

**MÉTODO AUTORREGRESIVO ARIMA
PARA UNA PREVISIÓN DE CARGA
RESIDENCIAL A CORTO PLAZO BASADO
EN EL APRENDIZAJE DEL
COMPORTAMIENTO DE LOS CLIENTES
RESIDENCIALES**



UNIVERSIDAD POLITÉCNICA SALESIANA

SEDE QUITO

CARRERA DE ELECTRICIDAD

**MÉTODO AUTORREGRESIVO ARIMA
PARA UNA PREVISIÓN DE CARGA
RESIDENCIAL A CORTO PLAZO BASADO
EN EL APRENDIZAJE DEL
COMPORTAMIENTO DE LOS CLIENTES
RESIDENCIALES.**

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

AUTOR: LUIS EDUARDO LORA ARIAS

TUTOR: LUIS FERNANDO TIPÁN VERGARA

Quito -Ecuador

2022

Luis Eduardo Lora Arias

MÉTODO AUTORREGRESIVO ARIMA PARA UNA PREVISIÓN DE CARGA RESIDENCIAL A CORTO PLAZO BASADO EN EL APRENDIZAJE DEL COMPORTAMIENTO DE LOS CLIENTES RESIDENCIALES.

Universidad Politécnica Salesiana

ELECTRICIDAD.

Breve Reseña Histórica e Información Del Contacto



Luis Eduardo Lora Arias (Y' 1997). Realizó sus estudios secundarios en el Colegio Técnico Industrial Miguel de Santiago, se graduó de bachiller en Instalaciones, Equipos y Máquinas Eléctricas. Egresado de Ingeniería en Electricidad de la Universidad Politécnica Salesiana. Su trabajo se basa en Método Autorregresivo ARIMA para una previsión de carga residencial a corto plazo basado en el aprendizaje del comportamiento de los clientes residenciales.

lora@est.ups.edu.ec

Dirigido por:



Luis Fernando Tipán Vergara (Y'1982). Realizó sus estudios superiores en la Escuela Politécnica Nacional de Quito, donde se graduó de Ingeniero en Electrónica y Control en 2005. Además, curso estudios de Maestría en Eficiencia Energética en 2015. Actualmente es Docente e Investigador en Universidad Politécnica Salesiana.

ltipan@ups.edu.ec

Todos los derechos reservados:

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

©2022 Universidad Politécnica Salesiana

QUITO - ECUADOR

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE
TITULACIÓN**

Yo, Luis Eduardo Lora Arias con documento de identificación N° 1726288242 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, 06 de mayo del año 2022

Atentamente,



Luis Eduardo Lora Arias

1726288242

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

Yo, Luis Eduardo Lora Arias con documento de identificación No. 1726288242, 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: “*Método autorregresivo arima para una previsión de carga residencial a corto plazo basado en el aprendizaje del comportamiento de los clientes residenciales.*”, 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, 06 de mayo del año 2022

Atentamente,



Luis Eduardo Lora Arias

1726288242

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Luis Fernando Tipán Vergara con documento de identificación N° 1717329005, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: MÉTODO AUTORREGRESIVO ARIMA PARA UNA PREVISIÓN DE CARGA RESIDENCIAL A CORTO PLAZO BASADO EN EL APRENDIZAJE DEL COMPORTAMIENTO DE LOS CLIENTES RESIDENCIALES, realizado por Luis Eduardo Lora Arias con documento de identificación N° 1726288242, obteniendo como resultado final el trabajo de titulación bajo la opción de Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 06 de mayo del año 2022

Atentamente,



Ing. Luis Fernando Tipán Vergara, MSc
1717329005

1 ÍNDICE GENERAL

1.	Introducción.	2
2.	Marco Teórico.	3
2.1	Métodos de previsión.	3
3.	Comportamiento del consumo eléctrico residencial.	3
3.1	Comportamiento eléctrico del consumidor.	4
4.	Equipo para medición eléctrica inteligente.	4
4.1	Intervención de los medidores inteligentes.	5
4.2	Interoperabilidad entre medidores inteligentes de energía eléctrica residencial.	5
5.	Modelo autorregresivo para previsión.	5
5.1	Previsión del consumo de energía.	6
5.2	Previsión del consumo eléctrico residencial memoria a corto plazo.	6
6.	Previsión de la demanda eléctrica residencial.	7
6.1	Respuesta a la demanda residencial.	7
6.2	Perspectiva del residente.	7
3.	Planteamiento del problema.	8
3.1	Comportamiento eléctrico del consumidor residencial.	8
3.2	Equipos de medición eléctrica.	8
3.3	Valores de medición.	8
3.4	Modelo de previsión autorregresivo ARIMA.	9
4.	Modelación matemática.	10
4.1	Modelo autorregresivo de orden (p)-AR.	10
4.2	Modelo de medias móviles de orden (q)-MA.	10
4.3	Modelo autorregresivo de medias móviles de orden (p, q)-ARMA.	11
4.4	Modelo autorregresivo integrado de media móvil de orden (p, q, d)-ARIMA.	11
5.	Resultados.	11
6	Conclusiones.	14
7	Referencias.	15

INDICE DE FIGURAS

Figura 1. Perfil que ilustra la energía importada de la red principal y la generación local [Autor].....	3
Figura 2. Gestión y consumo de electrodomésticos residenciales [Autor].	4
Figura 3. Estructura de consumo energético mensual [Autor].....	5
Figura 4. Procesamiento de una red de datos encontrados en una medición [Autor].	5
Figura 5. Red de estudio característico de los electrodomésticos. [Autor].	6
Figura 6. Creación de los elementos característicos del modelo ARIMA. [Autor].	7
Figura 7. Procesamiento de lectura y aplicación del modelo MATLAB [Autor].	8
Figura 8. Valores de medición diaria del perfil de carga enero 2018 y enero 2019. [Autor].	9
Figura 9. Perfil de consumo eléctrico enero 2020. [Autor].....	9
Figura 10. Perfil de consumo eléctrico residencial ARIMA año 2021. [Autor]	10
Figura 11. Consumo eléctrico en aparatos de uso cotidiano. [Autor]	11
Figura 12. Predicción de carga residencial enero 2019. [Autor].....	12
Figura 13. Predicción de carga residencial enero 2020. [Autor].....	12
Figura 14. Predicción de carga residencial enero 2021. [Autor].....	12
Figura 15. Error residual ARIMA. [Autor].....	13
Figura 16. Error residual enero 2019. [Autor]	13
Figura 17. Error residual enero 2020. [Autor]	13
Figura 18. Error residual enero 2021. [Autor]	13
Figura 19. Intervalos de confianza enero 2019, 2020 y 2021. [Autor]	14

INDICE DE TABLAS

Tabla 1. Algoritmo de previsión a corto plazo [Autor].	8
--	---

MÉTODO AUTORREGRESIVO ARIMA PARA UNA PREVISIÓN DE CARGA RESIDENCIAL A CORTO PLAZO BASADO EN EL APRENDIZAJE DEL COMPORTAMIENTO DE LOS CLIENTES RESIDENCIALES.

Resumen

En el presente trabajo de titulación se pretende el prever el comportamiento de carga de los clientes residenciales. Implementando un modelo de previsión autorregresivo ARIMA, basado en datos establecidos por un medidor inteligente, conociendo el consumo residencial en un tiempo establecido y diagnosticando una solución de expansión para satisfacer la demanda residencial. Una vez Validado los datos implementados mediante el uso de una base de datos de una nube Iot hacia Matlab, nos en el perfil de carga de eléctrica residencial.

Una vez implementada la solución, mediante la validación y comprobación de este método se toma en cuenta la carga total obtenida en un corto plazo de tiempo, y se determina la necesidad o no de una expansión en satisfacer la demanda que abarque un sector residencial.

Palabras Clave: Previsión de consumo eléctrico, Carga eléctrica residencial, Métodos de previsión, Equipo de medición inteligente, Modelo autorregresivo para previsión

Abstract

In the present titling work, it is intended to foresee the load behavior of residential clients. Implementing an ARIMA autoregressive forecasting model, based on data established by a smart meter, knowing residential consumption in a set time and diagnosing an expansion solution to meet residential demand. Once Validated the data implemented by using a database of an Iot cloud to MATLAB, we in the load profile of residential electricity.

Once the solution is implemented, through the validation and verification of this method, the total load obtained in a short period of time is taken into account, and the need or not of an expansion to satisfy the demand that covers a residential sector is determined.

Keywords: Electricity consumption forecast, Residential electric load, Forecasting methods, Smart metering equipment, Autoregressive model for forecasting.

1 Introducción.

El pronóstico de la demanda de energía eléctrica es una parte integral de la gestión de la parte eléctrica, no existe un método de pronóstico específico que funcione con precisión, con un resultado preciso respecto a la demanda. Tomar en cuenta los patrones y las tendencias del consumo de energía en el sector residencial es de gran importancia.[1]

El pronóstico de una carga eléctrica residencial es una parte esencial de la planificación y operación del sistema eléctrico. La predicción de carga a corto plazo es muy importante respecto al intercambio y la programación de energía respecto a la gestión de respuesta a la demanda.[2]

Las cargas eléctricas han evolucionado respecto a su acelerado crecimiento en los últimos años con la evolución de la mejora en respuesta a la demanda eléctrica. Tomando en cuenta, que se carece de conocimiento sobre qué tan bien funcionan para hogares con diferentes asignaciones de tecnologías actualmente prevalentes dentro de los hogares residenciales.[3],[4]

Se plantea un marco de predicción dentro del aprendizaje profundo basado en la memoria a corto plazo con serie de consumo adquiridos mediante dispositivos para abordar este problema variable de consumo. Se designa que la precisión de la predicción se puede optimizar notablemente al incluir mediciones inteligentes en la residencia.[4]

Las principales aportaciones del modelo propuesto basado dentro del estudio profundo producto del comportamiento de cada equipo de medición para el pronóstico de carga a nivel de cada contador, asumiendo su rendimiento a través de mediciones prolongadas con los otros contadores de vanguardia.[4],[5]

La previsión de carga eléctrica residencial exacta a corto plazo es una

labor fundamental para la respuesta de la demanda eléctrica. Tomando en cuenta el estudio realizado a corto plazo para datos de carga que se están estudiado ampliamente. Durante la previsión de carga para usuarios residenciales.[5]

El consumo eléctrico residencial es un factor considerable, debido a la característica activa y variable dentro del comportamiento de consumo eléctrico residencial en un solo usuario, mencionando, un comportamiento estocástico dentro del consumo en un día o hasta de una semana dependiendo de la escalabilidad del sistema.[6]

Una previsión de carga eléctrica ayuda a mejorar en diferentes aspectos de consumo energético, tanto a usuarios activos como no activos. Desarrollando un planteamiento de consumo de carga a corto plazo, que incorpora el modelado de series de tiempo ARIMA, con el entendimiento de los operadores autorregresivo, manifestando un enfoque para el pronóstico de carga residencial.[7]

La previsión de carga eléctrica en un lapso a corto plazo se fundamenta en el consumo de energía eléctrica dentro de un tiempo pasado y otros factores relacionados para prever el consumo de energía futuro.[8],[9]

Las curvas de perfil de carga eléctrica diaria, se definen como unas curvas no lineales influenciada por la variabilidad de consumo energético. El pronóstico de consumo de carga en un lapso a corto tiempo, principalmente tiene a conocimiento carga de energía en horas, un día y hasta un mes, lo que tiene una gran importancia dentro de la previsión de carga.[9]

La predicción de consumo eléctrico correcto permite al residente reducir el costo de generación dentro de un sistema eléctrico, proporcionando una mejora en el consumo de energía para el residente, el modelo ARIMA aplica en una mejora dentro del pronóstico de carga eléctrica a corto plazo considerando el

comportamiento variable del residente.[10]

2 Marco Teórico.

En la presente sección se pondrá en conocimiento una investigación basada en los casos de estudio de diferentes autores tomando en cuenta su ideología acerca del conjunto de conocimientos presentes.

2.1 Métodos de previsión.

Es un término utilizado para definir la predicción o pronóstico de la demanda eléctrica dentro de un lapso de tiempo determinado. Se relaciona con las técnicas relacionadas a la previsión.[11]

La previsión es una, proyección o estimación de alguna actividad, es un evento relacionado con hechos del pasado mejorando el futuro. Tomando en cuenta que todas las decisiones pasadas pueden llegar a afectar el futuro, tanto en la categoría estratégica como en la táctica, mencionando siempre una mejora en la estimación de una demanda futura.[12]

Tipos de pronósticos:

Previsiones económicas: Predecir una variedad de indicadores económicos, como la oferta monetaria, la inflación

Previsiones tecnológicas: Predecir tasas de progreso tecnológico e innovación.

Previsiones de demanda: Predecir la demanda futura de los productos o servicios energéticos.

2.1.1 La importancia de una previsión a corto plazo.

La formación de una previsión es una alternativa prometedora a la predicción tradicional, se considerando tomar en cuenta estrategias apropiadas de información de grandes conjuntos de datos de series. En definición seleccionar un método de pronóstico, tomando los resultados prácticos, asumiendo la variabilidad presente.[13]

Existe la necesidad de tomar en cuenta un método de previsión para mejorar la calidad de la demanda de energía eléctrica que pueda reflejar las características y adaptarse al entorno operativo del consumo actual. Recopilando los datos del pasado y analizando patrones utilizando métodos de predicción ante datos estimados aparatos de consumo de energía inteligente.[14]

Evaluando los pronósticos de carga determinados una vez que se ha recopilado una muestra suficientemente de datos mediante el pronóstico, observación y validación de un modelo de previsión. Evaluando así un modelo de predicción autorregresivo dentro de lapso a corto plazo, como se observa en la Figura 1.

Precisión: se ocupa de las diferencias entre el pronóstico individual y las observaciones que se tienen en cuenta.

Habilidad: se refiere a la precisión de un pronóstico en relación con un punto de partida.

Fiabilidad: se refiere a la precisión en la recopilación de datos.

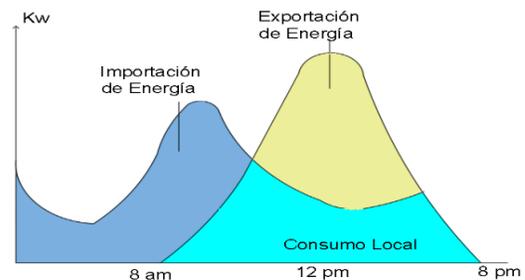


Figura 1. Perfil que ilustra la energía importada de la red principal y la generación local [Autor].

3 Comportamiento del consumo eléctrico residencial.

El comportamiento variable de un consumidor durante su actividad, es relacionada al consumo de energía residencial dentro de un lapso de corto tiempo. Estimando una previsión de la carga residencial es decisivo ante el

planteamiento, análisis y operación de sistemas de energía.[15]

Se presenta una vital importancia a los diferentes aspectos, que presentan un elevado consumo de la demanda energética residencial. Evaluando el comportamiento variable del residente. Tomando en cuenta los errores y oportunidades sobre el comportamiento del residente.[16]

3.1 Comportamiento eléctrico del consumidor.

El conocer como en comportamiento del consumo de electricidad se relaciona con las características variables dentro de un residencia es importante al momento planificar una predicción de la demanda. Siendo que el consumo varía significativamente con las características del hogar y el uso de aparatos eléctricos, lo cual afecta al momento del consumo eléctrico.[17]

Se establecen varios factores que afectan directamente al comportamiento volátil que tiene el residente al consumo de electricidad en los hogares, como los factores que intervienen dentro de un comportamiento volátil, las características de los aparatos electrónicos y gran parte del mal uso de los mismos al igual que la mala información sobre el uso de la energía residencial.[18]

La gestión de la carga residencial desempeñará un papel más importante, mejorando eficazmente la eficiencia y la satisfacción del consumo residencial, como se observa en la Figura 2, la demanda de electricidad residencial ha ido en aumento. La dirección que toma la variabilidad del residente va de la mano con los valores que toman los perfiles de carga.[19]

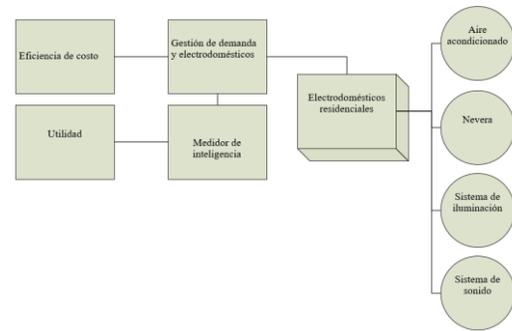


Figura 2. Gestión y consumo de electrodomésticos residenciales [Autor].

Al tomar datos reales obtenidos de las salidas de los equipos de medición eléctrica inteligente control de carga eléctrica obtenidos de un medidor inteligente, se evalúa la relación entre el consumo de energía, durante los períodos de máxima demanda y el consumo anual de energía.[20]

El comportamiento volátil de los consumidores, son principalmente el principal error en el sector residencial, al no tener control del consumo relacionado con la activación de electrodomésticos y el mismo desempeño sobre ellos, elevando los perfiles de consumo que se llegan a obtener de manera desequilibrada.[21]

El consumo de electricidad de los hogares influenciado por diversos factores notorios dentro de los perfiles de carga, el consumo eléctrico es difícil de predecir debido a la incertidumbre dentro del comportamiento humanos.[22]

4 Equipo para medición eléctrica inteligente.

Con la llegada de las recientes apariciones de nuevos elementos de medición eléctrica inteligente. El aumento de uso colectivo de los medidores inteligentes aumentando significativamente en la última década y aplicaciones de uso final, como sistemas de administración de energía para el hogar.[23]

Las residencias se han ido convertido en sistemas heterogéneos que consumen diferentes cantidades de electricidad

variando dentro del comportamiento humano en diferentes propósitos, horas del día o semanas de un mes. Comprender cómo el nivel y el momento del consumo de electricidad se relaciona con las características de los hogares es vital para una predicción.[23],[24]

4.1 Intervención de los medidores inteligentes

Los contadores inteligentes aprovechados en la actualidad, permiten una amplia progresión dentro de los intervalos de medición, desde horas hasta unos pocos segundos.[25] La previsión de la demanda de electricidad en sí misma se ha investigado durante décadas y hay una gran cantidad de información y una variedad de métodos, desde un nivel residencial individual hasta un nivel de sistema eléctrico, desde la previsión a corto plazo.[26]

La determinación de las tasas de autoconsumo y el potencial de respuesta de la demanda a través de los consumos dentro del hogar requieren una replicación realista de los patrones de consumo.[26],[27]

El pronóstico de la carga eléctrica ha estado atrayendo la investigación y la atención de la industria debido a su importancia para la gestión de la energía. La mejora de la gestión de la energía también conduce a beneficios financieros para los consumidores en términos de reducción de los costes energéticos dentro del consumo eléctrico.[28]

A partir de la introducción de contadores inteligentes, se ha generalizado la posibilidad de las mejoras en el control de picos de potencia para clientes residenciales, como se observa en la Figura 3.[29]

Estructura de Consumo Residencial



Figura 3. Estructura de consumo energético mensual [Autor].

4.2 Interoperabilidad entre medidores inteligentes de energía eléctrica residencial

Dentro de los datos obtenidos por los contadores inteligentes mencionando el uso de la nube de información y recolección de los mismos, se pueden utilizar en varias formas y para diversos fines. El propósito general de estos datos pueden llegar a convertirse en el recurso suficiente para trabajar en un modelo de previsión de la carga residencial.[30]

Además, los datos de los medidores inteligentes pueden proporcionar información referenciada, como se observa en la Figura 4. Dicha inquisición permite mejorar la precisión de las previsiones a nivel individual.[31]

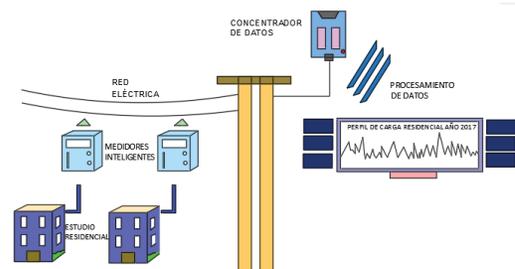


Figura 4. Procesamiento de una red de datos encontrados en una medición [Autor].

5. Modelo autorregresivo para previsión.

La previsión de carga es de vital importancia en el funcionamiento de un sistema de energía. Si bien los pronósticos a largo y mediano plazo ayudan en la

planificación del desarrollo o el programa de mantenimiento, el pronóstico a corto plazo proporciona principalmente información para el control ante un modelo de previsión.[32]

Hay muchos factores que influyen en el perfil de carga residencial además del comportamiento aleatorio de los clientes. La previsión dentro de los perfiles de demanda eléctrica son variables respecto a los residentes y su alta versatilidad dentro de una residencia individual, por tanto no llega a ser precisa.[33]

Modelos de series de tiempo y promedio móvil autorregresivo (ARIMA).

Modelos de redes neuronales artificiales (ANN).

Los modelos de previsión siempre son variables dependiendo del modelo que se llega a efectuar dentro de un sistema de previsión de consumo eléctrico. Las previsiones de series de tiempo en las cuales se efectúa el uso de datos recolectados por elementos de medición inteligentes siendo esta un área importante de la previsión en la que se recopilan y analizan las observaciones pasadas.[33],[34]

El pronóstico de carga a corto plazo juega un papel importante en la planificación y operación del sistema eléctrico residencial. La precisión de este valor predicho llega a ser indispensable para la creación de un modelo de previsión.[34]

5.1 Previsión del consumo de energía

Dentro de la implementación de un modelo de previsión de energía. Pueden llegar a existir la identificación de datos anormales de consumo de energía. Mencionados como consumo volátil.[35]

La implementación de un modelo de previsión de energía llega a fomentar una solución ante la actividad volátil que tiene un usuario ante el consumo erróneo de energía.[35],[10]

El pronóstico de carga a corto plazo, que permite prever los altos niveles de consumo de carga futura en un intervalo de tiempo de un día a varias semanas y hasta meses. Puede llegar a proyectar un pronóstico de carga preciso en la que se pueda llegar a reducir el costo de generación.[10]

5.2 Previsión del consumo eléctrico residencial memoria a corto plazo.

Un modelo de previsión tiene como fin la orientación y el enfoque basado en aprendizajes a nivel de carga de energía agregada, siendo relativamente exitosa ante un problema de predicción de carga residencial, como se observa en la Figura 5.

Se propone un enfoque ascendente teniendo en cuenta la carga característica del nivel de dispositivos.[36] considerando:

Los principios de trabajo y la carga característicos de los electrodomésticos clasificándose mediante carga continua e intermitente, para lograr una previsión de carga más refinada.

Tomando en conocimiento la fluctuación de las curvas de carga, el procedimiento de descomposición de tendencia estacional que se aplica en aparatos de carga continua.

Tomar en consideración el comportamiento del consumo de energía volátil de algunos usuarios y las correlaciones de los dispositivos.

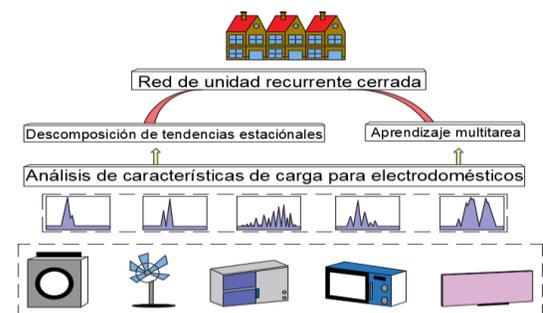


Figura 5. Red de estudio característico de los electrodomésticos. [Autor].

6. Previsión de la demanda eléctrica residencial.

Es la capacidad de llegar a un pronóstico con precisión de la demanda eléctrica a conocer establecida dentro de un estudio analítico y verídico en un lapso de corto tiempo, siendo este días, meses o años visto en la figura 5. Logrando garantizar decisiones de planificación de electricidad sostenibles y asegurar el suministro de electricidad para los consumidores.[37]

Un tema importante aplicable en este criterio es la estimación del consumo eléctrico, que revela el crecimiento del consumo hacia el futuro. Debido a que nuestras observaciones y datos ya que suelen ser imprecisos, ambiguos o inciertos, para ello se debe incorporar un método cualitativo capaz de explicar este modelo.[38]

6.1 Respuesta a la demanda residencial.

La previsión de la carga eléctrica actualmente llega a ser un factor decisivo dentro de las operaciones de consumo energético. Siendo una prioridad en tiempos inestables del sistema eléctrico actual.[39]

La previsión de la carga eléctrica presenta una tarea desafiante ya que varios factores inciertos afectarán la precisión del modelo y deben considerarse, incluida la fluctuación de la demanda, la curva de carga histórica compleja.[40]

La respuesta voluntaria a la demanda, proporcionan importantes ahorros de energía en el sector residencial, que es uno de los principales contribuyentes a los picos de demanda.[41]

Además, el sistema de gestión de energía para el hogar se convierte en una forma efectiva para que los clientes residenciales participen en la respuesta a la demanda.[42]

6.2 Perspectiva del residente.

Las acciones aleatorias de los clientes residenciales son aquellas que cambian el perfil de carga. Estos incluyen la falta de respuesta ante su comportamiento volátil, el alto costo de la infraestructura de medición.[43]

La previsión del consumo de energía facilita la gestión de la demanda de electricidad y la planificación de la carga de los servicios públicos dentro de los alrededores residenciales.[44]

La mayoría de los estudios se han centrado en los clientes comerciales o en el consumo de energía a nivel de edificio residencial, por otra parte se han obtenido datos de mediciones adquiridas del comportamiento y variabilidad características del consumo eléctrico de un hogar individual.[45]

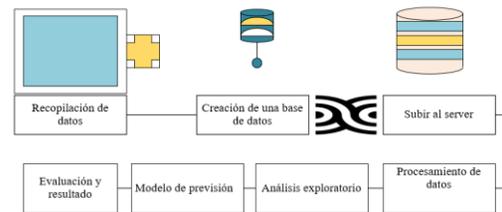


Figura 6. Creación de los elementos característicos del modelo ARIMA. [Autor].

Al modelar y pronosticar el consumo de electricidad de los hogares utilizando datos de medidores inteligentes, como se observa en la Figura 6, permitiremos implementar una gestión de carga eficaz en el lado de la demanda de los servicios residenciales.[46]

Debido a la insuficiencia de datos sobre el consumo de electricidad, la falta de información sobre el comportamiento del usuario final y el desconocimiento de la conducta del cliente residencial, es prudente la integración de un nuevo modelo de previsión ante los altos perfiles de consumo eléctrico actuales.[47]

3 Planteamiento del problema.

En la presente sección se da a conocer la incógnita de la demanda ante el usuario residencial y la variable afectada dentro del caso de estudio, manifestando así el comportamiento del perfil eléctrico residencial.

3.1 Comportamiento eléctrico del consumidor residencial.

El enigma actual de un consumidor de energía eléctrica o un cliente residencial en el presente va desde cuanto consume, hasta cuanto está dejando de consumir.

El consumo de electricidad se relaciona con las características internas de los hogares dando a conocer el consumo diario, semanal, mensual y hasta anual de un hogar residencial.

En días presentes la demanda de electricidad residencial ha ido en aumento. La gestión de la carga residencial es importante dado que el consumo de demanda ha aumentado en días en donde la mayoría de personas permanecen en sus hogares, siendo que gran parte de dicho consumo se da en horas pico.

Es importante en la planificación y el correcto uso de electricidad en días en los que ya mayoría de personas permanecen en sus hogares. A diferencia de la carga agregada, el consumo de energía de una casa residencial tiene una mayor correlación con el comportamiento de los residentes, por tanto, se decidió realizar un modelo de previsión de carga basado en la conducta de un sistema eléctrico residencial, evaluando el comportamiento volátil del usuario.

3.2 Equipos de medición eléctrica.

Al agrupar los datos asociados al consumo residencial, tomados en consideración por los medidores inteligentes para recopilar los datos asociados al consumo eléctrico residencial.

Examinando un agrupamiento jerárquico dentro del conjunto de la curva demanda para decidir la frecuencia óptima en curvas diarias, horarias, mensuales o anuales, mostrando un caso de alta variabilidad en la demanda de energía.

Empleando datos registrados reales obtenidos de las salidas de los equipos de control de carga eléctrica a partir de un medidor inteligente, como se observa en la Figura 7.



Figura 7. Procesamiento de lectura y aplicación del modelo MATLAB [Autor].

A partir de valores implementados mediante el uso de una base de datos de una nube hacia Matlab registrados por un medidor inteligente, tomados durante 3 años a partir de 2018 a 2020. Basándonos en el perfil de carga residencial se presenta un modelo de previsión autorregresivo ARIMA.

3.3 Valores de medición.

Un modelo autorregresivo es una representación de un proceso aleatorio, en el que la variable de interés depende de sus observaciones pasadas. A través de la metodología experimental.

Partimos con el análisis de perfil de voltaje establecido por datos recogidos de la nube registrados por el medidor inteligente durante los meses de enero 2018 y 2019.

Tabla 1. Algoritmo de previsión a corto plazo [Autor].

Algoritmo de predicción basada en el perfil de carga residencial.

Paso 1: Inicio del algoritmo

Paso 2: Procesamiento de datos tomados de la nube IoT.

Paso 3: Lectura de datos del consumo diario Aeon.

Paso 4: Implementación del modelo de previsión ARIMA

Paso 5: Visualización de gráficas comparativas de previsión anual.

Paso 6: Fin.

Los datos tomados por nuestros equipos de medición fueron recolectados de diferentes lugares. Durante el año 2018 los datos obtenidos y almacenados fueron tomados de un sector residencial ubicado por la Av. Isabel la Católica. Durante el año 2019 los datos obtenidos fueron recolectados por la Av. De los Guayacanes cerca del hospital Solca. Durante el año 2020 los datos registrados fueron tomados por San Isidro del Inca cerca de la Av. De las toronjas, tomando en cuenta datos pasados se estima una previsión para los años siguientes.[48]

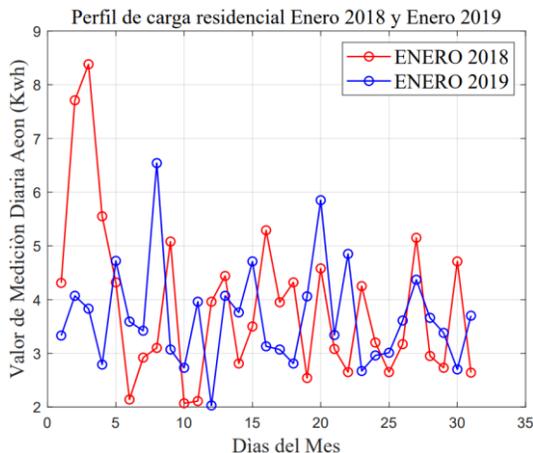


Figura 8. Valores de medición diaria del perfil de carga enero 2018 y enero 2019. [Autor].

Registrando el consumo diario y mensual obtenido durante todo el mes de enero, tomando en cuenta el perfil de carga residencial dentro de un corto plazo y analizando el consumo registrado, como se observa en la Figura 8.

A principios de 2019 el consumo energético sufrió un pequeño cambio disminuyendo el consumo energético durante los 7 primeros días del mes con respecto a los 3 primeros días de consumo en enero 2018, tomando en cuenta los

valores registrados anteriormente durante enero 2018.

Realizando una comparativa entre el año 2018 y 2019 el consumo ha ido en aumento durante el 2019, aumentando los picos de consumo registrados durante los días 7 y 8 y durante los días del 16 al 22 dentro del mismo mes.

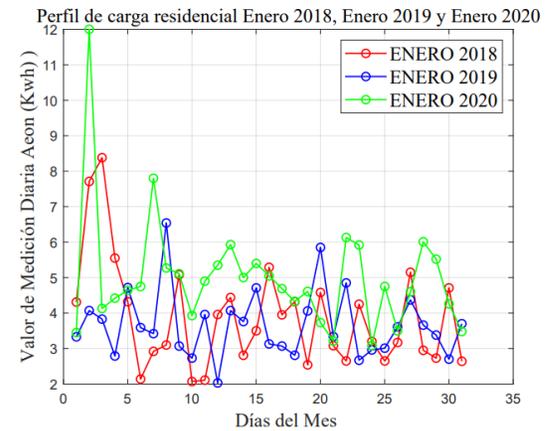


Figura 9. Perfil de consumo eléctrico enero 2020. [Autor]

Durante los primeros meses de enero 2020, tras sufrir una gran pandemia alrededor de todo el mundo el consumo energético se vio afectado drásticamente, tomando valores sumamente elevados debido a que el residente se vio en la obligación de permanecer dentro de su residencia.

Siendo un factor causante en el elevado aumento de consumo energético dentro del hogar, afectando mayormente a la taza excedente de carga establecida, como se observa en la Figura 9.

El incremento energético en base al comportamiento volátil del residente es el primer factor a dar a conocer durante este periodo, tomando en cuenta el consumo energético variable residencial.

3.4 Modelo de previsión autorregresivo ARIMA.

Establecido como un modelo de condición no estacional, relacionado con hechos pasados y una variable aleatoria. Este

modelo estadístico utiliza patrones de tiempos pasados permitiendo que el usuario encuentre patrones para una previsión a futuro.

Perfil de carga residencial Enero 2018 , Enero 2019 , Enero 2020 y Enero 2021

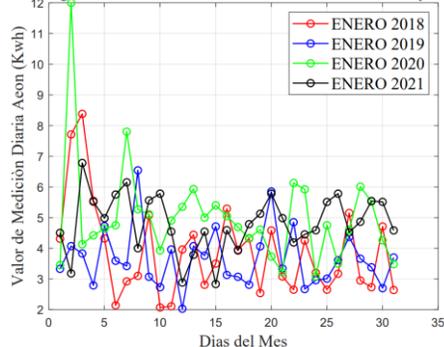


Figura 10. Perfil de consumo eléctrico residencial ARIMA año 2021. [Autor]

Durante el mes de enero 2021 se implementó la modelación de previsión ARIMA de consumo de carga eléctrica residencial establecido mediante datos registrados dentro de nuestra nube, durante el año 2018, 2019 y 2020 implementados mediante nuestros equipos de medición inteligente.

Permitiendo el uso del modelo de predicción de consumo de carga residencial eléctrico para enero del año 2021, como se observa en la Figura 10, disminuyendo el carácter volátil en cuanto a consumo energético.

Este modelo nos ayuda en gran parte a conocer o relacionar el consumo energético a futuro, estableciendo una idea al usuario en cuando a mejorar su calidad de vida dentro de su hogar, mejorando así la variabilidad existente en cuanto a consumo energético.

4. Modelación matemática.

Partimos de la intervención de un modelo matemático que interviene dentro de nuestro sistema de previsión. Establecido con el nombre de modelo ARIMA, conceptualizado como un modelo de series de tiempo autorregresivo y de medias móviles.

El cual utiliza variaciones y regresiones de datos tomados en el pasado con el fin de encontrar patrones hacia una predicción a futuro.

4.1 Modelo autorregresivo de orden (p)-AR.

En este modelo se establece a partir de una observación anterior, en donde la observación actual, se define como la suma de una cantidad finita (p).

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \dots + \phi_p Y_{t-p} + a_t \quad (1)$$

Donde:

- Y_t = Es una variable dependiente.
- Y_{t-1} = Es una variable independiente.
- Y_{t-2} = Es una variable independiente.
- Y_{t-3} = Es una variable independiente.
- a_t = Error o termino residual

En este caso las variables independientes son valores de las mismas variables, siendo que de este caso se da el nombre de autorregresivo.

4.2 Modelo de medias móviles de orden (q)-MA.

Es determinada mediante la llegada de impulsos aleatorios de observaciones ocurridas en el pasado. Está definida como la suma de los impulsos actuales y los impulsos anteriores.

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2)$$

Donde:

- a_t = Residuo o error en el periodo t.
- a_{t-1} = Valores anterior al error.
- a_{t-2} = Valores anteriores al error.

4.3 Modelo autorregresivo de medias móviles de orden (p, q)-ARMA.

Este modelo es la representación definida por el modelo autorregresivo y el modelo de medias móviles, siendo este determinado por las observaciones anteriores y los impulsos aleatorios de un caso en específico.

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3)$$

4.4 Modelo autorregresivo integrado de media móvil de orden (p, q, d)-ARIMA.

Siendo una representación de modelo anterior ARMA, tomando en cuenta el modelo autorregresivo y media móvil con la integración de un proceso de restablecimiento de integración de inestabilidad presente en una serie de tiempo pasado.

$$Y'_t = \phi_1 Y'_{t-1} + \phi_2 Y'_{t-2} + \phi_3 Y'_{t-3} + \dots + \phi_p Y'_{t-p} + at - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (4)$$

Donde:

Y'_t = Serie inducida a la estabilidad

5 Resultados.

La ecuación número 1 permite determinar un modelo autorregresivo determinando datos establecidos en un tiempo pasado, dando referencia a la obtención de datos en años anteriores tomando en cuenta datos actuales.

Siendo está una referencia al cambio entre una línea de acontecimientos pasados con la observación de resultados actuales.

Una vez determinada la ecuación se ratifica la obtención dentro de una base de

datos implementada en una nube Iot, implementada mediante la recopilación de datos y el análisis de evaluación, estimado en la aplicación de un modelo de previsión generado mediante MATLAB, basándonos en el perfil de carga residencial cubiertos en cada año.

Los factores obtenidos dentro del modelo autorregresivo dan espacio al modelo de la ecuación 2 en donde se ratifica un modelo de medias móviles, tomando en cuenta la observación de puntos aleatorios dentro de las observaciones pasadas.

Esto nos da a conocer que las observaciones pasadas nunca serán lineales, en cambio dan referencias a puntos variables. esta da referencia a las observaciones pasadas con los resultados actuales.

Mediante el modelo autorregresivo y medias móviles obtenemos el primer modelo de previsión establecido mediante la observación de eventos pasados con la variabilidad de los mismos, dando paso a un modelo ARMA representada en la ecuación 3.

Encontramos la representación de un modelo ARMA con la implementación de la integración de una inestabilidad en eventos pasados la cual a conocer la ecuación 4, determinada como el modelo ARIMA, siendo esta el modelo que nos permite relacionar patrones en observaciones pasadas con resultados actuales de previsión.

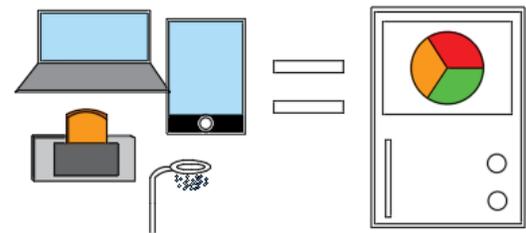


Figura 11. Consumo eléctrico en aparatos de uso cotidiano. [Autor]

Los equipos de medición eléctrica inteligente permiten almacenar datos del

consumo diario que tienen algunos aparatos o electrodomésticos de uso cotidiano en el día a día dentro del comportamiento variable del usuario.

Gracias a estos equipos obtenemos observaciones pasadas dentro de un lapso de tiempo determinado, llegando a tomar medidas respecto al manejo de su consumo a futuro.

La gran variabilidad del excesivo consumo eléctrico se debe mayormente a la falta del conocimiento del usuario respecto a su comportamiento volátil en el hogar, como se observa en la Figura 11.

Se puede determinar que el consumo de algunos electrodomésticos o aparatos de consumo diario son inestables respecto a su uso diario, el cual varía respecto al tiempo de consumo y elemento en uso como se puede apreciar en la figura 5 que nos puede dar a detalle la cantidad de energía que pueden llegar a consumir algunos elementos.

Realizando una secuencia comparativa entre datos reales y el modelo de predicción ARIMA dentro de enero del año 2019, mediante la extracción de datos recolectados y almacenados por un medidor inteligente, establecemos una predicción dentro del entorno de consumo variable del usuario.

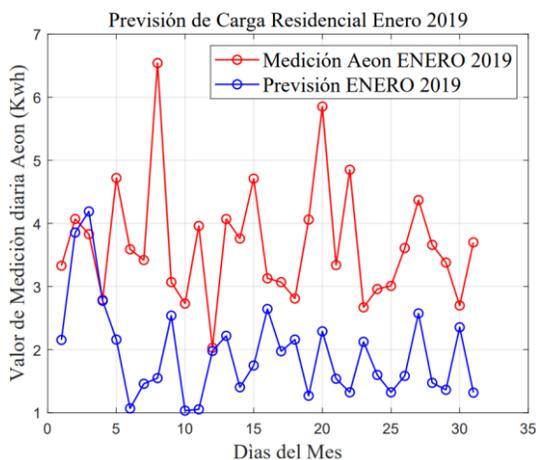


Figura 12. Predicción de carga residencial enero 2019. [Autor]

A partir del uso del modelo de predicción, como se observa en la Figura 12, logramos aventajarnos en años

posteriores mediante observaciones pasadas encontramos patrones para una predicción dentro de los siguientes años.

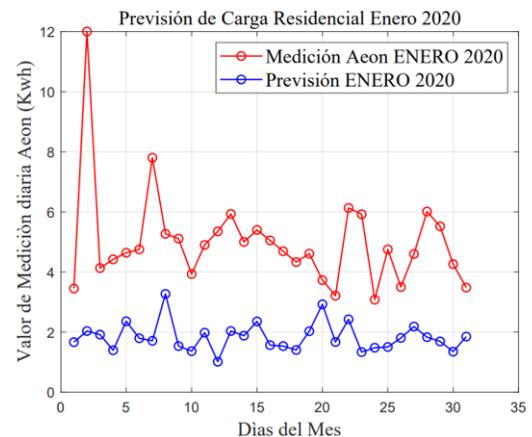


Figura 13. Predicción de carga residencial enero 2020. [Autor]

El modelo ARIMA es determinado por observaciones de datos pasados como una función lineal dada en la ecuación 4, al determinar dichas observaciones obtenidas por las variaciones en medias móviles, considerando en mejorar el perfil de carga eléctrica durante el año 2020, como se observa en la Figura 13.

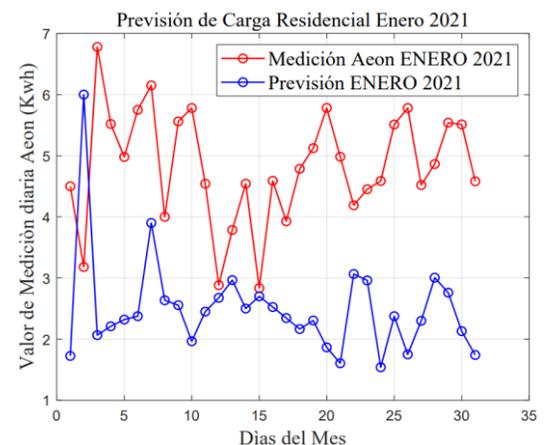


Figura 14. Predicción de carga residencial enero 2021. [Autor]

La estimación de predicción prevista durante el año 2021, como se observa en la vista en la Figura 14, es una mejora en cuanto a calidad de la carga establecida en observaciones de años pasados, reconocida como una predicción o patrones de medición para años futuros

En este punto se toma en cuenta las diferencias históricas pasadas con las estimadas por el modelo ARMA. El estudio del modelo ARIMA determina de manera que la suma cuadrática de dichos errores sea menor representando un proceso (p, q, d) . Siendo el error residual el cual disminuye con un mayor número de parámetros dentro del modelo.

El error dentro de una predicción de carga siempre será el pico inicial al igual que una desviación que degradan la estimación en una predicción.

Realizando una media comparativa en cada año obteniendo un caso de error residual dentro de nuestro conjunto de datos. Siendo la desviación resultante la cual afecta en el proceso de predicción entre datos pasados y el modelo ARIMA

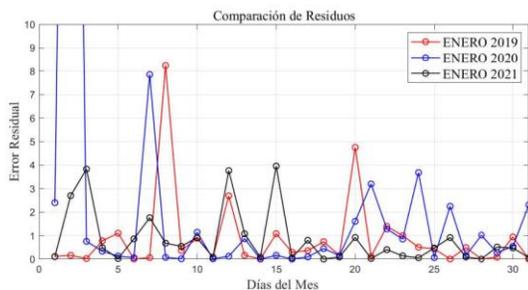


Figura 15. Error residual ARIMA. [Autor]

En cuanto a la desviación producida o error residual toma un cambio en consideración a la variación de datos observados en años pasados con respecto a una predicción prevista para años futuros, como se observa en la Figura 15.

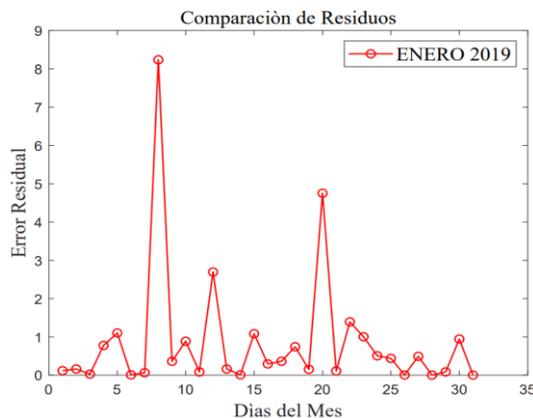


Figura 16. Error residual enero 2019. [Autor]

Aplicando el modelo ARIMA encontramos picos de error residual durante enero de 2019 observados en la figura 16, con respecto al modelo ARMA. En comparación con el modelo matemático de la ecuación 4 definida por el modelo ARIMA durante enero del año 2019, la diferencia entre el error se ve reducida, como se observa en la Figura 16.

La ventaja de un modelo de previsión ARIMA es cual permite reducir el error residual, como se observa en la Figura 17.

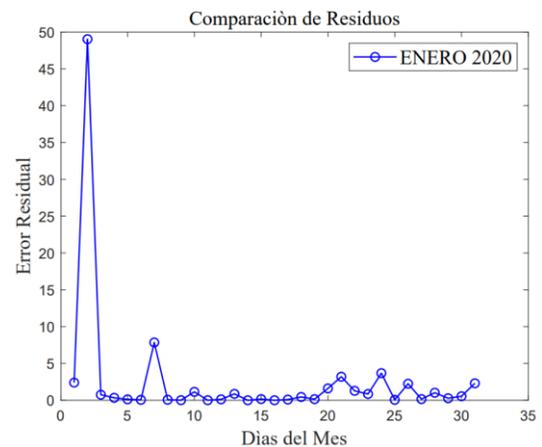


Figura 17. Error residual enero 2020. [Autor]

Mediante una previsión pronosticada a años futuros, dicho de otra manera, permitiendo llevar gran ventaja ante las pérdidas innecesarias de energía eléctrica residencial evitando el excesivo consumo de carga, como se observa en la Figura 18.

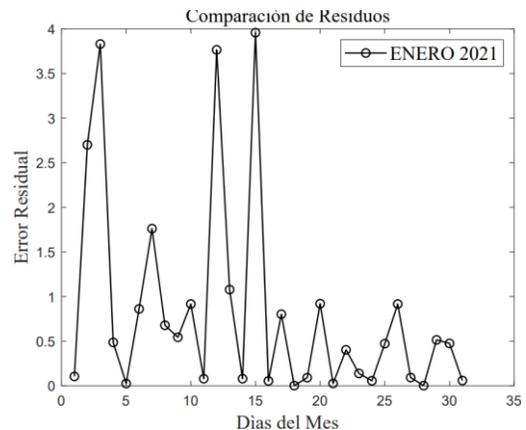


Figura 18. Error residual enero 2021. [Autor]

El modelo autorregresivo ARIMA establece una gran confiabilidad predictiva para años futuros, el modelo establecido y representado en este artículo representa la evolución ante la previsión de consumo energético residencial y la reducción del error residual con patrones observados en años pasados, como se observa en la Figura 19.

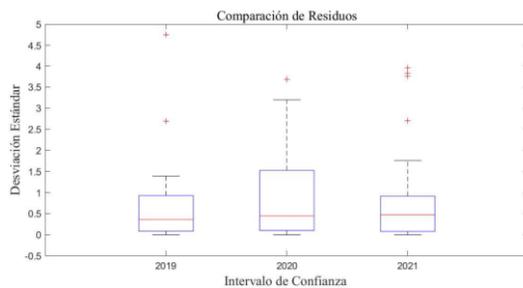


Figura 19. Intervalos de confianza enero 2019, 2020 y 2021. [Autor]

6 Conclusiones

Debido a las repercusiones ocasionadas por el alto consumo eléctrico, relacionado con respecto al comportamiento volátil del usuario consumidor es necesario el implementar un modelo que represente mejoras en cuanto a calidad de consumo domiciliario se refiere, es necesario que el modelo represente patrones pasados de consumo residencial, tomando en cuenta consumos anteriores representativos durante un lapso de tiempo establecido y compararlos en años futuros.

En base al modelo reflejado en este documento se da a conocer soluciones futuras, aumentando progresivamente al utilizar variaciones o regresiones de datos con el fin de encontrar patrones para una predicción a futuro. Mencionando que cada variación dependerá del consumidor y el uso cotidiano de elemento de consumo eléctrico residencial.

A partir de la estimación y validación del método de previsión ARIMA, estimado mediante la recopilación de datos implementados en una nube Iot, estimado mediante la evaluación de los mismo e implementando una programación

estimada de previsión de carga residencial en MATLAB, mediante la ejecución de la programación obtuvimos resultados favorables en el proceso de previsión de años futuros mediante la observación de patrones pasados.

La validación del modelo se ve dada por la extracción de datos registrados por nuestros equipos de medición inteligentes, implementando la lectura de una base de datos extraídos de una nube y creando un modelo matemático dentro del programa MATLAB, basados en el perfil de carga eléctrica residencial establecidos durante los años 2018, 2019 y 2020.

Durante estos años de prueba se analizó el incremento o decremento respectivamente del perfil de consumo mensual dentro conjunto de datos recogidos y almacenados durante un lapso de tiempo, en el cual se implementó el modelo de previsión ARIMA reflejando la previsión estimada para enero del año 2021.

Se trata de un modelo dinámico de series temporales en donde las estimaciones futuras vienen explicadas por hechos pasados. La estimación de previsión del modelo ARIMA, es bien vista por el usuario consumidor denotando gran ventaja en cuanto a otros modelos de predicción, tomando en cuenta variaciones y regresiones pasadas encontrando con gran facilidad predicciones para años futuros.

Los años estudiados dentro de este modelo permiten demostrar las soluciones y la efectividad del uso de una previsión, encontrando y estimando con claridad soluciones ante el comportamiento volátil en cuanto a consumo se refiere. La ventaja de este modelo es que permite determinar si en realidad es necesario o no una expansión de generación dentro del sector estudiado, determinando si la carga residencial excede la carga establecida en el sector.

A partir de la recopilación de datos obtenidos y considerando que el conjunto de datos obtenidos, estudiados y analizados en 3 sectores residenciales de diferente procedencia permite mejorar el estudio de previsión, al obtener un mayor conjunto de datos de muestreo permitiendo una escalabilidad al momento de manejar y evidenciar resultados verídicos del modelo de previsión ARIMA en el estudio de carga residencial dentro del comportamiento del usuario consumidor.

7 Referencias

- [1] P. Amin, L. Cherkasova, R. Aitken, and V. Kache, "Automating energy demand modeling and forecasting using smart meter data," *Proc. - 2019 IEEE Int. Congr. Internet Things, ICIOT 2019 - Part 2019 IEEE World Congr. Serv.*, pp. 133–137, 2019, doi: 10.1109/ICIOT.2019.00032.
- [2] A. Kapoor and A. Sharma, "A Comparison of Short-Term Load Forecasting Techniques," *Int. Conf. Innov. Smart Grid Technol. ISGT Asia 2018*, pp. 1189–1194, 2018, doi: 10.1109/ISGT-Asia.2018.8467788.
- [3] F. Amin and M. M. Borhan Elmi, "Security Assessment and Reliability Improvement with considering Demand Response," pp. 71–75, 2021, doi: 10.1109/epdc53015.2021.9610824.
- [4] W. Kong, Z. Y. Dong, D. J. Hill, F. Luo, and Y. Xu, "Short-term residential load forecasting based on resident behaviour learning," *IEEE Trans. Power Syst.*, vol. 33, no. 1, pp. 2017–2018, 2018, doi: 10.1109/TPWRS.2017.2688178.
- [5] Y. Hong, Y. Zhou, Q. Li, W. Xu, and X. Zheng, "A deep learning method for short-term residential load forecasting in smart grid," *IEEE Access*, vol. 8, pp. 55785–55797, 2020, doi: 10.1109/ACCESS.2020.2981817.
- [6] M. Razghandi and D. Turgut, "Residential appliance-level load forecasting with deep learning," *2020 IEEE Glob. Commun. Conf. GLOBECOM 2020 - Proc.*, vol. 2020-Janua, 2020, doi: 10.1109/GLOBECOM42002.2020.9348197.
- [7] M. Elsaraiti, G. Ali, H. Musbah, A. Merabet, and T. Little, "Time series analysis of electricity consumption forecasting using ARIMA model," *IEEE Green Technol. Conf.*, vol. 2021-April, pp. 259–262, 2021, doi: 10.1109/GreenTech48523.2021.00049.
- [8] Q. Peng and Z. Liu, "Short-Term Residential Load Forecasting Based on Smart Meter Data Using Temporal Convolutional Networks," pp. 5423–5428, 2020.
- [9] Y. Zhang, D. Li, and B. Yang, "Application of long-short term memory network and its variants in short-term power load time series forecasting," *Proc. - 2020 Int. Conf. Smart Grids Energy Syst. SGENS 2020*, pp. 197–202, 2020, doi: 10.1109/SGES51519.2020.00042.
- [10] M. Y. Cho, J. C. Hwang, and C. S. Chen, "Customer short term load forecasting by using ARIMA transfer function model," *Proc. Int. Conf. Energy Manag. Power Deliv. EMPD*, vol. 1, no. 95, pp. 317–322, 1995, doi: 10.1109/empd.1995.500746.
- [11] P. Koponen, "Short-term load forecasting model based on smart metering data: Daily energy prediction using physically based component model structure," *2012 Int. Conf. Smart Grid Technol. Econ. Policies, SG-TEP 2012*, pp. 1–4, 2012, doi: 10.1109/SG-TEP.2012.6642386.

- [12] M. A. Zuniga-Garcia, G. Santamaria-Bonfil, G. Arroyo-Figueroa, and R. Batres, "An Association-Rule Method for Short-Term Electricity Demand Forecasting and Consumption Pattern Recognition," *Proc. Spec. Sess. - 2018 17th Mex. Int. Conf. Artif. Intell. MICAI 2018*, pp. 3–7, 2018, doi: 10.1109/MICAI46078.2018.00008.
- [13] P. Amin, L. Cherkasova, R. Aitken, and V. Kache, "Analysis and demand forecasting of residential energy consumption at multiple time scales," *2019 IFIP/IEEE Symp. Integr. Netw. Serv. Manag. IM 2019*, pp. 494–499, 2019.
- [14] S. Park, S. Han, and Y. Son, "Demand power forecasting with data mining method in smart grid," *2017 IEEE Innov. Smart Grid Technol. - Asia Smart Grid Smart Community, ISGT-Asia 2017*, pp. 1–6, 2018, doi: 10.1109/ISGT-Asia.2017.8378423.
- [15] H. Cai, S. Shen, Q. Lin, X. Li, and H. Xiao, "Predicting the Energy Consumption of Residential Buildings for Regional Electricity Supply-Side and Demand-Side Management," *IEEE Access*, vol. 7, pp. 30386–30397, 2019, doi: 10.1109/ACCESS.2019.2901257.
- [16] Z. Guo, K. Zhou, C. Zhang, X. Lu, W. Chen, and S. Yang, "Residential electricity consumption behavior: Influencing factors, related theories and intervention strategies," *Renew. Sustain. Energy Rev.*, vol. 81, no. August 2017, pp. 399–412, 2018, doi: 10.1016/j.rser.2017.07.046.
- [17] L. Yijing *et al.*, "Journal of Building Environment," vol. 184, no. August, p. 107229, 2020.
- [18] K. Xiang, H. Lin, and B. Chen, "A residential use-electric energy consumption model based development of household appliances," pp. 0–4, 2002.
- [19] M. Sabbaghi, S. Behdad, and J. Zhuang, "crossmark," vol. 182, no. October, pp. 545–563, 2016.
- [20] L. T. Al-Bahrani, M. Seyedmahmoudian, B. Horan, and A. Stojcevski, "Distribution transformer load behavior, burden, and characteristics of residential consumers: A case study of Baghdad City," *Energy Build.*, vol. 210, 2020, doi: 10.1016/j.enbuild.2019.109693.
- [21] K. V. Zúñiga, I. Castilla, and R. M. Aguilar, "Using fuzzy logic to model the behavior of residential electrical utility customers," *Appl. Energy*, vol. 115, pp. 384–393, 2014, doi: 10.1016/j.apenergy.2013.11.030.
- [22] M. Shen, Y. Lu, K. H. Wei, and Q. Cui, "Prediction of household electricity consumption and effectiveness of concerted intervention strategies based on occupant behaviour and personality traits," *Renew. Sustain. Energy Rev.*, vol. 127, no. April, 2020, doi: 10.1016/j.rser.2020.109839.
- [23] P. Day *et al.*, "Residential power load forecasting," *Procedia Comput. Sci.*, vol. 28, pp. 457–464, 2014, doi: 10.1016/j.procs.2014.03.056.
- [24] F. M. Andersen, P. A. Gunkel, H. K. Jacobsen, and L. Kitzing, "Residential electricity consumption and socioeconomic characteristics. An econometric analysis of Danish microeconomic and smart meter data," vol. 100, no. December 2020, 2021.
- [25] C. Stegner, O. Glaß, and T. Beikircher, "Comparing smart metered, residential power demand with standard load profiles," *Sustain. Energy, Grids Networks*, vol. 20, pp. 1–10, 2019, doi: 10.1016/j.segan.2019.100248.

- [26] H. Komatsu and O. Kimura, "Peak demand alert system based on electricity demand forecasting for smart meter data," *Energy Build.*, vol. 225, 2020, doi: 10.1016/j.enbuild.2020.110307.
- [27] M. N. Fekri, H. Patel, K. Grolinger, and V. Sharma, "Deep learning for load forecasting with smart meter data: Online Adaptive Recurrent Neural Network," *Appl. Energy*, vol. 282, no. July 2020, 2021, doi: 10.1016/j.apenergy.2020.116177.
- [28] G. Amaral *et al.*, "Algoritmos De Optimización Basados En Capacidad Y Cobertura De Redes Inalámbricas Para La Infraestructura De Medición Avanzada De Energía Eléctrica," *J. Petrol.*, vol. 369, no. 1, pp. 1689–1699, 2013.
- [29] V. Ganesh, S. Senthilmurugan, A. K. V M, A. R. R. R, and A. Prabhu, "Smart Grid - Meters and Communications - Design , Challanges , Issues , Oppurtunities and Applications," no. Icadee, pp. 1–5, 2020.
- [30] B. Yildiz, J. I. Bilbao, J. Dore, and A. B. Sproul, "Recent advances in the analysis of residential electricity consumption and applications of smart meter data," *Appl. Energy*, vol. 208, no. January, pp. 402–427, 2017, doi: 10.1016/j.apenergy.2017.10.014.
- [31] N. Qi *et al.*, "Smart meter data-driven evaluation of operational demand response potential of residential air conditioning loads," *Appl. Energy*, vol. 279, no. May, 2020, doi: 10.1016/j.apenergy.2020.115708.
- [32] D. H. Vu, K. M. Muttaqi, A. P. Agalgaonkar, and A. Bouzerdoum, "Intra-hour and hourly demand forecasting using selective order autoregressive model," *2016 IEEE Int. Conf. Power Syst. Technol. POWERCON 2016*, pp. 1–6, 2016, doi: 10.1109/POWERCON.2016.7754014.
- [33] X. Jin, Y. Dong, J. Wu, and J. Wang, "An improved combined forecasting method for electric power load based on autoregressive integrated moving average model," *Proc. - 2010 Int. Conf. Inf. Sci. Manag. Eng. ISME 2010*, vol. 2, pp. 476–480, 2010, doi: 10.1109/ISME.2010.124.
- [34] N. Kamel and Z. Baharudin, "Short term load forecast using burg autoregressive technique," *2007 Int. Conf. Intell. Adv. Syst. ICIAS 2007*, pp. 912–916, 2007, doi: 10.1109/ICIAS.2007.4658519.
- [35] X. Wang, T. Zhao, H. Liu, and R. He, "Power consumption predicting and anomaly detection based on long short-term memory neural network," *2019 IEEE 4th Int. Conf. Cloud Comput. Big Data Anal. ICCCBDA 2019*, pp. 487–491, 2019, doi: 10.1109/ICCCBDA.2019.8725704.
- [36] S. Wang, X. Deng, H. Chen, Q. Shi, and D. Xu, "A bottom-up short-term residential load forecasting approach based on appliance characteristic analysis and multi-task learning," *Electr. Power Syst. Res.*, vol. 196, no. July 2020, 2021, doi: 10.1016/j.epsr.2021.107233.
- [37] H. Son and C. Kim, "Short-term forecasting of electricity demand for the residential sector using weather and social variables," *Resour. Conserv. Recycl.*, vol. 123, pp. 200–207, 2017, doi: 10.1016/j.resconrec.2016.01.016.
- [38] A. Azadeh, S. F. Ghaderi, and A. Gitiforouz, "Estimating electricity demand function in residential sector by fuzzy regression," *IEEE Int. Symp. Ind. Electron.*, vol. 1, no. 1982, pp. 390–394, 2006, doi:

- 10.1109/ISIE.2006.295625.
- [39] Y. Zhang, R. Yang, K. Zhang, H. Jiang, and J. J. Zhang, "Consumption Behavior Analytics-Aided Energy Forecasting and Dispatch," *IEEE Intell. Syst.*, vol. 32, no. 4, pp. 59–63, 2017, doi: 10.1109/MIS.2017.3121551.
- [40] Y. Liu and F. Gao, "Ultra-short-term forecast of power load based on load characteristics and embedded system," *Microprocess. Microsyst.*, no. November, 2020, doi: 10.1016/j.micpro.2020.103460.
- [41] F. A. Diawuo, M. Sakah, S. de la Rue du Can, P. C. Baptista, and C. A. Silva, "Assessment of multiple-based demand response actions for peak residential electricity reduction in Ghana," *Sustain. Cities Soc.*, vol. 59, no. May, 2020, doi: 10.1016/j.scs.2020.102235.
- [42] X. Qu, H. Hui, Y. Ding, and K. Luan, "ScienceDirect ScienceDirect ScienceDirect Optimal Control of Intelligent Electricity Consumption for on District Heating and Cooling for Optimal Control of Intelligent Electricity Consumption Residential Customers Considering Demand Response Residential C," *Energy Procedia*, vol. 145, pp. 510–515, 2018.
- [43] S. Gyamfi, S. Krumdieck, and T. Urmee, "Residential peak electricity demand response - Highlights of some behavioural issues," *Renew. Sustain. Energy Rev.*, vol. 25, pp. 71–77, 2013, doi: 10.1016/j.rser.2013.04.006.
- [44] X. M. Zhang, K. Grolinger, M. A. M. Capretz, and L. Seewald, "Forecasting Residential Energy Consumption: Single Household Perspective," *Proc. - 17th IEEE Int. Conf. Mach. Learn. Appl. ICMLA 2018*, pp. 110–117, 2019, doi: 10.1109/ICMLA.2018.00024.
- [45] Y. Iwafune, Y. Yagita, and K. Ogimoto, "Estimation of appliance electricity consumption by monitoring currents on residential distribution boards," *2010 Int. Conf. Power Syst. Technol. Technol. Innov. Mak. Power Grid Smarter, POWERCON2010*, pp. 1–6, 2010, doi: 10.1109/POWERCON.2010.5666076.
- [46] D. A. Bashawyah and S. M. Qaisar, "Machine Learning Based Short-Term Load Forecasting for Smart Meter Energy Consumption Data in London Households," pp. 99–102, 2021, doi: 10.1109/ELIT53502.2021.9501104.
- [47] M. Afrasiabi, M. Mohammadi, M. Rastegar, L. Stankovic, S. Afrasiabi, and M. Khazaei, "Deep-Based Conditional Probability Density Function Forecasting of Residential Loads," *IEEE Trans. Smart Grid*, vol. 11, no. 4, pp. 3646–3657, 2020, doi: 10.1109/TSG.2020.2972513.
- [48] J. Taco and L. Tipán, "Metodología para la determinación de indicadores de Eficiencia Eléctrica en la Zona Residencial," *Rev. Técnica "Energía"*, vol. 16, no. 2, pp. 70–90, 2020, doi: 10.37116/revistaenergia.v16.n2.2020.354.