



UNIVERSIDAD POLITÉCNICA SALESIANA

SEDE QUITO

CARRERA DE ELECTRICIDAD

**ESTIMACIÓN DE LA DEMANDA ELÉCTRICA
MEDIANTE LA RED NEURONAL
RECURRENTE TIPO LSTM APLICADO AL
ESTUDIO DE UN SECTOR RESIDENCIAL EN
UNA MICRO-RED**

Trabajo de titulación previo a la obtención del
Título de Ingeniero Eléctrico

AUTOR: DYLAN WLADIMIR PAWANKIZA CASTELLANO

TUTOR: ALEXANDER AGUILA TÉLLEZ

Quito -Ecuador

2024

CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Yo, Dylan Wladimir Pawankiza Castellano con documento de identificación N° 1726949561 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Quito, 11 de septiembre del año 2024

Atentamente,



Dylan Wladimir Pawankiza Castellano
1726949561

CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA

Yo, Dylan Wladimir Pawankiza Castellano con documento de identificación No. 1726949561, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del Artículo Académico: “Estimación de la demanda eléctrica mediante la red neuronal recurrente tipo LSTM aplicado al estudio de un sector residencial en una micro-red”, el cual ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, 11 de septiembre del año 2024

Atentamente,



Dylan Wladimir Pawankiza Castellano

1726949561

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Alexander Aguila Téllez con documento de identificación N° 1755983184, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: ESTIMACIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE LA RED NEURONAL RECURRENTE TIPO LSTM APLICADO AL ESTUDIO DE UN SECTOR RESIDENCIAL EN UNA MICRO-RED, realizado por Dylan Wladimir Pawankiza Castellano con documento de identificación N° 1726949561, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 11 de septiembre del año 2024

Atentamente,



Ing. Alexander Aguila Téllez, PhD
1755983184

ÍNDICE GENERAL

1	Introducción	2
2	Marco teórico.....	3
2.1	Importancia de la estimación para la demanda eléctrica	4
2.1.1	Demanda eléctrica.....	4
2.1.2	Suministro de energía eléctrica.....	4
2.2	Generación distribuida	5
2.2.1	Fuentes de energía renovables.....	5
2.2.2	Efecto de la Generación Distribuida en los sistemas de distribución	6
2.3	Micro-red	7
2.3.1	Características de la micro-red	7
2.3.2	La micro-red como tendencia de desarrollo.....	8
2.4	Red neuronal recurrente LSTM	8
2.4.1	Celda LSTM.....	9
2.4.2	La Red neuronal recurrente LSTM en sistemas de estimación	9
2.4.3	Validación mediante la raíz del error medio cuadrático (RMSE)	10
2.5	Curva de la demanda eléctrica.....	10
2.5.1	Series de tiempo	10
2.5.2	Demanda pico	11
3	Planteamiento del problema	11
3.1	Pseudocódigo para obtener la estimación de la demanda	11
3.1.1	Parámetros de la red LSTM.....	12
4	Caso de estudio.....	13
4.1	Curva de consumo horario (demanda).....	14
4.2	Curva de consumo diario (demanda)	14
4.3	Curva de consumo mensual (demanda).....	15
5	Análisis de resultados.....	15
5.1	Estimación de demanda horaria.....	15
5.2	Estimación de demanda diaria	16
5.3	Estimación de demanda mensual	18
6	Conclusiones.....	21
6.1	Trabajos futuros	22
7	Referencias.....	22
7.1	Matriz de Estado del Arte	27
7.2	Resumen de Indicadores.....	32

ÍNDICE DE FIGURAS

Figura 1. Curva de la demanda eléctrica.	4
Figura 2. Suministro de energía eléctrica para el usuario residencial.	5
Figura 3. Generación Distribuida.	5
Figura 4. Aplicación de la energía renovable en la Generación Distribuida.	6
Figura 5. Sistema de control de una Micro-red.	7
Figura 6. Micro-red híbrida.	7
Figura 7. Arquitectura de la red LSTM.	8
Figura 8. Celda LSTM.	9
Figura 9. Series de tiempo.	11
Figura 10. Entrenamiento horario de la red LSTM.	12
Figura 11. Entrenamiento diario de la red LSTM.	13
Figura 12. Entrenamiento mensual de la red LSTM.	13
Figura 13. Ubicación geográfica del primario 23 D.	14
Figura 14. Curva de la demanda eléctrica horaria.	14
Figura 15. Curva de la demanda eléctrica diaria.	14
Figura 16. Curva de la demanda eléctrica mensual.	15
Figura 17. Comparación de demanda histórica con demanda estimada (día).	15
Figura 18. RMSE en análisis horario.	16
Figura 19. Comparación de demanda histórica con demanda estimada (semana).	17
Figura 20. RMSE en análisis diario.	17
Figura 21. Comparación de demanda histórica con demanda estimada (Octubre).	18
Figura 22. Comparación de demanda histórica con demanda estimada (Noviembre).	18
Figura 23. Comparación de demanda histórica con demanda estimada (Diciembre).	18
Figura 24. Comparación de demanda histórica con demanda estimada (Enero).	19
Figura 25. Comparación de demanda histórica con demanda estimada (Febrero).	19
Figura 26. Comparación de demanda histórica con demanda estimada (Marzo).	19
Figura 27. Comparación de demanda histórica con demanda estimada (Abril).	19
Figura 28. Comparación de demanda histórica con demanda estimada (Mayo).	19
Figura 29. Comparación de demanda histórica con demanda estimada (Junio).	19
Figura 30. Comparación de demanda histórica con demanda estimada (Julio).	20
Figura 31. Comparación de demanda histórica con demanda estimada (Agosto).	20
Figura 32. Comparación de demanda histórica con demanda estimada (Septiembre).	20
Figura 33. RMSE en análisis mensual.	20
Figura 34. Resumen e indicador de la temática - Estado del arte.	32

Figura 35. Indicador de formulación del problema - Estado del arte.....	32
Figura 36. Indicador de solución - Estado del arte.....	32

ÍNDICE DE TABLAS

Tabla 1. Comparación de los perfiles de carga en horas de un día.	16
Tabla 2. Comparación de los perfiles de carga en días de una semana.....	17
Tabla 3. Comparación de los perfiles de carga en meses de un año.	21
Tabla 4: Matriz de estado del arte.	27

ESTIMACIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE LA RED NEURONAL RECURRENTE TIPO LSTM APLICADO AL ESTUDIO DE UN SECTOR RESIDENCIAL EN UNA MICRO-RED

Resumen

Este trabajo se realiza con la finalidad de estimar la demanda eléctrica de un sector residencial en determinados periodos de tiempo empleando la Red neuronal recurrente conocida como Long-Short Term Memory (LSTM). El sector residencial de estudio es la Armenia, perteneciente a la ciudad de Quito en Ecuador; sus datos históricos corresponden a un año comprendido entre el mes de septiembre del 2022 a septiembre del 2023 tomados del primario 23 D. Este sector residencial es analizado como micro-red en modo aislado, los resultados de las estimaciones futuras del consumo de energía permiten idear la planificación adecuada para garantizar la suficiencia de generación distribuida en función de las nuevas cargas obtenidas y observar los datos de demanda histórica en relación a los nuevos datos de demanda proporcionados por la red LSTM. Sabiendo la generación necesaria que se debe suministrar, sería posible garantizar el servicio de energía continuo y sin interrupciones para los usuarios. El caso de estimación mencionado se realiza utilizando el software Matlab para visualizar la curva de demanda en tres escenarios, por horas de un día, días de una semana y meses de un año.

Palabras Clave: Estimación de demanda eléctrica, Suficiencia de generación, Micro-red, Generación distribuida, Red neuronal LSTM, Series temporales.

Abstract

This work is carried out with the purpose of estimating the electrical demand of a residential sector in certain periods of time using the Recurrent Neural Network known as Long-Short Term Memory (LSTM). The residential sector of study is Armenia, belonging to the city of Quito in Ecuador; its historical data corresponds to a year between September 2022 and September 2023 taken from primary 23 D. This residential sector is analyzed as a micro-grid in isolated mode, the results of the future estimates of energy consumption allow us to devise the appropriate planning to guarantee the sufficiency of distributed generation based on the new loads obtained and to observe the historical demand data in relation to the new demand data provided by the LSTM network. Knowing the necessary generation that must be supplied, it would be possible to guarantee continuous and uninterrupted energy service for users. The aforementioned estimation case is carried out using the Matlab software to visualize the demand curve in three scenarios, by hours of a day, days of a week and months of a year.

Keywords: Electrical demand estimation, Generation sufficiency, Micro-grid, Distributed generation, LSTM neural network, Times series.

1 Introducción

El consumo eléctrico se ha determinado como un caso de estudio primordial para el sector residencial actual, debido a que se han generado pérdidas de energía por sobrecarga en el sistema eléctrico, costos adicionales, suspensiones de energía y quejas por parte de los usuarios con respecto al suministro eléctrico [1]. El sector residencial presenta un comportamiento variado en cuanto al consumo de energía en diferentes periodos de tiempo; es así que, se requiere conocer una proyección de demanda que permita tomar decisiones adecuadas para evitar apagones en dicho sector y garantizar la suficiencia de generación distribuida [2]. El sector mencionado podría operar como una micro-red, desconectándose de la red principal y conectándose a un sistema de generación distribuida, un proceso conocido como ‘modo aislado’ [3]. Las empresas distribuidoras solicitan el abastecimiento de energía en función de una estimación incorrecta, de esta manera existe un inadecuado suministro de energía que no satisface al sector residencial.

La estimación de la demanda eléctrica es un trabajo que requiere de gran responsabilidad en el sector residencial, comercial e industrial; debido a que según el resultado obtenido se determina la planificación respectiva para garantizar la suficiencia de generación y favorecer a la etapa de distribución [4]. Existen distintos métodos que pueden realizar la estimación de la demanda para diferentes periodos de tiempo como Arima, Regresión lineal, Forecasting, Montecarlo, Red neuronal recurrente LSTM y el más empleado el modelo estocástico [5]. Las empresas distribuidoras cuentan con su propio modelo de estimación, dicho modelo permite analizar el estado y cambio que presenta la curva de consumo en relación con la variable de tiempo. Este evento de estimación brinda una ventaja a las distribuidoras porque mientras más

acertado sea el resultado, más eficaz y seguro será la distribución de energía para los usuarios [6].

El caso de estudio consiste en obtener la estimación del consumo de energía y visualizar su curva característica para la Armenia empleando la Red LSTM a fin de asegurar un plan que garantice la suficiencia de generación distribuida, dicha red neuronal posee celdas de memoria que tienen la capacidad de recordar varios conjuntos de datos por un lapso de tiempo corto y largo [7]. Es así que, su objetivo se basa en la comprensión de eventos históricos para estimación, clasificación, relleno y reconocimiento de datos; su compuerta de entrada se encarga de llevar el control de la información que ingresa a la memoria, la puerta de olvido controla el tiempo de retención de dicha información ingresada y la puerta de salida es la encargada de controlar cuando la información que contiene la celda es utilizada como salida de la misma [8]. El uso principal que se ha dado a la red LSTM es para el área de pronóstico [7], de esta forma es la adecuada para el caso de estimación de demanda por horas de un día, días de una semana y meses de un año, ya que puede obtener el comportamiento de la curva para escenarios futuros del sector mencionado.

La generación distribuida es una tecnología implementada para generar energía en lugares estratégicos de consumo [9], dicha generación se aplica en las micro-redes utilizando fuentes renovables como mecanismo factible debido a que son la más apropiadas para la instalación cercana al cliente [2]. La micro-red es un sistema eléctrico conformado por cargas y fuentes de generación de energía, sus modos de operación son en modo individual conocido como aislado y el otro modo se rige en una conexión con la red principal. En el modo de operación con conexión habitual, una micro-red intercambia energía con su red convencional y en el modo aislado funciona

sin depender de dicha red convencional [10]. De esta manera la micro-red se ha posicionado como una alternativa muy viable ante el incremento de la demanda eléctrica, gracias al modo aislado se puede satisfacer los consumos de energía que tienen los usuarios cuando existen apagones y posibles interferencias en la red.

La suficiencia de generación distribuida para el sector residencial es un parámetro de gran importancia, debido a que es la capacidad que poseen los sistemas de generación con la finalidad de atender las condiciones de energía requeridas por las residencias que se encuentran en el sector mencionado [11]. Es por ello que se requiere una estimación adecuada de la demanda eléctrica para observar con antelación los tiempos en donde la demanda crece y disminuye, de esta forma conociendo las estimaciones se puede determinar el trabajo necesario por parte de los sistemas de generación [12]. Conocer el posible comportamiento de la curva de demanda es una gran ventaja porque permite emplear estrategias adecuadas para suministrar la suficiente energía continua y reducir pérdidas de la misma en las casas de la Armenia.

A nivel mundial la estimación de demanda eléctrica implica un tema crucial, debido a que se exponen dos escenarios al momento de estimar la demanda, el primer escenario corresponde a subestimar la demanda provocando apagones e interrupciones en las actividades de los usuarios, mientras que el segundo escenario corresponde a sobreestimar la demanda provocando pérdidas de energía y gastos económicos [13]. El incremento en la demanda está ligado al aspecto económico, ya que el abastecer de energía a toda la población incluye ciertos gastos económicos en los periodos de generación, luego pasando a transmitir dicha energía y finalmente distribuirla de forma segura. Existe un caso actual correspondiente a Etiopía, este país ubicado al este Africano

con un aumento económico y de demanda eléctrica que requiere un plan adecuado de generación y distribución para atender el crecimiento mencionado y de esta forma adecuarse a la situación que vive dicho país; su situación fue tan preocupante que incluso en 2020 solo el 51.1 % de esta población disponía de energía eléctrica [13].

La importancia de emplear el método adecuado de estimación de demanda eléctrica radica en su efectividad, un método es más confiable cuando sus resultados son lo más parecido a la realidad de los datos históricos [14]. Con el paso del tiempo se ponen a prueba nuevos modelos de estimación con el objetivo de verificar su porcentaje de precisión. Ha habido casos de estudio en donde se emplean diferentes modelos de prueba para estimar la demanda eléctrica, el modelo gris de Holt Winters se empleó a modo de estudio para China y se sustenta en el periodo de prioridad de datos históricos [15], otro modelo de estudio empleado en Turquía es el modelo mixto de redes neuronales medianas, algoritmo de optimización de ballenas y máquina de vectores de soporte basadas en sistemas de clasificación, método de burbujas y localización de datos [16]; también se presenta en Kenia un modelo basado en redes neuronales convolucionales empleando fotografías satelitales [17]. Cada uno de los diferentes métodos de predicción es estudiado para verificar que cumplan con los requisitos adecuados.

2 Marco teórico

En base al alcance del tema propuesto, a continuación se realizará la presentación de cada uno de los temas investigativos que permitan comprender el desarrollo de la estimación en la demanda eléctrica de la Armenia utilizando la red LSTM [18].

La estimación respectiva se empleará para una micro-red en modo aislado y permitirá comprender el estado de la curva de la demanda para garantizar la suficiencia de generación distribuida en la micro-red,

evitando tener posibles suspensiones, apagones, cortocircuitos o cualquier otro inconveniente al respecto [19].

2.1 Importancia de la estimación para la demanda eléctrica

La estimación ha sido un caso de investigación relevante en las épocas modernas, debido a la necesidad de conocer las predicciones futuras del consumo de energía en base a un periodo de tiempo determinado [20].

El análisis de los mayores consumos de electricidad puede garantizar el suministro de energía en la red principal y brindar una operación efectiva de los sistemas encargados de la energía eléctrica para cada sector [21]. La Figura 1 indica un ejemplo característico del consumo de potencia que tienen los usuarios en diferentes horas del día, la conducta que tiene dicho consumo se presenta como hora pico a partir de las 18:00 y luego va disminuyendo progresivamente.




Figura 1. Curva de la demanda eléctrica.

La falta de exactitud en la estimación para la demanda eléctrica puede causar el suministro excesivo de energía para el sistema eléctrico, lo que ocasiona alteraciones en el sistema de distribución y puede dañar los equipos destinados para la generación [20].

Es así que, la estimación de la demanda eléctrica ayuda a determinar procesos basados en la planeación y ejecución para

los sistemas de generación, transmisión y distribución [18].

2.1.1 Demanda eléctrica

La demanda eléctrica es la cantidad de energía consumida por los usuarios para abastecer sus actividades diarias en función de diferentes periodos de tiempo [21].

Los hábitos de comportamiento por parte de los usuarios y el mal uso de los electrodomésticos causan pérdidas y desperdicios de energía eléctrica, dichos desperdicios se deben reducir mediante el consumo responsable de la energía para abastecer las necesidades futuras de los mismos usuarios [22].

El patrón de seguimiento para el consumo de energía eléctrica depende del comportamiento que tengan los usuarios, ya que dicho comportamiento puede hacer que la demanda eléctrica sea variable y en distintos casos exista mayor o menor consumo [22].

El tiempo es un parámetro vital determinado por distintas temporadas con horas, días y meses en donde el consumo de energía es inestable [23].

Es por ello que, cada rango de tiempo tiene diferentes consumos de energía, para lo cual la estimación ayuda a tener una idea más acertada acerca de los próximos consumos de energía y poder garantizar la suficiente energía para los usuarios [23].

2.1.2 Suministro de energía eléctrica

El suministro de electricidad se encuentra a cargo de la entrega necesaria de la misma para las viviendas, empresas, centros educativos y demás establecimientos con necesidades de abastecimiento de energía eléctrica [24].

La calidad del suministro de energía eléctrica debe tener una onda de tensión adecuada sin interrupciones, ya que es un factor esencial para los consumidores en las ocupaciones de su día a día y en el proceso eficaz que deben cumplir las empresas [24].

Los equipos electrónicos cada vez presentan mayor crecimiento en cuanto a cantidad y tecnología, es por ello que, la onda de tensión que los provee debe ser correctamente funcional [18].

El correcto desempeño del suministro de energía eléctrica muchas veces se ve afectado por la aparición del fenómeno de las perturbaciones eléctricas, dichas perturbaciones se producen debido al aumento de electrónica de potencia en la etapa de generación y el consumo de cada sector [22].

En la actualidad existen normativas que ayudan a limitar las perturbaciones que se pueden producir en los sistemas eléctricos, las perturbaciones deben tener características de corriente y tensión parecida a la señal sinusoidal para evitar posibles desagravios ocasionados en el sistema eléctrico de potencia y perjuicios en el desabastecimientos de energía para los consumidores [22]. El sistema de distribución convencional comienza en la generación de energía, luego el nivel de voltaje es transformado para ser transmitido, llega a las subestaciones para reducir el nivel de voltaje y finalmente de las subestaciones se distribuye para los usuarios. La Figura 2 indica la representación de dicho proceso.




Figura 2. Suministro de energía eléctrica para el usuario residencial.

2.2 Generación distribuida

Para entender el concepto de generación distribuida se debe analizar el grado de consumo eléctrico que tiene la población, es

así que, dicha generación es una forma de producción de energía con menor magnitud que puede ser controlada por la instalación cercana a los usuarios [25].

La generación distribuida ha sido un gran avance tecnológico de los últimos años, es por ello que, su efectividad y aplicación han ganado mayor atención en los clientes y sus necesidades. Dicha generación disminuye pérdidas en la red y se conecta a la misma empleando un convertidor de potencia [26].

La generación mencionada posee sistemas que operan utilizando fuentes renovables, las cuales son renovadas por la naturaleza y tienen un desarrollo amigable con el medio ambiente [27].

En la Figura 3 se observa un sistema tradicional de generación distribuida en donde las fuentes renovables generan electricidad, los rectificadores convierten de corriente alterna a continua y los inversores realizan la misma función pero viceversa. También emplean baterías para el almacenamiento de energía y finalmente los reguladores se encargan de entregar la energía para el consumo residencial [27].




Figura 3. Generación Distribuida.

2.2.1 Fuentes de energía renovables

El uso de alimentación renovable tiene la capacidad de generar energía sin desprender gases contaminantes. Es así que, dichas fuentes cooperan en la batalla contra los cambios climáticos [28].

Cuando se refiere a energía renovable, sus principales fuentes son hidráulica, eólica, solar, geotérmica, biomasa y

energías marinas. Los costos en cuanto a energía renovable, tienden a ser predecibles y prácticos, ya que se puede idear una planificación consciente teniendo en cuenta la inversión ocupada en su uso y no su costo correspondiente a los instrumentos empleados [28].

Para comprender el uso de la energía hidráulica se debe analizar la fuerza del agua y el movimiento que produce para mover las turbinas de una central, permitiendo obtener energía eléctrica para su distribución. Este recurso es el único que puede ser almacenado y retenido en embalses apropiados [29].

Otra forma de producir energía eléctrica es mediante la energía eólica, dicha energía es conseguida gracias al esfuerzo del viento que produce un movimiento para el aerogenerador convirtiendo la energía del movimiento en eléctrica. Esta forma de producir energía ayuda a evitar la intervención de gases perjudiciales que originan la lluvia ácida y el efecto invernadero [29].

En relación a los ambientes renovables, la energía originaria del sol es otra fuente renovable que proviene de la luz de sol como fuente natural. Dicha energía es captada mediante los paneles solares o colectores para producir energía térmica o eléctrica [29].

Siguiendo con las fuentes renovables para producir energía, la energía geotérmica es comprendida gracias al uso de la calidez característica del mundo. Dicha energía puede obtener agua caliente proveniente de dicho calor que emana la tierra. Es así que, se puede emplear para producir electricidad y recolectar energía térmica [29].

En función de las fuentes renovables, también existe la energía biomasa que usa la materia orgánica como fuente de alimentación, esta materia brota de algún resultado de un proceso biológico y no contiene carbón, gas o petróleo [29].

Finalmente, la energía marina es una nueva tecnología empleada para producir

energía a partir del agua de los mares, debido a que existe gran cantidad de océanos [29]. La Figura 4 muestra una representación de que los usuarios residenciales pueden mantener una conexión con la red común y al mismo tiempo tener generación propia para su consumo mediante fuentes renovables.




Figura 4. Aplicación de la energía renovable en la Generación Distribuida.

2.2.2 Efecto de la Generación Distribuida en los sistemas de distribución

El desarrollo de la generación distribuida ha sido un progreso muy importante en los sistemas de distribución, ya que ayuda a minorar los apagones y a estabilizar sus niveles de voltaje en la misma red [30].

De esta manera, utilizando la generación distribuida habrá menores pérdidas de energía en el transporte de electricidad hasta llegar a los usuarios. Además, debido a su avance ha sido considerada para la operación y plan de expansión del sistema eléctrico [31].

La incorporación de unidades de generación distribuida, producen un reordenamiento de los flujos de energía mediante conductores específicos; esto genera la alteración de pérdidas de energía y perfil de voltaje [32].

De esta manera, la incorporación de unidades de generación distribuida puede modificar de forma variable la planificación asignada para la reconfiguración del sistema de distribución [31].

2.3 Micro-red

La micro-red es una tecnología que ha adquirido mayor relevancia debido al gran rendimiento que ofrece en comparación con la red eléctrica habitual [33]. Esta tecnología se refiere al uso de una pequeña cantidad de los recursos energéticos distribuidos conectados a un determinado subsistema de energía [34].

La micro-red ofrece beneficios como constante seguridad energética, menor tarifa de energía y la ejecución de un método amigable con el medio ambiente [34]. La micro-red brinda un sistema de control seguro que puede estar a cargo de la generación eléctrica con alimentación renovable para abastecer a viviendas, carros eléctricos y también tiene la capacidad de almacenar la energía generada en baterías para ocuparla en futuros casos según se requiera. La Figura 5 plasma elementos que integran el sistema característico de una micro-red.




Figura 5. Sistema de control de una Micro-red.

Su modo de acción puede ser con un modo conectado a la red, modo aislado y modo híbrido, es así que, se puede volver un complemento importante para la red de distribución en los mayores consumos de energía [33].

Para el modo conectado a la red, dicha micro-red se encuentra en conexión con la red eléctrica principal, es así que, tiene la capacidad de exportar o importar la energía eléctrica para el uso respectivo. En cambio, en el modo aislado, la micro-red funciona

sin estar conectada a la red principal, usando recursos energéticos distribuidos [33].

Finalmente, en el modo híbrido, la micro-red opera en modo aislado y con conexión a su fuente principal; para este caso la alimentación es renovable y requiere de conversión de corriente continua a alterna en conjunto con los inversores bidireccionales en caso de que la red principal necesite energía. Además, en su estructura necesita de baterías para almacenar la energía generada y utilizarla en casos de emergencia [33], La Figura 6 expresa dicho estado de operación analizado.




Figura 6. Micro-red híbrida.

2.3.1 Características de la micro-red

La característica de desarrollo que tiene una micro-red puede impulsar el ingreso con gran magnitud de la generación distribuida y la aplicación de energía renovable para lograr un eficaz suministro de energía [34].

Presenta un rendimiento eficaz que en comparación con la fuente habitual es diferente, debido a que la composición de dicha micro-red presenta un tamaño reducido con alimentadores que son muy cortos y se desempeñan a niveles de voltaje medio [34].

Es así que, presenta una relación de la reactancia a resistencia mucho más menor en contraste con los sistemas habituales de la red eléctrica principal a la que se encuentran conectadas la mayoría de casas, edificios, centros educativos y demás zonas comerciales [35].

Teniendo en cuenta que la energía eléctrica es suministrada por el recurso energético distribuido con pequeñas máquinas síncronas, la inercia es menor en el sistema de micro-red comparado con el sistema de energía tradicional [36].

La micro-red disminuye las cargas presentes en el sistema eléctrico, ya que distribuye energía a los usuarios finales que podrían estar conectados a la red, generando una solución para consumir energía que no es de la red convencional [37].

Cuando existen cambios en la configuración de la micro-red, por más mínimo que sea; puede alterar el voltaje y la frecuencia respectiva convirtiéndose en desviaciones considerables que pueden causar problemas en la micro-red [34].

2.3.2 La micro-red como tendencia de desarrollo

El aumento del número de habitantes y la reducción de energía accesible en los bienes naturales provocan que el consumo de energía se esté convirtiendo en un problema [38].

Las energías renovables han ido progresando de forma positiva y son un avance determinante del consumo responsable de energía. El desarrollo de dicha energía renovable más la aplicación de micro-red podrá garantizar el suministro adecuado de energía eléctrica y un adelanto en la economía que permita ahorrar energía y proteger la naturaleza [39].

El desarrollo de la micro-red cada vez se destaca más y es una tecnología muy útil para impulsar el desarrollo en el entorno colectivo, con una propuesta de separación de la red principal y funcionamiento de forma independiente con muchos modos de operación con respecto a la red habitual [38].

El mercado eléctrico es un tema decisivo y controversial debido a la economía que representa para las empresas distribuidas, dichas empresas determinan normativas y precios de consumo. Pero el mercado

eléctrico abre las puertas a varios clientes con la posibilidad de adquirir determinados productos con precios más accesibles [40]; en este caso la micro-red como medio independiente requiere de elementos seguros para su implementación en diferentes sectores.

2.4 Red neuronal recurrente LSTM

La red LSTM es una red neuronal de tipo recurrente, que significa memoria a largo y corto plazo [41]. La red recurrente presenta una característica de arquitectura relacionada a la red artificial, es decir que empleando sus conexiones puede comprender la información y transferirla a otras neuronas o nodos enlazados [42].

La red LSTM tiene la capacidad de analizar un dato específico de su almacenamiento y mantenerlo presente en su memoria por varios periodos de tiempo hasta el momento necesario de utilizarlo, este aspecto es una ventaja debido a que la red puede recordar diferentes comportamientos del conjunto de datos que se va a analizar. [41].

Dicha red pasa por una fase de entrenamiento que corresponde a los datos respectivos, permitiendo entender el comportamiento de los hechos que ocurren en un periodo de tiempo establecido antes de ser analizados para su implementación en campos de predicción basado en un conjunto de datos [42]. La Figura 7 muestra la representación del proceso mencionado correspondiente a la arquitectura de la red LSTM.




Figura 7. Arquitectura de la red LSTM.

2.4.1 Celda LSTM

La naturaleza de las celdas LSTM es de gran utilidad, debido a su alta capacidad para aprender grandes periodos de tiempo sin la presencia de inconvenientes por datos no procesados [43].

La estructura de dicha celda es mucho más profunda que una celda recurrente, ya que a diferencia de la celda normal recurrente, la celda LSTM puede retener un valor puntual de acuerdo con sus datos de entradas [43].

La celda de memoria LSTM detecta toda la secuencia de tiempo, es decir que recuerda los datos que han sido almacenados y no únicamente el dato final [44].

Esta celda posee tres puertas de control encargadas del orden en el interior y exterior de dicha celda. Las puertas mencionadas anteriormente son de entrada (i), olvido (f) y salida (o), además integran la función de candidato a memoria (g). Dicha composición se presenta en la unidad de tiempo (t) [45].

La puerta de entrada es la encargada de recibir y supervisar la información que va a entrar a la celda, esta etapa es muy importante ya que verifica que tipo de información va a ser procesada antes de proceder con su entrenamiento [46].

Siguiendo con la estructura, la puerta de olvido es la encargada de verificar que toda la información sea procesado, es decir que interviene en el momento que una parte de los datos es olvidada, recordando a la celda dicho datos [46].

Por último, la puerta de salida es la encargada de almacenar todos los datos procesados y verificar en qué momento se emplearán dichos datos para la salida respectiva de la celda LSTM [46].

La Figura 8 muestra la representación de la celda característica de la red LSTM con el proceso ya explicado anteriormente. Además integra ecuaciones características como la ecuación (1) que corresponde a la puerta de entrada, la ecuación (2) a la puerta

de olvido, la ecuación (3) al candidato a celda, la ecuación (4) a la puerta de salida, la ecuación (5) al estado de la celda y finalmente la ecuación (6) al estado oculto [45].




Figura 8. Celda LSTM.

$$i_t = \sigma_g(W_i x_t + R_i h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma_g(W_f x_t + R_f h_{t-1} + b_f) \quad (2)$$

$$g_t = \sigma_c(W_g x_t + R_g h_{t-1} + b_g) \quad (3)$$

$$o_t = \sigma_g(W_o x_t + R_o h_{t-1} + b_o) \quad (4)$$

$$c_t = f_t * c_{t-1} * + i_t * g_t \quad (5)$$

$$h_t = o_t * \sigma_c(c_t) \quad (6)$$

Donde:

W Peso de entrada.

R Peso recurrente.

b Sesgo.

t Tiempo.

σ Activación del estado.

i Puerta de entrada.

f Puerta de olvido.

g Candidato a celda.

o Puerta de salida.

c_t Estado de celda.

h_t Estado oculto.

h_{t-1} Estado de la red recurrente.

2.4.2 La Red neuronal recurrente

LSTM en sistemas de estimación

La red LSTM ha incrementado su nivel de aplicación debido a su comportamiento eficaz al momento de realizar una estimación o predicción de datos que representen un comportamiento específico [47].

La capacidad de memoria y las respectivas puertas de dicha red han sido puntos determinantes en su elección con respecto a las demás redes neuronales. Esta red mejora la comprensión de datos al momento de su entrenamiento, generando un resultado de estimación mucho más acertado de la secuencia en relación el tiempo [42].

Además, la capacidad que ofrece al momento de entender los datos a largo plazo ha hecho que dicha red sea empleada cada vez más para reconocimiento de patrones, estimación de datos, clasificación de variables y relleno de secuencias [48].

2.4.3 Validación mediante la raíz del error medio cuadrático (RMSE)

Los resultados de la estimación de demanda eléctrica muestran los perfiles de carga para diferentes escenarios y la nueva curva estimada. La red LSTM en base a su proceso de entrenamiento obtiene los resultados de estimación de demanda, dichos resultados requieren de un método de validación para verificar su nivel de operación [49].

La raíz del error medio cuadrático tiene la capacidad de medir el grado de error que existe entre dos conjuntos de datos, es decir entre su información histórica y la nueva información de datos estimados [50]. Su capacidad para cuantificar la similitud que existe entre dos conjuntos lo convierte en el error adecuado para la estimación de demanda eléctrica.

La ecuación (7) corresponde al error medio cuadrático (MSE) que se caracteriza como una función de pérdida de retroceso, expresa la distancia al cuadrado entre los datos históricos y estimados. En la ecuación (8) se aplica la raíz a los valores de distancia ya mencionados para evaluar el nivel de dispersión de los datos analizados [49].

$$MSE = \sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n} \quad (7)$$

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (8)$$

Donde:

- n** Número de ciclos.
- $\hat{y}_i$** Dato real o histórico de demanda eléctrica.
- y_i** Dato estimado de demanda eléctrica.

Al obtener los resultados se puede observar el grado de precisión, el valor más pequeño muestra mayor similitud entre los casos.

2.5 Curva de la demanda eléctrica

El análisis característico del consumo eléctrico se comprende como una representación gráfica de dicho consumo, que indica el comportamiento de máxima y mínima demanda eléctrica correspondiente al consumo respectivo en un tiempo determinado [51].

La representación gráfica de la curva se muestra en un plano con dos ejes comprendidos por “X” y “Y”, en eje “X” se encuentran los periodos de tiempo establecidos y en el eje “Y” se encuentra la carga consumida por los usuarios [51].

El consumo de energía puede variar en diferentes periodos de tiempo debido a que los usuarios tienen diferentes conductas durante un tiempo específico, la mayoría de veces el comportamiento de la curva sigue un patrón determinado en relación al consumo de energía que ya es conocido por la trayectoria de su historial [52].

2.5.1 Series de tiempo

Las series de tiempo se representan en intervalos que tienen límites puntuales dependiendo del caso de estudio, dichas series son de gran importancia para comprender el estado de la demanda eléctrica en relación a su mayor y menor consumo de energía [53].

Dichas series permiten comprender el comportamiento de una variable y compararla con su comportamiento futuro, es decir que su función primordial es configurar y entender un periodo de tiempo para estimar datos futuros a partir de valores ingresados [54].

Las series de tiempo pueden ser periodos horarios, diarios, mensuales, semestrales, anuales y por lo general cualquier intervalo de tiempo establecido para el análisis de un acontecimiento [54]. La Figura 9 representa explicación realizada.




Figura 9. Series de tiempo.

2.5.2 Demanda pico

Los picos de demanda eléctrica son la representación de la mayor cantidad de energía consumida en el transcurso del proceso que contenga en análisis de estudio [55].

Los picos mencionados son un problema en el abastecimiento continuo, debido a que se requiere contar con la potencia necesaria para abastecer las más altas demandas [56].

Para abastecer la demanda requerida se necesita implementar un plan para fortalecer la red, es decir que se podría implementar un plan de concientización de consumo responsable para los usuarios y conocimientos adecuados para la instalación de generación distribuida [56].

La ocupación responsable de las reservas renovables al momento de obtener electricidad es un comportamiento eficaz que permite evitar el desgastamiento de la red y almacenar energía eléctrica que puede

ser utilizada para satisfacer los picos de demanda [57].

3 Planteamiento del problema

En la investigación planteada se emplea un método capaz de estimar la demanda eléctrica con la finalidad de obtener predicciones futuras del sector residencial en una micro-red. El análisis para la estimación de la demanda eléctrica se realiza a partir de la información registrada por la Empresa Eléctrica Quito, dicha información tomada corresponde a un año comprendido entre septiembre del 2022 a septiembre del 2023 del primario 23 D correspondiente al sector residencial de la Armenia.

El primario mencionado tiene su propio medidor de energía, dichos medidores son bidireccionales y registran el consumo de energía en periodos de cada 15 minutos. Además, la información de los medidores es almacenada en bases de datos locales para analizar pérdidas técnicas que se pueden presentar.

La demanda eléctrica es un tema de estudio de vital importancia debido a que existe variación en el consumo por parte de las personas, el sector residencial presenta gran variación en su curva de consumo debido a que muchas veces existe un alto consumo de potencia.

Es así que, la red LSTM obtendrá la estimación de la demanda eléctrica residencial con sus datos promedio de carga para garantizar la suficiencia de generación distribuida en la Armenia, evitando posibles apagones, cortocircuitos o cualquier otro inconveniente al respecto.

3.1 Pseudocódigo para obtener la estimación de la demanda

El método que será utilizado para la estimación de la demanda eléctrica es la red neuronal recurrente tipo LSTM, la cual ha sido un caso de estudio muy relevante debido a su mayor precisión con respecto a las demás redes neuronales. Dicha red se

encarga de recordar un dato importante del patrón que tiene la demanda para luego tenerlo presente por determinados instantes de tiempo.

Los datos procesados fueron recopilados cada 15 minutos durante todo un año, por lo que su información es muy extensa. La red LSTM se entrenó con dicha información extensa, la cual fue vital para la estimación horaria, diaria y mensual. Al obtener las estimaciones se observan las curvas de demanda que permiten analizar el consumo eléctrico en un tiempo específico para determinar la planificación adecuada en cada escenario.

Una demanda horaria se basa en datos de 60 minutos, una demanda diaria se basa en datos de 24 horas y una demanda mensual se basa en datos de días correspondientes. Es importante comprender las series de tiempo para analizar los casos de estudio.

La red LSTM tiene la capacidad de predecir valores futuros en base a la secuencia de datos ingresada, su conjunto de datos es amplio por lo que se realizó un promedio de la estimación para lograr una mejor comprensión del panorama futuro.

3.1.1 Parámetros de la red LSTM

Para el desarrollo de la estimación de la demanda eléctrica se inicia con el tratamiento de datos, el cual consiste en la agrupación de datos para obtener una matriz con datos tipo tiempo y numérico.

Luego se procede con el ordenamiento y agrupación de datos en celdas individuales para entradas en la red LSTM.

Una vez terminada la agrupación, se define el modelo de dicha red neuronal mediante 6 capas, comienza por la capa de acceso, seguida por una capa totalmente conectada, capa LSTM, capa de deserción, otra capa conectada y finalmente la capa de salida de regresión.

Luego se prosigue con el entrenamiento de dicha red LSTM empleando los datos de validación y entrenamiento en 3 opciones, es decir que dicho entrenamiento es

independiente para cada caso. La opción 1 entrena la red para demanda horaria, la opción 2 entrena la red para demanda diaria y la opción 3 entrena la red para demanda mensual.

El error seleccionado para la red LSTM es la raíz del error medio cuadrático (RMSE) como método de regresión. La red LSTM es entrenada tres veces, es decir una vez por cada análisis mencionado. Cada entrenamiento muestra el rendimiento de la red en un ambiente iterativo, dicho entrenamiento refleja el error de entrenamiento (RMSE) y las pérdidas a lo largo del tiempo.

La Figura 10 muestra el avance del primer entrenamiento correspondiente al análisis horario. El RMSE es el error de predicción y su descenso indica que el modelo de estimación cada vez va mejorando, el descenso de las pérdidas indica que el desarrollo de optimización está operando adecuadamente y que dicho modelo se está ajustando correctamente a los parámetros de la red.




Figura 10. Entrenamiento horario de la red LSTM.

La Figura 11 muestra el avance del segundo entrenamiento correspondiente al análisis diario en un ambiente iterativo. En este caso el RMSE y las pérdidas también descienden, lo cual indica que el entrenamiento se mantiene en un nivel adecuado, es decir que indica buena precisión y ajuste a los parámetros de la red.




Figura 11. Entrenamiento diario de la red LSTM.

La Figura 12 muestra el avance del tercer y último entrenamiento correspondiente al análisis mensual en un ambiente iterativo. En este caso tanto el RMSE como las pérdidas tienen un comportamiento más variado, ya que tienen buena precisión y ajuste a la red pero su entrenamiento al final no es tan efectivo; siendo este caso el menos preciso en relación a los entrenamientos anteriores.




Figura 12. Entrenamiento mensual de la red LSTM.

Para finalizar se procede a proyectar la demanda eléctrica residencial en 3 escenarios que corresponden a una demanda horaria, diaria y mensual para garantizar el suministro de energía adecuado en sus diferentes periodos de tiempo.

Algoritmo de Estimación mediante la red neuronal recurrente LSTM

Inicio

- Paso 1: Ingresar como matriz los datos históricos de la Armenia
- Paso 2: Almacenar los datos históricos en la función Data_1
- Paso 2: Dividir los datos almacenados en datos de entrenamiento y de prueba
 $\text{numObservations} = \text{numel}(\text{data});$
 $\text{idxTrain} = 1:\text{floor}(0.9*\text{numObservations});$
 $\text{idxTest} = \text{floor}(0.9*\text{numObservations})+1:\text{numObservations};$
 $\text{dataTrain} = \text{data}(\text{idxTrain});$
 $\text{dataTest} = \text{data}(\text{idxTest});$
- Paso 3: Preparar datos de entrenamiento
for n = 1: numel(dataTrain)
 $X = \text{dataTrain}\{n\};$
 $X\text{Train}\{n\} = X(:,1:\text{end}-1);$
 $T\text{Train}\{n\} = X(:,2:\text{end});$
end
- Paso 4: Implementar la red LSTM mediante capas
layers = [
sequenceInputLayer(numseries)
lstmLayer(128)
fullyConnectedLayer(numseries)
regressionLayer];
- Paso 5: Entrenar la red LSTM
net = trainNetwork(XTrain,TTrain,layers,options);
disp("Algoritmo LSTM Entrenado con éxito")
- Paso 6: Con la red entrenada se proyecta la demanda horaria, diaria y mensual
YTest = predict(net,XTest,SequencePadding,Direction="left");

Fin

4 Caso de estudio

Para el análisis de demanda se utilizan datos del consumo eléctrico residencial en donde se presenta la fecha y potencia respectiva, presenta un comportamiento basado en series de tiempo con una frecuencia de muestreo de cada 15 minutos desde septiembre del 2022 hasta septiembre del 2023. Dichos datos también muestran comportamientos estacionales debido al consumo variado en días habituales, fines de semana y feriados.

La estimación se plantea realizar en tres escenarios, el primer escenario por horas de un día, el segundo escenario por días de una semana y el tercer escenario por meses de un año; las estimaciones se realizan para un ambiente de estudio en donde se desconecta de la red y se conecta al sistema de generación distribuida para conseguir el modo aislado, convirtiéndose en una micro-red y verificando la suficiencia de generación distribuida en el modo aislado para el usuario, cuando sea el caso.

La demanda eléctrica residencial presenta mayor variación debido al comportamiento inusual que tienen los usuarios en sus respectivas viviendas, gracias a la red LSTM se puede obtener una estimación que ayude a tomar decisiones favorables en una micro-red y garantizar la suficiencia de generación.

El primario 23 D abastece a 18 puntos de consumo, dichos puntos representan comportamientos variados en cuanto a consumo de energía, en la Figura 13 se puede observar una representación geográfica de la distribución de cargas que existen en este sector.




Figura 13. Ubicación geográfica del primario 23 D.

En el siguiente apartado, se presentan las curvas tiempo-carga de la demanda horaria, diaria y mensual del sector residencial mencionado.

4.1 Curva de consumo horario (demanda)

El comportamiento que presenta esta curva corresponde a la demanda diaria que se

puede apreciar en la Figura 14, dicha curva tiene un periodo de tiempo horario que va de 1 a 24 horas de un día. La demanda residencial correspondiente a un día cotidiano presenta un comportamiento inestable ya que su estado de demanda cambia en diferentes horas del día, su demanda máxima se puede presentar de 7 a 10 de la noche y su demanda mínima se puede presentar de 5 a 8 de la mañana.




Figura 14. Curva de la demanda eléctrica horaria.

4.2 Curva de consumo diario (demanda)

Para esta curva diaria se tomaron datos de lunes a domingo de una semana completa, dicha curva se visualiza en la Figura 15. Las demandas máximas se presentan en la noche, es decir al finalizar el día y las demandas mínimas se presentan en la mañana.




Figura 15. Curva de la demanda eléctrica diaria.

4.3 Curva de consumo mensual (demanda)

Para el escenario de demanda mensual se tomaron datos mensuales de 1 año, su periodo va desde septiembre del 2022 a septiembre del 2023. En este análisis son 12 meses que incluyen periodos de tiempo horarios y diarios para obtener una curva de demanda mensual, en la Figura 16 se puede apreciar dicho comportamiento de un mes a otro.




Figura 16. Curva de la demanda eléctrica mensual.

Identificar la demanda eléctrica permite interpretar el comportamiento de la curva en diferentes escenarios con respecto al periodo de tiempo y consumo. Al conocer la demanda se puede definir la capacidad que debe tener la red para producir energía y garantizar la suficiencia de generación en la micro-red.

5 Análisis de resultados

A continuación, se presentan las curvas resultantes que corresponden a las estimaciones respectivas para los tres escenarios mencionados en función de los datos históricos. Cada uno de los escenarios muestra los perfiles de carga históricos y la respectiva estimación.

5.1 Estimación de demanda horaria

Para el primer escenario se muestra una comparación horaria que contiene dos secciones, la primera es la demanda horaria

en un día cotidiano y va de 1 a 24 horas, mientras que la segunda parte corresponde a la estimación de la demanda horaria mediante la red LSTM para el siguiente día.

La estimación de la demanda eléctrica proporcionada por dicha red ayuda a garantizar suficiente energía para la micro-red con una posible operación individual, debido a que conociendo el estado del consumo horario con su demanda pico se puede disminuir las interrupciones en el suministro de energía para el siguiente día.

En la Figura 17 se puede observar la comparación que existe entre la demanda histórica y su respectiva estimación. La estimación proyecta que a las 9 pm del siguiente día existirá la demanda máxima de 327.16 W, esto ayuda de forma anticipada para saber cuánta energía es necesaria al momento de abastecer las necesidades de los usuarios.



Figura 17. Comparación de demanda histórica con demanda estimada (día).

La red LSTM presenta una gráfica del avance de su entrenamiento en un ambiente iterativo, dicha gráfica refleja el error de entrenamiento (RMSE) en relación a la frecuencia y pérdidas. Se entrena la red LSTM y su error va llegando a cero, lo cual indica que tiene un nivel de precisión adecuado para estimar la demanda eléctrica. En este caso de estimación horaria el error es de 0.0738, se puede apreciar la representación en la Figura 18 que indica un nivel bastante preciso para estimar la

demanda eléctrica en base a datos históricos.




Figura 18. RMSE en análisis horario.

En la Tabla 1 se presentan las cargas promedio correspondientes a la demanda real y a la estimación mediante la red LSTM. Esta tabla presenta una comparación entre ambos consumos y sus valores son similares, lo que indica que la estimación es bastante acertada para un escenario con demanda horaria.

Tabla 1. Comparación de los perfiles de carga en horas de un día.

Horas	Demanda real	Estimación de la demanda
1	181.3	182.35
2	165.09	164.51
3	158.2	152.88
4	154.79	150.57
5	153.6	170.43
6	162.97	197.99
7	144.62	246.79
8	173.6	210.37
9	202.43	208.46
10	218.5	219.53
11	225.07	220.16
12	232.98	235.04
13	233.72	237.06
14	222.49	221.1

15	211.52	211.32
16	199	201.33
17	207.84	201.04
18	215.94	227
19	275.32	259.45
20	346.11	320.15
21	338.97	327.16
22	306.33	292.59
23	261.54	267.42
24	214.74	220.65

Los resultados que se obtuvieron presentan diferentes cargas horarias para lo cual se puede idear una planificación en base a la incorporación de nuevas fuentes de generación renovable empleando paneles solares en las terrazas o balcones, incluso dependiendo del clima y los factores ambientales del sector residencial se podría instalar sistemas de energía híbrida para combinar dos fuentes renovables como solar y eólica que permitan mantener un suministro continuo en la Armenia. De esta manera se estaría determinando un plan que asegure un suministro continuo y sin posibles interferencias para los usuarios.

5.2 Estimación de demanda diaria

En el segundo escenario se presenta la estimación de demanda diaria con los siete días de una semana, la red LSTM recuerda el comportamiento del patrón por varios periodos de tiempo hasta el preciso momento de ser utilizada la información para estimar la demanda respectiva. En este caso se analiza todos los días de una semana para determinar los comportamientos que presentan dichas curvas de demanda y determinar los días en donde se debe generar mayor energía para atender a los usuarios de la Armenia.

La micro-red en modo aislado opera sin conexiones con la fuente habitual, utiliza fuentes renovables para generar energía

eléctrica y baterías para almacenar dicha energía. De esta forma es necesario conocer la estimación de la demanda semanal para saber la cantidad de energía requerida para el consumo y en qué momento se necesita mayor suministro de energía.

La estimación promedio de la red LSTM indica que los días lunes, sábado y domingo presentan mayor demanda, es decir que para estos días se requiere mayor generación de energía que garantice un suministro continuo y adecuado para los usuarios.

La Figura 19 muestra la comparación diaria del consumo histórico y la estimación característica proporcionada por dicha red LSTM, la primera parte de la gráfica pertenece a la demanda diaria en una semana habitual y la segunda parte corresponde a la estimación de la demanda diaria para la siguiente semana. Los días miércoles, jueves y domingo tienen mayor exactitud en la estimación.




Figura 19. Comparación de demanda histórica con demanda estimada (semana).

Para este caso de estimación diaria el error es de 0.1340 que indica un valor mayor al de estimación horaria ya presentado, su representación se puede observar en la Figura 20 con un error que sigue estando en un rango permisible, es decir que tiene un buen nivel de precisión pero muestra cierto decrecimiento en comparación con el escenario horario.




Figura 20. RMSE en análisis diario.

Los datos de la Tabla 2 pertenecen a la carga promedio tanto de demanda real como de demanda estimada. La red LSTM proporciona datos de carga promedio muy parecidos en comparación a los presentados en los datos históricos. Aunque los resultados de estimación diaria cumplen con una proyección casi similar a la demanda histórica, no son tan similares como en el escenario de la estimación horaria.

Tabla 2. Comparación de los perfiles de carga en días de una semana.

Días	Demanda real (W)	Estimación de demanda (W)
1	196.19	154.18
2	178.16	162.75
3	170.03	153.25
4	164.64	154.07
5	164.14	163.79
6	182.23	192.04
7	180.01	157.47

Para atender a las nuevas cargas resultantes de la estimación de demanda se podría implementar baterías como sistema de almacenamiento de energía para ocupar dicha energía en ocasiones críticas de suministro eléctrico y cuando no existe producción por parte del sol, de esta forma se puede asegurar que todos los usuarios dispongan de electricidad.

5.3 Estimación de demanda mensual

El último escenario corresponde a la estimación de demanda mensual con sus respectivos doce meses, la red LSTM aprende de los datos de entrada y salida anterior, es así que, para este caso la red analiza toda la información de datos históricos correspondientes a un año. Para la estimación mensual se realiza el tratamiento de datos por días, es decir que dicha red analiza el conjunto de datos correspondientes a todos los días de cada mes para su entrenamiento.

La estimación es de gran importancia debido a que se puede conocer con anticipación la demanda pico, incluso se puede garantizar un plan de respaldo cuando existe alta demanda. Dicho plan de respaldo ayuda a ejecutar una solución cuando existan casos de emergencia, evitando posibles inconvenientes en el suministro constante y asegurando que los usuarios dispongan de energía.

En este caso se estima la demanda mensual de un año, la demanda máxima se presenta de octubre a diciembre. Es así que, con las futuras estimaciones se garantiza la suficiencia de generación porque se sabe en qué periodos de tiempo existirá mayor demanda de energía y se tomará decisiones adecuadas en casos específicos.

Las siguientes gráficas desde la Figura 21 hasta la Figura 32 muestran la estimación que proyecta la red para doce meses. Este caso muestra doce demandas mensuales desde octubre de 2022 hasta septiembre de 2023 con sus respectivas estimaciones visualizadas para el siguiente año, cada gráfica muestra la comparación de la demanda histórica y la estimación proporcionada por dicha red neuronal para identificar el comportamiento de la demanda real y la efectividad de la estimación en el momento que se requiera una base de datos que ayude a garantizar la suficiencia de generación en una micro-red.




Figura 21. Comparación de demanda histórica con demanda estimada (Octubre).




Figura 22. Comparación de demanda histórica con demanda estimada (Noviembre).




Figura 23. Comparación de demanda histórica con demanda estimada (Diciembre).




Figura 24. Comparación de demanda histórica con demanda estimada (Enero).




Figura 27. Comparación de demanda histórica con demanda estimada (Abril).




Figura 25. Comparación de demanda histórica con demanda estimada (Febrero).




Figura 28. Comparación de demanda histórica con demanda estimada (Mayo).




Figura 26. Comparación de demanda histórica con demanda estimada (Marzo).




Figura 29. Comparación de demanda histórica con demanda estimada (Junio).




Figura 30. Comparación de demanda histórica con demanda estimada (Julio).




Figura 31. Comparación de demanda histórica con demanda estimada (Agosto).




Figura 32. Comparación de demanda histórica con demanda estimada (Septiembre).

En este caso de estimación mensual el error es de 0.4670 que indica un valor mayor al de los dos escenarios anteriores, la representación de dicho error se observa en la Figura 33 y sigue siendo cercano a cero lo cual indica que su nivel de precisión todavía se encuentra en un grado permisible de estimación.




Figura 33. RMSE en análisis mensual.

Una vez conocido los 3 errores para los casos estudiados, se puede analizar su cambio desde el caso horario hasta el caso mensual, se debe tener en cuenta que un error que se acerca más a cero indica mejor precisión. Al comparar el error en estimación horaria de 0.0738 con el error en estimación diaria de 0.1340 y el error en estimación mensual de 0.4670 se tiene en cuenta las escalas diferentes de series de tiempo.

El error de demanda horaria tiene mayor precisión para la operación y estabilidad inmediata de la red brindando una gestión eficaz de demanda eléctrica. El error de demanda diaria también es muy preciso y adecuado para la planificación energética del siguiente día, es menos preciso que el caso horario por lo que se debe tomar precauciones para evitar complicaciones y desvíos de generación en el panorama futuro. Finalmente, el error de demanda mensual tiene buena precisión pero es más utilizado en la toma de decisiones y planificación energética a largo plazo.

Minimizar los errores RMSE de una micro-red en modo aislado es un factor esencial debido a su operación independiente de la red, su nivel de precisión en la estimación de demanda debe ser eficaz y seguro para garantizar un suministro suficiente de energía. Un error adecuado en el caso de demanda horaria permite optimizar recursos y ajustar el plan de generación, en demanda diaria permite almacenar suficiente energía para atender la demanda respectiva y en demanda mensual permite idear una planificación responsable con respecto a la administración de recursos tanto de generación como de capital económico.

En la Tabla 3 se puede observar los datos de carga promedio real y estimada para el escenario de demanda mensual, dichos datos varían de manera significativa en comparación con el escenario horario y diario analizado anteriormente. Para este escenario mensual se puede observar que la estimación obtenida cumple con una base de demanda parecida a la real, pero presenta un error mayor.

Tabla 3. Comparación de los perfiles de carga en meses de un año.

Meses	Demanda real (W)	Estimación de demanda (W)
1	218.16	221.21
2	437.97	439.54
3	430.74	428.8
4	219.21	221.13
5	409.69	434.57
6	444.17	418.97
7	343.23	440.83
8	223.41	220.94
9	227.08	220.13
10	438.85	429.03
11	226.76	220.87
12	220.13	220.41

Como otro aporte en la planificación para garantizar la suficiencia de generación distribuida se puede incorporar grupos electrógenos con su motor de combustión interna como un respaldo ante posibles cortes de energía y altos picos de demanda con el fin de evitar inconvenientes en el suministro eléctrico.

6 Conclusiones

La estimación de demanda eléctrica para una micro-red en modo aislado es muy importante, ya que en este modo la micro-red no cuenta con el apoyo de la red principal y se conecta al sistema de generación distribuida. Es así que, se requiere conocer con precisión el estado de la demanda a futuro para garantizar una administración apropiada en cuanto a generación y evitar posibles cortes eléctricos para los usuarios.

Mediante la red neuronal recurrente LSTM se han obtenido las curvas de estimación en base a datos históricos de la Armenia, consiguiendo los resultados adecuados que ayuden a generar la energía necesaria para el consumo de los usuarios residenciales de la Armenia y a evitar pérdidas de energía. Cada uno de los 3 escenarios mencionados se ajustaron a los parámetros de la red ya que el RMSE y las pérdidas en el tiempo mostraron un comportamiento descendente.

La estimación de demanda eléctrica se ha planteado para 3 escenarios, horas de un día, días de una semana y meses de un año; cada uno de los casos presenta los perfiles de carga promedio de demanda histórica y estimación para la comparación de ambos perfiles. En el caso de estimación horaria la demanda máxima que hay que cubrir se encuentra en el lapso de las 19:00 con 275.32 W hasta las 22:00 con 306.33 W. Para el caso de estimación diaria la demanda máxima que hay que cubrir es el lunes con 196.19 W y el sábado con 182.23 W. Finalmente para el caso de estimación mensual, la demanda máxima que hay que

cubrir es en noviembre con 437.97 W, diciembre con 430.74 W, marzo con 444.17 W y julio con 438.85 W.

El valor de error permite obtener el nivel de precisión que tiene la red LSTM para estimación de datos, el valor deber acercarse a cero para que el proceso sea correcto. En los 3 escenarios los valores de error se acercan a cero, la estimación horaria presenta un error de 0.0738, la estimación diaria un error de 0.1340 y la estimación mensual un error de 0.4670. Estos resultados presentan un nivel de precisión muy bueno que se encuentra dentro del rango adecuado, lo cual indica que la red LSTM es apropiada para estimar la demanda eléctrica.

La precisión de la estimación de demanda eléctrica permite idear la planificación adecuada para garantizar la suficiencia de generación, ya que en función de los resultados se solicita la generación necesaria. Además, gracias a dicha precisión se puede optimizar los recursos de generación y almacenamiento, conocer con antelación el comportamiento de la demanda es una gran ventaja debido a que se puede tener un plan de reserva ante cualquier situación de emergencia.

6.1 Trabajos futuros

En función de los resultados presentados, se plantea nuevas investigaciones que aporten al avance y desarrollo de la estimación de demanda eléctrica para determinadas aplicaciones en respectivos periodos de tiempo:

- Análisis del crecimiento de la demanda con un amplio conjunto de datos integrados que brinden resultados con mayor información.
- Determinar el comportamiento de la demanda para sectores comerciales e industriales, verificando la variabilidad de las cargas y la curva de demanda en

comparación con el sector residencial.

- Estudio de sectores con proyección para implementación de energías renovables convencionales y no convencionales que requieran información anticipada del comportamiento de la demanda para saber la cantidad de energía que se debe generar.
- Comparar el método presentado con otras redes neuronales para verificar el error de entrenamiento y con ello el nivel de precisión.

7 Referencias

- [1] D. S. Garcia-Miranda, F. Santamaria, C. L. Trujillo, H. E. Rojas-Cubides, and W. A. Riaño, "Factors Influencing Electricity Consumption in Rural Households," *Energies*, vol. 17, no. 6, 2024, doi: 10.3390/en17061392.
- [2] Mohamed Belrzaeg, Mohamed Abou Sif, Emad Almabsout, and Umar Ali Benisheikh, "Distributed generation for Microgrid technology," *Int. J. Sci. Res. Updat.*, vol. 6, no. 1, pp. 083–092, 2023, doi: 10.53430/ijrsru.2023.6.1.0062.
- [3] V. Saravanan, K. M. Venkatachalam, M. Arumugam, M. A. K. Borelessa, and K. T. M. U. Hemapala, "Overview of microgrid systems," *Int. J. Adv. Appl. Sci.*, vol. 10, no. 4, pp. 378–391, 2021, doi: 10.11591/ijaas.v10.i4.pp378-391.
- [4] T. B. Tsuchida *et al.*, "Electricity Demand Growth and Forecasting in a Time of Change," *Brattle Gr. Rep.*, no. May, 2024, [Online]. Available: <https://www.brattle.com/insights-events/publications/electricity-demand-growth-and-forecasting-in-a-time-of-change/>
- [5] A. Gellert, L. M. Olaru, A. Florea, I.

- I. Cofaru, U. Fiore, and F. Palmieri, "Estimating electricity consumption at city-level through advanced machine learning methods," *Conn. Sci.*, vol. 36, no. 1, 2024, doi: 10.1080/09540091.2024.2313852.
- [6] S. Önay, A. Yücekaya, A. Bilge, and E. A. Aktunç, "A supply and demand analysis for the turkish electricity market: Supply adequacy and resource utilization," *Int. J. Energy Econ. Policy*, vol. 11, no. 6, pp. 315–327, 2021, doi: 10.32479/ijeep.11412.
- [7] M. Bilgili, N. Arslan, A. Sekertekin, and A. Yasar, "Application of long short-term memory (LSTM) neural network based on deep learning for electricity energy consumption forecasting," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 30, no. 1, pp. 140–157, 2022, doi: 10.3906/elk-2011-14.
- [8] W. Peujio-Jiotsop-Foze and A. Hernández-Del-Valle, "Hours ahead automed long short-term memory (LSTM) electricity load forecasting at substation level: Newcastle substation," *Contaduria y Adm.*, vol. 68, no. 1, pp. 77–96, 2023, doi: 10.22201/fca.24488410e.2023.3356.
- [9] Xavier Leopoldo Gracia-Cervantes, "La Generación Distribuida y las Fuentes Renovables de energía en el Ecuador," *Dominio las Ciencias*, vol. 7, no. 3, pp. 1–12, 2021, [Online]. Available: <http://dominiodelasciencias.com/ojs/index.php/es/index>
- [10] M. Uddin, H. Mo, D. Dong, S. Elsayah, J. Zhu, and J. M. Guerrero, "Microgrids: A review, outstanding issues and future trends," *Energy Strateg. Rev.*, vol. 49, no. September, p. 101127, 2023, doi: 10.1016/j.esr.2023.101127.
- [11] L. Chabla-Auqui, D. Ochoa-Correa, E. Villa-Ávila, and P. Astudillo-Salinas, "Distributed Generation Applied to Residential Self-Supply in South America in the Decade 2013–2023: A Literature Review," *Energies*, vol. 16, no. 17, 2023, doi: 10.3390/en16176207.
- [12] R. Sujatha, G. Sukumar, V. Rajesh, R. S. Kumar, and J. David, "Electricity Consumption Forecasting System Using Deep Learning," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 1258, no. 1, p. 012061, 2022, doi: 10.1088/1757-899x/1258/1/012061.
- [13] M. T. Gebre, J. Hwang, and G. Biru, "Electricity demand analysis and forecasting: The case of GADA special economic zone," *Heliyon*, vol. 10, no. 3, p. e25364, 2024, doi: 10.1016/j.heliyon.2024.e25364.
- [14] E. Efekemo, E. G. Saturday, and J. C. Ofodu, "Electricity Demand Forecasting: a Review," *Int. J. Multidiscip. Curr. Educ. Res.*, vol. 4, no. 2, pp. 279–301, 2022, [Online]. Available: www.ijmcer.com
- [15] W. Zhou, H. Tao, J. Chang, H. Jiang, and L. Chen, "Forecasting Chinese Electricity Consumption Based on Grey Seasonal Model with New Information Priority," *Sustain.*, vol. 15, no. 4, pp. 1–20, 2023, doi: 10.3390/su15043521.
- [16] M. Saglam, C. Spataru, and O. A. Karaman, "Forecasting Electricity Demand in Turkey Using Optimization and Machine Learning Algorithms," *Energies*, vol. 16, no. 11, 2023, doi: 10.3390/en16114499.
- [17] VIDA and e-GUIDE, "Electricity demand estimation and viability analysis for off-grid villages in Kenya - Village Data Analytics," 2020.
- [18] M. S. Bakare, A. Abdulkarim, M. Zeeshan, and A. N. Shuaibu, "Short-Term Prediction of Residential Power Energy Consumption via

- CNN and Multi-Layer Bi-Directional LSTM Networks,” *IEEE Access*, vol. 8, pp. 123369–123380, 2020, doi: 10.1109/ACCESS.2019.2963045.
- [19] G. Ma *et al.*, “A Bi-Level Capacity Optimization of an Isolated Microgrid with Load Demand Management Considering Load and Renewable Generation Uncertainties,” *IEEE Access*, vol. 7, pp. 83074–83087, 2019, doi: 10.1109/ACCESS.2019.2924288.
- [20] N. Boogen, S. Datta, and M. Filippini, “Estimating residential electricity demand: New empirical evidence,” *Energy Policy*, vol. 158, no. April, p. 112561, 2021, doi: 10.1016/j.enpol.2021.112561.
- [21] C. Hugo, L. Cabrera, N. Patricia, A. Apolo, D. Vinicio, and P. Moran, “Predicción de demanda eléctrica utilizando redes neuronales artificiales para un sistema de distribución de energía eléctrica,” *Cienc. Lat. Rev. Científica Multidiscip.*, vol. 6, no. 3, pp. 3871–3894, 2022, doi: 10.37811/cl_rcm.v6i3.2502.
- [22] M. Pinhão, M. Fonseca, and R. Covas, “Electricity Spot Price Forecast by Modelling Supply and Demand Curve,” *Mathematics*, vol. 10, no. 12, pp. 1–20, 2022, doi: 10.3390/math10122012.
- [23] F. Félix, N. Leyva, Ó. Urías, M. Medrano, H. Rodríguez, and J. Flores, “Load prediction in electrical networks using LSTM,” *2021 Mex. Int. Conf. Comput. Sci. ENC 2021*, 2021, doi: 10.1109/ENC53357.2021.9534794.
- [24] M. C. Llumitasig Galarza, “Simulación de pronósticos de ventas en la empresa IMPACTEX mediante redes neuronales,” *Repos. Inst. la Univ. Técnica Ambato*, vol. 593, no. 03, p. 119, 2021.
- [25] P. Khetrupal, “Distributed generation: A critical review of technologies, grid integration issues, growth drivers and potential benefits,” *Int. J. Renew. Energy Dev.*, vol. 9, no. 2, pp. 189–205, 2020, doi: 10.14710/ijred.9.2.189-205.
- [26] Adebayo Adeniyi Daavid and Chinedu James Ujam, “An overview of distributed generation in power systems,” *Int. J. Front. Res. Eng. Technol.*, vol. 1, no. 1, pp. 027–033, 2022, doi: 10.56355/ijfret.2022.1.1.0001.
- [27] J. Y. Lee, R. Verayiah, K. H. Ong, A. K. Ramasamy, and M. B. Marsadek, “Distributed generation: A review on current energy status, grid-interconnected pq issues, and implementation constraints of dg in malaysia,” *Energies*, vol. 13, no. 24, 2020, doi: 10.3390/en13246479.
- [28] J. Andruszkiewicz, J. Lorenc, and A. Weychan, “Distributed generation as efficient measure to improve power generation adequacy,” *Arch. Electr. Eng.*, vol. 68, no. 2, pp. 373–385, 2019, doi: 10.24425/ae.2019.128274.
- [29] E. Renováveis and J. O. O. I, “Las Energías Renovables y la Sostenibilidad en Territorio Renewable Energies and Sustainability in Territory,” vol. 8, pp. 1401–1417, 2022.
- [30] X. Zhang, K. Guo, L. Wang, Y. Cong, and Q. Wang, “Analysis of the Influence of Distributed Generation on Distribution Network Voltage,” *J. Phys. Conf. Ser.*, vol. 2418, no. 1, pp. 0–6, 2023, doi: 10.1088/1742-6596/2418/1/012034.
- [31] A. M. ELTAMALY, Y. S. MOHAMED, A.-H. M. EL-SAYED, and A. N. A. ELGHAFFAR, “Impact of Distributed Generation (Dg) on the Distribution System Network,”

- Ann. Fac. Eng. Hunedoara - Int. J. Eng.*, vol. 17, no. 1, pp. 165–170, 2019.
- [32] M. Meskin, A. Domijan, and I. Grinberg, “Impact of distributed generation on the protection systems of distribution networks: Analysis and remedies – review paper,” *IET Gener. Transm. Distrib.*, vol. 14, no. 24, pp. 5816–5822, 2020, doi: 10.1049/iet-gtd.2019.1652.
- [33] S. Shahzad, M. A. Abbasi, H. Ali, M. Iqbal, R. Munir, and H. Kilic, “Possibilities, Challenges, and Future Opportunities of Microgrids: A Review,” *Sustain.*, vol. 15, no. 8, 2023, doi: 10.3390/su15086366.
- [34] M. Farrokhbadi *et al.*, “Microgrid Stability Definitions, Analysis, and Examples,” *IEEE Trans. Power Syst.*, vol. 35, no. 1, pp. 13–29, 2020, doi: 10.1109/TPWRS.2019.2925703.
- [35] K. Cabana-Jiménez, J. E. Candelo-Becerra, and V. S. Santos, “Comprehensive Analysis of Microgrids Configurations and Topologies,” *Sustain.*, vol. 14, no. 3, pp. 1–25, 2022, doi: 10.3390/su14031056.
- [36] M. H. Saeed, W. Fangzong, B. A. Kalwar, and S. Iqbal, “A Review on Microgrids’ Challenges Perspectives,” *IEEE Access*, vol. 9, pp. 166502–166517, 2021, doi: 10.1109/ACCESS.2021.3135083.
- [37] E. Garcia, A. Águila, L. Ortiz, and D. Carrión, “Optimal Resource Assignment in Hybrid Microgrids Based on Demand Response Proposals,” *Sustain.*, vol. 16, no. 5, 2024, doi: 10.3390/su16051797.
- [38] C. Liu, “A Review of Microgrid Development and Technology,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 300, no. 4, 2019, doi: 10.1088/1755-1315/300/4/042048.
- [39] S. L. Chartier, V. K. Venkiteswaran, S. S. Rangarajan, E. R. Collins, and T. Senjyu, “Microgrid Emergence, Integration, and Influence on the Future Energy Generation Equilibrium—A Review,” *Electron.*, vol. 11, no. 5, 2022, doi: 10.3390/electronics11050791.
- [40] E. Garcia, A. Águila, L. Ortiz, and M. Ruiz, “Optimum Stochastic Allocation for Demand Response for Power Markets in Microgrids,” *Energies*, vol. 17, no. 5, 2024, doi: 10.3390/en17051037.
- [41] W. D. Alcoser Manya, “Redes Neuronales Artificiales y modelos ARIMA aplicados a la modelación y predicción del tipo de cambio euro-dólar [Trabajo de grado],” p. 91, 2020.
- [42] J. Oruh, S. Viriri, and A. Adegun, “Long Short-Term Memory Recurrent Neural Network for Automatic Speech Recognition,” *IEEE Access*, vol. 10, pp. 30069–30079, 2022, doi: 10.1109/ACCESS.2022.3159339.
- [43] Cea Morán J.J., “Redes neuronales recurrentes para la generación automática de música,” pp. 1–72, 2020.
- [44] S. Catunta Esquivel and D. M. Roncal Hidalgo, “Redes neuronales recurrentes para la predicción de casos por Covid- 19 usando datos abiertos en el Perú, 2020,” *Univ. Cesar Vallejo*, p. 122, 2020, [Online]. Available: http://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/47102/Gutiérrez_RS-SD.pdf?sequence=1&isAllowed=y
- [45] M. Ishfaq, Q. Dai, N. Ul Haq, K. Jadoon, S. M. Shahzad, and H. T. Janjuhah, “Use of Recurrent Neural Network with Long Short-Term Memory for Seepage Prediction at Tarbela Dam, KP, Pakistan,” *Energies*, vol. 15, no. 9, 2022, doi:

- 10.3390/en15093123.
- [46] B. Lindemann, T. Müller, H. Vietz, N. Jazdi, and M. Weyrich, "A survey on long short-term memory networks for time series prediction," *Procedia CIRP*, vol. 99, no. March, pp. 650–655, 2021, doi: 10.1016/j.procir.2021.03.088.
 - [47] J. De Lucio, "Estimación adelantada del crecimiento regional mediante redes neuronales LSTM," *Investig. Reg. - J. Reg. Res.*, vol. 49, pp. 45–64, 2021, doi: 10.38191/iirr-jorr.21.007.
 - [48] P. S. Muhuri, P. Chatterjee, X. Yuan, K. Roy, and A. Esterline, "Using a long short-term memory recurrent neural network (LSTM-RNN) to classify network attacks," *Inf.*, vol. 11, no. 5, pp. 1–21, 2020, doi: 10.3390/INFO11050243.
 - [49] H. Pham, "A new criterion for model selection," *Mathematics*, vol. 7, no. 12, pp. 1–12, 2019, doi: 10.3390/MATH7121215.
 - [50] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput. Sci.*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.
 - [51] V. Z. Castillo, H. S. de Boer, R. M. Muñoz, D. E. H. J. Gernaat, R. Benders, and D. van Vuuren, "Future global electricity demand load curves," *Energy*, vol. 258, no. July, p. 124741, 2022, doi: 10.1016/j.energy.2022.124741.
 - [52] D. S. Pereira and A. C. Marques, "An analysis of the interactions between daily electricity demand levels in France," *Util. Policy*, vol. 76, no. May 2021, 2022, doi: 10.1016/j.jup.2022.101368.
 - [53] G. Leguizamo, "Propuesta de un modelo de series de tiempo para el pronóstico de ingresos por prestación de servicios en la empresa de operación nacional Falcón Academia de Aviación S.A.S.," 2022, [Online]. Available: <https://repositorio.unbosque.edu.co/handle/20.500.12495/8545>
 - [54] M. K. Sandhya Arora, "Forecasting the Future: A Comprehensive Review of Time Series Prediction Techniques," *J. Electr. Syst.*, vol. 20, no. 2s, pp. 575–586, 2024, doi: 10.52783/jes.1478.
 - [55] I. Salehin, S. M. Noman, and M. M. Hasan, "Electricity energy dataset 'BanE-16': Analysis of peak energy demand with environmental variables for machine learning forecasting," *Data Br.*, vol. 52, 2024, doi: 10.1016/j.dib.2023.109967.
 - [56] A. Shaqour, H. Farzaneh, and H. Almogdady, "Day-ahead residential electricity demand response model based on deep neural networks for peak demand reduction in the jordanian power sector," *Appl. Sci.*, vol. 11, no. 14, 2021, doi: 10.3390/app11146626.
 - [57] M. A. Alduailij, I. Petri, O. Rana, M. A. Alduailij, and A. S. Aldawood, "Forecasting peak energy demand for smart buildings," *J. Supercomput.*, vol. 77, no. 6, pp. 6356–6380, 2021, doi: 10.1007/s11227-020-03540-3.

7.1 Matriz de Estado del Arte

Tabla 4: Matriz de estado del arte.

ESTIMACIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE LA RED NEURONAL RECURRENTE TIPO LSTM APLICADO AL ESTUDIO DE UN SECTOR RESIDENCIAL EN UNA MICRO-RED																											
ITEM	DATOS			TEMÁTICA					FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA					PROPUESTAS PARA RESOLVER EL PROBLEMA					SOLUCIÓN PROPUESTA				
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	Demanda Eléctrica	Red Neuronal Recurrente LSTM	Estimación de Demanda	Micro-Red	Generación Distribuida	Análisis de Datos	Entrenamiento de Datos	Crecimiento de la Demanda	Tratamiento del Conjunto de Datos	Suficiencia de Generación	Consumo Eléctrico	Cambios Climáticos	Energía Eléctrica	Suministro Continuo	Redes Neuronales	Series Temporales	Monte Carlo	Regresión Lineal	Patrón del Periodo de Prioridad de Datos	Análisis del Comportamiento de la Demanda	Red Neuronal Tipo LSTM	Estimación de la Demanda	Fuentes Renovables	Plan de Generación
1	2023	Distributed generation for Microgrid technology	1	✖	□	□	✖	✖	✖	□	□	□	✖	✖	✖	□	✖	□	□	□	□	✖	□	□	□	✖	✖
2	2021	Overview of microgrid systems	2	✖	□	□	✖	✖	✖	□	□	□	□	✖	□	✖	✖	□	□	□	□	✖	✖	□	□	✖	✖
3	2021	A supply and demand analysis for the turkish electricity market: Supply adequacy and resource utilization	2	✖	□	✖	✖	□	✖	✖	✖	□	✖	✖	✖	✖	□	□	□	□	✖	✖	✖	□	✖	✖	✖
4	2022	Application of long short-term memory (LSTM) neural network based on deep learning for electricity energy consumption forecasting	29	✖	✖	✖	□	□	✖	✖	✖	✖	✖	✖	✖	✖	□	✖	✖	□	✖	□	✖	✖	✖	✖	□
5	2023	Microgrids: A review, outstanding issues and future trends	66	✖	□	✖	✖	✖	✖	□	✖	□	✖	✖	✖	✖	✖	□	✖	□	□	□	✖	□	✖	✖	✖
6	2023	Distributed Generation Applied to Residential Self-Supply in South America in the Decade 2013–2023: A Literature Review	4	✖	□	□	✖	✖	✖	□	✖	□	□	✖	□	✖	□	□	✖	✖	□	□	✖	□	□	✖	✖
7	2024	Electricity demand analysis and forecasting: The case of GADA special economic zone	2	✖	□	✖	□	□	✖	□	□	□	✖	✖	✖	✖	✖	□	✖	□	✖	✖	✖	□	✖	✖	✖

ESTIMACIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE LA RED NEURONAL RECURRENTE TIPO LSTM APLICADO AL ESTUDIO DE UN SECTOR RESIDENCIAL EN UNA MICRO-RED																											
ITEM	DATOS			TEMÁTICA					FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA					PROPUESTAS PARA RESOLVER EL PROBLEMA					SOLUCIÓN PROPUESTA				
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	Demanda Eléctrica	Red Neuronal Recurrente LSTM	Estimación de Demanda	Micro-Red	Generación Distribuida	Análisis de Datos	Entrenamiento de Datos	Crecimiento de la Demanda	Tratamiento del Conjunto de Datos	Suficiencia de Generación	Consumo Eléctrico	Cambios Climáticos	Energía Eléctrica	Suministro Continuo	Redes Neuronales	Series Temporales	Monte Carlo	Regresión Lineal	Patrón del Periodo de Prioridad de Datos	Análisis del Comportamiento de la Demanda	Red Neuronal Tipo LSTM	Estimación de la Demanda	Fuentes Renovables	Plan de Generación
8	2023	Forecasting Chinese Electricity Consumption Based on Grey Seasonal Model with New Information Priority	4	☒	☐	☐	☐	☐	☒	☒	☐	☐	☒	☒	☐	☒	☐	☒	☒	☐	☐	☐	☒	☐	☐	☒	☐
9	2023	Forecasting Electricity Demand in Turkey Using Optimization and Machine Learning Algorithms	10	☒	☒	☒	☐	☐	☒	☒	☒	☒	☐	☒	☒	☐	☐	☒	☒	☐	☒	☒	☒	☒	☒	☒	☒
10	2019	A Bi-Level Capacity Optimization of an Isolated Microgrid with Load Demand Management Considering Load and Renewable Generation Uncertainties	42	☒	☐	☐	☒	☒	☒	☐	☐	☐	☐	☒	☐	☐	☒	☐	☐	☒	☐	☐	☒	☐	☐	☒	☒
11	2021	Estimating residential electricity demand: New empirical evidence	10	☒	☐	☒	☐	☐	☒	☐	☐	☐	☐	☒	☒	☐	☐	☐	☒	☐	☒	☐	☒	☒	☐	☒	☒
12	2022	Electricity Spot Price Forecast by Modelling Supply and Demand Curve	11	☒	☒	☒	☐	☐	☒	☒	☐	☐	☐	☐	☒	☐	☒	☒	☒	☐	☒	☒	☒	☒	☒	☒	☐
13	2020	Distributed generation: A critical review of technologies, grid integration issues, growth drivers and potential benefits	30	☒	☐	☐	☐	☒	☐	☐	☐	☐	☐	☒	☐	☒	☒	☐	☐	☐	☐	☐	☒	☐	☐	☒	☒
14	2020	Distributed generation: A review on current energy status, grid-interconnected pq issues, and implementation constraints of dg in malaysia	20	☒	☐	☒	☐	☒	☒	☒	☒	☐	☐	☒	☒	☐	☒	☒	☒	☒	☐	☐	☐	☒	☐	☒	☒

ESTIMACIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE LA RED NEURONAL RECURRENTE TIPO LSTM APLICADO AL ESTUDIO DE UN SECTOR RESIDENCIAL EN UNA MICRO-RED																												
ITEM	DATOS			TEMÁTICA					FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA					PROPUESTAS PARA RESOLVER EL PROBLEMA					SOLUCIÓN PROPUESTA					
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	Demanda Eléctrica	Red Neuronal Recurrente LSTM	Estimación de Demanda	Micro-Red	Generación Distribuida	Análisis de Datos	Entrenamiento de Datos	Crecimiento de la Demanda	Tratamiento del Conjunto de Datos	Suficiencia de Generación	Consumo Eléctrico	Cambios Climáticos	Energía Eléctrica	Suministro Continuo	Redes Neuronales	Series Temporales	Monte Carlo	Regresión Lineal	Patrón del Periodo de Prioridad de Datos	Análisis del Comportamiento de la Demanda	Red Neuronal Tipo LSTM	Estimación de la Demanda	Fuentes Renovables	Plan de Generación	
15	2019	Distributed generation as efficient measure to improve power generation adequacy	3	✖	□	□	□	✖	✖	□	□	□	✖	✖	□	□	✖	□	□	✖	□	□	✖	□	□	□	✖	□
16	2023	Analysis of the Influence of Distributed Generation on Distribution Network Voltage	3	□	□	□	□	✖	□	□	□	□	□	✖	□	✖	□	□	□	□	□	□	□	□	□	□	✖	✖
17	2019	Impact of Distributed Generation (Dg) on the Distribution System Network	29	✖	□	□	□	✖	✖	□	□	□	□	□	✖	✖	✖	□	✖	□	□	□	✖	□	□	□	✖	✖
18	2020	Impact of distributed generation on the protection systems of distribution networks: Analysis and remedies	56	□	□	✖	□	✖	✖	✖	□	✖	□	□	✖	□	□	✖	✖	□	□	□	□	□	□	✖	✖	✖
19	2023	Possibilities, Challenges, and Future Opportunities of Microgrids: A Review	37	✖	□	□	✖	□	✖	□	□	□	□	✖	✖	✖	✖	□	✖	□	□	✖	✖	□	□	□	✖	□
20	2022	Comprehensive Analysis of Microgrids Configurations and Topologies	26	✖	□	✖	✖	✖	□	□	✖	□	□	✖	□	✖	✖	□	□	□	□	□	✖	□	□	✖	✖	✖
21	2021	A review on microgrids' challenges & perspectives	285	✖	□	□	✖	✖	✖	□	□	□	□	✖	□	□	✖	✖	✖	✖	□	□	✖	□	□	□	✖	□

ESTIMACIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE LA RED NEURONAL RECURRENTE TIPO LSTM APLICADO AL ESTUDIO DE UN SECTOR RESIDENCIAL EN UNA MICRO-RED																											
ITEM	DATOS			TEMÁTICA					FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA					PROPUESTAS PARA RESOLVER EL PROBLEMA					SOLUCIÓN PROPUESTA				
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	Demanda Eléctrica	Red Neuronal Recurrente LSTM	Estimación de Demanda	Micro-Red	Generación Distribuida	Análisis de Datos	Entrenamiento de Datos	Crecimiento de la Demanda	Tratamiento del Conjunto de Datos	Suficiencia de Generación	Consumo Eléctrico	Cambios Climáticos	Energía Eléctrica	Suministro Continuo	Redes Neuronales	Series Temporales	Monte Carlo	Regresión Lineal	Patrón del Periodo de Prioridad de Datos	Análisis del Comportamiento de la Demanda	Red Neuronal Tipo LSTM	Estimación de la Demanda	Fuentes Renovables	Plan de Generación
22	2019	A Review of Microgrid Development and Technology	5	✖	□	□	✖	✖	□	□	□	□	□	✖	□	✖	✖	□	□	□	□	□	✖	□	□	✖	□
23	2022	Microgrid Emergence, Integration, and Influence on the Future Energy Generation Equilibrium—A Review	61	✖	□	□	✖	✖	✖	□	□	✖	□	□	✖	□	✖	□	✖	□	□	□	✖	□	□	✖	✖
24	2022	Long Short-Term Memory Recurrent Neural Network for Automatic Speech Recognition	69	□	✖	□	□	□	✖	✖	□	✖	□	□	□	□	□	✖	✖	□	□	✖	□	✖	□	□	□
25	2022	Use of Recurrent Neural Network with Long Short-Term Memory for Seepage Prediction at Tarbela Dam, KP, Pakistan	32	□	✖	□	□	□	✖	✖	□	✖	□	□	✖	□	□	✖	✖	□	□	□	□	□	✖	□	□
26	2021	A survey on long short-term memory networks for time series prediction	284	□	✖	□	□	□	✖	✖	□	✖	□	□	□	□	□	✖	✖	□	□	□	□	□	✖	□	□
27	2021	Estimación adelantada del crecimiento regional mediante redes neuronales LSTM	4	□	✖	□	□	□	✖	✖	□	✖	□	□	□	□	□	✖	✖	□	□	✖	□	✖	□	□	□
28	2020	Using a long short-term memory recurrent neural network (LSTM-RNN) to classify network attacks	81	□	✖	□	□	□	✖	✖	□	✖	□	□	□	□	□	✖	✖	□	□	✖	□	✖	□	□	□

ESTIMACIÓN DE LA DEMANDA ELÉCTRICA MEDIANTE LA RED NEURONAL RECURRENTE TIPO LSTM APLICADO AL ESTUDIO DE UN SECTOR RESIDENCIAL EN UNA MICRO-RED																											
ITEM	DATOS			TEMÁTICA					FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO				RESTRICCIONES DEL PROBLEMA					PROPUESTAS PARA RESOLVER EL PROBLEMA					SOLUCIÓN PROPUESTA				
	AÑO	TÍTULO DEL ARTÍCULO	CITAS	Demanda Eléctrica	Red Neuronal Recurrente LSTM	Estimación de Demanda	Micro-Red	Generación Distribuida	Análisis de Datos	Entrenamiento de Datos	Crecimiento de la Demanda	Tratamiento del Conjunto de Datos	Suficiencia de Generación	Consumo Eléctrico	Cambios Climáticos	Energía Eléctrica	Suministro Continuo	Redes Neuronales	Series Temporales	Monte Carlo	Regresión Lineal	Patrón del Periodo de Prioridad de Datos	Análisis del Comportamiento de la Demanda	Red Neuronal Tipo LSTM	Estimación de la Demanda	Fuentes Renovables	Plan de Generación
29	2019	A new criterion for model selection	148	☐	☐	☐	☐	☐	☒	☐	☐	☒	☐	☐	☐	☐	☐	☐	☒	☐	☒	☐	☐	☐	☐	☐	☐
30	2021	The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation	2108	☐	☐	☐	☐	☐	☒	☐	☐	☒	☐	☐	☐	☐	☐	☒	☒	☐	☒	☐	☐	☐	☐	☐	☐
31	2022	Future global electricity demand load curves	37	☒	☐	☒	☐	☐	☒	☐	☒	☐	☐	☐	☐	☒	☒	☐	☒	☐	☒	☒	☒	☒	☐	☒	☒
32	2022	An analysis of the interactions between daily electricity demand levels in France	4	☒	☐	☒	☐	☐	☒	☐	☒	☒	☐	☒	☐	☐	☒	☐	☒	☐	☐	☒	☒	☐	☒	☒	☐
33	2022	Propuesta de un modelo de series de tiempo para el pronóstico de ingresos por prestación de servicios en la empresa de operación nacional Falcón Academia de Aviación S.A.S.	3	☐	☐	☐	☐	☐	☒	☐	☐	☒	☐	☐	☐	☐	☐	☐	☒	☐	☐	☒	☐	☐	☐	☐	☐
34	2021	Day-ahead residential electricity demand response model based on deep neural networks for peak demand reduction in the jordanian power sector	7	☒	☒	☒	☒	☒	☒	☒	☐	☒	☒	☒	☒	☒	☒	☒	☒	☐	☐	☒	☒	☒	☒	☒	☒
35	2021	Forecasting peak energy demand for smart buildings	45	☒	☒	☒	☐	☐	☒	☒	☐	☒	☐	☒	☒	☐	☐	☒	☒	☐	☒	☒	☒	☒	☒	☒	☐
			CANTIDAD:	25	10	14	12	16	31	14	9	15	8	22	16	15	18	15	26	4	10	14	25	10	14	27	18

7.2 Resumen de Indicadores




Figura 34. Resumen e indicador de la temática - Estado del arte.




Figura 35. Indicador de formulación del problema - Estado del arte.




Figura 36. Indicador de solución - Estado del arte.