilidad del IDE permite ajustar estos algoritmos según los requisitos del proyecto [57]. La compatibilidad con diversas placas Arduino facilita la selección de la plataforma más adecuada, fomentando la interoperabilidad y la reutilización de código en diferentes proyectos, contribuyendo a una mayor eficiencia en el desarrollo de soluciones electrónicas [57].

3.2.1 Python

Python, un lenguaje de programación ampliamente reconocido por su versatilidad y carácter de código abierto, desempeña un papel crucial en diversas etapas del proceso de predicción de carga eléctrica. Su capacidad para adaptarse a diferentes requerimientos lo convierte en una herramienta fundamental desde el preprocesamiento inicial de datos hasta la generación de visualizaciones detalladas de los resultados obtenidos. En la fase de preprocesamiento, Python facilita la manipulación eficiente de datos, la limpieza y la preparación para su posterior análisis. Además, en la etapa de entrenamiento de modelos de aprendizaje automático, como las redes neuronales,

Python se destaca como una opción predilecta gracias a sus librerías especializadas, como TensorFlow y PyTorch, que proporcionan estructuras robustas y eficientes para el desarrollo y la optimización de modelos complejos [58].

Asimismo, Python se utiliza para realizar análisis estadísticos exhaustivos, permitiendo una comprensión profunda de los patrones y tendencias presentes en los conjuntos de datos. La rica variedad de librerías estadísticas, como NumPy y pandas, agiliza la implementación de técnicas analíticas avanzadas. En el ámbito de la visualización de datos, Python brinda herramientas como Matplotlib y Seaborn, que posibilitan la creación de representaciones gráficas claras e informativas para comunicar de manera efectiva los resultados del proceso de predicción de carga eléctrica [58].

La capacidad de Python para integrarse fluidamente en cada fase del proceso, combinada con su amplio ecosistema de librerías especializadas, lo posiciona como una opción integral y poderosa para abordar los desafíos complejos asociados con la predicción de carga eléctrica. Su presencia en el ámbito de la ciencia de datos y el aprendizaje automático destaca la importancia y la eficacia de este lenguaje en el desarrollo de soluciones avanzadas y precisas en el ámbito de la gestión energética [58].

3.2.2 TagoIO

TagoIO es una plataforma IoT que proporciona una solución completa para la recopilación, almacenamiento, análisis y visualización de datos generados por dispositivos y sensores IoT. La plataforma TagoIO ofrece una serie de características esenciales para el éxito de los proyectos IoT, incluyendo una interfaz de usuario amigable para la configuración de dispositivos y paneles de control personalizables para la visualización de datos en tiempo real. Además, permite la integración con dispositivos de una amplia variedad de fabricantes y tecnologías, lo que facilita la recopilación de datos de sensores de diferentes tipos y orígenes [59].

En la figura 14 se demuestra la arquitectura de red de un modelo IoT comunicado con la plataforma de TagoIO

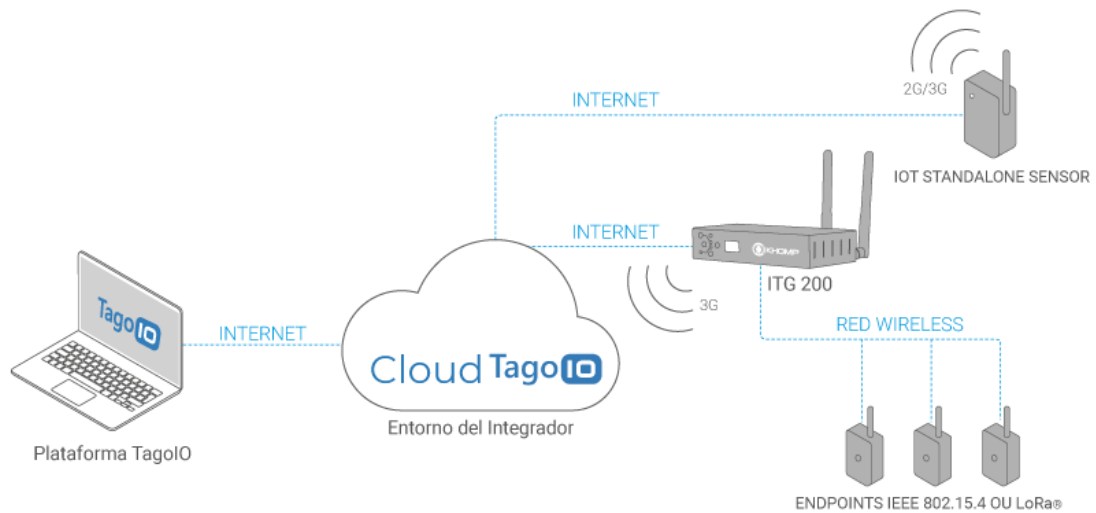


Figura 14. Modelo de aplicación con dispositivo IoT en la plataforma de TagoIO.

Fuente: Conozca TagoIO, Khomp (2019)

TagoIO no solo se centra en la recopilación de datos, sino que también proporciona potentes herramientas de análisis de datos y ofrece la capacidad de generar informes personalizados y cuadros de mando interactivos. Los usuarios pueden utilizar estos datos para tomar decisiones basadas en información precisa, desde la gestión de activos y la monitorización ambiental hasta la optimización de procesos industriales y la automatización de edificios inteligentes [59].

La plataforma TagoIO facilita la conectividad de dispositivos IoT a través de varios protocolos de comunicación, como HTTP, HTTPS, WebSockets, MQTT y otros. Esto permite que los dispositivos envíen datos a la plataforma y reciban comandos y actualizaciones en tiempo real. Además, TagoIO admite notificaciones a través de webhooks, lo que permite a los usuarios configurar alertas y automatizaciones basadas en eventos [59].

3.3 Escenario de desarrollo de la propuesta

El entorno de desarrollo para la propuesta se sitúa en una zona residencial, donde se han instalado estratégicamente los sistemas de monitoreo. La implementación de dispositivos innovadores tendrá lugar en la parte inferior de la vivienda, específicamente en el área que alberga el tablero principal, fundamental para el sistema de distribución de energía de la casa.

La figura 15 presenta el plano tridimensional de la planta baja de la residencia, y la figura 16 muestra el diseño correspondiente a la planta superior. Estas representaciones gráficas ofrecen una visión detallada del entorno donde se implementarán las tecnologías, brindando un conocimiento claro del lugar de aplicación.



Figura 15. Modelado 3D de la Propuesta en Planta Baja.

Fuente: El autor



Figura 16. Modelado 3D de la Propuesta en Planta Alta.

Fuente: El autor

3.4 Diseño de la propuesta tecnológica

El proceso de desarrollo de este prototipo comienza con una fase crucial. La selección de los dispositivos específicos que se someterán al monitoreo del consumo de potencia eléctrica. En esta etapa, se ejerce un criterio estratégico al dar prioridad a aquellos dispositivos del cual su funcionamiento tiene un impacto significativo en la demanda total de energía. Esto implica identificar y destacar los componentes que, debido a su elevado consumo eléctrico o su influencia en el rendimiento global, son fundamentales para un análisis preciso de la eficiencia energética.

Una vez finalizada la etapa inicial, se lleva a cabo la configuración tanto del hardware como del software necesarios para la adquisición de datos de consumo eléctrico mediante un dispositivo ESP32. La comunicación se establecerá eficientemente a través del protocolo MQTT, facilitando la transferencia de datos desde los dispositivos de medición hacia una ubicación centralizada. Los datos recopilados se exportarán en un formato conveniente, como archivos TXT.

Una vez completada la etapa de adquisición de datos, se procede con el procesamiento de señales de potencia eléctrica. El objetivo principal de esta fase es obtener datos precisos y confiables que se utilizarán en el proceso de entrenamiento de la Red Neuronal Artificial (RNA).

La creación de la RNA es la parte central de este proyecto y se llevará a cabo utilizando Python. Los datos de consumo eléctrico que son la corriente de las luminarias y tomacorriente, almacenados en archivos TXT, se emplearán como conjunto de entrenamiento para esta red. La configuración de la RNA implica la definición de parámetros clave, como el número de capas ocultas, la función de activación y los algoritmos de optimización. Este proceso se realizará de manera meticulosa para adaptarse a las características específicas de los datos recopilados y aplicar el modelo LSTM.

En la figura 17 se observa el desarrollo de la arquitectura empleada para cada parte de esta propuesta donde se muestra el sistema de monitoreo, la adquisición de datos y la red neuronal LSTM para la predicción del consumo eléctrico.

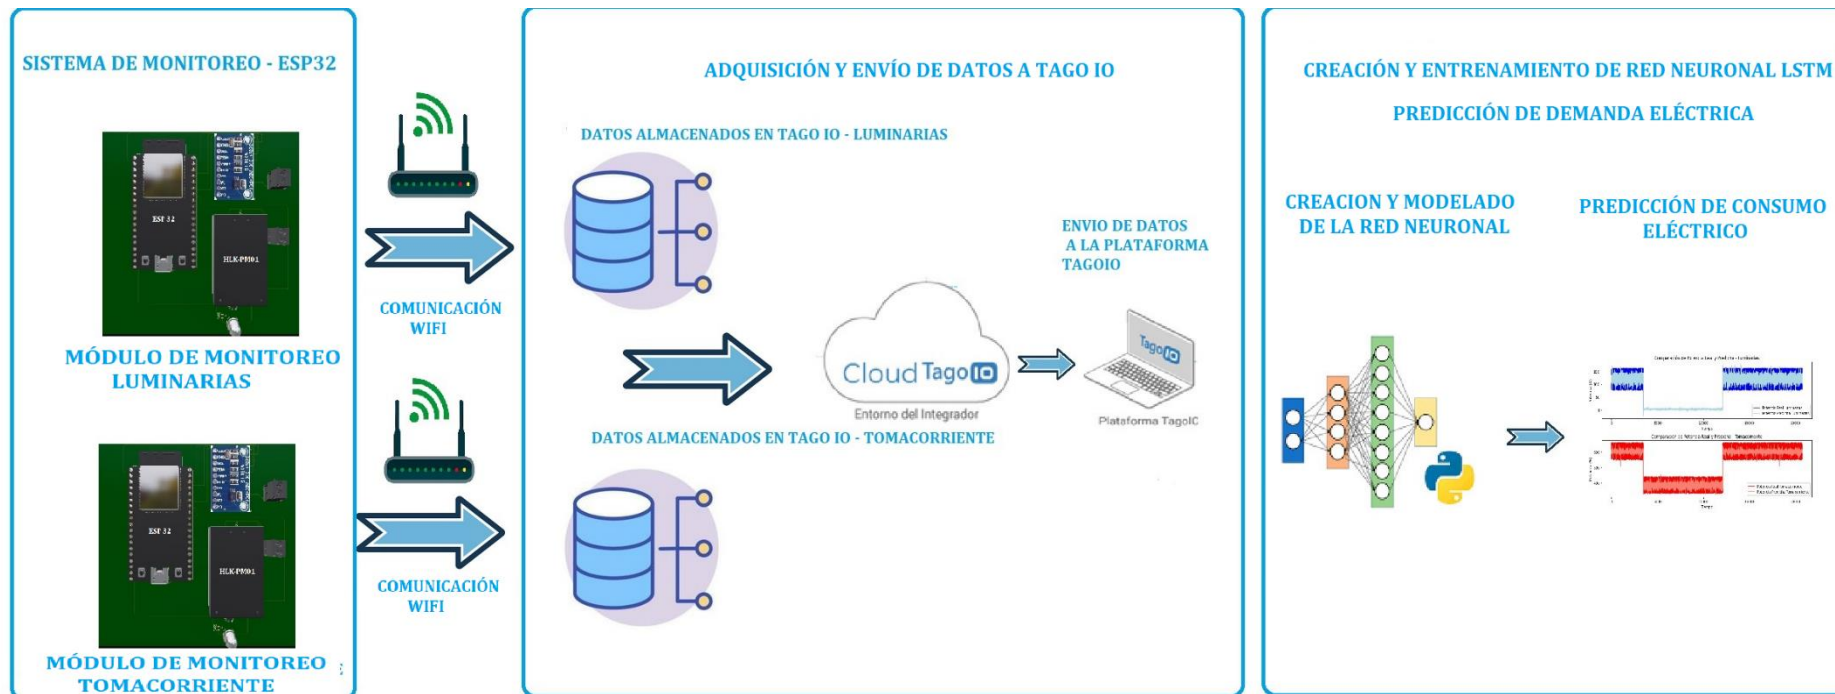


Figura 17. Arquitectura de Red para el desarrollo de la Propuesta.

Fuente: El autor

3.5 Desarrollo del Dispositivo de Monitoreo.

El diseño del dispositivo de monitoreo se ha concebido con la finalidad de reunir datos de forma precisa y eficiente para su posterior procesamiento y análisis. La base fundamental de esta configuración se encuentra en la elección del ESP32 como el microcontrolador central. Este elemento será esencial para coordinar la recopilación y administración de los datos generados por los diversos sensores conectados al sistema.

La integración de un sensor de corriente junto con el módulo de conversión analógico-digital ADS1115 constituye un elemento esencial en el diseño de este dispositivo. El sensor de corriente desempeña un papel fundamental como la fuente principal de datos, cuyas señales analógicas son convertidas a señales digitales mediante el módulo ADS1115. Esta transformación de datos se revela como un paso crucial para el subsiguiente procesamiento por parte del ESP32, posibilitando la obtención de mediciones de corriente eléctrica precisas y confiables.

Para asegurar un suministro eléctrico estable y confiable para el funcionamiento óptimo de los dispositivos, se ha integrado el módulo transformador HLK-PM01. Este componente se encarga de convertir el voltaje de corriente alterna (AC) proveniente de la red eléctrica a un voltaje continuo de 5 voltios (DC), esencial para alimentar de manera consistente al ESP32, al módulo ADS1115 y al sensor de corriente.

En la figura 18, se destaca el diagrama de bloques que configura la alimentación de los componentes esenciales a utilizar en el sistema. Este diagrama detalla la interconexión y distribución de la energía eléctrica a lo largo del sistema, mostrando cómo se suministra potencia a cada componente clave.




Figura 18. Diagrama de bloques para suministrar energía a los componentes.

Fuente: El autor

En la Figura 19, se ilustra la conexión del sistema de monitoreo, especificando la interconexión entre el dispositivo de medición, el convertidor analógico a digital y la

unidad central, representada por la ESP32. Se destaca que la alimentación de estos elementos proviene del HLK-PM01.

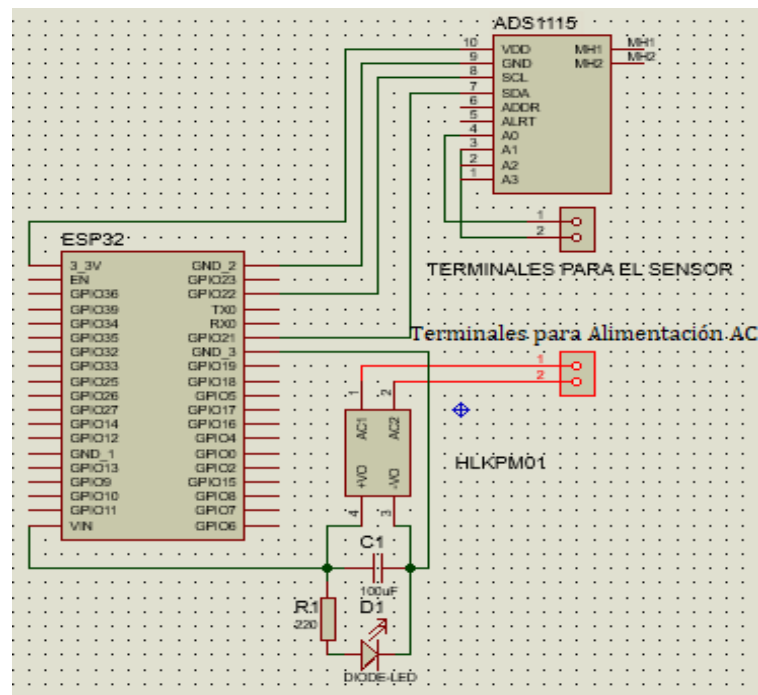


Figura 19. Esquema del circuito eléctrico del sistema de monitoreo de energía

Fuente: El autor

En la figura 20, se observa una visión en 3D del diseño completo del sistema. Aquí, se pueden apreciar no solo los componentes internos dispuestos en la PCB, sino también la integración cuidadosa de la ESP32, el convertidor y el transformador, los cuáles son clave para el sistema de monitoreo.



Figura 20. Esquema en 3D del sistema de monitoreo de energía

Fuente: El autor

3.6 Arquitectura para la Adquisición de datos

En el campo de la monitorización y adquisición de datos, la eficiente recopilación y procesamiento de información son fundamentales para obtener resultados precisos y significativos. La arquitectura de adquisición de datos que se propone se centra en la optimización de la información proveniente de los módulos de monitoreo conectados a sensores de corriente.

En la arquitectura de adquisición de datos, comenzamos capturando datos crudos de sensores de corriente y los filtramos para obtener variables clave como corriente, potencia y tiempo de adquisición. Luego, aplicamos preprocesamiento mediante minimización y escalamiento para mejorar la calidad y relevancia de los datos. Posteriormente, dividimos los datos preprocesados en conjuntos de entrenamiento y prueba, permitiendo evaluar la capacidad predictiva del modelo LSTM. Finalmente, implementamos el modelo LSTM, especializado en capturar relaciones temporales en secuencias de datos, entrenándolo con el conjunto de datos de entrenamiento para predecir con precisión las variables deseadas en nuevos datos.

La arquitectura de adquisición de datos consta de cuatro etapas clave: Sistema de Monitoreo, Variables de Entrada y Salida, Preprocesamiento de Datos, y Modelo de Aprendizaje Automático. La figura 21 ofrece una representación visual de estas etapas, facilitando la comprensión del flujo entre cada fase en la preparación de datos para el análisis.

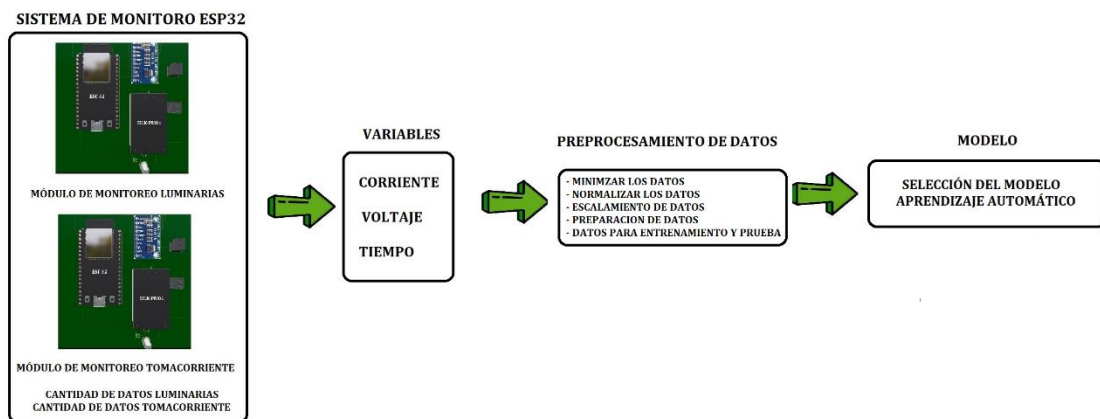


Figura 21. Arquitectura de Adquisición de Datos

Fuente: El autor

3.6.1 Adquisición de datos en el sistema de monitoreo.

En la Tabla 5, se presenta un detallado registro de las librerías esenciales empleadas para obtener y procesar datos del sensor de corriente. Cada librería cumple un papel específico en la configuración y funcionamiento del sistema, destacando la importancia de su integración para garantizar mediciones precisas.

Tabla 5. Librerías de Arduino para la conexión wifi de la ESP32

Librerías	Descripción
Wire.h	Proporciona las funciones para la comunicación I2C necesaria para interactuar con el ADS1115.
Adafruit_ADS1X15.h	Permite la comunicación con el sensor de corriente ADS1115 para la medición de voltajes.

Dentro del código desarrollado en el entorno de desarrollo de software Arduino IDE, se implementaron funciones específicas, entre las cuales se encuentra la denominada `getCorriente`, diseñada para obtener lecturas precisas de corriente del sensor en conjunto con el convertidor ADS1115. Con el propósito de realizar múltiples lecturas de voltaje diferencial, la función aplica factores de conversión específicos, como "multiplier" y "FACTOR", en cada iteración del bucle. Estas medidas de corriente se acumulan y cuentan durante el proceso. Al finalizar el bucle, se calcula la raíz cuadrada de la suma de las medidas al cuadrado, dividiendo este resultado por el número total de lecturas, logrando así la obtención de la corriente RMS.

Este valor eficaz refleja la magnitud promedio de la corriente a lo largo del periodo de muestreo y se devuelve como resultado de la función, ofreciendo una estimación precisa de la corriente eléctrica en amperios. La medición RMS es especialmente relevante en sistemas eléctricos, ya que capta la componente efectiva de la corriente, proporcionando una medida más exacta de la magnitud real de la corriente alterna.

La función `Imprimir Medidas` cumple la responsabilidad específica de visualizar las lecturas de corriente y potencia a través del puerto serie. Esta tarea se lleva a cabo mediante el uso de tres parámetros: prefix (prefijo), value (valor) y postfix (sufijo). Estos parámetros se utilizan en conjunto con las funciones de impresión `Serial.print` y

Serial.println, diseñadas para presentar de manera clara y legible las medidas en el formato definido por dichos parámetros.

Posteriormente, la corriente RMS se obtiene a través de la función `getCorriente()`. Una vez alcanzado este valor, se imprime en amperios utilizando la función `ImprimirMedidas`. El cálculo de la potencia se realiza multiplicando la corriente por un factor específico de voltaje, y el resultado se imprime en vatios utilizando nuevamente la función `ImprimirMedidas`.

En la figura 22 se evidencia el diagrama de flujo que conlleva a la obtención de datos de corriente y potencia para su posterior uso en la adquisición.

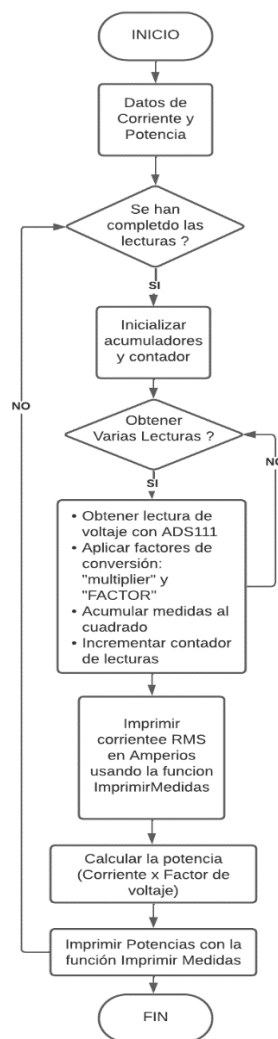


Figura 22. Diagrama de flujo de adquisición de datos

Fuente: El autor

3.6.2 Calibración del Sensor de Corriente SCT03-013

La calibración del sensor SCT03-013 es un proceso esencial para garantizar mediciones precisas y confiables de corriente eléctrica en sistemas de monitoreo. Este sensor de efecto Hall se emplea comúnmente para medir la corriente alterna, proporcionando datos cruciales para evaluar el consumo eléctrico en diversos dispositivos y sistemas.

De acuerdo con la figura 23, se puede apreciar la medición de corriente de las luminarias, la cual arroja valores cercanos a 0.02 A. Estos valores concuerdan satisfactoriamente con las lecturas del sensor, que se encuentran prácticamente en ese rango, demostrando así la calibración adecuada del sensor para esta aplicación específica.

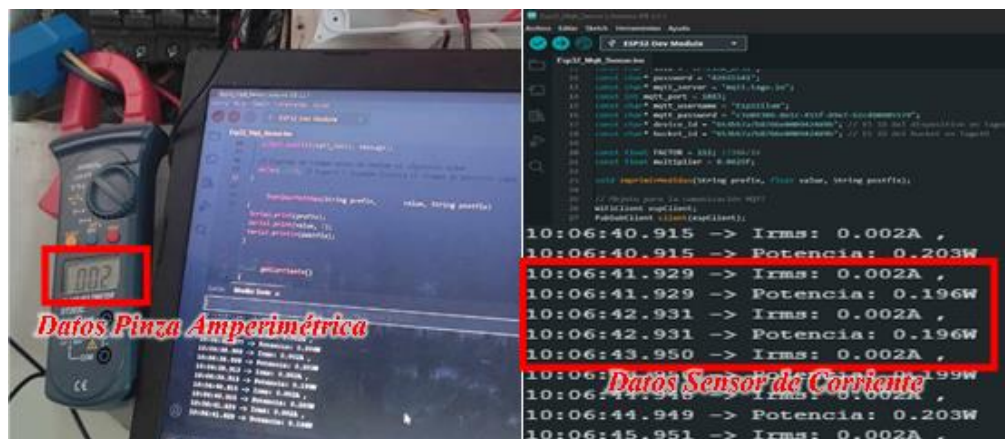


Figura 23. Comparación de mediciones en luminarias

Fuente: El autor

En contraste, al examinar la Figura 24, se evidencia una variabilidad significativa en los valores medidos en el tomacorriente. Estos valores fluctúan considerablemente, mostrando lecturas tan bajas como 0.4 A, mientras que la pinza amperimétrica registra valores de hasta 2.7 A. Esta disparidad señala claramente un error en el proceso de adquisición de corriente para evaluar los datos destinados a la predicción.

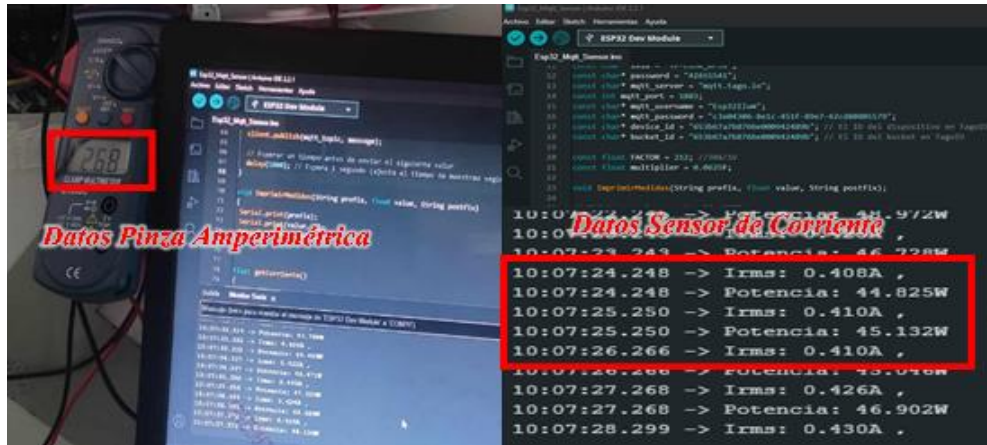


Figura 24. Comparación de mediciones tomacorrientes

Fuente: El autor

La información derivada de las mediciones efectuadas está disponible de manera detallada en la Tabla 6. En dicha tabla, se presenta de forma específica tanto las mediciones provenientes del sensor de corriente como las obtenidas mediante la pinza amperimétrica. Este conjunto de datos proporciona una visión integral de las lecturas de corriente, permitiendo comparar y analizar las mediciones provenientes de ambas fuentes.

Tabla 6. Error absoluto y relativo entre el sistema de monitoreo y la pinza amperimétrica.

Sensor	Pinza	Error	Error
SCT-013	amperimétrica	Absoluto	Relativo
0.40 A	2.65 A	2.25 A	84.91 %
0.42 A	2.68 A	2.26 A	84.33 %
0.41 A	2.71 A	2.30 A	84.85 %
0.42 A	2.72 A	2.30 A	84.85 %
0.43 A	2.69 A	2.26 A	84.03 %
0.41 A	2.66 A	2.25 A	84.51 %

Los errores entre las mediciones del sensor de corriente y la pinza amperimétrica revelan discrepancias sustanciales en los datos recopilados. El error absoluto, que mide la diferencia numérica real entre los dos conjuntos de mediciones, muestra valores que oscilan entre 2.25 A y 2.30 A. Estos números indican una discrepancia significativa independientemente de la dirección de la diferencia, resaltando la magnitud de la variación entre los dos conjuntos de datos.

Por otro lado, el error relativo, expresado en porcentaje, proporciona una perspectiva proporcional de la discrepancia en relación con los valores medidos por la pinza amperimétrica, considerados como los valores verdaderos. Los errores relativos son notoriamente altos, situándose alrededor del 84-85%, lo que sugiere que las mediciones del sensor difieren en gran medida proporcionalmente a las de la pinza amperimétrica. Este alto porcentaje indica una variación sustancial en la relación entre las mediciones de ambos dispositivos.

La calibración del sensor de corriente implica ajustar el factor de escala (representado por FACTOR en el código) para alinear las lecturas del sensor con los valores reales de corriente, considerando la relación entre la salida del sensor y la corriente efectiva. Durante la calibración, se utiliza un instrumento preciso para establecer un valor de referencia, y luego se ajusta de manera empírica el factor de escala en el código hasta que las lecturas del sensor coincidan con las mediciones reales.

La verificación se realiza con múltiples mediciones comparadas con la referencia. Es importante destacar que la calibración puede verse afectada por condiciones ambientales y cambios en el circuito. El ajuste del factor a 212 en el código indica la adaptación específica para lograr una correspondencia precisa entre las mediciones del sensor y los valores reales de corriente.

En la Tabla 7, los datos recalibrados demuestran una coincidencia significativa con las mediciones de referencia, evidenciando la precisión lograda mediante el ajuste del factor de escala. La Figura 25 respalda esta afirmación al mostrar una alineación precisa entre los valores reales de corriente y las mediciones recalibradas del sensor. Este resultado confirma la efectividad del ajuste del factor de escala para lograr una correspondencia precisa.

Tabla 7. *Diferencias entre el sistema calibrado y la pinza amperimétrica*

Sensor	Pinza	Error	Error
SCT-013	amperimétrica	Absoluto	Relativo
2.64 A	2.65 A	0.01 A	0.38 %
2.67 A	2.68 A	0.01 A	0.38 %
2.71 A	2.71 A	0.00 A	0.0 %
2.72 A	2.72 A	0.00 A	0.0 %

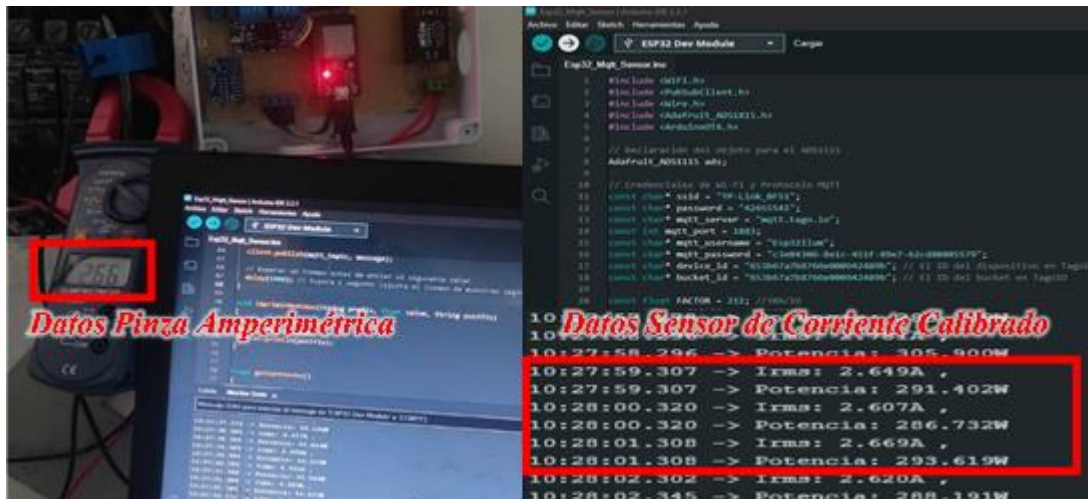


Figura 25. Comparación de valores del sensor calibrados vs. pinza amperimétrica

Fuente: El autor

Con base en los resultados que indican errores absolutos y relativos mínimos entre las mediciones del sensor SCT-013 y las de la pinza amperimétrica de referencia, se establece una base sólida para la implementación de un sistema de monitoreo destinado a la predicción de la demanda eléctrica.

3.7 Desarrollo del firmware de Monitoreo

En el marco de nuestro firmware de monitoreo y adquisición para el ESP32, se inicia el proceso mediante la configuración de las credenciales WiFi, lo que permite la conexión efectiva del dispositivo a la red. Tras la exitosa conexión, se procede a establecer las credenciales necesarias para la comunicación a través del protocolo MQTT, posibilitando una interacción eficiente entre el ESP32 y el servidor correspondiente.

3.7.1 Conexión Wifi ESP32

Para garantizar la precisión y eficiencia en la adquisición de datos, se emplean librerías esenciales que simplifican el desarrollo y depuración al proporcionar conjuntos de funciones y rutinas para tareas específicas. Esto es crucial en la conexión Wi-Fi del ESP32, donde la precisión y eficacia son esenciales. En la tabla 8 se evidencian las descripciones detalladas de las librerías incorporadas para la comunicación de la ESP32 con Wi-Fi.

Tabla 8. Librerías de Arduino para la conexión wifi de la ESP32

Librerías	Descripción
WiFi.h	Permite la conexión a redes WiFi y la configuración del ESP32 como un cliente en la red.
ArduinoOTA.h	Habilita las actualizaciones de firmware OTA (Over-The-Air) en el ESP32.

En el código mostrado en el cuadro, se detalla la programación específica para configurar la comunicación Wi-Fi del ESP32. Además de establecer las credenciales básicas, como el nombre y la contraseña de la red doméstica (SSID), este código incorpora los protocolos esenciales para establecer y mantener una conexión sólida con la red.

```
// Credenciales Wi-Fi

const char* ssid = "Nombre de Red";

const char* password = "*****";

// Conexión a Wi-Fi

WiFi.begin(ssid, password);

while (WiFi.status() != WL_CONNECTED) {

    delay (1000);

    Serial.println("Conectando a WiFi...");

}

Serial.println("Conexión Wi-Fi exitosa");
```

En la figura 26 se evidencia el diagrama de flujo representativo para la conexión wifi de la ESP32.




Figura 26. Diagrama de flujo de la conexión WiFi

Fuente: El autor

3.7.2 Creación de Canal en TagoIO

La configuración de un canal en la plataforma TagoIO implica el acceso a la sección designada para la gestión de dispositivos, comúnmente conocida como "Devices" (Dispositivos). Dentro de este espacio, se lleva a cabo la incorporación de un nuevo dispositivo, para lo cual se solicita información detallada, como nombre, descripción y otros detalles relevantes. Estos datos permiten la identificación y caracterización precisa del dispositivo conectado, como se ilustra en la figura 27.

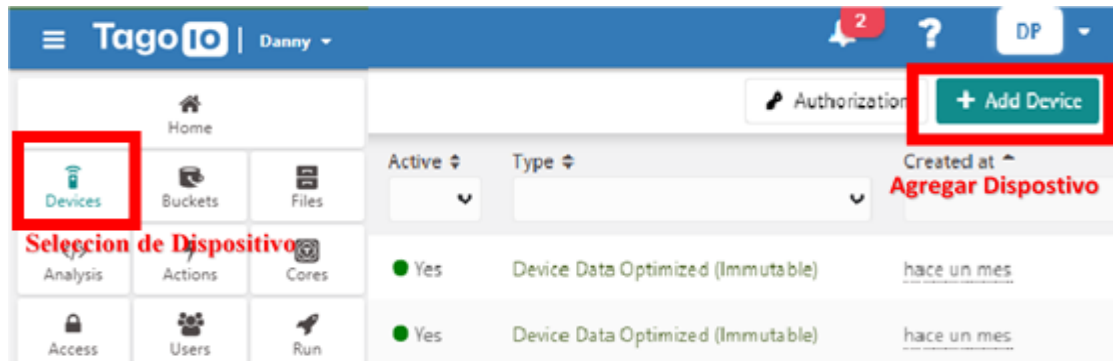


Figura 27. Integración de Dispositivo en la Plataforma de TagoIO

Fuente: El autor

Una vez realizado este paso, se inicia con la autenticación en la cuenta y la navegación hacia el panel principal. Al ingresar, como se detalla en la figura 28 se permite al usuario seleccionar el tipo de comunicación preferido. Este paso posibilita la elección entre protocolos de comunicación como HTTPS, MQTT u otros protocolos de comunicación para la adquisición de datos.



Figura 28. Selección de Protocolo de Comunicación a utilizar

Fuente: El autor

Después de la selección del protocolo en la configuración del canal, es crucial examinar la forma en que los datos pueden extraerse de la plataforma TagoIO. La figura 29 proporciona una representación visual de los diferentes formatos disponibles para la extracción de datos.

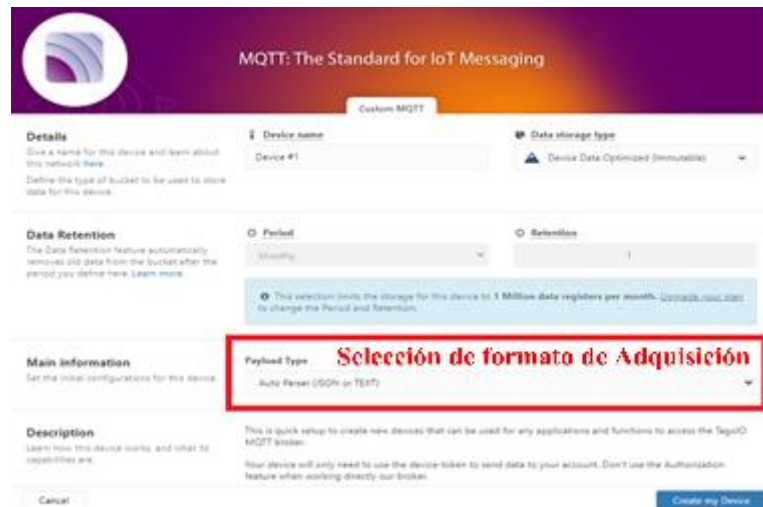


Figura 29. Selección de formato de adquisición de datos

Fuente: El autor

Tras la definición del dispositivo, en la figura se avanza hacia la configuración de los campos o variables, a través de los cuales se representarán y clasificarán los datos provenientes del dispositivo. Estos campos se designan de acuerdo con la naturaleza de los datos recopilados, abarcando parámetros específicos como corriente u otros valores que el dispositivo esté monitoreando.

En la figura 30 se detallan las variables que se utilizarán en la adquisición de datos en este caso en el módulo de monitoreo de los tomacorrientes, además se visualiza el token característico para obtener la comunicación por medio del protocolo MQTT

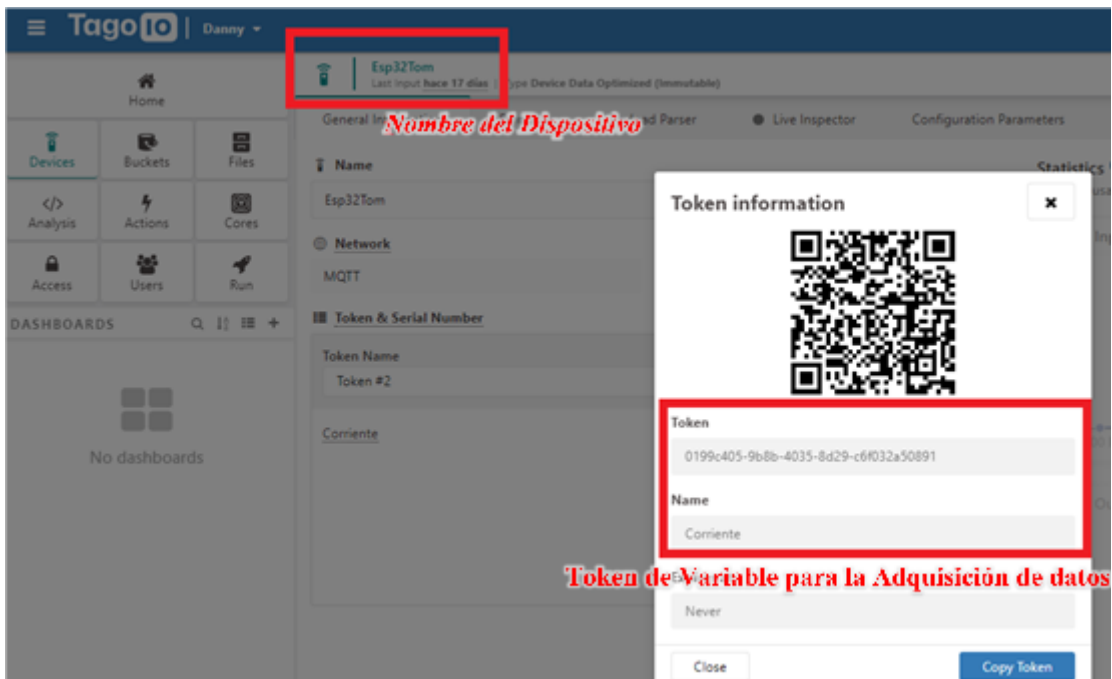


Figura 30. Descripción del Dispositivo del Tomacorriente en TagoIO

Fuente: El autor

En la figura 31 se detalla la variable de adquisición de datos del módulo de monitoreo de las luminarias, además se visualiza el token de la comunicación por medio del protocolo MQTT.

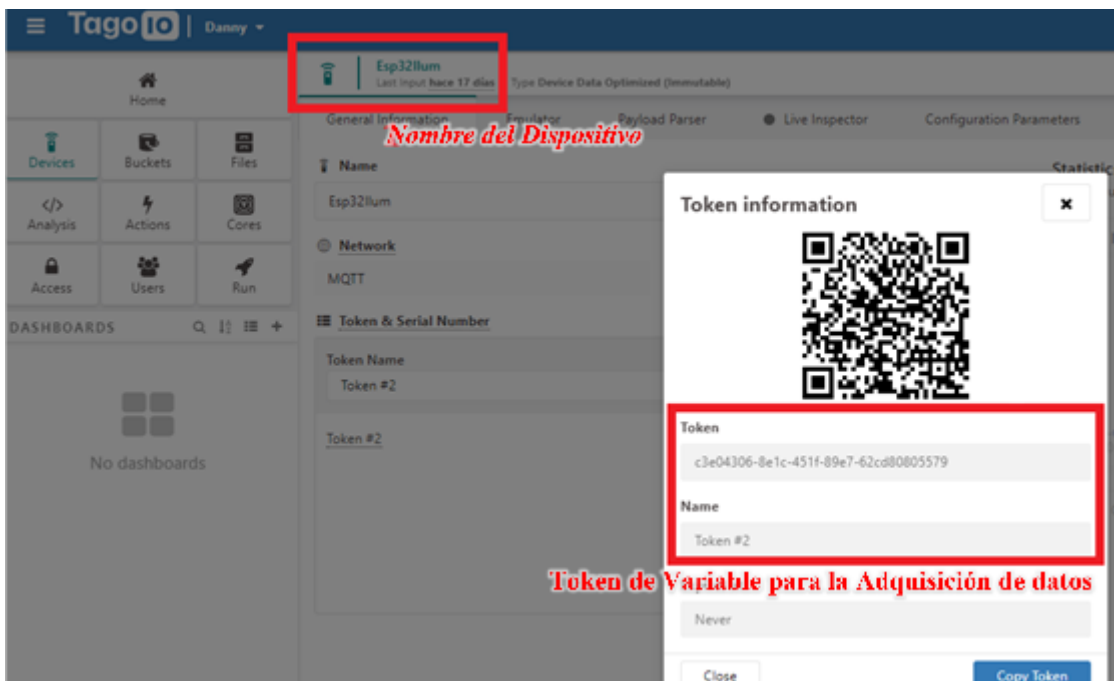


Figura 31. Descripción del Dispositivo de las luminarias en TagoIO

Fuente: El autor

3.7.3 Comunicación por Protocolo MQTT

La comunicación efectiva y eficiente es esencial en entornos conectados, y el protocolo MQTT emerge como una solución clave para la interconexión de dispositivos. En este contexto, este trabajo se centra en la implementación de la comunicación por protocolo MQTT, particularmente en el escenario donde una placa ESP32 se vincula con TagoIO

Para establecer la conexión entre una ESP32 y la plataforma TagoIO mediante el protocolo MQTT, se recomienda utilizar las siguientes librerías en el entorno de desarrollo de Arduino que se observa en la tabla 9.

Tabla 9. Librería de Arduino para la Comunicación MQTT con TagoIO

Librerías	Descripción
PubSubClient.h	Facilita la comunicación MQTT para enviar y recibir mensajes a través de un cliente MQTT.

La configuración de parámetros, como se observa en el recuadro, desempeña un papel fundamental al personalizar y ajustar el comportamiento del programa según las necesidades específicas de la aplicación. Estos parámetros incluyen las credenciales de del protocolo a utilizar. Los identificadores de dispositivo y "bucket" en TagoIO (device_id y bucket_id) son fundamentales para organizar y dirigir los datos en la plataforma, permitiendo una personalización detallada que asegura la integración precisa y eficiente del dispositivo ESP32 en el entorno de la aplicación.

```
const char* Mqtt_server = "mqtt.tago.io"; // Servidor MQTT

const int Mqtt_port = 1883; // Puerto definido para utilizar el protocolo

const char* Mqtt_username = "Nombre de la Variable";

const char* Mqtt_password = "Token de Adquisición";

const char* Device_id = "Nombre del Dispositivo"; // El ID del dispositivo en TagoIO

const char* Bucket_id = "Bandeja Principal del Dispositivo"; // El ID en TagoIO
```

En el contexto de la comunicación mediante el protocolo MQTT con la plataforma TagoIO, se destaca la implementación de la función Reconnect. Esta función se convierte en un elemento clave para facilitar la conexión, incorporando de manera segura el nombre de usuario y la contraseña necesarios.

En la figura 32 se evidencia el diagrama de flujo representativo para la conexión MQTT de la ESP32 a la plataforma de TagoIO.




Figura 32. Diagrama de flujo de la Comunicación MQTT a TagoIO

Fuente: El autor

3.7.4 Envió de Datos a la plataforma de TagoIO

Este proceso de recolección de datos se ejecuta con meticulosidad para garantizar la precisión y estructuración de la información. Los datos recopilados, que se representan mediante la corriente RMS, son cuidadosamente transmitidos al servidor MQTT de TagoIO.

La plataforma TagoIO recibe y almacena estos datos, permitiendo su análisis, visualización y gestión a través de su interfaz web. La integración de la comunicación MQTT facilita la conectividad entre el dispositivo y la plataforma, posibilitando la monitorización remota y el aprovechamiento eficiente de los datos recopilados en aplicaciones específicas de análisis y control de corriente eléctrica.

Para continuar con el proceso se prepara y envía el mensaje MQTT con el valor de la corriente total al servidor MQTT de TagoIO. En este fragmento, se inicializa un arreglo de caracteres llamado message con capacidad para almacenar hasta 20 caracteres. El formato "%.3f" asegura que el valor se presente con tres decimales, lo cual es relevante para la precisión de la medición. Seguido a esto, se define el tema MQTT en el que se publicará el mensaje. En este caso, el tema se denomina "CorrienteTotal". Finalmente, se utiliza el cliente MQTT (client) para enviar el mensaje al servidor MQTT de TagoIO en el tema especificado, donde se toma dos argumentos: el primer argumento es el tema MQTT al que se enviará el mensaje (mqtt_topic), y el segundo es el mensaje en sí

(message). El cliente MQTT se encarga de gestionar la conexión con el servidor y enviar el mensaje formateado. En el recuadro se observa el código realizado para el envío de datos a la plataforma IoT.

```
// Crear un mensaje MQTT con el valor de corriente total  
  
char message [20];  
  
sprintf (message, sizeof(message), "%.3f", CorrienteRMS);  
  
// Publicar el mensaje en un tema MQTT específico  
  
const char* mqtt_topic = "CorrienteTotal"; // "CorrienteTotal"tema MQTT  
  
client. Publish (mqtt_topic, message);
```

Como se evidenció en el proceso de adquisición de datos, el código incluye una etapa crucial donde se genera un mensaje específicamente diseñado para ser enviado a la plataforma de TagoIO. Este mensaje encapsula la corriente medida, la cual es recolectada por el sensor de corriente y transmitida desde la ESP32 hasta la plataforma de TagoIO.

El diagrama de flujo presentado en la Figura 33 es una representación visual del proceso detallado para el envío de datos a la plataforma de TagoIO. Este flujo de trabajo proporciona una guía clara y paso a paso que facilita la comprensión del proceso de envío de datos.



Figura 33. Diagrama de Flujo envío de Datos a TagoIO

Fuente: El autor

En la figura 34 se presenta las capturas de pantalla de la conexión por medio del protocolo MQTT de TagoIO, mientras que en la figura 35 se observa la adquisición de datos en la plataforma de TagoIO, donde el payload es el valor de “Corriente Total” que se obtiene de los valores del sensor de corriente.

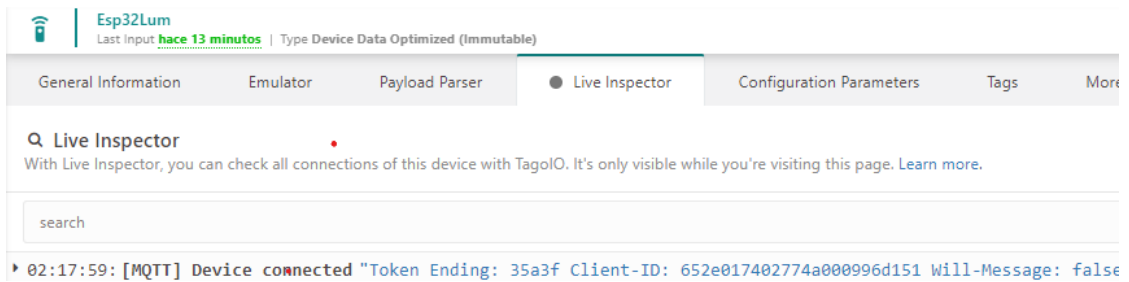


Figura 34. Conexión de Protocolo MQTT en la plataforma TagoIO

Fuente: El Autor

```

02:18:07: [MQTT] Device publish { "topic": "CorrienteTotal"
  {
    "topic": "CorrienteTotal",
    "payload": "0.1205",
    "qos": 0,
    "isHex": false,
    "bucket": "652e017402774a000996d151",
    "messageId": 0
  }
}
02:18:08: [MQTT] Device publish { "topic": "CorrienteTotal"
  {
    "topic": "CorrienteTotal",
    "payload": "0.1192",
    "qos": 0,
    "isHex": false,
    "bucket": "652e017402774a000996d151",
    "messageId": 0
  }
}

```

Figura 35. Descripción del mensaje en TagoIO para los valores de corriente.

Fuente: El Autor

La figura 36 ilustra la recopilación de datos del módulo de monitoreo del tomacorriente, mientras que la figura 37 muestra las mediciones de corriente de las luminarias. Proporcionan información detallada sobre el consumo eléctrico en el entorno monitorizado.

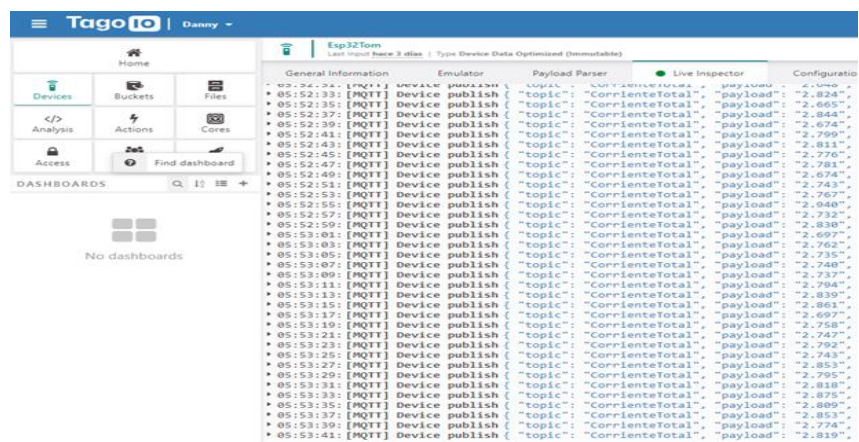


Figura 36. Recolección de Datos del Tomacorriente en la Plataforma TagoIO

Fuente: El Autor

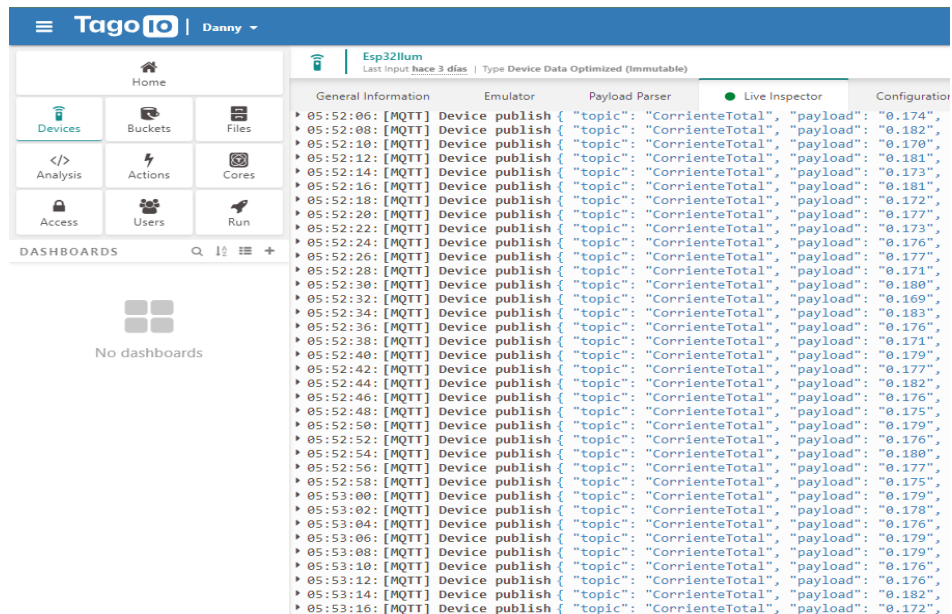


Figura 37. Recolección de Datos de las luminarias en la Plataforma TagoIO

Fuente: El Autor

Después de recopilar los datos de corriente de cada dispositivo, se decidió implementar una Dashboard visualmente atractiva para visualizar la corriente en tiempo real. El objetivo es proporcionar una experiencia más cómoda para conocer los valores exactos de la corriente durante la adquisición de datos. Las figuras 38 y 39 muestran la hora y el comportamiento de la corriente respectivamente. Además, se incluye una tabla de datos que mejora la experiencia de adquisición de datos al proporcionar información detallada.

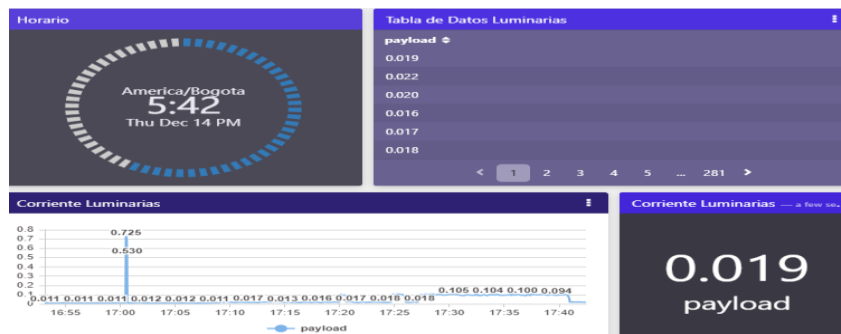


Figura 38. Dashboard de TagoIO para la corriente de las luminarias

Fuente: El autor



Figura 39. Dashboard de TagoIO para la corriente del tomacorriente

Fuente: El autor

Este método de monitoreo en tiempo real de la corriente mediante una interfaz gráfica detallada se corresponde con los principios vinculados a las "redes inteligentes". Estas redes aprovechan tecnologías avanzadas de información y comunicación con el fin de optimizar la eficiencia, confiabilidad y sostenibilidad en la generación, transmisión y distribución de energía eléctrica.

3.8 Gestión Eficiente de Cargas Eléctricas en la vivienda

En el entorno residencial propuesto, conforme se observa en las figuras 15 y 16, se evidencia una estructura de dos niveles. El tablero principal, ubicado en la planta baja, administra cuatro breakers principales. Dos de ellos abastecen la planta baja, alimentando luces y enchufes, mientras que los otros dos están asignados a la planta superior. En este sistema eléctrico, identificamos dos breakers operando a 110 V, actuando como fases cruciales para la distribución eficiente de cargas eléctricas, como se detalla en la tabla 10, que evalúa el consumo de potencia en watts [W].

Tabla 10. Distribución de fase de cada electrodoméstico.

Línea 1		Línea 2	
Dispositivos	Potencia Watts	Dispositivos	Potencia Watts
Refrigeradora	132 W	20 luminarias 5w	100 W
Lavadora	77 W	5 luminarias 7w	35 W
Televisores	165W	-	-
Laptops	27.5 W	-	-
Ventilador	33 W	-	-

Cada breakers cuenta con una capacidad nominal de 32 amperios, tanto para el control de luminarias como para los tomacorrientes, garantizando un suministro eléctrico robusto para cada sección de la vivienda.

La disposición del tablero principal ofrece una visión detallada de la distribución eléctrica en la vivienda. Utilizando estos datos, es posible calcular el consumo de potencia de la residencia, que ha sido analizado en términos de corriente y potencia para cada electrodoméstico, según la información proporcionada anteriormente.

Este análisis exhaustivo sienta las bases para la implementación de dos sistemas de monitoreo, centrados en la medición de potencia y corriente. La aplicación de estos sistemas permitirá un seguimiento preciso y continuo de los consumos eléctricos, ofreciendo una visión en tiempo real de la demanda de energía en la residencia.

Durante el día, se destina aproximadamente 3 amperios a los tomacorrientes, mientras que la iluminación utiliza alrededor de 0.02 amperios. En contraste, durante la noche, el consumo energético aumenta considerablemente, con la refrigeradora, los televisores y las luminarias contribuyendo significativamente a la demanda, donde el dispositivo de tomacorriente utiliza 7 A y el de iluminación 1.5 A.

En el contexto de este análisis, es esencial comprender la relación entre el voltaje, la corriente y la potencia nominal de cada dispositivo eléctrico. En la fórmula 7 se expresa de como calcular la potencia nominal de los dispositivos eléctricos que viene definida por:

$$P_{nom} = V_{nom} \times I_{nom} \quad (7)$$

Donde:

- P_{nom} es la potencia nominal.
- V_{nom} es el voltaje nominal del dispositivo.
- I_{nom} es la corriente nominal del dispositivo.

El análisis de carga, como se muestra en las Tablas 11 y 12, destaca diferencias notables en el consumo energético entre el período diurno y nocturno. Gracias a la aplicación de la fórmula [7], se determinó que la refrigeradora, por ejemplo, experimenta un cambio en su consumo energético, pasando de 132W durante el día a 198W durante la noche. Estos resultados enfatizan la importancia de implementar una

gestión de energía específica durante las horas nocturnas, ya que estas variaciones representan una carga sustancial para el sistema eléctrico.

Tabla 11. Identificación de Corriente de cada electrodoméstico en el día.

Dispositivos	Vnom	Inom	Pnom
Refrigeradora	110 v	1.2 A	132 w
Lavadora	110 v	0.7 A	77 w
Televisores	110 v	1.5 A	165 w
Laptops	110 v	0.25 A	27.5 w
Ventilador	110 v	0.3 A	33 w
Luminarias	110 v	0.003A	0.33 w

Tabla 12. Identificación de Corriente de cada electrodoméstico en la noche.

Dispositivos	Vnom	Inom	Pnom
Refrigeradora	110 v	1.8 A	198 w
Lavadora	110 v	1.1 A	121 w
Televisores	110 v	2.1 A	231 w
Laptops	110 v	0.5 A	55 w
Ventilador	110 v	0.5 A	55 w
Luminarias	110 v	1.4 A	154 w

3.9 Preparación de datos

La preparación de datos antes de crear una red neuronal LSTM es una etapa crucial que implica una serie de pasos destinados a optimizar la calidad y la adecuación de los datos para el proceso de entrenamiento de la red.

Estos pasos abarcan desde la normalización y escalado de los datos originales hasta la creación de secuencias adecuadas que puedan ser utilizadas como entradas y salidas para la red neuronal.

Normalización y Escalado

La normalización desempeña un papel crucial en el proceso de preparación de datos, ya que su objetivo principal es armonizar las escalas de las variables para garantizar que todas sean comparables entre sí. Este procedimiento se vuelve esencial

al lidiar con conjuntos de datos que poseen características con rangos diversos. En términos generales, la normalización ajusta los valores de las variables a una escala específica, típicamente entre 0 y 1. La fórmula 8, que describe la normalización mediante el método de escalamiento Min-Max para una variable x , se expresa de la siguiente manera:

$$X_{normalizada} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (8)$$

Esto garantiza que los valores normalizados estén en un rango unitario, facilitando la convergencia del modelo durante el entrenamiento. La visualización gráfica revela una distribución uniforme en un rango común, preparando los datos para la red neuronal. El escalado ajusta la magnitud de las variables para evitar sesgos, y la aplicación común de Min-Max Scaling asegura una escala uniforme, contribuyendo a la estabilidad del proceso de entrenamiento.

Secuencias Temporales

La creación de secuencias temporales es esencial cuando se trabaja con datos de series temporales, como el consumo de energía a lo largo del tiempo. Consiste en organizar los datos en segmentos secuenciales, donde cada segmento incluye una secuencia de pasos de tiempo y las correspondientes variables de entrada y salida. Esto permite a la red neuronal capturar patrones temporales complejos y aprender dependencias a lo largo del tiempo. La fórmula general para una secuencia de longitud n se define en la fórmula 9:

$$Secuencias_i = [x_i, x_i + 1, \dots, x_i + n - 1, Y_i + n - 1] \quad [9]$$

Donde:

- $x_i, x_i + 1, \dots, x_i + n - 1$ son los valores de la variable de entrada en la secuencia
- $Y_i + n - 1$ son los valores de la variable de salida en el tiempo.

Esto representa una secuencia de entrada \mathbf{x} y su correspondiente salida \mathbf{y} , facilitando la predicción de valores futuros.

División en conjuntos de entrenamiento y prueba

Antes de entrenar el modelo LSTM, se realiza una división del conjunto de datos en conjuntos de entrenamiento y prueba. La elección adecuada de esta división es esencial para evaluar la capacidad predictiva del modelo. En este caso, he optado por una división convencional del 80% para entrenamiento y el 20% restante para prueba, como se observa en el código a continuación.

```
# Dividir los datos en entrenamiento y prueba

train_size = int(len(data_sequences) * 0.8)

train_data = data_sequences[:train_size]

train_targets = targets[:train_size]

test_data = data_sequences[train_size:]

test_targets = targets[train_size:]
```

Esta configuración garantiza que el modelo se entrene en una cantidad significativa de datos históricos y se evalúe en datos futuros no vistos. La elección del tamaño de entrenamiento y prueba es crucial y se ha basado en una proporción comúnmente utilizada en la práctica. Sin embargo, esta proporción puede ajustarse según las características específicas de los datos y los objetivos del modelado.

En la figura 40 se muestra la representación de los datos originales después de ser normalizados y escalados, preparándolos para la creación del aprendizaje automático.

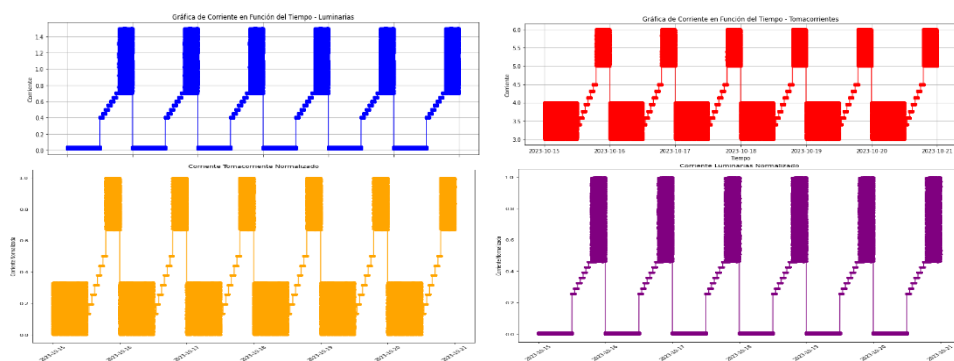


Figura 40. Representación de valores Escalados

Fuente: El Autor

En la tabla 13, se especifican las librerías que desempeñan un papel crucial en la etapa inicial del proceso, es decir, el procesamiento de datos antes de la creación de la red neuronal. Estas librerías son esenciales para garantizar la coherencia y eficacia de la manipulación de datos, un paso crucial en la construcción de modelos predictivos robustos.

Tabla 13. Librerías en Python para el Procesamiento de Datos

Librería	Versión	Descripción
re	NA	Procesamiento de Datos
Numpy	1.18.5	Utilizada para manipulación eficiente de matrices y operaciones numéricas, contribuye a la preparación y procesamiento de datos necesarios para la red neuronal LSTM.
Pandas	1.0.5	Esencial para la manipulación de conjuntos de datos estructurados, facilita la carga, limpieza y organización de datos antes de integrarlos en el proceso de entrenamiento.
MinMaxScaler	2.0.0 y superior	Escala las características a un rango dado, generalmente entre 0 y 1.

3.10 Creación de red neuronal en Python

Después de cada fase del desarrollo de la propuesta, que incluye el sistema de monitoreo y el preprocesamiento de datos, se inicia el siguiente paso crucial.

La creación de la red neuronal LSTM es un aspecto fundamental en la fase de modelado y predicción del consumo eléctrico en un entorno doméstico. En la figura 41 se muestra el diagrama de bloques del proceso previo a la creación de la red neuronal.




Figura 41. Diagrama de bloques Preparación de datos

Fuente: El Autor

Para llevar a cabo la creación efectiva de la red neuronal, es imprescindible incorporar librerías que satisfagan los requisitos esenciales para obtener un modelo de red neuronal LSTM robusto y eficiente. En la tabla 14, se detallan las librerías que han sido seleccionadas y utilizadas en el desarrollo de la red neuronal, resaltando su importancia y función específica en el proceso.

Tabla 14. Librerías en Python para la Creación de la Red Neuronal LSTM

Librería	Versión	Descripción
TensorFlow	2.0	Librería de código abierto para construir y entrenar modelos de redes neuronales. Proporciona una base sólida para implementar arquitecturas LSTM eficientes.
Keras	2.3.1	Integrada con TensorFlow, facilita la construcción modular de capas de red neuronal, simplificando el diseño y la configuración de arquitecturas LSTM.

El proceso se inicia con la recopilación de datos provenientes de los dispositivos de monitoreo de las luminarias y tomacorriente. Estos datos, almacenados en archivos de texto, son sometidos a una etapa inicial de preprocesamiento, donde se extrae la información relevante, como la hora y los valores de corriente registrados en cada evento.

La red LSTM, especializada en modelar secuencias temporales, se configura para aprender patrones en datos temporales generados por dispositivos. La arquitectura, representada en la Figura 42, consta de una capa inicial de 150 nodos diseñada para capturar relaciones temporales complejas. Complementando esta capa, se encuentra una capa de salida con dos neuronas, una para cada tipo de dispositivo eléctrico, ilustrando la arquitectura del modelo.

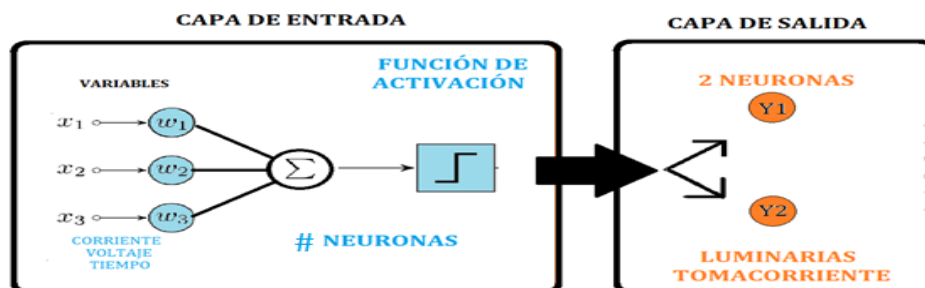


Figura 42. Arquitectura LSTM

Fuente: El Autor

3.11 Entrenamiento y validación del modelo predictivo

La etapa crítica de entrenamiento del modelo LSTM se ha diseñado con un enfoque riguroso. Para lidiar con la complejidad de la tarea de secuencia temporal, se ha incorporado una capa de salida con una activación ReLU, y se han seleccionado funciones de pérdida clave, incluyendo error cuadrático medio (MSE), error absoluto medio (MAE) y raíz cuadrada del error cuadrático medio (RMSE) para la optimización del rendimiento del modelo.

El ajuste preciso de los hiperparámetros, como el número de unidades LSTM y la longitud de las secuencias temporales, es fundamental. Este ajuste se realiza de manera minuciosa, considerando la naturaleza específica de los datos y los objetivos particulares de la tarea. Durante el proceso de entrenamiento, el 80% de los datos se utiliza para nutrir al modelo, y la evaluación se lleva a cabo en el restante 20%, proporcionando así una validación robusta de la capacidad predictiva de nuestro modelo en la estimación exacta del consumo energético. Este enfoque asegura que nuestro modelo esté afinado y listo para enfrentar desafíos en el mundo real.

Una herramienta crucial para comprender la eficacia de la red neuronal es la visualización de las métricas de entrenamiento y validación a lo largo de las épocas. Los resultados ofrecen una visión detallada del rendimiento del modelo durante el entrenamiento, permitiendo la identificación de posibles problemas, como sobreajuste o subajuste.

3.12. PRUEBAS Y RESULTADOS

En esta sección, se enfoca en la implementación de un modelo predictivo, destacando la importancia de las pruebas preliminares. Antes de entrar en el proceso general del modelo, es fundamental establecer una base sólida mediante la evaluación de datos, la selección de variables relevantes y la comprensión de la idoneidad del conjunto de datos para el propósito predictivo.

3.12.1 Implementación del sistema de monitoreo

En la Figura 43, se muestra la implementación de dos sistemas de monitoreo energético vinculados a la corriente eléctrica y la potencia de luminarias y tomacorrientes. El módulo derecho supervisa las luminarias, mientras que su contraparte izquierda monitorea los tomacorrientes en el entorno de la propuesta.




Figura 43. Instalación de los sistemas de monitoreo en el tablero principal

Fuente: El autor

3.12.2 Pruebas de Adquisición de Datos sin calibrar el sensor de corriente

Durante una etapa inicial de análisis, se evaluaron los datos durante dos horas, identificando errores en la adquisición de datos en la plataforma de TagoIO y una falta de calibración en el sensor. Las figuras 44 y 45 detallan los registros de tomacorrientes y luminarias, generando un conjunto de 3052 datos para el análisis.




Figura 44. Prueba de Adquisición e interpretación de Datos de las luminarias

Fuente: El autor




Figura 45. Prueba de Adquisición e interpretación de Datos del tomacorriente

Fuente: El autor

La evaluación de los valores de corriente en relación con las luminarias reveló una dispersión en el rango de 0.01 A hasta un aproximado de 0.2 A, indicando una inconsistencia en la adquisición de datos. En cuanto a los tomacorrientes, los valores no coincidían exactamente, ya que se midió el amperaje con una pinza amperimétrica, arrojando cifras aproximadas de 3 a 4 amperios durante el periodo analizado.

3.12.3 Pruebas de Adquisición de Datos con Sensores Calibrados

Después de realizar la calibración del sensor de corriente y evaluar la respuesta de la red neuronal mediante los datos de prueba, se procedió a realizar un análisis más extenso utilizando datos recopilados a lo largo de 6 días.

En la adquisición de datos de las luminarias y tomacorrientes, se llevó a cabo una estrategia que abarcó tres franjas horarias distintas: día, tarde y noche. Este enfoque se basó en observaciones previas del entorno de desarrollo, donde se identificó que los valores más altos de corriente se registraban durante la noche.

El análisis se materializó en la ilustración de datos, totalizando 103,680 para las luminarias y tomacorrientes respectivamente, como se puede apreciar en las figuras 46 y 47. Este enfoque temporal más amplio proporciona una perspectiva más detallada sobre los patrones de consumo eléctrico y permite una evaluación más precisa del rendimiento del modelo predictivo en condiciones más diversas.

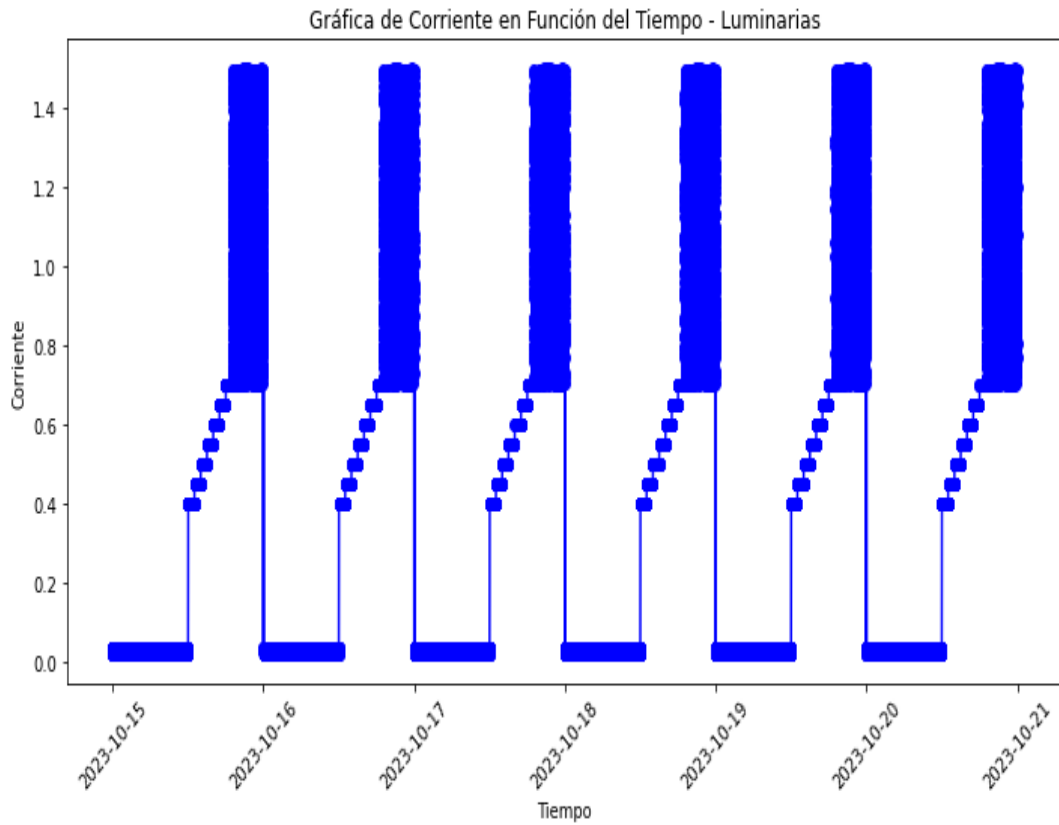


Figura 46. Gráfica de corriente de las luminarias del 15 al 21 de octubre de 2023

Fuente: El autor




Figura 47. Gráfica de corriente de tomacorrientes del 15 al 21 de octubre de 2023

Fuente: El autor

Adicionalmente, se llevó a cabo la integración de imágenes en relación con las potencias, considerando que el consumo de voltaje en mi residencia se mantiene constante en 110 V. Este proceso visual proporciona una representación gráfica más completa y detallada de las correlaciones entre las imágenes capturadas y los niveles de potencia asociados. La figura 48 exhibe esta relación para las luminarias, mientras que la figura 49 representa correspondiente al tomacorriente.




Figura 48. Gráfica de potencia de luminarias del 15 al 21 de octubre de 2023

Fuente: El autor




Figura 49. Gráfica de potencia de tomacorrientes del 15 al 21 de octubre de 2023.

Fuente: El autor

3.12.4 Comparación de Redes neuronales LSTM

En esta implementación, se han utilizado tres redes LSTM con diferentes funciones de activación: ReLU, Tanh y Lineal. Estas redes fueron diseñadas para abordar un problema de predicción en el cual las variables de entrada y salida son diferentes y constan de 150 neuronas activadas por la función respectiva en cada red.

Arquitectura de la Red

Entrada y Salida

La red recibe un conjunto de variables de entrada, y tiene 2 variables de salida, manteniendo una consistencia en el número de características. La elección de utilizar 150 neuronas en la capa de entrada y 2 neuronas en la de salida sugiere una complejidad en la representación de los datos.

ReLU (Rectified Linear Unit):

Esta función introduce no linealidades a la red y se ha observado que es efectiva para aprender patrones complejos en datos. La elección de ReLU puede haber contribuido a una respuesta más eficiente en términos de convergencia y representación de patrones no lineales.


Tanh (Tangente hiperbólica)

Aunque es una función de activación común, su naturaleza saturante puede causar problemas en el aprendizaje profundo. En este caso, la observación de que las predicciones con Tanh no son tan precisas sugiere que la saturación de la función puede afectar negativamente la capacidad de la red para modelar ciertos patrones.


Lineal

La función de activación lineal es directa y simplemente realiza una transformación lineal de los datos. En este escenario, la elección de la activación lineal puede haber limitado la capacidad de la red para capturar relaciones no lineales complejas, lo que se refleja en una menor precisión en las predicciones.


En la figura 50 se observa las comparaciones en base a las diferentes redes que se han aplicado para predecir el consumo.



ACTIVACIÓN RELU



ACTIVACIÓN TANH



ACTIVACIÓN LINEAL

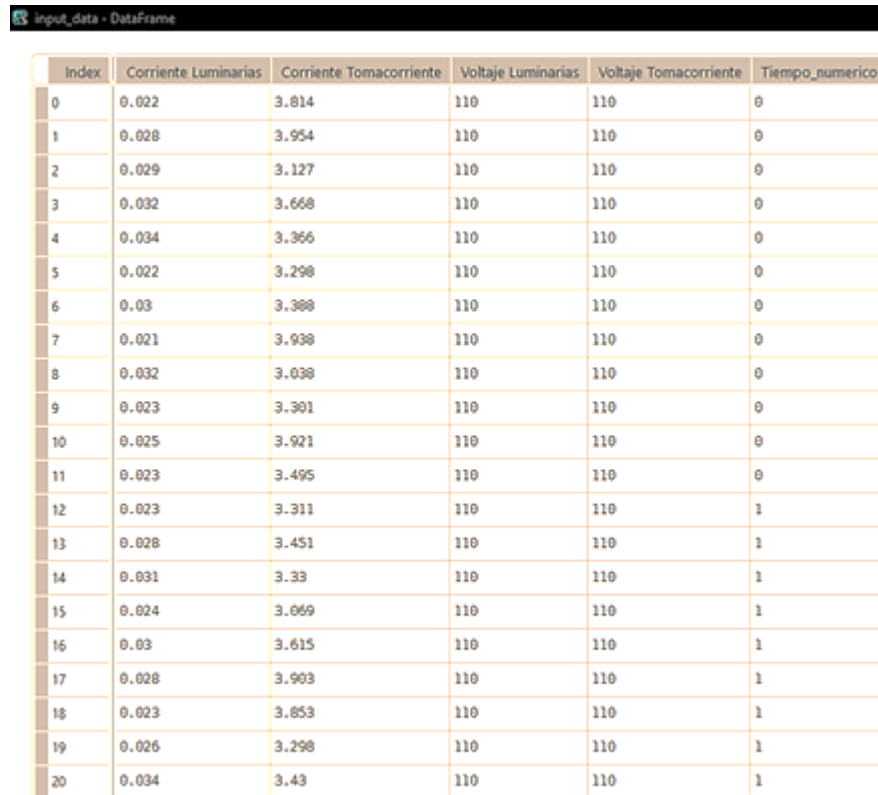
Figura 50. Comparación de predicciones de cada red LSTM con diferentes activaciones

Fuente: El autor

En la etapa de selección de modelos para mi problema de predicción, tras implementar redes LSTM con diferentes funciones de activación, como ReLU, Tanh y Lineal, he concluido que la red LSTM con activación ReLU sobresale como la opción más precisa y eficiente.

3.12.5 Estructura de la red LSTM

De acuerdo a la estructura del modelo LSTM, se han agregado variables que representan la corriente de cada dispositivo, el voltaje suministrado y el tiempo de los datos adquiridos. Estas variables forman parte de los conjuntos de entrenamiento, validación y prueba de la red neuronal demostrado en la figura 51.



Index	Corriente Luminarias	Corriente Tomacorriente	Voltaje Luminarias	Voltaje Tomacorriente	Tiempo_numerico
0	0.022	3.814	110	110	0
1	0.028	3.954	110	110	0
2	0.029	3.127	110	110	0
3	0.032	3.668	110	110	0
4	0.034	3.366	110	110	0
5	0.022	3.298	110	110	0
6	0.03	3.388	110	110	0
7	0.021	3.938	110	110	0
8	0.032	3.038	110	110	0
9	0.023	3.301	110	110	0
10	0.025	3.921	110	110	0
11	0.023	3.495	110	110	0
12	0.023	3.311	110	110	1
13	0.028	3.451	110	110	1
14	0.031	3.33	110	110	1
15	0.024	3.069	110	110	1
16	0.03	3.615	110	110	1
17	0.028	3.903	110	110	1
18	0.023	3.853	110	110	1
19	0.026	3.298	110	110	1
20	0.034	3.43	110	110	1

Figura 51. Variables de entrada para la red neuronal

Fuente: El autor

En contraste, la figura 52 presenta la estructura detallada de la red neuronal LSTM implementada. La arquitectura del modelo es de tipo Secuencial, lo que significa que las capas se apilan secuencialmente. La capa LSTM se encarga de procesar las secuencias temporales de las variables de entrada. Notablemente, la capa de salida (Dense) se configura para tener dos salidas, correspondientes a las potencias de las luminarias y tomacorrientes. Los parámetros de la red neuronal, es decir, los pesos y sesgos, se ajustan durante el entrenamiento para optimizar el rendimiento del modelo en función de la pérdida definida.


```
In [16]: model.summary()
Model: "sequential_9"
```

Layer (type)	Output Shape	Param #
lstm_9 (LSTM)	(None, 150)	94800
dense_9 (Dense)	(None, 2)	302

```

Total params: 95,102
Trainable params: 95,102
Non-trainable params: 0

```

Figura 52. Estructura de la Red LSTM empleada

Fuente: El autor

Los parámetros de entrada de la red neuronal constan de 150 neuronas, totalizando 94800 parámetros. En contraste, las variables de salida de la capa Dense están configuradas con 2 neuronas, lo que equivale a un total de 302 parámetros. Esta distribución de parámetros entre las capas de entrada y salida contribuye a la complejidad y capacidad de la red neuronal para procesar la información de entrada y generar resultados a través de sus salidas.

3.12.6 Desempeño de la red Neuronal LSTM

De acuerdo a la estructura que se implementará se obtiene los detalles de la red neuronal, así como las neuronas de entradas y las de salida, las épocas, el batch size y las secuencias utilizadas, como se detalla en la tabla 15.

Tabla 15. Datos de la Red neuronal

Datos	Valores
Neuronas de entrada	150
Neuronas de Salida	2
Epocas	150
Bacht Size	100
Secuencias	10

La figura 53 proporciona una visión detallada de la eficacia de entrenamiento en que experimenta el modelo LSTM al predecir el consumo. En esta representación gráfica, se destaca una eficacia del 94%, indicando un rendimiento sólido de esta red neuronal en la tarea de predicción. Esta respuesta es prometedora, ya que sugiere que la red está cumpliendo efectivamente con su función.

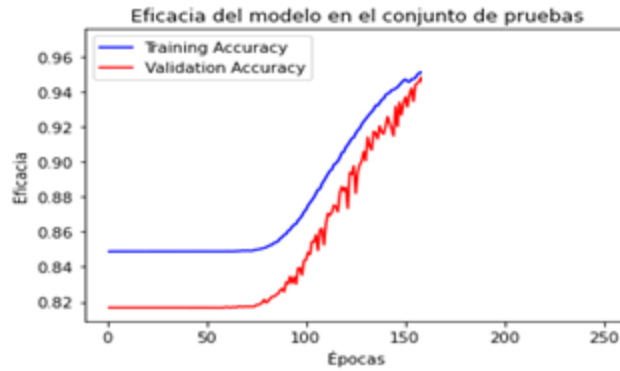


Figura 53. Desempeño de la red neuronal LSTM en las etapas de entrenamiento y validación

Fuente: El autor

3.12.7 Predicción de potencia real y predicha de los dispositivos

Una vez que se han obtenido los valores de desempeño de la Red Neuronal, el modelo se utiliza para realizar predicciones de potencias en kWh dentro de un intervalo temporal específico. Aunque el modelo demuestra un rendimiento satisfactorio en la predicción de las cargas de luminarias y tomacorrientes, tal como se observa en la figura 54, es importante destacar que estos resultados aún deben ajustarse a los valores reales.




Figura 54. Predicción de carga vs. valores reales

Fuente: El autor

3.12.8 Muestreo de valores reales y predichos

Se decidió evaluar la precisión del modelo de la red neuronal a través de un conjunto de datos de muestra que abarca 50 observaciones. Como se muestra en la figura 55, se presenta una comparativa detallada de las predicciones realizadas por el modelo para las cargas de luminarias y tomacorrientes. Este enfoque gráfico facilitó la obtención y comparación directa entre los valores predichos por el modelo y los valores reales, brindando una representación visual clara de la efectividad del modelo




Figura 55. Comparativa entre valores Reales y Predichos

Fuente: El autor

La Tabla 16 muestra los errores relativo y absoluto asociados a estos datos, proporcionando un análisis detallado de la diferencia entre las predicciones del modelo y los valores reales de las luminarias.

Tabla 16. Comparación de errores del modelo para las luminarias.

Ítems	Valores de potencia luminarias (kWh)	Valores predichos de las luminarias (kWh)	Error absoluto	Error relativo (%)
1	0.147	0.146	0.001	0.68
2	0.126	0.133	0.007	5.56
3	0.147	0.143	0.004	2.72
4	0.132	0.137	0.005	3.79
5	0.144	0.141	0.003	2.08

En cambio, al dirigirnos hacia la predicción de tomacorrientes, ampliamos nuestro enfoque para evaluar la precisión del modelo en relación con esta categoría específica de carga. En la Tabla 17 se presentan los errores relativos y absolutos asociados a estos datos, proporcionando un análisis detallado de la discrepancia entre las predicciones del modelo y los valores reales de los tomacorrientes

Tabla 17. Comparación de errores del modelo para el tomacorriente.

Item	Valores de potencias del tomacorriente (kWh)	Valores predichos de tomacorriente (kWh)	Error absoluto	Error relativo (%)
1	0.582	0.571	0.011	1.89
2	0.624	0.603	0.021	3.37
3	0.594	0.601	0.007	1.18
4	0.617	0.613	0.004	0.65
5	0.577	0.584	0.007	1.21

Después del entrenamiento, se analizan métricas cruciales como MAE, MSE y RMSE para medir la precisión del modelo en comparación con los datos reales. El MAE, que indica la magnitud promedio de los errores, y el MSE, que brinda una visión detallada de la variabilidad en las predicciones, son fundamentales para comprender el rendimiento del modelo. La inclusión del RMSE facilita la interpretación de los errores en la misma escala que los valores originales.

Estas métricas, presentadas detalladamente en la Tabla 18, proporcionan una perspectiva cuantitativa de los errores relacionados con las predicciones de las cargas de luminarias y tomacorrientes. En términos generales, la observación de valores más bajos en estas métricas sugiere que la red LSTM está llevando a cabo predicciones más precisas, logrando una adaptación más ajustada a los datos reales.

Tabla 18. Comparativa de Errores de Desempeño de la Red LSTM

Tipo de corriente	MSE	MAE	RMSE
Luminarias	0.0033	0.0360	0.0571
Tomacorrientes	0.0458	0.1668	0.2140

Una vez completado el entrenamiento inicial del modelo, se procede a una fase de refinamiento mediante la adición de más épocas. Esta estrategia busca mejorar la eficacia del modelo en la fase de predicción. La adición de épocas permite que la red LSTM ajuste y corrija los errores identificados durante la evaluación del primer modelo. Este proceso iterativo de ajuste y adaptación contribuye a perfeccionar la capacidad predictiva de la red, proporcionando una mayor precisión en las predicciones al permitir que el modelo aprenda de manera más completa y precisa de los datos de entrenamiento.

3.12.9 Desempeño segundo entrenamiento del modelo LSTM

Los datos que se mostraran en la tabla 19, son los datos adicionales que se agregaron para un segundo entrenamiento de la red LSTM.

Tabla 19. Datos Para el Segundo entrenamiento

Datos	Valores
Neuronas de entrada	150
Neuronas de Salida	2
Epocas	50
Bacht Size	64
Secuencias	10

Tras el entrenamiento del segundo modelo, se evalúa su eficacia mediante métricas clave. Los valores alcanzados para las métricas de entrenamiento y validación, denotan un 98% de eficacia, con una alta precisión en la capacidad del modelo para ajustarse a ambos conjuntos de datos al predecir. La figura 56, ilustra vívidamente este excepcional rendimiento, mostrando gráficamente cómo las predicciones del modelo se alinean estrechamente con los valores reales tanto en el conjunto de entrenamiento como en el de validación.




Figura 56. Eficacia de la Red Neuronal LSTM

Fuente: El autor

El desempeño de la red neuronal se revela de manera significativa al analizar la visualización de las pérdidas durante el periodo de entrenamiento a lo largo de las épocas. Este indicador crítico ofrece una visión detallada de cómo el modelo asimila la información y mejora su capacidad predictiva. Observar una disminución constante de las pérdidas, llegando a alcanzar el valor 0, indica que la red neuronal está aprendiendo de manera efectiva y se está ajustando a los patrones en los datos de entrenamiento, así como se observa en la figura 57.

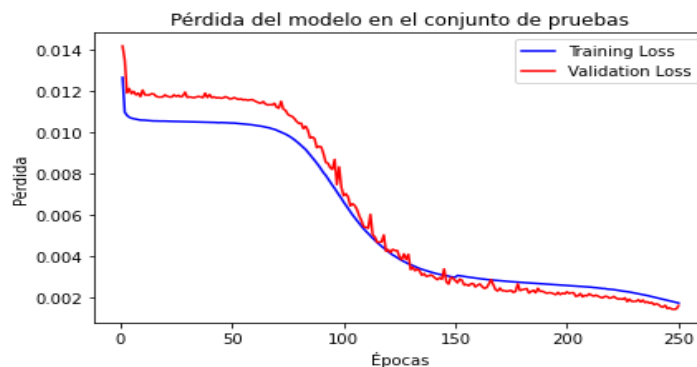


Figura 57. Desempeño de la Red Neuronal en las pérdidas

Fuente: El autor

3.12.10 Predicción de la potencia tras el segundo entrenamiento

En la Figura 58, se presenta detalladamente la comparación de las predicciones de las dos corrientes tras la implementación del segundo modelo de entrenamiento, donde se incorporaron épocas adicionales para mejorar la precisión de la predicción. Este proceso de ajuste resultó en una eficacia notable, evidenciada por un comportamiento que se asemeja de manera sorprendente a los datos reales.

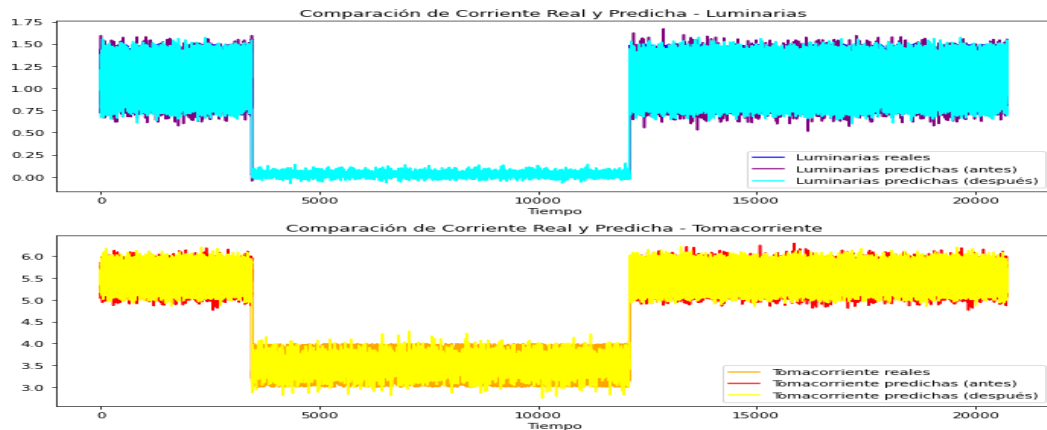




Figura 58. Comparación de potencia real y predicha tras el segundo entrenamiento LSTM

Fuente: El autor

Se decidió evaluar la precisión del segundo modelo de la red neuronal mediante un análisis detallado de una muestra de 50 datos, como se ilustra en la Figura 59. En la figura a), se presenta una comparativa detallada de las predicciones para las luminarias, mientras que en la figura b) se exhibe una comparativa similar para los tomacorrientes. Este enfoque gráfico facilitó la obtención y la comparación directa entre los valores predichos por el modelo y los valores reales. La nitidez visual de estas comparativas proporcionó una perspectiva clara y concisa sobre la eficacia del modelo en la precisa predicción de ambas cargas eléctrica



a) Comparativa de Predicción de Cargas Luminarias



b) Comparativa de Predicción de Cargas Tomacorrientes

Figura 59. Comparación de 50 muestras reales y predichas tras el segundo entrenamiento.

Fuente: El autor

En la Tabla 20, se puede apreciar cómo los valores predichos de las luminarias se han acercado notablemente a sus valores reales. De manera similar, en la Tabla 21, se observa que los valores predichos para los tomacorrientes también muestran una aproximación efectiva a sus valores reales. Este resultado demuestra la validez y precisión de la red neuronal en su capacidad para predecir con éxito los comportamientos de las luminarias y tomacorrientes.

Tabla 20. Comparación de errores de luminarias tras el segundo entrenamiento

Ítems	Valores de potencia luminarias (kWh)	Valores predichos de las luminarias (kWh)	Error absoluto	Error relativo (%)
1	0.147	0.147	0.000	0.00
2	0.126	0.126	0.000	0.00
3	0.147	0.146	0.001	0.68
4	0.132	0.132	0.000	0.00
5	0.144	0.144	0.000	0.00

Tabla 21. Comparación de errores de tomacorriente tras el segundo entrenamiento

Item	Valores de potencias del tomacorriente (kWh)	Valores predichos de tomacorriente (kWh)	Error absoluto	Error relativo (%)
1	0.582	0.581	0.001	0.68
2	0.624	0.623	0.001	0.68
3	0.594	0.594	0.000	0.00
4	0.617	0.617	0.000	0.00
5	0.577	0.577	0.000	0.00

En cuanto a las métricas, se observa que tienen valores mínimos, indicando así que el modelo implementado es eficaz, preciso y robusto. Estos resultados refuerzan la capacidad de validación de la red LSTM para la predicción de cargas eléctricas. La Tabla 22 proporciona un desglose detallado de las métricas de Error Cuadrático Medio (MSE), Error Absoluto Medio (MAE) y Raíz del Error Cuadrático Medio (RMSE) para cada dispositivo, respaldando la eficiencia y confiabilidad del modelo en la estimación de las cargas eléctricas predichas en comparación con los valores reales.

Tabla 22. Comparativa de Errores de Desempeño de la Red LSTM tras el segundo entrenamiento

Tipo de corriente	MSE	MAE	RMSE
Luminarias	0.003	0.0030	0.005
Tomacorrientes	0.004	0.0016	0.002

3.12.11 Aproximación de valores de potencia después de la predicción

En la figura 60, se presenta una aproximación visual de 50 muestras de valores predichos en comparación con los datos reales. Esta representación gráfica ofrece una visión detallada de cómo el modelo de la red neuronal se desempeña al prever las cargas eléctricas en un conjunto específico de datos. La comparación directa entre las predicciones del modelo y los valores reales a lo largo de estas 50 muestras proporciona una evaluación visual inmediata de la precisión y eficacia del modelo en la tarea de predicción.




Figura 60. Aproximación de 50 muestras en comparación a los valores reales

Fuente: El autor

3.12.12 Consumo Anual Predicho

Después de evaluar exhaustivamente la red neuronal a lo largo de dos fases de entrenamiento y analizar la eficacia en la predicción de cargas eléctricas, hemos avanzado con confianza hacia la siguiente etapa: la predicción de la demanda eléctrica de la casa.

Como se observa en la figura 61, se presentan los valores de consumo de energía obtenido durante el periodo de octubre 2022 hasta septiembre 2023, cuyos datos se extrajeron de la aplicación de CNEL. Se evidencia también que en la aplicación se saca

el cálculo de consumo total dentro de este periodo y el promedio de potencia en kWh aproximado de cada mes.



Figura 61. Consumo anual de mi Residencia

Fuente: El autor

Después de obtener el segundo modelo de la red LSTM, se procede a vincularlo con el rendimiento del sistema de monitoreo y el código empleado para desarrollar la red neuronal LSTM. Para realizar una evaluación preliminar, se utilizan datos recopilados entre octubre de 2022 y septiembre de 2023. Al analizar la potencia consumida en kilovatios, se observa un crecimiento logarítmico en los últimos meses en comparación con los meses finales de 2022 y los primeros meses de 2023, como se evidencia en la figura 62.




Figura 62. Consumo de potencia consumida en el periodo octubre 2022 hasta septiembre 2023

Fuente: El autor

La eficiencia del modelo de la red neuronal se traduce en una asociación exitosa con los datos previos de consumo anual. En este contexto, se examinó detenidamente el mes de octubre de 2022, incorporando los datos predictivos generados por la red neuronal. El propósito principal de este análisis era determinar el consumo mensual predicho a través de la implementación del modelo. Una vez aplicado el modelo, se identificó el valor predicho, que se vinculó con las predicciones de los seis días iniciales de octubre. Al comparar estos resultados con el consumo real registrado en octubre de 2022, se evidenció que el consumo predicho para el mes de octubre a través del modelo ascendía a 271 kWh, mientras que en el mes de noviembre llega a un valor de 340 kWh.

3.12.13 Comparación de la predicción del consumo anual

La Figura 58 proporciona una visualización clara de este dato predicho, destacando la efectividad del modelo evaluado en este análisis específico. Además, gracias a la eficacia obtenida por el modelo, se logró también extraer el valor correspondiente al mes de octubre, consolidando así un modelo preciso y exacto en sus predicciones. Es importante resaltar que los datos seleccionados para este propósito se enmarcan dentro del mes de noviembre, considerando los diferentes periodos de consumo establecidos por CNEL. Estos datos fueron específicamente elegidos con el objetivo de evaluar y obtener la predicción correspondiente al mes de noviembre.





Figura 63. Consumo anual junto con el valor predicho aplicando el modelo LSTM

Fuente: El autor

3.12.14 Validez de la Red Neuronal

Con el propósito de respaldar la validez del valor predicho para el consumo de los meses de octubre y noviembre, se presenta en la figura 59 la factura de luz correspondiente, la cual es contrastada con el consumo real registrado en ese periodo. Esta comparación detallada no solo confirma la eficacia del modelo, alcanzando un nivel del 96 % de precisión, sino que también refuerza la confiabilidad de la predicción de la demanda eléctrica. La inclusión de estos datos específicos demuestra la capacidad del modelo para anticipar con precisión el consumo real en un escenario mensual específico, consolidando así su robustez y utilidad en situaciones prácticas.



1. Consumo Real Facturado Mes de Octubre: 272 kWh

2. Consumo Real Facturado Mes de Noviembre: 341 kWh

Figura 64. Planilla de Luz de mes de octubre y noviembre

Fuente: El autor

CAPITULO IV

4.1. CONCLUSIONES

La investigación ha alcanzado con éxito sus objetivos al lograr una comprensión profunda del modelo de pronóstico de carga, en este caso, la red neuronal de memoria a corto y largo plazo (LSTM), abordando con meticulosidad los factores que influyen en este proceso, incluyendo las limitaciones de dichos modelos. Se ha destacado la importancia de la categorización detallada de los factores según los horarios, con un énfasis especial en la diferenciación entre el día y la noche, lo que ha enriquecido la comprensión del consumo eléctrico y proporcionado una visión más precisa de los patrones de demanda a lo largo del tiempo.

Con respecto a los dispositivos, estos han desarrollados y validado eficazmente su capacidad para adquirir con precisión los valores de corrientes y potencias de luminarias y tomacorrientes, estableciendo así la base esencial para un monitoreo detallado del consumo eléctrico en mi vivienda. La exitosa adquisición de datos en la plataforma TagoIO, a través de la implementación de credenciales de WiFi y el protocolo de comunicación MQTT en el entorno del software Arduino IDE, ha posibilitado el establecimiento de una comunicación estable y segura entre los dispositivos de monitoreo y la plataforma en la nube.

Con base al implementar el modelo predictivo es crucial realizar un análisis exhaustivo de los datos disponibles y definir claramente los objetivos del modelo. La obtención de una escala de datos efectiva se convierte en el primer paso esencial,

asegurando que la información recolectada esté adecuadamente preparada para el proceso de entrenamiento. Este proceso incluye la normalización y escalado de los datos, estableciendo las condiciones óptimas para la red neuronal LSTM. La cuidadosa selección de variables y la definición estructurada de la red tuvieron lugar, considerando la complejidad temporal y las dependencias a corto plazo que el modelo ha capturado con éxito.

La evaluación experimental del modelo predictivo mediante la meticulosa consideración de los errores de pronóstico, incluyendo el MAE, MSE y el RMSE, ha sido esencial para determinar con precisión la eficacia del modelo en la predicción de la demanda eléctrica. La atención detallada a estos indicadores ha permitido obtener una evaluación integral de la precisión del modelo en su capacidad para anticipar las cargas eléctricas a corto plazo. La sobresaliente eficacia demostrada por la red neuronal en su segundo entrenamiento, con un impresionante 98% de eficiencia en el modelo predictivo, se ha visto respaldada de manera concluyente mediante la corroboración con la factura eléctrica correspondiente al mes de noviembre. La estimación de consumo predicha por el modelo, establecida en 340.5 kWh, ha demostrado una notoria concordancia con el consumo real registrado en la factura.

4.2 RECOMENDACIONES

Con el propósito inequívoco de optimizar la funcionalidad y robustez del sistema de monitoreo, se subraya la imperiosa necesidad de asegurar una conexión eficiente entre los dispositivos. La coherencia y estabilidad en esta interconexión resultan fundamentales para la efectiva adquisición de datos relativos al consumo eléctrico residencial.

En la calibración del sensor de corriente, el cual es un elemento que funge como la columna vertebral de la adquisición de datos en tiempo real. Los inconvenientes iniciales que revelaron divergencias entre los valores obtenidos por el sensor y los medidos mediante una pinza amperimétrica subrayan la necesidad de un ajuste preciso.

En el ámbito de la adquisición y transmisión de datos a la plataforma TagoIO, se pone énfasis en la importancia de la especificidad en las credenciales utilizadas. La conexión exitosa entre los dispositivos y la plataforma en la nube depende directamente de la correcta especificación de las credenciales de WiFi y el protocolo de comunicación

MQTT dentro del software Arduino IDE. Una gestión precisa de estos detalles se traduce en una conectividad sin contratiempos, asegurando así una transmisión fluida y segura de datos.

Con el objetivo de optimizar la calidad de los datos recopilados, se propone la posibilidad de seleccionar datos específicos, incluso discriminando entre diferentes horarios. La recopilación de datos durante períodos diurnos y nocturnos ofrece una panorámica más completa de los patrones de consumo, facultando así un análisis exhaustivo y diferenciado de los comportamientos eléctricos en distintas franjas horarias.

En lo que respecta a la creación de la red neuronal, se aboga por explorar diversas configuraciones para maximizar la comprensión del modelo. Establecer una red neuronal con una capacidad de 50 nodos durante 50 épocas no solo brinda una perspectiva inicial del comportamiento del modelo, sino que también permite evaluar de manera preliminar la influencia de factores como las funciones de activación y los optimizadores, como el algoritmo Adam, en el rendimiento del modelo.

En el transcurso iterativo del entrenamiento de la red neuronal, la inclusión de 100 épocas adicionales ha demostrado ser crucial, logrando así un 98% de eficacia del modelo. Este ajuste continuo y la validación persistente han fortalecido significativamente la capacidad predictiva y la adaptabilidad de la red neuronal.

En el análisis de las métricas resultantes del modelo, se subraya la importancia de una evaluación constante y detallada. La vigilancia periódica de métricas como la precisión y la confiabilidad proporciona una retroalimentación esencial, permitiendo una evaluación en tiempo real de la eficiencia y utilidad del modelo predictivo.

Finalmente, se resalta la necesidad de considerar una variedad extensa de datos para el análisis, especialmente en lo que respecta a la predicción de carga a corto plazo. La elección deliberada de datos provenientes de diferentes períodos, enfocándonos particularmente en el mes objeto de predicción, no solo amplía la representación de los patrones de consumo, sino que también constituye un componente crucial para mejorar la precisión de las estimaciones.

REFERENCIAS BIBLIOGRÁFICAS

- [1] INEC, “Estadística Cantón La Libertad 2001”, 2001. Consultado: el 8 de marzo de 2023. [En línea]. Disponible en: https://www.ecuadorencifras.gob.ec/documentos/web-inec/Bibliotecas/Fasciculos_Censales/Fasc_Cantonales/Guayas/Fasciculo_La_Libertad.pdf
- [2] Dateas, “La Libertad - Censo de Población, Densidad Poblacional y Superficie de Ecuador”. Consultado: el 8 de marzo de 2023. [En línea]. Disponible en: <https://www.dateas.com/es/explore/censo-poblacion-densidad-superficie-ecuador/la-libertad-1018>
- [3] G. Strbac, “Demand side management: Benefits and challenges”, *Energy Policy*, vol. 36, núm. 12, pp. 4419–4426, 2008, doi: <https://doi.org/10.1016/j.enpol.2008.09.030>.
- [4] R. E. Brown, “Impact of Smart Grid on distribution system design”, en *2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*, 2008, pp. 1–4. doi: [10.1109/PES.2008.4596843](https://doi.org/10.1109/PES.2008.4596843).
- [5] M. P. Raju y A. J. Laxmi, “IOT based Online Load Forecasting using Machine Learning Algorithms”, *Procedia Comput Sci*, vol. 171, pp. 551–560, 2020, doi: <https://doi.org/10.1016/j.procs.2020.04.059>.
- [6] E. A. Feinberg y D. Genethliou, “Load Forecasting”, en *Applied Mathematics for Restructured Electric Power Systems: Optimization, Control, and Computational Intelligence*, J. H. Chow, F. F. Wu, y J. Momoh, Eds., Boston, MA: Springer US, 2005, pp. 269–285. doi: [10.1007/0-387-23471-3_12](https://doi.org/10.1007/0-387-23471-3_12).
- [7] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas, y M. J. Damborg, “Electric load forecasting using an artificial neural network”, *IEEE Transactions on Power Systems*, vol. 6, núm. 2, pp. 442–449, 1991, doi: [10.1109/59.76685](https://doi.org/10.1109/59.76685).
- [8] S. J. Kiartzis, A. G. Bakirtzis, y V. Petridis, “Short-term load forecasting using neural networks”, *Electric Power Systems Research*, vol. 33, núm. 1, pp. 1–6, 1995, doi: [https://doi.org/10.1016/0378-7796\(95\)00920-D](https://doi.org/10.1016/0378-7796(95)00920-D).
- [9] H. S. Hippert, C. E. Pedreira, y R. C. Souza, “Neural networks for short-term load forecasting: a review and evaluation”, *IEEE Transactions on Power Systems*, vol. 16, núm. 1, pp. 44–55, 2001, doi: [10.1109/59.910780](https://doi.org/10.1109/59.910780).
- [10] S. M. Al-Alawi y S. Islam, “Principles of electricity demand forecasting. I. Methodologies”, *Power Engineering Journal*, vol. 10, pp. 139–143, 1996.
- [11] Y. Dong, Z. Zhang, y W.-C. Hong, “A Hybrid Seasonal Mechanism with a Chaotic Cuckoo Search Algorithm with a Support Vector Regression Model for Electric Load Forecasting”, *Energies (Basel)*, vol. 11, núm. 4, 2018, doi: [10.3390/en11041009](https://doi.org/10.3390/en11041009).
- [12] j. Jiménez, K. Donado, y C. G. Quintero, “A Methodology for Short-Term Load Forecasting”, *IEEE Latin America Transactions*, vol. 15, núm. 3, pp. 400–407, 2017, doi: [10.1109/TLA.2017.7867168](https://doi.org/10.1109/TLA.2017.7867168).
- [13] CENACE, “Informe Anual 2019”, 2019, Consultado: el 8 de marzo de 2023. [En línea]. Disponible en: <http://www.cenace.gob.ec/informe-anual-2019/>

- [14] M. Montaña y J. Briceño, "SISTEMA INTEGRAL DE HOGAR INTELIGENTE BASADO EN HOME ASSISTANT Y RASPBERRY PI". 2021. [En línea]. Disponible en: https://www.researchgate.net/profile/Maryory-Urdaneta-2/publication/353826882_Sistema_de_seguimiento_de_requerimientos_eventos_e_incidentes_para_los_clientes_de_la_empresa_TELCONET_SA_en_la_ciudad_de_Quito/links/6113d39b1e95fe241ac5c3d5/Sistema-de-seguimiento-de-requerimientos-eventos-e-incidentes-para-los-clientes-de-la-empresa-TELCONET-SA-en-la-ciudad-de-Quito.pdf#page=101
- [15] CNEL EP, "CNEL en Cifras", 2020. Consultado: el 8 de marzo de 2023. [En línea]. Disponible en: «CNEL en Cifras», CNEL EP. <https://www.cnelep.gob.ec/cnel-en-cifras/>
- [16] L. Pazmiño *et al.*, "Challenges and Opportunities of IoT Deployment in Ecuador", 2019 *International Conference on Information Systems and Software Technologies (ICI2ST)*, pp. 108–115, 2019.
- [17] L. Fernando, S. Cumbe, I. J. Xavier, y S. Guerrero, "Aplicación de métodos estadísticos para el análisis y predicción de perfiles de consumo de energía eléctrica", Universidad Politécnica Salesiana, Cuenca, 2018.
- [18] A. Ramírez y A. Marcela, "MÉTODOS UTILIZADOS PARA EL PRONÓSTICO DE DEMANDA DE ENERGÍA ELÉCTRICA EN SISTEMAS DE DISTRIBUCIÓN". septiembre de 2013. [En línea]. Disponible en: <http://repositorio.utp.edu.co/dspace/bitstream/11059/3862/1/62131A719.pdf>
- [19] K. Alanne y A. Saari, "Distributed energy generation and sustainable development", *Renewable and sustainable energy reviews*, vol. 10, núm. 6, pp. 539–558, 2006.
- [20] C. Chatfield, S. Wheelwright, y S. Makridakis, "Forecasting Methods for Management", *J R Stat Soc Ser A*, vol. 141, p. 113, feb. 1978, doi: 10.2307/2344788.
- [21] S. J. Kirtzis, A. G. Bakirtzis, y V. Petridis, "Short-term load forecasting using neural networks", *Electric Power Systems Research*, vol. 33, núm. 1, pp. 1–6, 1995, doi: [https://doi.org/10.1016/0378-7796\(95\)00920-D](https://doi.org/10.1016/0378-7796(95)00920-D).
- [22] J. Li, S. Wei, y W. Dai, "Combination of Manifold Learning and Deep Learning Algorithms for Mid-Term Electrical Load Forecasting", *IEEE Trans Neural Netw Learn Syst*, pp. 1–10, 2021, doi: 10.1109/TNNLS.2021.3106968.
- [23] H. Daneshi, M. Shahidehpour, y A. L. Choobbari, "Long-term load forecasting in electricity market", en *2008 IEEE International Conference on Electro/Information Technology*, 2008, pp. 395–400. doi: 10.1109/EIT.2008.4554335.
- [24] J. M. A y F. V. L, *Compendio de modelos cuantitativos de pronósticos*. J. Masini, 2014.
- [25] A. G. Ryan, D. C. Montgomery, E. A. Peck, y G. G. Vining, *Solutions Manual to accompany Introduction to linear regression analysis*. Wiley, 2013.
- [26] M. Kutner, C. Nachtsheim, J. Neter, y W. Li, *Applied Linear Statistical Models with student CD*. McGraw-Hill/Irwin, 2004.
- [27] R. J. Hyndman y G. Athanasopoulos, *Forecasting: Principles and practice*. OTexts, 2018.

- [28] C. López, *Modelos multivariantes de series temporales*. CreateSpace, 2015.
- [29] M. V. A. Fabian, “Predicción de la demanda de energía eléctrica en la producción de petróleo de los campos de petroamazonas EP utilizando redes neuronales artificiales”. septiembre de 2020. [En línea]. Disponible en: <http://bibdigital.epn.edu.ec/handle/15000/20936>
- [30] P. B *et al.*, “Deep Learning for Intelligent Demand Response and Smart Grids: A Comprehensive Survey”, ene. 2021, [En línea]. Disponible en: <http://arxiv.org/abs/2101.08013>
- [31] J. Brownlee, *Long Short-Term Memory Networks with Python*. Machine Learning Mastery, 2017.
- [32] I. Gridin, *Time series Forecasting using Deep learning*. BPB Publications, 2021.
- [33] M. Montaña-Blacio, J. González-Escarabay, Ó. Jiménez-Sarango, L. Mingo-Morocho, y C. Carrión-Aguirre, “Diseño y despliegue de un sistema de monitoreo basado en IoT para cultivos hidropónicos”, *Ingenius: Revista de Ciencia y Tecnología*, núm. 30, pp. 9–18, dic. 2023, doi: 10.17163/ings.n30.2023.01.
- [34] *Aplicación de las redes neuronales artificiales a la predicción de cargas en sistemas eléctricos de potencia*. 1997.
- [35] R. F. López y J. M. F. Fernández, *Las redes neuronales artificiales*. Netbiblo, 2008.
- [36] F. Berzal, *Redes neuronales and deep learning*. 2018.
- [37] I. Goodfellow, Y. Bengio, y A. Courville, *Deep learning*. MIT Press, 2016.
- [38] Libretexts, “8: Entrenamiento de una red neuronal”. noviembre de 2021. [En línea]. Disponible en: https://espanol.libretexts.org/Matematicas/Las_matematicas_de_la_inteligencia_artificial/08%3A_Entrenamiento_de_una_Red_Neuronal
- [39] E. S. Olivas, M. A. S.-M. Isla, R. G. Cruz, y B. C. Caballer, *Sistemas de aprendizaje automático*. Ra-Ma Editorial, 2023.
- [40] F. Barrero Gonzalez, *Sistemas de Energía Eléctrica*. 2004. Consultado: el 8 de marzo de 2023. [En línea]. Disponible en: <https://books.google.com.co/books?id=wZoyiFKf5IkC&printsec=frontcover#v=onepage&q&f=false>
- [41] M. Schulze, H. Nehler, M. Ottosson, y P. Thollander, “Energy management in industry – a systematic review of previous findings and an integrative conceptual framework”, *J Clean Prod*, vol. 112, pp. 3692–3708, 2016, doi: <https://doi.org/10.1016/j.jclepro.2015.06.060>.
- [42] E. De México, J. Alberto Ortiz-Velázquez, G. Bueno, y J. Jaime Arana-Coronado, “Análisis de la demanda residencial de electricidad en el Analysis of the residential electricity demand in the State of Mexico”, 2017.
- [43] F. Monachesi y M. Zambetti, “Gestión inteligente de la energía”.

- [44] C. S. Antonio, B. D. David, C. F. Eduardo, y C. G. M. Alonso, *GENERACIÓN DISTRIBUIDA, AUTOCONSUMO y REDES INTELIGENTES*. Editorial UNED, 2016.
- [45] Giampaolo Fiorentino and Antonello Corsi, "Internet of Things for Demand Side Management", *Journal of Energy and Power Engineering*, vol. 9, núm. 5, may 2015, doi: 10.17265/1934-8975/2015.05.010.
- [46] S. Padmanaban, R. K. Dhanaraj, M. Sathyamoorthy, J. B. Holm-Nielsen, y B. Balusamy, *Smart grids and internet of things*. John Wiley & Sons, 2023.
- [47] V. Merino, "Gestión energética basada en protocolos IoT y procesamiento de datos en la nube", *ALICANTE*, jul. 2019.
- [48] K. Grgić, I. Špeh, y I. Heđi, "A web-based IoT solution for monitoring data using MQTT protocol", en *2016 international conference on smart systems and technologies (SST)*, IEEE, 2016, pp. 249–253.
- [49] J. F. León, *Redes informáticas: protocolos de comunicación, protocolo de aplicación y software*. Jacinto Fung León, 2019.
- [50] P. Ortiz Mondragón, "PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL ÓPTIMA PABLO ORTIZ MONDRAGÓN", Tesis, Instituto Politécnico Nacional, Mexico D.F., 2011. Consultado: el 27 de febrero de 2023. [En línea]. Disponible en: <https://sepielectrica.esimez.ipn.mx/tesise/2011/pronosticopablo.pdf>
- [51] M. E. Ortiz Alvarado, "PRONÓSTICO DE LA DEMANDA ELÉCTRICA RESIDENCIAL BASADO EN EL MODELO DE REGRESIÓN ADAPTATIVA MULTIVARIANTE SPLINE (MARS)", *Electricidad*, 2015, Consultado: el 27 de febrero de 2023. [En línea]. Disponible en: <https://dspace.ups.edu.ec/bitstream/123456789/11290/3/UPS-KT01191.pdf>
- [52] E. Simancas y G. Daniel, "Modelos híbridos basados en datos para la predicción de carga eléctrica a corto y mediano plazo", *Sangolqui*, dic. 2020. Consultado: el 27 de febrero de 2023. [En línea]. Disponible en: <http://repositorio.espe.edu.ec/bitstream/21000/23392/1/T-ESPE-044112.pdf>
- [53] A. Kurniawan, *Internet of Things projects with ESP32*. Packt Publishing Ltd, 2019.
- [54] "Tutorial Sensor de corriente AC no invasivo SCT-013". [En línea]. Disponible en: https://naylampmechatronics.com/blog/51_tutorial-sensor-de-corriente-ac-no-invasivo-sct-013.html
- [55] L. Del Valle Hernández, "ADS1115 Convertidor analógico digital ADC para arduino y ESP8266". noviembre de 2022. [En línea]. Disponible en: <https://programarfacil.com/blog/arduino-blog/ads1115-convertidor-analogico-digital-adc-arduino-esp8266/>
- [56] A. V Electronics, "Mini Fuente HLK-PM01 5V - AV Electronics". noviembre de 2023. [En línea]. Disponible en: <https://avelectronics.cc/producto/mini-fuente-hlk-pm01-5v/#:~:text=El%20HLK%20DPM01%20es%20una,sin%20fuentes%20de%20alimentaci%C3%B3n%20externas.>

- [57] Jecrespom, “Entorno de programación de arduino (IDE)”. noviembre de 2016. [En línea]. Disponible en:
<https://aprendiendoarduino.wordpress.com/2016/03/29/entorno-de-programacion-de-arduino-ide/>
- [58] “¿Qué es Python? - Explicación del lenguaje Python - AWS”. [En línea]. Disponible en:
<https://aws.amazon.com/es/what-is/python/>
- [59] L. Torres, “Conozca TagoIO, la primera herramienta en la nube para el desarrollo de soluciones IoT homologadas de Khomp”. noviembre de 2019. [En línea]. Disponible en: <https://www.khomp.com/es/tagoio-solucion-iot/#:~:text=TagoIO%20es%20una%20plataforma%20web,IoT%20conectados%20a%20su%20red.>