



Modelo de optimización para la gestión colectiva de la demanda de energía en hogares inteligentes

Optimization Model for Collective Energy Demand Management in Smart Homes

  Nelson Mauricio Bejarano¹;
 Francisco David Moya Chaves²;
 Óscar Danilo Montoya³

¹Universidad Distrital Francisco José de Caldas,
Bogotá D.C.- Colombia
nmbejaranob@udistrital.edu.co

²Universidad Distrital Francisco José de Caldas,
Bogotá D.C.- Colombia
fdmoyac@udistrital.edu.co

³Universidad Distrital Francisco José de Caldas,
Bogotá D.C.- Colombia
odmontoyag@udistrital.edu.co

Cómo citar / How to cite

N. M. Bejarano, F. D. Moya Chaves, and O. D. Montoya, “Modelo de optimización para la gestión colectiva de la demanda de energía en hogares inteligentes,” *Tecnológicas*, vol. 27, no. 60, e3014, 2024.
<https://doi.org/10.22430/22565337.3014>

Resumen

Los sistemas eléctricos están evolucionando hacia redes inteligentes para mejorar su eficiencia y confiabilidad mediante estrategias de gestión y respuesta a la demanda. Este estudio presenta el Modelo Multiusuario de Cargas Eléctricas Controlables (MMCEC), un modelo de optimización desarrollado para gestionar colectivamente la demanda residencial de múltiples usuarios mediante la Programación de Cargas Eléctricas Controlables (PCEC). El objetivo del modelo fue minimizar el costo de la energía y lograr una distribución más uniforme de la carga eléctrica, teniendo en cuenta tarifas dinámicas de precios y restricciones específicas. La metodología se basó en técnicas clásicas de optimización en dos etapas. La primera se enfocó a nivel de único usuario utilizando el método de búsqueda exhaustiva para seleccionar soluciones que minimicen el costo de la factura de cada usuario. La segunda etapa empleó el método de búsqueda local para la optimización multiusuario, para encontrar una curva de demanda más plana. Para ello, se diseñó un algoritmo en MATLAB® que simuló un escenario con 60 usuarios durante 24 horas, programando los periodos más adecuados de encendido/apagado de las cargas controlables. Se compararon dos escenarios: uno donde los usuarios administran sus cargas a su conveniencia y otro donde se aplicó el modelo propuesto. Los resultados indicaron una disminución de los picos de demanda, con un ahorro promedio del 4.94 % en la factura eléctrica para el conjunto de usuarios y hasta el 12.34 % individualmente. La simulación logró esta solución óptima en 25 minutos a pesar de la complejidad computacional que implica gestionar la demanda de 60 usuarios. Por tal motivo, el modelo planteado utilizó métodos simples para optimizar múltiples variables, proporcionando un mejor rendimiento en comparación con el procesamiento requerido por algoritmos más complejos.

Palabras clave

Gestión de la demanda, respuesta a la demanda energética, programación de cargas eléctricas, perfil de consumo energético, métodos de optimización matemática.

Abstract

Power systems are evolving towards smart grids to improve their efficiency and reliability through demand response and management strategies. This study presents the Multi-User Model of Controllable Electric Loads (MUMCEL), an optimization model developed to collectively manage the residential demand of multiple users, through Controllable Electric Load Scheduling (CELS). The objective of the model was to minimize the cost of energy and achieve a more uniform distribution of the electric load, taking into account dynamic pricing rates and specific constraints. The methodology was based on classical optimization techniques in two stages. The first stage focused on the single user level using the exhaustive search method to select solutions that minimize the cost of each user's bill. The second stage employed the local search method for multi-user optimization to find a flatter demand curve. For this purpose, an algorithm was designed in MATLAB® that simulated a scenario with 60 users for 24 hours, scheduling the most appropriate on/off periods of controllable loads. Two scenarios were compared: one where users manage their loads at their convenience and the other where the proposed model was applied. The results indicated a decrease in peak demand, with an average savings of 4.94 % on the electricity bill for all users and up to 12.34 % individually. The simulation achieved this optimal solution in 25 minutes, despite the computational complexity involved in managing the demand of 60 users. Therefore, the model used simple methods to optimize multiple variables, providing better performance compared to processing that would require a more complex algorithm.

Keywords

Demand management, response to energy demand, electric load scheduling, energy consumption profile, mathematical optimization methods.

1. INTRODUCCIÓN

En las últimas décadas, los sistemas eléctricos han venido enfrentando frecuentes escenarios de esfuerzo excesivo a causa del continuo crecimiento de la demanda de energía, interrupciones de las líneas de transmisión durante horas pico, envejecimiento de la infraestructura de la red, incorporación de recursos de generación distribuida, entre otros; de ahí que conlleven a problemas de confiabilidad, baja eficiencia, pérdidas de energía y aumento de costos eléctricos asociados [1]-[5], así mismo, el uso de combustibles fósiles plantea preocupaciones ambientales a causa de las altas emisiones de gases de efecto invernadero [6], [7]. Ante esta situación, las redes eléctricas han iniciado un proceso de modernización y transformación hacia las redes inteligentes [8], [9], estableciendo cambios tecnológicos, financieros y sociales que posibiliten el suministro de energía eléctrica con mayor calidad, sustentabilidad, seguridad y confiabilidad. Estas redes permiten un flujo bidireccional de electricidad y datos, desde el distribuidor de energía hasta el usuario final, ya que combinan tecnologías de la información y comunicación con metodologías de automatización para el control, monitoreo y mantenimiento de sistemas eléctricos [10]-[12]. No obstante, afrontar los cambios mencionados en la implementación de redes inteligentes implica el empleo de sistemas de gestión de energía para hogares inteligentes (HEMS, por sus siglas en inglés) teniendo en cuenta que más de un tercio de la energía eléctrica se consume en instalaciones residenciales [2], [9], [11], [13], [14].

Por lo cual, las redes inteligentes incorporan conceptos como: la gestión al lado de la demanda (DSM, por sus siglas en inglés), que se encarga de planificar e implementar estrategias orientadas a modificar el horario de consumo de energía eléctrica para reducir los picos de demanda y las emisiones de CO₂ [15]-[17], esto se logra mediante la conexión y desconexión automática de cargas eléctricas en el hogar por medio de tecnologías en domótica y modelos de optimización [18], de manera que permite minimizar los costos de la factura de electricidad y equilibrar la curva de demanda [11], [19]; el segundo concepto es la respuesta a la demanda (DR, por sus siglas en inglés), que se refiere al uso de precios dinámicos para incentivar a los usuarios finales a disminuir el consumo de electricidad durante ciertos periodos tarifarios [6], [8], [9], [17], estos precios varían según la demanda, siendo altos cuando la demanda es mayor (horas pico) y bajos cuando la demanda es menor (horas valle).

En las décadas de los 80's y 90's, se desarrollaron métodos de DSM como el recorte de picos, conservación estratégica, relleno de valles, crecimiento estratégico de la carga, desplazamiento de carga y flexibilización de la carga; sin embargo, fue a partir del año 2000 cuando se implementó la generación distribuida con tecnologías enfocadas al control, monitoreo y medición a través de equipos electrónicos inteligentes [20]. Así mismo, en la DSM se emplean dos enfoques: el control indirecto y el control directo. En el control indirecto, se utilizan incentivos en los precios y la interacción social para fomentar cambios en el comportamiento de consumo mediante algoritmos de optimización. Los esquemas tarifarios utilizados incluyen el tiempo de uso, el precio crítico de pico, el precio por carga máxima y el precio dinámico o de tiempo real [5]. En el control directo, la comercializadora actúa directamente sobre las cargas, lo que implica duras restricciones al usuario en la administración de sus cargas eléctricas [21].

Es importante mencionar que al usuario final le resulta difícil programar el encendido y apagado de los electrodomésticos manualmente debido a la falta de conocimientos técnicos, de tiempo o no son lo suficientemente proactivos para participar en la DR en sus hogares [1], [22]. Por consiguiente, la Programación de Cargas Eléctricas Controlables (PCEC) es fundamental en un HEMS, siendo responsable del monitoreo y control de las cargas eléctricas según indicaciones y especificaciones por parte del usuario [23]; además para el desarrollo

del HEMS influyen variables externas como el precio, los problemas medio ambientales, el bienestar personal, la educación en eficiencia energética y la responsabilidad del usuario para ser un agente activo en la DSM, que afectan los hábitos y el comportamiento por parte del consumidor residencial a la hora de hacer uso de sus electrodomésticos [9].

Es importante mencionar, que al programar los electrodomésticos en los horarios que más les convenga a los usuarios, no garantiza el aplanamiento de la curva de carga en las redes de distribución; por ello se presenta el desafío de realizar una coordinación entre los usuarios que permita la conexión de sus cargas en diferentes momentos del día y, por tanto, obtener una optimización adecuada del consumo eléctrico. Con base en lo mencionado, esta investigación pretende contribuir al desarrollo de una estrategia para la PCEC en la gestión colectiva de la demanda en redes eléctricas de distribución, planteando un modelo matemático que busque aplanar la curva de consumo y disminuir el costo de la energía eléctrica. En la literatura se encuentran varios algoritmos de optimización enfocados en soluciones para la gestión de la demanda, algunos de estos se presentan a continuación.

Los algoritmos de optimización son una herramienta matemática que permite solucionar problemas en ingeniería y ciencia de gran complejidad en tiempos de cómputo relativamente bajos [24]. Estas metodologías de optimización incluyen algoritmos heurísticos y metaheurísticos, así como métodos exactos basados en gradiente y puntos interiores, que en combinación con algoritmos de ramificación y sondeo pueden resolver desde problemas de programación lineal, hasta modelos de programación no lineal entera mixta [22].

Múltiples algoritmos se han desarrollado para discutir el problema de la PCEC, en la literatura se observan distintas soluciones con enfoque lineales, no lineales, heurísticos o metaheurísticos, que tienen en consideración parámetros como: los requerimientos del usuario, restricciones de confort, aspectos ambientales y sociales, entre otros. En [1], se presenta un algoritmo para la gestión de la energía en el hogar que garantiza que el consumo del hogar se establezca por debajo de un límite de demanda, considerando las preferencias del cliente y a la vez, proporcionando una mayor flexibilidad en el funcionamiento de las cargas. En [10], se propone un esquema de control cooperativo para una red inteligente de edificios residenciales, utilizando el modelo de control predictivo para realizar una adecuada coordinación entre edificios y con ello, aprovechar el uso de fuentes renovables y la flexibilidad en la operación de las cargas térmicas.

En [23], se utiliza un enfoque heurístico de procedimiento de búsqueda adaptativa aleatoria codiciosa para maximizar la energía disponible de los recursos distribuidos en una casa inteligente y disminuir el suministro de energía proveniente de la red de distribución. Los autores destacan como ventaja la contribución original de un modelo simplificado para programar cargas controlables, aunque señalan como desventaja el tiempo de simulación en el cálculo. En [18] y [22], se presenta el modelo de optimización matemática para la programación de cargas controlables (MCELS, por sus siglas en inglés) en edificios inteligentes y en una casa inteligente, respectivamente. El MCELS es un método clásico de optimización con modelado lineal, lo que le permite tener un mejor rendimiento al ser un modelo simple y al compararlo con el método heurístico mostrado en [23], demuestra un desempeño superior al reducir costos y uso de la red eléctrica; en el caso de los edificios inteligentes, se ofrece la posibilidad de reducir la factura eléctrica de cada usuario y establecer un cálculo para el pago equitativo entre los diferentes usuarios.

También se tienen otros enfoques como el modelado no lineal entero mixto (MINLP, por sus siglas en inglés) y la programación lineal de enteros mixtos (MILP, por sus siglas en inglés). En [8], se formula un MINLP multiobjetivo que considera el costo y el nivel de comodidad del consumidor, los resultados indican que los usuarios pueden mejorar su comodidad, pero mayor será su costo en la factura. Además, en [25] se presenta un modelo HEMS en tres escenarios: normal, económico e inteligente, que utiliza un MINLP de múltiples objetivos, incluyendo costos de energía, comodidad

del usuario y relación pico-promedio (PAR, por sus siglas en inglés). Los resultados muestran que el escenario inteligente reduce considerablemente los costos de energía con una mínima disminución en la comodidad del usuario y el PAR. Sin embargo, este modelo requiere que los usuarios configuren manualmente muchos parámetros y no puede adaptarse en tiempo real a cambios externos.

Mientras que en [2], [3], [6], [7], se interesan por el enfoque MILP; [3] y [6] utilizan este algoritmo para reducir la carga máxima y homogeneizar la curva de carga dentro de la red eléctrica. Sin embargo, [3] indica que un mayor número de restricciones puede evitar que se produzcan nuevos picos después de cambiar las cargas eléctricas, pero señala como desventaja que el modelo prioriza la solución más barata. En el caso de [2], minimiza el costo total de producción y, al mismo tiempo, reduce las facturas de electricidad individuales; pero a diferencia de [3] y [6], el estudio [2] considera las preferencias de los hogares participantes, obteniendo una conclusión similar a la expuesta por [8]. Por último, [7] utiliza el MILP junto con un método de solución exacta para minimizar el costo de la electricidad en una casa inteligente, donde el segundo método mostró mejor eficiencia que el MILP.

Ahora bien, también se destacan algoritmos estocásticos como el presentado en [9], [26], [27]. En [9], se propone un prototipo de sistema que posibilita la medición y gestión de la energía, facilitando actividades de supervisión, monitoreo y control en el hogar mediante algoritmos de decisión; en [26] se propone un algoritmo para disminuir el costo de cada ciclo de carga de un cargador residencial para vehículos eléctricos y aplanar la curva de carga del usuario; con la validación del modelo, se implementa un hardware para integrarlo a un cargador inteligente. En el artículo [27] se propone un enfoque de optimización estocástica biobjetivo para la programación de electrodomésticos controlables en hogares inteligentes. El modelo se formula como un problema de programación entera mixta con el objetivo de minimizar el costo de la factura eléctrica y maximizar la satisfacción del usuario, para ello, se desarrollan métodos de resolución estocástica, planteando un enfoque de simulación-optimización y una heurística voraz. Los resultados demuestran que el primer enfoque obtiene mejores soluciones que la heurística; sin embargo, esta última es más rápida. Además, se señala que los casos con múltiples usuarios son más difíciles de resolver que aquellos con un solo usuario, debido a la necesidad de coordinar el uso de los electrodomésticos entre los clientes, lo que ocasiona un tiempo de computación más largo.

Por otro lado, existen software que incorporan algoritmos de optimización, por ejemplo, en [28] se desarrolla un modelo matemático para la programación de cargas eléctricas flexibles y sistemas de almacenamiento de energía, teniendo en cuenta las curvas de demanda generadas por la pandemia del COVID-19; este modelo ha sido implementado en Python, basado en la herramienta de optimización Gurobi.

Otros modelos utilizados por la comunidad científica para la gestión de la demanda son el algoritmo genético y el algoritmo evolutivo, definidos como técnicas de programación fundamentadas en la evolución biológica para resolver problemas de optimización. La Tabla 1 muestra algunos artículos que utilizan estos algoritmos para gestionar la demanda.

De igual manera, un enfoque ampliamente reconocido en la DSM es la optimización por enjambre de partículas, un método heurístico orientado a encontrar mínimos o máximos globales, su funcionamiento está inspirado en el comportamiento de algunos animales que viajan en manadas. En la Tabla 2 se puede observar algunas investigaciones que plantean este método de optimización, en [15], [19] y [29] se encuentran mejores resultados de rendimiento en comparación con [13].

Tabla 1. Antecedentes algoritmos genético y evolutivo. Fuente: elaboración propia.

Ref.	Descripción
[5]	Explora el algoritmo genético en dos métodos de optimización de dos niveles (mayorista y minorista). Uno considerando requerimientos técnicos (aplanamiento de la curva) y el otro tiene en cuenta criterios económicos (ganancia de la distribuidora). Aunque en ambos casos se mejora el perfil de demanda y aumentan las ganancias del minorista, se concluye que el criterio técnico es preferible debido a la distribución uniforme de cargas sin afectar la reducción de costos de la factura eléctrica.
[11]	Formula un algoritmo evolutivo considerando tres tipos de clientes: residencial, comercial e industrial, donde se utiliza el intercambio de los horarios de uso previstos de las cargas para el día siguiente, con el objetivo de minimizar el costo de energía.
[17]	Desarrolla un algoritmo híbrido (Genético-Taguchi) para un HEMS con baterías y generadores fotovoltaicos, demostrando mayor eficiencia que los algoritmos genéticos tradicionales al requerir menos generaciones para su cálculo.
[21]	Usa el algoritmo genético por su naturaleza aleatoria, evitando la concentración de cargas y permitiendo que la distribuidora realice la optimización sin afectar el confort del usuario, mediante un control indirecto.
[30]	Se aplica el algoritmo genético para minimizar el costo total de electricidad bajo una tarifa dinámica, mientras se satisface un conjunto de restricciones y con ello, se obtuvo un ahorro en el pago de la factura de aproximadamente 48 % respecto al consumo de energía sin optimización para un día simulado.
[31]	Emplea el algoritmo genético para complementar el procedimiento manual de control de demanda, conocido como acomodo de cargas, reduciendo el consumo en horarios pico, la demanda máxima y manteniendo la continuidad del gráfico de carga.
[32]	Utiliza el algoritmo genético y la técnica de cambio de carga para la DSM en usuarios residenciales, involucrando el cálculo del perfil de carga medio de los dispositivos usados por el consumidor cada hora con el objetivo de reducir el costo eléctrico y los picos de demanda.
[33]	Propone un algoritmo evolutivo para implementar la DR entre el agregador y el consumidor utilizando fuentes de energía renovable, lo que resulta en la maximización del confort del usuario y la minimización de la relación pico-promedio de demanda.
[34]	Se presenta un HEMS que integra energía renovable (eólica y fotovoltaica), almacenamiento de energía y cargas eléctricas y térmicas, se usa un algoritmo genético mejorado con la técnica del frente de Pareto, considerando la disponibilidad de energía renovable y la actividad del usuario, con el objetivo de minimizar el consumo energético y los costes energéticos. Los resultados muestran reducciones de costos del 25 % y un aumento en el uso de fuentes renovables.

Tabla 2. Estado del arte optimización por enjambre de partículas. Fuente: elaboración propia.

Ref.	Descripción
[13]	La optimización por enjambre de partículas es empleada por su inteligencia de enjambre, que le otorga una ventaja sobre otros métodos al requerir solo los valores de la función objetivo para cada una de las posibles soluciones, y con esto, proponer nuevas y mejores alternativas por medio de múltiples iteraciones. El autor identifica que el tiempo de ejecución de la simulación no es el óptimo, con periodos superiores a 20 minutos.
[15]	Implementa la optimización por enjambre de partículas para un conjunto de cargas con diferentes características de funcionamiento en tres áreas de actividad (residencial, comercial e industrial), lo cual plantea cierta complejidad al modelo. Los mejores resultados se presentaron en la curva residencial, donde se obtuvo una reducción de la demanda máxima de aproximadamente 23 %, y superior al 17 % para el sector comercial e industrial.
[19]	Propone una optimización por enjambre de partículas mejorado capaz de programar los dispositivos inteligentes bajo un nivel de potencia discreto y un modelo de precios cuadrático. Los resultados indican una reducción del 4.6 % en el costo total y del 94.5 % en el tiempo de ejecución en comparación con una programación dinámica.
[29]	La investigación utiliza la optimización por enjambre de partículas para programar electrodomésticos desplazables, con el fin de reducir la demanda punta a 200 usuarios residenciales y obtener un ahorro en costo de la factura diaria, como resultado se obtuvo una disminución en ambos ámbitos del 20 % aproximadamente.
[35]	Presenta un modelo de despacho económico para sistemas de potencia que integra distribuciones de probabilidad para modelar fuentes renovables de energía y vehículos eléctricos, y, adicionalmente se establecen los criterios necesarios para que un centro de consumo sea considerado como carga controlable. La optimización heurística del despacho se lleva a cabo mediante un algoritmo de optimización diferencial de enjambre de partículas evolutivo, el cual demuestra que la gestión de cargas controlables puede suavizar los perfiles de demanda, reducir las pérdidas y el costo total de generación.

Los algoritmos de optimización bi-nivel son una herramienta que se ocupa de problemas de optimización que considera dos niveles jerárquicos (un líder y N seguidores), donde la decisión de uno afecta al otro, y viceversa [36]. Algunos artículos que utilizan esta metodología se presentan en la Tabla 3.

Tabla 3. Estado del arte algoritmos bi-nivel. Fuente: elaboración propia.

Ref.	Descripción
[37]	Presenta una explicación del modelo de optimización bi-nivel, además, su aplicación en la respuesta de la demanda con la tarifa por tiempo de uso (ToU, por sus siglas en inglés), en la incorporación de vehículos en el esquema eléctrico, en la operación de microrredes y en la expansión de la red eléctrica y de los sistemas de generación.
[38]	Se desarrollan dos enfoques híbridos basados en población: bi-nivel algoritmo evolutivo y bi-nivel optimización por enjambre de partículas, donde el objetivo en el nivel superior es maximizar la ganancia del distribuidor y en el nivel inferior, es minimizar el pago de la factura eléctrica del usuario. Los resultados indican que el enfoque bi-nivel optimización por enjambre de partículas encontró mejores soluciones en la mayoría de escenarios simulados, además, observan que la programación de las cargas depende de los precios dados por el minorista y de requisitos de comodidad del usuario.
[39]	Se propone un esquema de precios en tiempo real para la gestión de la respuesta a la demanda, donde el minorista determina el precio y lo anuncia a los clientes, quienes gestionan sus cargas en función del precio. En este artículo se utiliza un juego de Stackelberg con un líder y N seguidores, maximizando la ganancia del minorista y la satisfacción del cliente.
[40]	Se propone un enfoque híbrido de dos niveles teniendo en cuenta las transformaciones KKT (Karush-Kuhn-Tucker), con el fin de maximizar las ganancias del minorista y la satisfacción del cliente.
[41]	Se plantea un modelo de optimización multi-objetivo para un sistema de gestión de energía en edificios con tarifas ToU, integrando generación fotovoltaica y confort para el usuario, con el propósito de mejorar la economía del edificio.

Teniendo en cuenta el estado del arte previamente discutido, esta investigación contribuye a la optimización del consumo energético en los hogares, mediante la implementación de un modelo matemático que permita gestionar de forma colectiva la demanda de un conjunto de usuarios residenciales, con el objetivo de minimizar el costo de la factura eléctrica y aplanar la curva de demanda de energía respecto a un caso base, donde los clientes no optimizan el encendido y apagado de las cargas. Para cumplir con este propósito, se utilizan dos metodologías: la búsqueda exhaustiva y la búsqueda local, las cuales aseguran modelos más sencillos, en contraste con los presentados en la literatura estudiada, ya que utilizan técnicas complejas y, en su mayoría, optimizan solo un hogar. Adicionalmente, se realizará la simulación del modelo matemático en el software MATLAB® para un conjunto de usuarios, lo cual permitirá validar la efectividad del algoritmo en un entorno práctico y realista.

Para alcanzar los objetivos planteados, se presentan las siguientes secciones del artículo: en la sección 2, se muestra el fundamento matemático de los modelos de optimización (usuario y multiusuario) junto con los conjuntos, parámetros y variables asociados, en la sección 3 se describe la metodología de solución para la simulación. Los resultados se exponen en la sección 4, seguidos por un análisis y discusión de los datos obtenidos en la simulación. Finalmente, en la sección 5 se plantean las conclusiones de la investigación y algunos posibles trabajos futuros para idear modelos más eficientes y eficaces.

2. MODELADO MATEMÁTICO

Esta investigación tuvo como objetivo reducir el costo de la energía eléctrica de forma colectiva para un conjunto de hogares, además de disminuir los picos de consumo durante ciertas horas del día sin afectar drásticamente la comodidad de los usuarios finales. Para lograr esto, se utiliza la PCEC que permite el encendido o apagado de las cargas eléctricas de forma automática a través de un horario establecido por el usuario final y el operador de red y con ello, abordar eficientemente la gestión de la demanda en esos hogares. El Modelado Multiusuario de Cargas Eléctricas Controlables (MMCEC) se desarrolla en dos etapas, una a nivel de usuario (individual) y la otra a

nivel multiusuario (colectivo). En la Tabla 4 se presenta la nomenclatura utilizada en esta metodología. Adicionalmente, en las Tablas 5, 6 y 7 se detallan los conjuntos, parámetros y variables implementados en el modelo matemático, respectivamente.

Tabla 4. Nomenclatura modelo matemático. Fuente: elaboración propia.

Abreviatura	Descripción
CEC	Cargas Eléctricas Controlables.
CENC	Cargas Eléctricas No Controlables.
CEFNI	Cargas Eléctricas Flexibles No Interrumpibles.
CEFI	Cargas Eléctricas Flexibles Interrumpibles.
CES	Cargas Eléctricas Subsecuentes.

Tabla 5. Conjuntos modelo matemático. Fuente: elaboración propia.

Conjunto	Descripción
$U_n = \{U_1, U_2, \dots, U_n\}$	Conjunto de usuarios que representan a cada hogar evaluado.
$T_k = \{t_1, t_2, \dots, t_k\}$	Conjunto de tiempo del período analizado.
$CEC = \{CEC_1, CEC_2, \dots, CEC_n\}$	Conjunto de CEC.

Tabla 6. Parámetros modelo matemático. Fuente: elaboración propia.

Parámetro	Descripción
$Ticc$	Representa el tiempo inicial para conectar CEC j .
$Tfdc$	Representa el tiempo final para desconectar CEC j .
$Hcarga$	Cantidad de tiempo necesaria en la que el electrodoméstico completa su funcionamiento.
Ti_{CES}	Tiempo inicial de conexión de la CES.
H_{CES}	Tiempo de funcionamiento de CES.
Tf_{CES}	Tiempo final de conexión de CES.
$p_1(x_{jt}CES)$	Hora de inicio de conexión de la CES.
$p_{\text{último}}(x_{jt}CEFNI)$	Hora final de actividad de la CEFNI.
Pot_{CENC_t}	Potencia de las CENC.
Pot_{CEC_j}	Potencia de la CEC j .
P_t	Precio de la energía en el periodo t .
FCI	Factor capacidad instalada.
CI_n	Capacidad instalada de cada hogar analizado.
φ_t	Factor de demanda de las cargas eléctricas por hora.
θ_t	Factor de CEC conectadas por hora.
$numC$	Número total de cargas controlables.

2.1 Función objetivo modelo matemático de optimización a nivel de usuario

El MMCEC a nivel de usuario se enfoca en determinar una adecuada programación óptima de conexión y desconexión de las cargas eléctricas, que minimicen el costo total de la energía para cada usuario durante el transcurso de un día. El modelo, representado por las ecuaciones (1) a (21), proporciona un marco integral para la optimización de la programación de carga.

Tabla 7. Variables modelo matemático. Fuente: elaboración propia.

Variable	Descripción
X_{jt}^i	Define el estado de la carga j en el tiempo t . Si $x_{jt} = 1$, entonces la CEC j está encendida en el tiempo t , en cambio, si $x_{jt} = 0$, la carga j se encuentra apagada en ese momento. Para denotar cada una de las alternativas que tiene un usuario n para la optimización CEC, se utiliza el superíndice i .
Pot_{Total_t}	Representa la potencia total, compuesta por la potencia de CENC y la suma de las potencias de las CEC j evaluado en el periodo t .
$Rcarga$	Restricción de número de cargas permitido en el periodo t .
$RPot$	Restricción de potencia permitida en el periodo t .
b_k	Combinaciones posibles de las diferentes opciones de solución del nivel usuario para cada usuario.
$C_{b,n,t}$	Representa la potencia total consumida por cada usuario en función de la combinación b en la opción óptima i y en el horizonte de tiempo t .
\bar{C}	Media de los datos guardados en la variable $C_{b,n,t}$.
$xstd$	Desviación estándar de las combinaciones posibles b en la optimización multiusuario.

La ecuación (4) define la potencia total consumida en cada periodo t como la suma de la potencia de las CENC y la potencia de las CEC para cada alternativa óptima i de la PCEC, representada por (X_{jt}^i) . A partir de lo anterior, las ecuaciones (1) y (2) describen la función objetivo que aborda este modelo matemático. En (2), se determina el costo total de la energía consumida para la opción i , donde este índice denota cada una de las alternativas que tiene un usuario n para la optimización CEC y el costo se calcula como la sumatoria del producto entre el precio de la energía P_t y la potencia total consumida, en cada periodo de tiempo t . Finalmente, en (1) se minimiza el valor de la función $fi(X_{jt}^i)$ para seleccionar la(s) alternativa(s) que conduzca(n) al costo mínimo del usuario n , considerando todas las CEC para ese usuario.

$$fobj = \min \{f1(X_{jt}^1), f2(X_{jt}^2), \dots, fi(X_{jt}^i)\} \quad (1)$$

$$fi(X_{jt}^i) = \sum_{t \in T} P_t * Pot_{Total_t}(X_{jt}^i) \quad (2)$$

$$P_t = [P_1, P_2, \dots, P_T] \quad (3)$$

$$Pot_{Total_t}(X_{jt}^i) = Pot_{CENC_t} + \sum_{t \in T} Pot_{CEC_j} * X_{jt}^i \quad (4)$$

El modelo requiere una serie de restricciones para asegurar su correcto funcionamiento, las cuales son: capacidad instalada, potencia permitida, número de cargas, tiempo de uso y funcionamiento de las cargas eléctricas. A continuación, se explicará cada una de ellas.

2.2 Restricción capacidad instalada

Con el fin de prevenir sobrecargas y posibles riesgos de seguridad eléctrica, se usa (5) para asegurar que el consumo total de energía, derivado de las decisiones tomadas en la programación de las cargas, se ajuste y no exceda la capacidad máxima de la instalación eléctrica del hogar. Por consiguiente, se debe establecer un factor o porcentaje de consumo (FCI) sobre la capacidad instalada (CI), para garantizar un margen de seguridad y evitar problemas eléctricos potenciales.

$$0 \leq Pot_{Total_t}(X_{jt}^i) \leq FCI * CI \quad (5)$$

2.3 Restricción de potencia permitida en el periodo t

Siguiendo un enfoque similar al presentado en [18] y [22], se emplea una metodología para minimizar el impacto de los picos de demanda que surgen en ciertas horas del día. Por esta razón, se plantea una restricción que limite la potencia total consumida en cada hora del día a través de la variable $RPot$, formulada en (6). Esta variable se compone del vector φ_t , cuyos elementos son el factor de demanda de las cargas eléctricas por hora que luego se multiplican con la demanda diaria del usuario n . Esta restricción considera tanto la potencia de cargas no controlables como la potencia de cargas controlables, lo que brinda una perspectiva completa de la demanda total de energía en el hogar, facilitando una planificación más precisa y eficiente del consumo energético.

Por lo tanto, la ecuación (7) asegura que la potencia total calculada para cada alternativa i sea menor que $RPot$ para todos los periodos t , lo que es una forma adecuada de regular el consumo de energía y optimizar la distribución de cargas eléctricas en el entorno residencial.

$$RPot = [\varphi_1, \varphi_2, \dots, \varphi_T] * \left[\sum_j Hcarga_j * Pot_{CEC_j} + \sum_{t=1}^T Pot_{CENC_t} \right] \quad (6)$$

$$Pot_{Total_t}(X_{jt}^i) < RPot \quad \forall t \quad (7)$$

2.4 Restricción de número de cargas permitido en el periodo t

Con el fin de mitigar los picos de demanda cuando se conectan simultáneamente múltiples CEC, se establece la variable $Rcarga$, que representa la cantidad máxima de cargas que pueden estar conectadas en el periodo t . Esto se formula mediante (8), donde el vector θ_t consiste en el factor de CEC conectadas por hora, utilizado para limitar el número total de cargas controlables ($numC$) para el usuario n .

$$Rcarga = [\theta_1, \theta_2, \dots, \theta_T] * numC \quad (8)$$

Asimismo, la ecuación (9) establece que el número total de CEC que pueden estar activas en el mismo periodo t se encuentra limitado por $Rcarga$:

$$\sum_{j \in numC} X_{jt}^i < Rcarga \quad \forall t \quad (9)$$

2.5 Restricción de tiempo de uso

Esta restricción establece que la suma de las potencias de las CEC debe ser mayor a cero durante el intervalo entre $Ticc$ y $Tfdc$, mientras que fuera de este intervalo, la suma debe ser igual a cero. Esto se expresa en (10), la cual asegura que las cargas controlables operen exclusivamente dentro del intervalo de tiempo especificado.

$$Pot_{TotalCEC} = \sum_j Pot_{CEC_j} * X_{jt}^i \text{ donde } \begin{cases} Pot_{TotalCEC} > 0, & \text{para } t \in [Ticc, Tfdc] \\ Pot_{TotalCEC} = 0, & \text{para } t \notin [Ticc, Tfdc] \end{cases} \quad (10)$$

2.6 Tipo de cargas eléctricas y sus restricciones

En este ítem se desarrolla la PCEC, que permite optimizar la conexión y desconexión de las cargas controlables para minimizar el costo total de energía y mitigar los picos de demanda. Las restricciones posibilitan la configuración y gestión de las cargas eléctricas que intervienen en el HEMS a través del modelado matemático, tal como se abordó en los artículos [5], [18] y [22]. En esta investigación, las cargas se clasifican según sus características de consumo en dos categorías: cargas controlables y cargas no controlables.

2.6.1 Cargas Eléctricas Controlables (CEC)

El modelo CEC propone determinar el momento adecuado para conectar o desconectar electrodomésticos en un hogar inteligente, teniendo en cuenta los requisitos tanto de gestión de la demanda como de confort para el usuario; esto implica encontrar un equilibrio entre el control directo e indirecto en los objetivos de la DSM. El MMCEC define una variable de decisión x para cada CEC, relacionada en un tiempo t . Por lo cual, al denotar x_{jt} , se define el estado de la carga j en el tiempo t ; si $x_{jt} = 1$, entonces la CEC j está encendida en el tiempo t , en cambio, si $x_{jt} = 0$, la carga j se encuentra apagada en ese momento. A través del uso de datos binarios, se establece una matriz de resultados X_{jt} para representar los estados de todas las cargas j en los diferentes intervalos de tiempo t para un usuario n . La matriz X_{jt} se visualiza en (11):

$$X_{jt} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1t} \\ x_{21} & x_{22} & \dots & x_{2t} \\ \vdots & \vdots & \ddots & \vdots \\ x_{j1} & x_{j2} & \dots & x_{jt} \end{bmatrix} = \begin{bmatrix} 0 & 1 & \dots & 0 \\ 1 & 1 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} \quad (11)$$

Las ecuaciones (12)-(15) presentan las restricciones generales de las cargas controlables; (12) y (13) garantizan que el intervalo de operación de las cargas esté dentro del horizonte de programación, además de asegurar que el tiempo de funcionamiento de cada electrodoméstico $Hcarga$ no exceda el intervalo de uso de dicha carga. La ecuación (14) establece que la suma de los estados binarios de la carga CEC debe ser igual al número de horas en las que la carga está en funcionamiento. Mientras tanto, (15) asegura que la variable de estados sea cero durante los periodos en que la CEC no está conectada, en otras palabras, una carga programada no se puede alimentar fuera del horario definido por $Ticc$ y $Tfdc$. Así, si $Ticc \leq t \leq Tfdc$, la variable x_{jt} tomará los valores de cero o uno, para cualquier otro caso, su valor es cero. La ejecución de (14) y (15) son análogas a la aplicación de (10). Estas restricciones aseguran que la programación de las CEC sea coherente y eficiente dentro de los límites de tiempo permitidos, y garantizan un funcionamiento óptimo del modelo.

$$Ticc \leq Tfdc \leq T \quad (12)$$

$$Tfdc - Ticc \geq Hcarga \quad (13)$$

$$\sum_{t=Ticc}^{t=Tfdc} x_{jt} = Hcarga, \quad \forall j \quad (14)$$

$$\sum_{t < Ticc \text{ o } t > Tfdc} x_{jt} = 0, \quad \forall j \quad (15)$$

Las cargas eléctricas controlables se componen de tres tipos principales: Cargas Eléctricas Flexibles No Interrumpibles (CEFNI), Cargas Eléctricas Flexibles Interrumpibles (CEFI) y Cargas Eléctricas Subsecuentes (CES). Las CEFNI son aquellas cargas que requieren operar de forma continua, sin permitir su apagado hasta que se haya completado su ciclo de funcionamiento. Para este tipo de cargas, el modelo matemático se basa en las ecuaciones (12)-(15) junto con (16), encargada de asegurar que la carga permanezca encendida sin interrupción durante las horas programadas. En esta ecuación, al incorporar los estados previo y actual de x , se busca determinar si la carga j opera de manera ininterrumpida. Si este es el caso, se clasifica como una CEFNI; en caso contrario, se considera otro tipo de carga que no se ajusta a la definición de CEFNI.

$$\sum_{t=Ticc}^{Tfdc} x_{jt} * x_{j(t-1)} \geq Hcarga - 1 \quad (16)$$

En cuanto a las CEFI, son aquellas que pueden ser controladas, con la particularidad de desconectarse temporalmente durante su ciclo de operación, es decir, tienen la capacidad de funcionar intermitentemente dentro del intervalo de tiempo predefinido. Para este tipo de cargas, se formula (17), la cual establece que dentro del rango de $Ticc$ y $Tfdc$, la variable x_{jt} tomará valores de cero o uno; de modo que la integración de esta ecuación con las restricciones definidas en las ecuaciones (12)-(15), impone condiciones en todo el rango de t para asegurar un manejo adecuado de las CEFI.

$$x_{jt}(t) = \{0,1\}, t \in [Ticc, Tfdc] \quad (17)$$

Por otro lado, las CES se conectan únicamente después de que ciertas CEFNI hayan completado su operación. Un ejemplo de esto es cuando una secadora de ropa se activa después de que la lavadora haya finalizado su ciclo de funcionamiento. Las CES tienen las siguientes consideraciones: funcionan como electrodomésticos no interrumpibles, todos sus posibles horarios de conexión comienzan después del apagado de la CEFNI, ya sea de manera inmediata o en un momento posterior y su desconexión se dará luego de su tiempo de funcionamiento (H_{CES}), donde su última posibilidad de apagado se establece exactamente al final del día. De acuerdo con esta premisa, se establecen (18) y (19) para definir el tiempo inicial de conexión (Ti_{CES}) y el tiempo final de conexión (Tf_{CES}) de estas cargas. Por otro lado, (20) garantiza la duración del ciclo de funcionamiento de la carga subsecuente, al tomar en consideración los tiempos de encendido y apagado.

$$Ticc_{CEFNI} + Hcarga_{CEFNI} \leq Ti_{CES} \leq T - H_{CES} \quad (18)$$

$$Ti_{CES} + H_{CES} \leq Tf_{CES} \leq T \quad (19)$$

$$Tf_{CES} - Ti_{CES} = H_{CES} \quad (20)$$

Finalmente, se debe tener en cuenta que el número de cargas de cualquier tipo no puede ser negativo, puesto que va en oposición a la lógica planteada en el modelo matemático (21).

$$CEFNI, CEFI, CES \geq 0 \forall j \quad (21)$$

2.6.2 Cargas Eléctricas No Controlables (CENC)

Estas cargas operan según patrones de uso preestablecidos y no pueden ser gestionadas ni ajustadas durante el proceso de optimización. Representan servicios obligatorios que brindan un valor necesario a los residentes de la vivienda, por lo que deben ser atendidos de inmediato cuando los usuarios lo soliciten [8]. Los refrigeradores son un ejemplo de este tipo de cargas y, además, en esta categoría se han incluido aquellas de potencia reducida, como la iluminación del hogar. En este modelo matemático, no se plantean ecuaciones específicas para este tipo de cargas, ya que se recurre a la base teórica de las referencias bibliográficas para obtener el conjunto de datos del consumo de CENC por hora.

2.7 Modelo de optimización multiusuario

El MMCEC a nivel multiusuario toma el conjunto de soluciones a nivel usuario y evalúa las diferentes combinaciones entre ellas para encontrar la mejor opción, con el objetivo de generar una curva de consumo más plana, con una distribución de cargas más estable y el menor costo de energía para todos los usuarios. El comportamiento ideal del consumo de energía para un conjunto de usuarios es una curva de demanda totalmente aplanada, esto evitaría situaciones de sobre exigencia o subutilización del sistema eléctrico en momentos específicos del día.

Para aproximarse al caso ideal, inicialmente se calcula el promedio de la potencia consumida por los hogares en un intervalo de tiempo (media de los datos). No obstante, para evaluar qué tan cercana está una curva con respecto a su promedio, se empleará la desviación estándar como métrica, permitiendo analizar la dispersión de los datos y encontrar una solución que no solo sea óptima a nivel individual, sino también estable y con menor variabilidad para múltiples usuarios. Se seleccionará la combinación de alternativas entre usuarios que tenga la menor desviación estándar, lo que resulta en una curva de consumo más cercana al caso ideal (media de los datos) y en una mejor distribución de las cargas para los clientes.

De lo explicado anteriormente, ahora se presenta las ecuaciones (22) a (26) que definen el MMCEC a nivel multiusuario. En (22) se define la variable $C_{b,n,t}$, que representa la potencia total consumida por cada usuario en función de la combinación b en la opción óptima i . Por lo tanto, b establece cada una de las múltiples combinaciones posibles en el modelo, lo que implica que, si hay más de una solución óptima por cada usuario, $C_{b,n,t}$ tendría múltiples valores correspondientes a las diferentes combinaciones de b que se encuentren.

La ecuación (23) calcula la media de los datos almacenados en la variable $C_{b,n,t}$, considerando el número de usuarios y el horizonte de tiempo. Finalmente, (24) determina la desviación estándar del consumo de los usuarios para cada combinación posible b , posteriormente, en (25) se recogen todas las desviaciones estándar de las combinaciones posibles b . La ecuación (26) define el objetivo de minimizar la desviación estándar entre todas las combinaciones posibles, encontrando la combinación b con la menor variabilidad en el consumo de potencia, es decir, se halla la curva de demanda más plana para la combinación de los múltiples usuarios.

$$C_{b,n,t} = \{Pot_{Total_t}^1(X_{jt}^i); Pot_{Total_t}^2(X_{jt}^i); \dots; Pot_{Total_t}^n(X_{jt}^i)\} \quad (22)$$

donde $n = 1, 2, \dots, n$ usuarios

$$\bar{C} = \frac{1}{T} \sum_{t=1}^T \sum_{n=1}^N C_{b,n,t} \quad (23)$$

$$xstd(C_b) = \sqrt{\frac{1}{T-1} \sum_{t=1}^T \left| \sum_{n=1}^N C_{b,n,t} - \bar{C} \right|^2} \quad (24)$$

$$xstd(C) = [xstd(C_{b1}), xstd(C_{b2}), \dots, xstd(C_{bk})] \quad (25)$$

$$Objetivo = \min_b(xstd(C)) \quad (26)$$

3. METODOLOGÍA DE SOLUCIÓN

En este apartado se describe la implementación del MMCEC discutido previamente, el cual se enfoca en la PCEC en hogares inteligentes para coordinar eficientemente la demanda de un conjunto de usuarios residenciales en un sistema de precios dinámicos por hora. Este modelo se ejecutará en el entorno de programación MATLAB®, incorporando procedimientos y consideraciones adicionales a lo expuesto en la sección 2, con el fin de realizar una gestión óptima de las cargas eléctricas para múltiples usuarios. Además, en la sección 3.3 se detallarán los parámetros iniciales de la simulación, como el comportamiento de las cargas eléctricas, los precios de la energía por cada hora, la capacidad instalada de los hogares, el número de usuarios, la cantidad y tipos de cargas, entre otros.

La metodología plantea dos etapas, una es la optimización del usuario y la otra multiusuario, que interactúan y se ejecutan entre sí. En cuanto a los métodos de optimización empleados en este artículo, se consideran la búsqueda exhaustiva (nivel usuario) y la búsqueda local (nivel multiusuario). El primer método (es un enfoque de fuerza bruta) es una técnica exacta que consiste en evaluar todas las posibles soluciones en un espacio de búsqueda definido hasta encontrar la mejor solución global. El segundo método, es una técnica heurística iterativa que parte de una solución inicial, luego explora y compara otras posibles soluciones en un entorno local, si durante el proceso encuentra una alternativa óptima, reemplazará la solución actual y continuará iterando hasta que ya no sea posible mejorar más [18], [36] y [42]. En la sección 3.1 y 3.2 se explicará más detalladamente esta implementación.

3.1 Implementación usuario

En la implementación del MMCEC a nivel de usuario, se propone el uso del método de búsqueda exhaustiva, el cual permite explorar todas las posibles soluciones de cada usuario y encontrar la óptima. En el algoritmo de simulación, este método se divide en dos fases con el objetivo de encontrar la(s) combinación(es) que permitan minimizar el costo de energía para el usuario evaluado.

En términos generales, la primera fase implementa un espacio de búsqueda que incluye todas las posibilidades de conexión de las cargas, utilizando matrices binarias para representar el estado (encendido/apagado) de cada carga por hora. Posteriormente, se verifica que cada carga esté activa durante su intervalo de tiempo requerido ($Ticc$ y $Tfdc$) y que se cumpla el tiempo total de operación de cada carga ($Hcarga$). Finalmente, se generan y

evalúan las combinaciones posibles de horarios según los tipos de CEC y descarta aquellas que no cumplan con las restricciones expuestas en la sección 2.6.1.

En la segunda fase, el código de la simulación recorre todas las posibles combinaciones de horarios de las cargas que la fase uno designó como viables y evalúa cada una en función del conjunto de restricciones de las secciones 2.2 a la 2.5, aquellas que no cumplan se descartan y las que sí, se validan y seleccionan las que logren el objetivo de minimizar el costo de la energía eléctrica para ese usuario. En los apartados 3.1.1 y 3.1.2 se explicará cada etapa más en detalle.

3.1.1 Consideraciones primera fase búsqueda exhaustiva

Para la implementación de esta fase, se considera el horizonte de programación como $T = 24 \text{ horas}$ y compuesto por periodos t que abarcan una hora, donde $t \in T$. Además, los parámetros $Ticc$, $Tfdc$ y $Hcarga$ son elegidos por cada usuario según su preferencia de horario para encender y apagar las cargas, lo que proporciona cierto nivel de comodidad. Posteriormente, como se menciona en la sección 2.6.1, se utiliza la variable de decisión x , la cual genera múltiples combinaciones de los estados de encendido o apagado de las cargas a través de matrices binarias. Una vez inicializadas y configuradas las variables y matrices de entrada, se procede al procesamiento de estas combinaciones, calculando los estados posibles de las cargas y organizando las matrices de estados conforme a las restricciones establecidas en las ecuaciones (12)-(15), cabe aclarar que estas ecuaciones se implementan en todos los tipos de CEC para garantizar que una carga programada no se pueda encender fuera del horario definido por el usuario.

El siguiente paso consiste en descartar las combinaciones de estados que no cumplen con las restricciones (16)-(21), las cuales corresponden a los criterios de las CEFNI, CEFI y CES. Adicionalmente, durante las simulaciones de conexión y desconexión de las CEFI, es crucial verificar y eliminar aquellas opciones que presenten comportamientos no interrumpibles. Así mismo, las CES requieren consideraciones adicionales en la simulación, teniendo en cuenta que la última posibilidad de apagado de una CES se establece exactamente al final del día, es decir, a la hora 23:59 y, por otra parte, pueden surgir horarios de conexión de las CES en el que su rango de operación inicie antes o simultáneamente al funcionamiento de la CEFNI, por lo cual, se introducen las ecuaciones (27)-(29) para resolver esta situación y descartar las opciones inválidas.

Para realizar esta comprobación en todas las posibilidades de conexión de CES, se determina la hora de inicio de la CES (p_1) y se resta con la última hora de actividad de la CEFNI correspondiente ($p_{\text{último}}$), si el resultado es positivo se considerará un horario válido de conexión, de lo contrario, es decir con valores negativos o cero, será inválido (ver ecuación 29).

$$p_1(x_{jtCES}) = \min\{i | x_{jtCES_i} = 1\} \quad (27)$$

$$p_{\text{último}}(x_{jtCEFNI}) = \max\{i | x_{jtCEFNI_i} = 1\} \quad (28)$$

$$\begin{cases} \text{si } p_1 - p_{\text{último}} > 0, & \text{Posibilidad } x_{jtCES} \text{ válida} \\ \text{sino} & \text{Posibilidad } x_{jtCES} \text{ inválido} \end{cases} \quad (29)$$

Finalmente, se seleccionan las opciones de estado válidas para el usuario y que permiten determinar el momento adecuado para conectar o desconectar electrodomésticos, cumpliendo con los criterios mostrados anteriormente. A continuación, las matrices de estados avanzan a la siguiente fase de programación.

3.1.2 Consideraciones segunda fase búsqueda exhaustiva

Esta segunda fase utiliza la búsqueda exhaustiva para encontrar la opción óptima que minimice el costo de la energía dentro de las múltiples opciones de conexión. El proceso inicia calculando el número de cargas controlables (*numC*) que tiene el usuario a evaluar, y con ello obtener el límite *Rcarga* para cada periodo de tiempo. Luego, se calcula la demanda total diaria del hogar a través de la suma de las potencias de las CEC y la potencia de las CENC (los datos se mostrarán en la sección 3.3), para definir la matriz *RPot* del límite de potencia permitida por hora (ver ecuación 6). Finalmente, se establece que el límite de consumo en el momento *t* debe ser igual o inferior al 90 % de la capacidad instalada (CI), para garantizar un margen de seguridad y evitar problemas eléctricos potenciales. El siguiente paso, es traer todas las matrices de estados de las CEC (X_{jt}) dentro del espacio de búsqueda del usuario *n*, generadas en la fase previa y como se muestra en (30):

$$X_{jt_n} = \{X_{jt}^1, X_{jt}^2, \dots, X_{jt}^i\} \text{ donde } i = 1, 2, \dots, k \quad (30)$$

En esta ecuación, el índice *i* representa cada alternativa individual de X_{jt} y *k* refleja el total de alternativas para el usuario *n*. Por lo cual, para cada *k* de X_{jt_n} de las CEC, se calcula el consumo energético por hora expresado mediante la suma de la potencia de las CEC y CENC, tal como se mostró en el MMCEC en (4). Posteriormente, se realiza el proceso de búsqueda exhaustiva evaluando cada alternativa *k* del usuario *n* mediante el uso de las restricciones (5), (7), (9) y (10), verificando y descartando aquellas opciones que no cumplen, para luego encontrar la(s) opción(es) óptima(s) para minimizar el costo eléctrico en el hogar, por medio de la implementación de las ecuaciones (1)-(3).

Por último, se selecciona(n) la(s) alternativa(s) que minimiza(n) el costo de energía diaria para ese usuario, asegurando que la solución final respete las capacidades y limitaciones establecidas en el sistema. La implementación de las ecuaciones (1)-(21) y (27)-(30), con el uso del método de búsqueda exhaustiva en la simulación, describen el comportamiento del MMCEC a nivel de usuario, obteniendo una o varias soluciones óptimas posibles que minimizan el costo de energía eléctrica. Así pues, las salidas de esta parte de la simulación en MATLAB® están compuestas por: la potencia total de los diferentes periodos de *t* ($Pot_{Total_t}(X_{jt}^i)$) y la programación de las cargas eléctricas controlables (X_{jt}^i) de cada solución válida, variables que serán las entradas para el modelo multiusuario.

3.2 Implementación multiusuario

En la implementación del MMCEC a nivel multiusuario, se propone el uso del método de búsqueda local a partir del conjunto de opciones seleccionadas en la etapa a nivel usuario, basándose en los criterios de diseño y especificaciones propias de la simulación. La metodología planteada es una técnica heurística que combina secuencialmente las posibles soluciones de cada usuario, siguiendo una trayectoria local en busca de la mejor solución. El proceso de simulación comienza con la selección de las curvas de demanda de los dos primeros usuarios (1 y 2) y, posteriormente combinarlas. Es importante mencionar que cada usuario puede tener múltiples opciones con costos mínimos (nivel usuario), permitiendo varias combinaciones posibles. Luego, para todas las combinaciones establecidas, se selecciona la mejor opción mediante el cálculo de la desviación estándar como métrica de evaluación y, se descartan las restantes. A continuación, se añade(n) la(s) curva(s) del usuario 3 y se combina(n) con la mejor opción previamente seleccionada entre los usuarios 1 y 2.

Nuevamente, se calcula la desviación estándar y se elige la mejor combinación para esos tres usuarios. Este proceso se repite sucesivamente, añadiendo un usuario a la vez y seleccionando siempre la mejor combinación basada en la desviación estándar, hasta llegar al último usuario.

El modelo encuentra una solución local al procesar usuario por usuario en un orden secuencial, ya que no considera todas las combinaciones posibles del espacio de búsqueda de los n usuarios para encontrar una solución óptima global. Esto significa que el resultado final depende del punto de partida, y al realizar la combinación de soluciones de los usuarios en diferente orden, el modelo podría converger en soluciones locales distintas. Este enfoque, aunque no garantiza la solución óptima global, ofrece resultados satisfactorios, como se verá en la sección 4. Se elige esta metodología teniendo en cuenta el tiempo de cómputo requerido para resolver el problema, así como la cantidad de variables y combinaciones que existirían si se consideraran todas las posibles combinaciones de soluciones de los n usuarios.

Teniendo en cuenta los argumentos anteriores, se expondrá de manera más específica la implementación del MMCEC a nivel multiusuario en tres etapas. La primera etapa del modelo multiusuario inicia almacenando las variables $Pot_{Total_t}(X_{jt}^i)$, X_{jt}^i y el costo de energía del primer usuario obtenidas en el nivel usuario; luego, se procede a seleccionar y guardar las mismas variables para el segundo usuario. En su segunda etapa, crea un vector a independiente para cada usuario con el número de soluciones; después, se determina las combinaciones posibles por medio del vector a de cada usuario, se almacena en la variable (b_k) y se define la variable $C_{b,n,t}$, que contiene el comportamiento de consumo hora a hora de cada una de las opciones según b_i . En la tercera etapa, durante el ciclo de b_i y la creación de $C_{n,t}$, se calcula y se selecciona la menor desviación estándar a lo largo de las iteraciones, la cual servirá como métrica para escoger la mejor combinación, posteriormente se guardan las variables de $Pot_{Total_t}(X_{jt}^i)$, X_{jt}^i y el costo de energía correspondientes a los dos usuarios de aquella combinación que se ha considerado mejor según el nivel más inferior de desviación estándar. El proceso continúa, combinando las variables generadas de la etapa anterior con las soluciones del tercer usuario, por lo cual, en este punto se ejecuta nuevamente el proceso de las tres etapas mencionadas, y finalmente, se seguirá iterando con cada usuario hasta llegar al resultado final del modelo.

En la ecuación (31), se define la tercera etapa mediante la búsqueda de la mejor combinación b_i que minimice la desviación estándar, esta se obtiene al iterar sobre diferentes opciones vecinas y evaluar una combinación, donde la desviación estándar actual ($xstd_{actual}$) sea menor que la desviación estándar mínima ($xstd_{min}$) por ciclo para cada una de las opciones, tal como se expresa en (24)-(26).

$$xstd_{actual} < xstd_{min} \quad (31)$$

En resumen, el comportamiento de consumo de un usuario residencial genera picos de demanda en ciertas horas del día, debido a sus decisiones o preferencias de uso de las cargas. Por lo cual, el MMCEC coordina y programa el encendido/apagado de un conjunto de electrodomésticos para múltiples usuarios, logrando un perfil de carga más aplanado y un menor costo diario de energía. Lo anterior, se alcanza con la ayuda de la desviación estándar, que se convierte en una métrica que evalúa la calidad de las combinaciones del consumo eléctrico, en la búsqueda de una distribución estable y uniforme en la programación de cargas eléctricas de los usuarios en un intervalo definido y, por tanto, promover una gestión más inteligente de los recursos disponibles, contribuyendo a una mayor estabilidad en el suministro eléctrico.

3.3 Parámetros iniciales

En este apartado, se plantean los parámetros de entrada necesarios antes de ejecutar la simulación del MMCEC, cabe señalar que el horario tendrá un rango temporal desde la hora 0:00 hasta las 23:59, estos parámetros son: los precios de la energía, las características de las cargas utilizadas en el algoritmo, el número de usuarios, la capacidad instalada de los hogares, entre otros.

3.3.1 Precios de la energía en diferentes periodos (P_t)

En mercados eléctricos a nivel residencial de países como Colombia, existe un sistema de tarifa plana (monomía), donde se tiene un costo de energía único para cualquier hora del día. Este tipo de tarifas no motiva al cliente a programar y administrar su consumo de energía, limitando la posibilidad de obtener los beneficios que ofrece una adecuada gestión de la demanda [16]. Mientras en países como España, Brasil y Uruguay, implementan esquemas de precios dinámicos, donde los costos de energía varían en función de los intervalos de horas pico, horas llano y horas valle. Sin embargo, es importante considerar que la eficiencia energética en relación con el sistema tarifario puede variar según las condiciones específicas de cada país y su infraestructura energética [43]. En este contexto, el mercado eléctrico colombiano se dirige hacia una evolución progresiva, con el desafío de adaptar al usuario regulado mediante cambios a la estructura tarifaria, la aparición de nuevos agentes de mercado y la busca de una inclusión gradual de infraestructura acorde con las redes inteligentes[16]. Por lo cual, en [43] se proponen estrategias para la implementación de esquemas de precios dinámicos a los usuarios finales en Colombia, con base en esa información, se determinan las tarifas por intervalos de tiempo que se ejecutaran en la simulación del modelo matemático (ver Tabla 8), además, en (3) se presenta el sistema tarifario dinámico, al definir el vector P_t , que almacena los precios de la energía para un determinado intervalo de tiempo dado.

Tabla 8. Tarifa horaria. Fuente: datos tomados del análisis tarifario para usuarios finales en programas de respuesta de la demanda en Colombia [43]. COP \$: peso colombiano (2020).

Intervalo de tiempo (h)	0-3	4-8	9-11	12-17	18-20	21-22	23
Precio (COP \$)	381.34	563.75	646.60	563.75	646.60	563.75	381.34

3.3.2 Parámetros de las cargas eléctricas controlables (CEC)

Las Tablas 9 y 10 muestran los parámetros que los usuarios pueden establecer para la PCEC. El conjunto de electrodomésticos está compuesto por 14 CEFNI, 2 CES y 4 CEFI, las cuales tienen múltiples momentos en los que pueden encenderse y apagarse según las preferencias del usuario. Así que, para el modelo desarrollado se les considera múltiples opciones para una misma carga, por esta razón, los dispositivos programables tendrán en total 67 posibilidades, incluyendo 41 CEFNI, 15 CEFI y 11 CES. En las tablas se incluyen parámetros como: los intervalos de operación de las cargas controlables (T_{icc} y T_{fdc}) y las características de las cargas eléctricas (H_{carga_j} , H_{CES} , Pot_{CEC_j}).

Tabla 9. Parámetros cargas eléctricas CEFNI y CEFI. Fuente: elaboración propia.

# Carga	Carga	Ticc (h)	Tfde (h)	H_carga (h)	Potencia nominal (kW)	Potencia CEC (kW)	Tipo de carga
1		6	13	2	1.80	1.630	
2	Lavaplatos: Intensivo	18	24	2	1.80	1.630	
3		8	12	2	1.80	1.630	
4		0	5	2	1.80	1.020	
5	Lavaplatos: Normal	19	23	2	1.80	1.020	
6		13	18	2	1.80	1.020	
7		4	10	3	1.80	0.840	
8	Lavaplatos: ECO	14	19	3	1.80	0.840	
9		18	23	3	1.80	0.840	
10		20	24	3	1.80	0.840	
11		5	7	1	1.80	0.640	
12	Lavaplatos: Rápido	13	16	1	1.80	0.640	
13		20	23	1	1.80	0.640	
14		9	12	1	1.80	0.640	
15		0	6	2	1.70	0.182	
16	Lavadora: Automática	7	11	2	1.70	0.182	
17		17	21	1	1.70	0.182	
18		20	24	1	1.70	0.182	
19		0	6	2	1.70	0.882	
20	Lavadora: Automática	7	11	2	1.70	0.882	
21		15	20	2	1.70	0.882	CEFNI
22	calentando agua	17	22	1	1.70	0.882	
23		20	24	1	1.70	0.882	
24	Horno	16	20	1	1.20	1.000	
25		11	13	1	1.20	1.000	
26		4	7	2	1.50	1.500	
27	Calentador de agua	6	10	2	1.50	1.500	
28		19	24	1	1.50	1.500	
29	Aspiradora	8	15	2	0.75	0.675	
30		11	18	3	0.75	0.675	
31	Plancha	19	23	2	1.00	0.600	
32		18	22	1	1.00	0.600	
33	Arrocera	11	14	1	0.70	0.700	
34		10	13	1	0.70	0.700	
35	Estufa	11	14	2	1.50	1.200	
36		18	21	2	1.50	1.200	
37		4	7	1	1.20	1.200	
38	Ducha Eléctrica	7	10	1	1.20	1.200	
39		20	23	1	1.20	1.200	
40	Freidora	12	15	1	1.00	1.000	
41		19	21	1	1.00	1.000	

# Carga	Carga	Ticc (h)	Tfdc (h)	H_carga (h)	Potencia nominal (kW)	Potencia CEC (kW)	Tipo de carga
42		12	24	8	1.35	1.013	
43		8	18	8	1.35	1.013	
44	Aire acondicionado	0	3	1	1.35	1.013	
45		8	11	2	1.35	1.013	
46		13	16	2	1.35	1.013	
47		9	18	7	0.09	0.090	
48	Ventilador	8	15	6	0.09	0.090	
49		19	24	4	0.09	0.090	CEFI
50		7	10	1	0.90	0.720	
51	Cafetera	13	16	1	0.90	0.720	
52		19	22	1	0.90	0.720	
53		7	11	3	1.50	1.500	
54	Calefactor	6	9	2	1.50	1.500	
55		13	16	2	1.50	1.500	
56		18	22	3	1.50	1.500	

Nota: Los datos presentados en esta tabla son recopilados de varias fuentes bibliográficas, incluyendo [44]-[50] y han sido organizados y estructurados en esta tabla por el autor.

Tabla 10. Parámetros de cargas subsecuentes. Fuente: elaboración propia.

# Carga	Carga CES	H_carga (h)	Potencia nominal (kW)	Potencia CEC (kW)	# Carga precedente	Carga precedente
1		2	2.2	0.874	15	
2		2	2.2	0.874	16	Lavadora:
3		1	2.2	0.874	17	Automática
4		1	2.2	0.874	18	
5	Secadora	2	2.2	0.874	19	
6		2	2.2	0.874	20	Lavadora:
7		2	2.2	0.874	21	Automática
8		1	2.2	0.874	22	calentando
9		1	2.2	0.874	23	agua
10	Brilladora	2	0.5	0.500	29	
11		2	0.5	0.500	30	Aspiradora

Nota: Los datos presentados en esta tabla son recopilados de varias fuentes bibliográficas, incluyendo [44], [49], [51], han sido organizados y estructurados en esta tabla por el autor.

Como se observa en las Tablas 9 y 10, se presentan las potencias de las cargas eléctricas, las cuales constan de: la potencia obtenida a partir de la información de la placa de características del electrodoméstico, y la potencia efectiva promedio que consume el dispositivo durante su funcionamiento en condiciones reales [44]-[51], esta última potencia, será utilizado para la programación de las cargas eléctricas.

3.3.3 Parámetro de consumo de las cargas eléctricas no controlables (POT_CENC)

Como se mencionó anteriormente, las CENC tienen un comportamiento de consumo eléctrico fijo durante el día, para el estudio del caso propuesto, se tomarán como referencia las investigaciones [20], [51] y [52], donde se extraen los datos de las curvas de perfil de carga

para cinco usuarios residenciales Pot_{CENC_t} , proporcionando al modelo matemático, una aproximación realista de los patrones de consumo. Estas curvas son la base para la construcción del perfil de consumo de todos los usuarios, los parámetros se muestran en la Tabla 11.

Tabla 11. Potencia de las CENC. Fuente: elaboración propia.

Usuario	U1 (kW)	U2 (kW)	U3 (kW)	U4 (kW)	U5 (kW)
Hora 0	0.066	0.085	0.168	0.156	0.119
Hora 1	0.058	0.040	0.173	0.130	0.100
Hora 2	0.054	0.045	0.167	0.118	0.096
Hora 3	0.091	0.050	0.169	0.127	0.109
Hora 4	0.214	0.107	0.217	0.165	0.176
Hora 5	0.272	0.130	0.278	0.261	0.235
Hora 6	0.329	0.170	0.293	0.276	0.267
Hora 7	0.301	0.220	0.283	0.316	0.280
Hora 8	0.290	0.175	0.276	0.270	0.253
Hora 9	0.230	0.162	0.190	0.265	0.212
Hora 10	0.228	0.150	0.198	0.275	0.213
Hora 11	0.256	0.157	0.198	0.226	0.209
Hora 12	0.212	0.190	0.171	0.249	0.206
Hora 13	0.173	0.175	0.182	0.227	0.190
Hora 14	0.173	0.155	0.183	0.219	0.182
Hora 15	0.202	0.151	0.169	0.216	0.185
Hora 16	0.208	0.178	0.174	0.216	0.194
Hora 17	0.190	0.182	0.189	0.240	0.200
Hora 18	0.198	0.225	0.364	0.311	0.274
Hora 19	0.301	0.213	0.385	0.330	0.307
Hora 20	0.348	0.217	0.389	0.305	0.315
Hora 21	0.246	0.212	0.306	0.298	0.265
Hora 22	0.137	0.200	0.240	0.246	0.206
Hora 23	0.074	0.140	0.225	0.181	0.155
Hora 24	0.066	0.085	0.168	0.156	0.119

3.3.4 Parámetro de la capacidad instalada

El siguiente parámetro para tener en cuenta, es la capacidad instalada (CI) por usuario, en el que se consideran valores dentro del rango promedio para viviendas unifamiliares o bifamiliares en Colombia [53], por lo que se establece el intervalo entre 6 kW y 12 kW.

3.3.5 Parámetro del número de usuarios

Por último, para el ingreso de datos es importante definir la cantidad de consumidores finales que participarán en el proceso de simulación ($NumUsu$). Para este artículo, se determina un total de 60 usuarios residenciales.

Es importante destacar que la elección de los parámetros iniciales y las estrategias de optimización pueden tener un impacto significativo en los resultados de la simulación, por lo tanto, se deben llevar a cabo análisis de sensibilidad para verificar cómo varían los resultados

ante cambios en los parámetros. La metodología computacional proporciona información pertinente para una gestión más eficiente y sostenible de la demanda de energía, en el desarrollo de mercados eléctricos, que contemplen implementar un esquema tarifario dinámico como es el caso del Colombia.

3.4 Diagrama de flujo MMCEC

De lo expuesto anteriormente, el MMCEC propuesto se encargará de optimizar tanto la curva de demanda como los costos de energía de 60 usuarios residenciales, teniendo en cuenta su comodidad. Para lograr esto, se utilizará la PCEC aplicando una serie de parámetros iniciales (ver apartado 3.3), en los que cada usuario cuenta con un comportamiento específico para varios tipos de cargas (ver apartado 3.3.2), ajustados a una tarifa de precios dinámicos y considerando una potencia base por usuario (potencia no controlable).

Tabla 12. Etapas del MMCEC en la simulación. Fuente: elaboración propia.

Etapa	Descripción
1. Definición de parámetros iniciales	Se establece los parámetros de entrada del caso de estudio tales como: precios de la energía, características de las cargas utilizadas en el algoritmo, número de usuarios, capacidad instalada, entre otros (ver apartado 3.3).
2. Ejecución del modelo de optimización a nivel de usuario	Se ejecuta el método de búsqueda exhaustiva, para obtener las soluciones óptimas posibles que minimizan el costo de energía eléctrica para cada usuario (ver apartado 3.1). Cada solución del usuario n se identifica con el índice i , las filas de estas matrices X_{jt}^i establecen la programación de la carga controlable j , y las columnas representan los periodos de tiempo (t) en el horizonte de programación.
3. Ejecución del modelo de optimización multiusuario	Se implementa el modelo de optimización multiusuario, donde se utilizan características del método de búsqueda local, el algoritmo identifica las combinaciones óptimas a partir de las soluciones individuales de cada usuario (ver apartado 3.2). Esas combinaciones, son evaluadas en términos de la desviación estándar de las potencias totales de los usuarios y los costos de energía eléctrica. Se comparan diferentes combinaciones de soluciones multiusuario para identificar aquella que presenta la menor variabilidad y un consumo energético más uniforme a lo largo del tiempo.
4. Salida del modelo y visualización	Se genera un documento con los resultados obtenidos de la simulación, incluyendo tablas con los datos del perfil de carga, costos de la energía eléctrica y las matrices que permiten la adecuada programación de las cargas eléctricas controlables.

La ejecución de la metodología propuesta y explicada en las secciones 3.1 y 3.2, se lleva a cabo por medio de una simulación computacional que se implementará en el software MATLAB®, herramienta ampliamente utilizada por la comunidad científica por sus facilidades en el manejo y cálculo de operaciones matriciales, se utilizó la versión R2022b y se desarrolló la simulación en una computadora con procesador Intel(R) Core (TM) i5-8250U CPU @ 1.60GHz 1.80 GHz y con una RAM de 12GB. El algoritmo de simulación se compone de cuatro etapas, en la Tabla 12 se proporciona una descripción de cada una de estas etapas.

En la Figura 1, se presenta el diagrama de flujo de la implementación del algoritmo de optimización, en el que se ilustra visualmente las etapas y decisiones claves. El diagrama comienza importando el número de usuarios e inicializando la variable de iteración n . Para cada usuario, se importan sus parámetros, se crean las matrices de estado de las cargas y se inicia una búsqueda exhaustiva. Si una opción no cumple con las restricciones, se elimina y se continúa evaluando la siguiente. Las opciones óptimas a nivel usuario se almacenan y se genera una combinación inicial para realizar la búsqueda local, evaluando iterativamente las

combinaciones. Posteriormente, se calcula la desviación estándar de la potencia y se actualizan las mejores combinaciones. Este proceso se repite incrementando n hasta evaluar todos los usuarios. Finalmente, se exportan los resultados con la solución óptima y sus detalles.

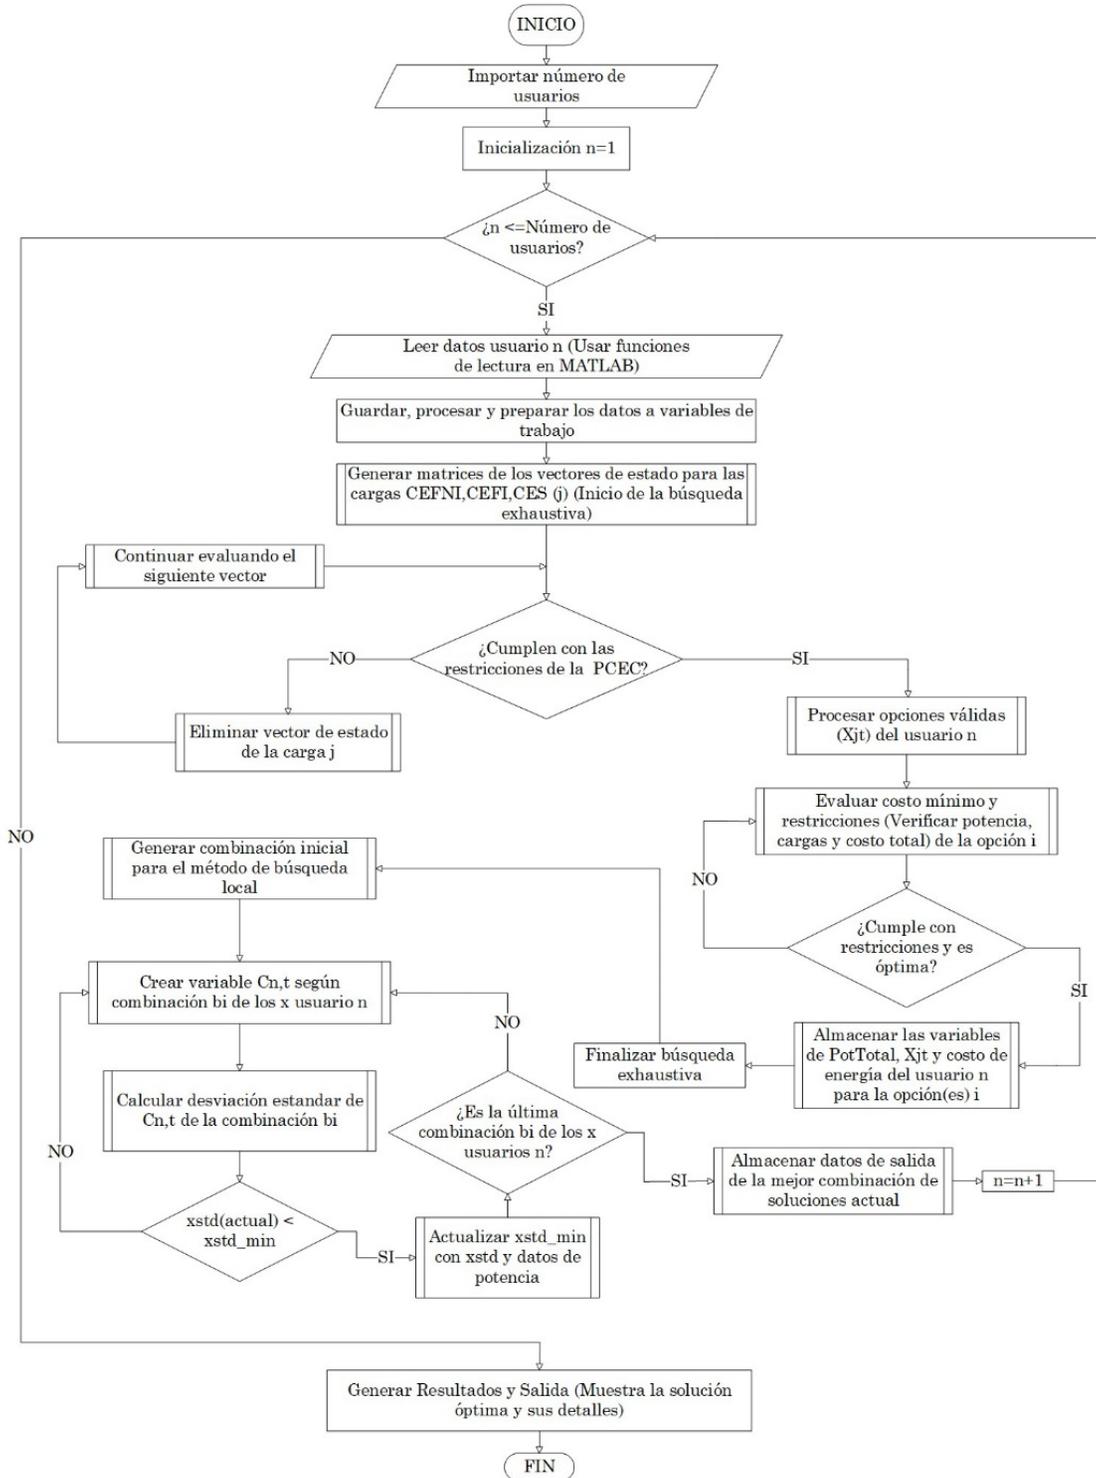


Figura 1. Diagrama de flujo de la optimización propuesta. Fuente: elaboración propia.

4. RESULTADOS Y DISCUSIÓN

En esta sección de resultados, se lleva a cabo la comparación entre los datos de un caso de estudio sin optimización, donde cada uno de los 60 usuarios posee una serie de electrodomésticos con un consumo eléctrico diario establecido y los casos de estudio con optimización, en los cuales se implementa el modelo planteado mediante la PCEC.

En la Figura 2, se presenta la comparación de los escenarios para uno de los 60 usuarios, denominado como usuario (a), entre el caso sin optimizar y los resultados cuando hay participación en la gestión de la demanda. El gráfico de barras representa el tiempo de operación de las CEC y las CENC a lo largo del horizonte de tiempo T, mostrando las cargas que se activan en cada período de tiempo t al realizar la optimización. Además, para visualizar el perfil de carga de ese usuario en el escenario sin optimizar, se utiliza una gráfica lineal en verde.

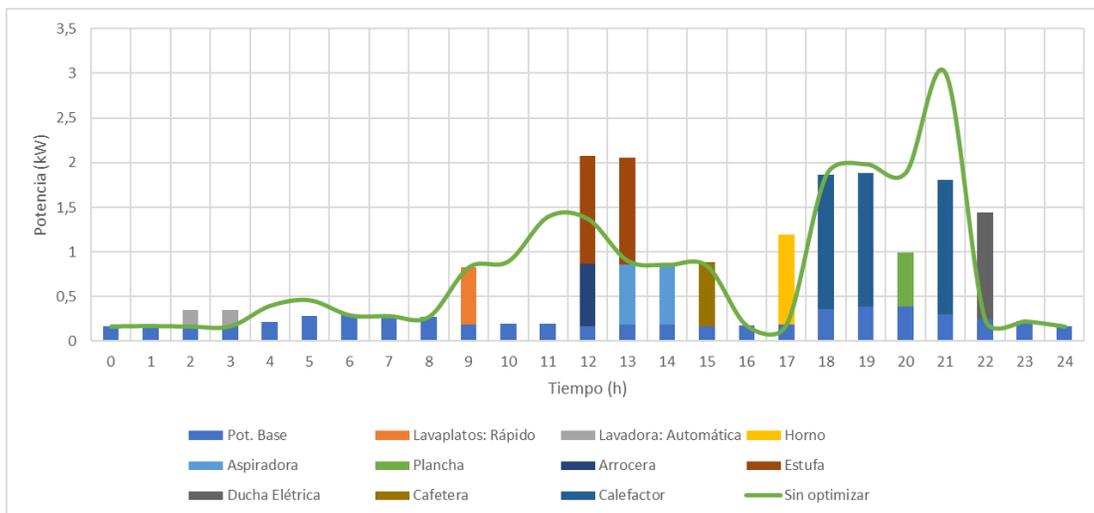


Figura 2. Perfil de carga sin optimizar y Programación CEC para el usuario (a). Fuente: elaboración propia.

A continuación, se exponen las curvas de demanda correspondientes a cuatro usuarios adicionales, con el propósito de analizar casos específicos de consumo con la implementación de la PCEC, tal como se observa en las gráficas de la Figura 3. En estas, se muestra el escenario base a través de un gráfico lineal azul, en el cual el usuario conecta las CEC según su conveniencia, mientras que el caso optimizado, se representa mediante un gráfico de área rellena en tono naranja.

Antes de seguir con la discusión de los resultados, es importante definir el concepto de relación de pico a promedio (PAR), que se refiere a la proporción entre el valor máximo (pico) de una curva y su valor promedio. Para los cuatro usuarios contemplados, se observa una disminución de los picos de demanda en las horas de mayor precio de la energía al hacer uso de la PCEC. En la Tabla 13, se muestran los resultados para los casos con y sin optimización de los usuarios mencionados.

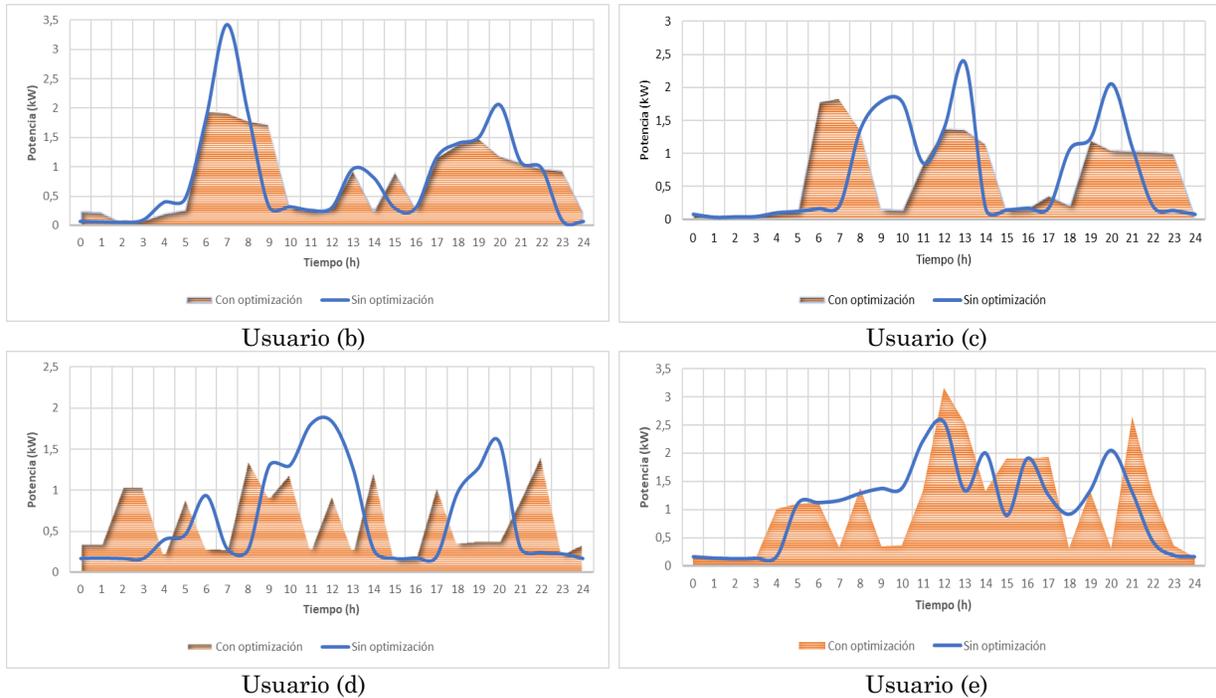


Figura 3. Perfil de carga sin optimizar vs perfil de carga optimizado para tres usuarios. Fuente: elaboración propia.

Tabla 13. Resultados análisis de potencia activa pico para cinco usuarios. Fuente: elaboración propia.

Usuario	Potencia pico (KW) sin optimización	Potencia pico (KW) con optimización	PAR sin optimización	PAR con optimización	% de reducción de potencia pico
(a)	3.01	2.07	3.78	2.60	31.08
(b)	3.43	1.95	4.09	2.33	42.90
(c)	2.38	1.85	3.37	2.63	22.10
(d)	1.84	1.44	2.76	2.17	21.53
(e)	2.55	3.16	2.32	2.87	-23.90

De las Figuras 2 y 3, se observa que los cinco usuarios utilizan diferentes estrategias para gestionar su demanda, además, en la Tabla 14 se muestran los costos de la factura de electricidad para cada uno de los cinco usuarios, donde se obtienen ahorros que varían entre 1 % y el 8 % para el día evaluado en la simulación. Una de las estrategias, es el traslado de cargas que se presenta en los cinco perfiles de demanda, en el cual se desplaza el consumo a horas en las que el costo de la energía es más bajo. Examinando detenidamente las estrategias para gestionar la demanda, el algoritmo para el usuario (b) lleva a cabo una acción de recorte de picos con un leve llenado de valles en ciertas horas del día. El modelo de optimización para el usuario (a), opta por un enfoque combinado de recorte de picos y conservación estratégica, es decir, mantiene los horarios de picos de demanda entre los casos con y sin optimización, pero evalúa en el modelo si el pico debe disminuir o aumentar, según lo que resulte más conveniente para la optimización. A pesar de que los usuarios (a) y (b) muestran una reducción significativa en el pico de demanda, se observa que el ahorro en la factura es menor en comparación con otros usuarios, esto podría deberse al hecho de que la principal estrategia adoptada fue el recorte de los picos de consumo en lugar de trasladar las cargas a horarios de menor costo.

En el caso del usuario (c), el algoritmo realiza un desplazamiento de carga de uno de sus picos de demanda de un horario con mayor precio a uno más económico y para los otros dos picos, hace un recorte y llenado de valles. Para el usuario (d), se implementa una distribución del consumo a lo largo del día en comparación con el caso base, en el que se concentran picos en las horas donde la energía es más costosa. Los usuarios (c) y (d) presentan mejores resultados de ahorro, obteniendo un 5.74 % y 8.12 %, respectivamente. Ahora bien, si observamos el valor pico de los usuarios (a), (b), (c) y (d) se reduce entre un 21 % a 42 %, por el contrario, el usuario (e) experimenta un aumento del 23 % en su pico al realizar la optimización, esto se debe a que el modelo empieza a acumular las cargas en los periodos donde la energía es más barata y a la libertad del cliente a la hora de programar sus cargas, lo cual podría ser una desventaja sino se tienen las restricciones adecuadas como lo son, los límites de potencia y el número de cargas conectadas. Por las razones mencionadas, el usuario obtiene un ahorro del 3.01 % en su factura eléctrica.

Las estrategias o acciones expuestas anteriormente se pueden identificar en la optimización que presenta el modelo propuesto sobre el perfil de carga de los 60 usuarios, logrando una reducción del valor de la factura eléctrica. Además, es importante tener en consideración, que el modelo ejecuta una optimización de costos a nivel individual, y luego coordina un conjunto de usuarios en búsqueda del aplanamiento de la curva de demanda, sin afectar negativamente el confort del cliente y dándole flexibilidad en la programación de sus cargas eléctricas.

Tabla 14. Costo de la factura eléctrica para los usuarios. Fuente: elaboración propia.

Usuario	Costo sin optimización (\$COP)	Costo con optimización (\$COP)	Ahorro (%)
(a)	11314.26	11007.60	2.71
(b)	11765.58	11584.16	1.54
(c)	10169.90	9586.11	5.74
(d)	9493.78	8722.53	8.12
(e)	15550.05	15081.64	3.01

En párrafos anteriores, se daba un panorama individual de como el modelo ha logrado optimizar aspectos de los usuarios. A partir de este momento, se muestran los resultados para todos los usuarios evaluados en conjunto. La Figura 4 ilustra el perfil de carga para los 60 usuarios, donde la línea punteada en verde es la tarifa propuesta en \$ COP/kWh (ver Tabla 8), mientras que las barras naranjas y azules representan el caso con y sin optimización respectivamente. De la Figura se observa que, en el estudio optimizado hay un desplazamiento de las cargas desde las horas pico del caso sin optimizar, hacia periodos con un menor precio. El escenario base, presenta un consumo de energía sin ningún tipo de restricciones y sin una programación específica para las cargas, causando que el usuario no se beneficie de las tarifas dinámicas y encienda sus electrodomésticos en el horario con los precios más altos de energía; en cambio, para el escenario del modelo optimizado se evidencia un perfil de carga que aprovecha las tarifas más bajas, buscando no afectar la comodidad de los usuarios y no generar picos de demanda significativos en otros intervalos de tiempo.

Una forma de evitar los picos significativamente altos durante cualquier periodo de tiempo, es mediante restricciones a los modelos matemáticos; en este artículo se contemplan algunas de ellas en relación con la potencia activa, como la capacidad instalada para prevenir sobrecargas y posibles riesgos de seguridad eléctrica, así como los límites de potencia por hora para minimizar el impacto de los picos de demanda en otras horas del día, estas dos restricciones dependen de las características eléctricas y hábitos de consumo del hogar (ver Sección 2). Pero aumentar estas restricciones, como definir un límite de demanda baja, puede

resultar en sacrificios en la comodidad del cliente y en la generación de nuevos picos de demanda en periodos de menor actividad, lo que podría causar daños a la infraestructura eléctrica del hogar o la red eléctrica, por lo cual en el modelo implementado también se realizó un análisis de sensibilidad para estas dos restricciones, teniendo como prioridad las preferencias del cliente o flexibilidad en la programación de sus cargas. Un ejemplo de lo mencionado es cuando el usuario establece los tiempos T_{icc} y T_{fdc} , donde se otorga un cierto grado de libertad a través de un control indirecto sobre el consumo de energía y, por ende, reducir el costo de la factura eléctrica. Al contrario, si el usuario desea una reducción más significativa de ese costo, deberá sacrificar cierto grado de comodidad.

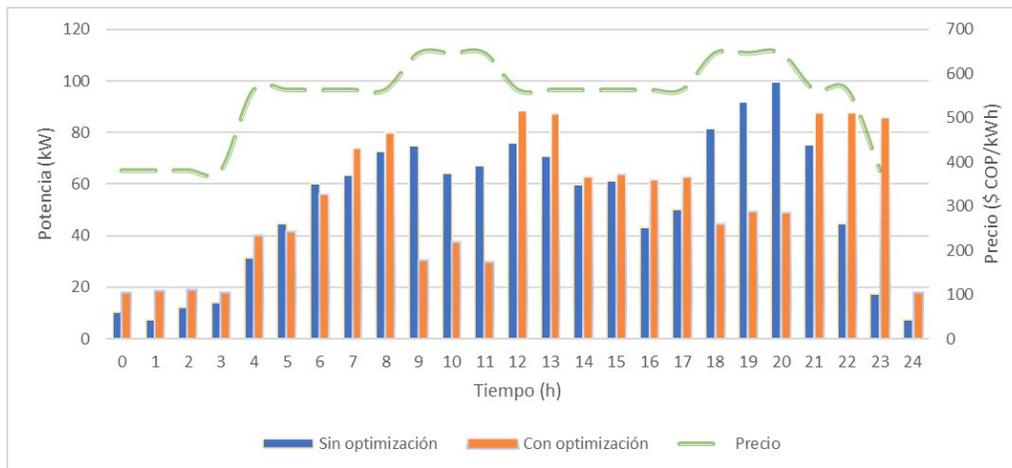


Figura 4. Perfil de carga de los 60 usuarios. Fuente: elaboración propia.

De manera individual en el análisis de los picos de demanda, se obtienen los siguientes resultados: 35 usuarios en el caso optimizado tienen una demanda pico máxima mayor que en el caso sin optimizar, 6 usuarios coincidieron que el pico de demanda es igual para los dos casos y 19 usuarios tienen un pico de demanda máxima menor en el caso optimizado. Estos escenarios fueron evaluados en el horizonte de tiempo T y con el nivel de flexibilidad disponible y dado para cada usuario. Asemejando la realidad de los hogares, no todos los clientes tienen los mismos hábitos de consumo y además con la premisa de no afectar negativamente el confort del usuario, se presentan días en los que el caso de optimización tiene picos de demanda más altos, tal cual como se mostró en el usuario (e), en el cual desplaza las cargas a horas de menor costo, y hace que estas se vayan agrupando en un horario específico; sin embargo, también se establecen las restricciones adecuadas, para que no se generen picos de demanda significativos por lo señalado anteriormente y que no ocasionen problemas a nivel multiusuario.

Como se observa en la Figura 4, la participación de los 60 usuarios en la PCEC obtiene una reducción del 11.49% en la potencia máxima respecto al caso sin optimizar, presentando una potencia pico de 88.11 kW y un nivel de PAR de 1.63, en comparación a los 99.55 kW con un nivel de PAR 1.84. Los resultados cuantitativos evidencian para el PCEC, que el conjunto de usuarios ha logrado un perfil de demanda con una distribución más uniforme de las cargas eléctricas y una disminución del pico de consumo en horas en las que la tarifa es alta. Esto se consigue mediante el uso de las ecuaciones (24)-(26), donde la desviación estándar como métrica de evaluación, analiza la dispersión de los datos y obtiene una solución con menor variabilidad en la programación de las cargas por cada usuario, de ahí que se produce una curva de demanda más plana (PAR) en comparación con el caso no optimizado.

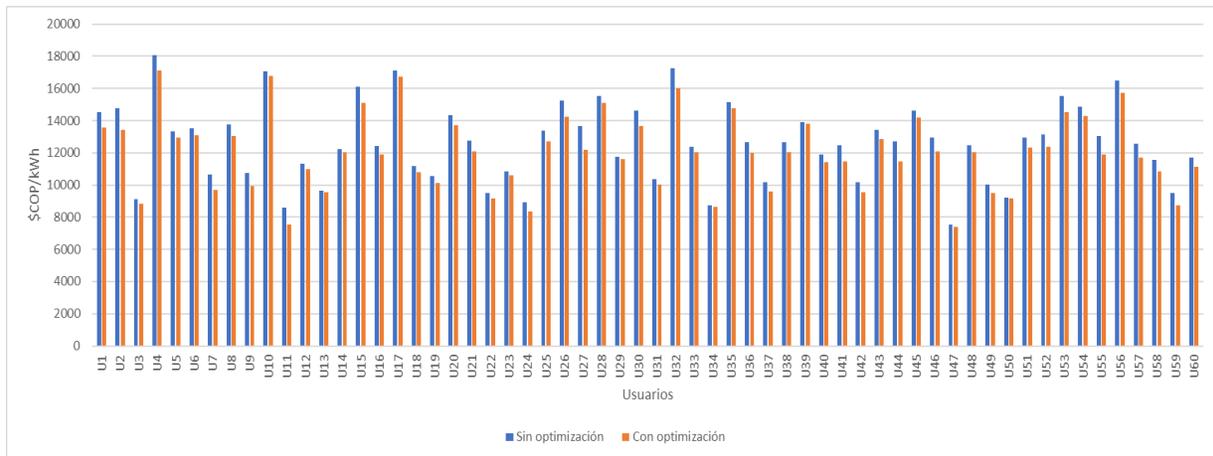


Figura 5. Comparación de costos de energía por usuario. Fuente: elaboración propia.

Otro de los objetivos del modelo de optimización implementado, consiste en lograr la minimización del costo de la energía para un cierto número de usuarios. En vista de ello, en la Figura 5 se observa para los 60 usuarios, la comparación del costo de la factura eléctrica entre el caso base (barras azules) y la ejecución del modelo optimizado (barras naranjas); del gráfico se deduce que el costo de la energía es menor para todos los usuarios al implementar la metodología diseñada en este artículo, ya que el perfil de demanda ha aplanado la curva en las horas pico, cuando el precio de la energía es más alto. Aparte de eso, la reducción de costos varía en función de las características de las cargas involucradas para cada cliente, sus hábitos de consumo y sus necesidades individuales, lo que lleva a que algunos usuarios pueden obtener grandes ahorros, mientras que otros pueden experimentar ahorros más modestos. En la Figura 6 se observa lo mencionado, donde el mayor porcentaje de reducción de la factura es de 12.34 % y el menor obtuvo un 0.54 %. En cuanto al conjunto de usuarios, se encuentra que el ahorro promedio del costo de la factura eléctrica es de aproximadamente el 4.94 % para el día de simulación.

En la Tabla 15, se presentan los resultados de potencia máxima, PAR y costo de la energía, entre el caso base y el modelo optimizado propuesto, en el que se encuentra una reducción del 11.49 % en la potencia activa máxima, un aplanamiento de curva al disminuir el valor del PAR del 1.84 a 1.63 y, además un ahorro promedio del 4.94 % para los 60 usuarios. Además de los beneficios para los usuarios finales, la gestión de la demanda mediante el aplanamiento de la curva de carga conlleva un ahorro en los costos de construir nueva capacidad de generación para suplir los picos de demanda, y en la infraestructura para las líneas de transmisión eléctrica. También se reduce el gasto de comprar electricidad en el mercado eléctrico, cuando la demanda presenta un rápido aumento en horas pico; esto mismo, ocasiona un alivio para los operados de red, ya que mejora la confiabilidad y eficiencia del sistema al evitar someter a la red a picos altos de consumo, reduciendo la probabilidad de salidas forzadas de generación, así como fallos en la infraestructura de transmisión y distribución. Adicionalmente, se previene el riesgo de apagones por las fluctuaciones repentinas de la demanda, lo que proporciona más tiempo para la incorporación de nuevas centrales en respuesta al aumento natural de la demanda. De igual forma, es importante señalar que se puede reducir la huella de carbono al disminuir las emisiones de gases de efecto invernadero, evitando el uso y construcción de centrales alimentadas con combustibles fósiles que generalmente sirven de reserva cuando la demanda es alta y no se puede suplir con la generación actual.

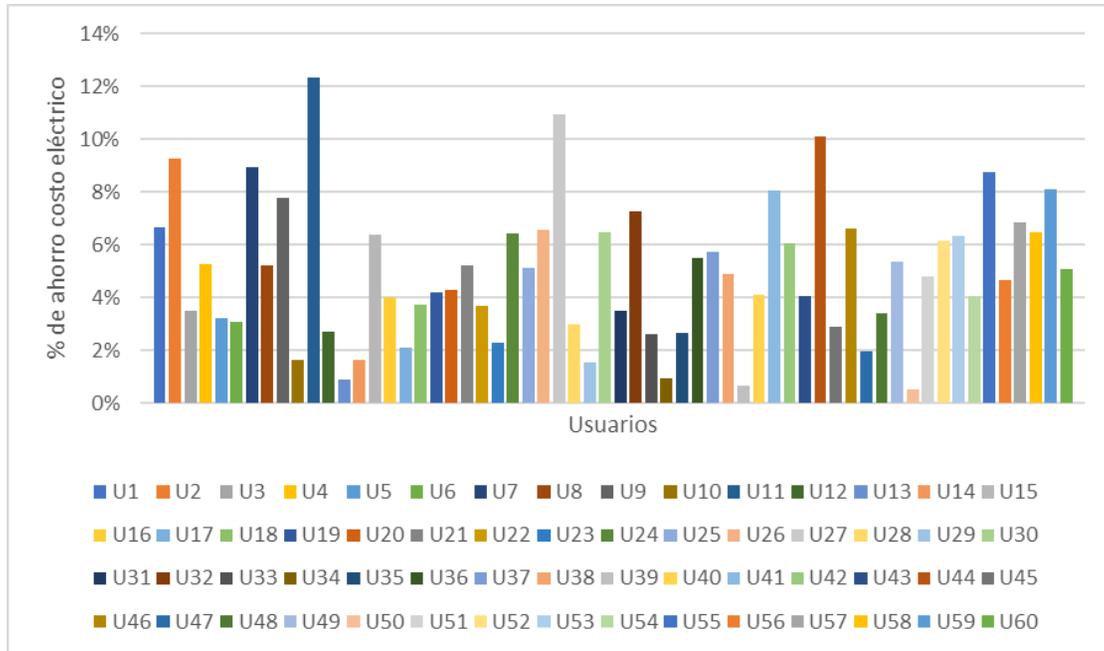


Figura 6. Porcentaje de ahorro del costo de energía para los 60 usuarios. Fuente: elaboración propia.

Entonces, así como el usuario presenta unos desafíos al momento de programar sus cargas, debido a que no son proactivos en la participación de la gestión de la demanda o por desconocimiento técnico, a su vez, la distribuidora enfrenta el reto de implementar tecnologías que desarrollen los programas de la DSM, donde se pueda monitorear de manera más eficaz el consumo de energía, brindar información en tiempo real y automatizar procesos de consumo, para lograr una sólida infraestructura de redes inteligentes. Por lo cual, la DSM necesita de estrategias en la planeación y operación de los sistemas eléctricos, además de considerar programas para incentivar a los usuarios a gestionar su demanda en el hogar y utilizar infraestructuras como medidores inteligentes, HEMS y recursos de generación distribuida.

Tabla 15. Resultados generales usuarios. Fuente: elaboración propia.

Caso	Potencia máxima (kW)	PAR	Costo (\$COP)
Sin optimización	99.55	1.84	757695.88
Con optimización	88.11	1.63	720095.80

Al analizar los resultados presentados en otras investigaciones, se observa que los autores de [6] propusieron una estrategia de optimización para un único usuario residencial con dos CEC y un punto de recarga para vehículo eléctrico (VE), logrando una reducción del 43 % en el pico de la demanda y un ahorro del 6 % en la factura, en comparación con nuestro mejor caso, que obtuvo una disminución del 42 % de la demanda máxima y un ahorro del 1.55 %. Esta diferencia se debe a que los autores de [6] implementaron un desplazamiento de la carga de VE a un horario de consumo optimizado con precios de energía más bajos, lo cual hace que el costo total disminuya significativamente. De manera similar, en [7] y [18] se programaron las cargas de un usuario, alcanzando mayores ahorros, con un 36 % y 16.98 % respectivamente, gracias a la incorporación de energías renovables y al almacenamiento de energía en baterías. Aunque el enfoque de esta investigación no fue en este tipo de tecnologías, se consiguieron beneficios importantes, como un ahorro máximo del 12.34 % al

contemplar más usuarios y más cargas controlables, teniendo en cuenta que se maneja un gran número de variables en la implementación del MMCEC.

En el caso multiusuario, como el de [5], que simula 10 usuarios con 3 CEC cada uno, obtienen una reducción de pico del 16 % y un ahorro del 17.68 % desde un enfoque que ellos han llamado técnico y donde tiene presente una optimización de los precios de la distribuidora, nuestro estudio muestra una optimización con un mayor número de cargas por usuario, logrando una reducción de picos de 11.49 % y ahorro 4.94 % entre todos los usuarios, esa diferencia entre los datos también se debe a que nuestro modelo tiene en cuenta el precio de la energía como un parámetro y no una variable a optimizar. En [21], se programaron dos usuarios residenciales, cada uno con una carga controlable, obteniendo un ahorro del 1.51 %; este dato es menor a lo presentado en nuestro modelo, debido a que se optimizó entre 9 a 12 CEC por usuario, lo cual destaca la complejidad del modelo y su visión realista de los hábitos de los clientes. Por otro lado, la investigación en [22] obtuvo ahorros entre el 18.53 % y el 26 % en 7 usuarios residenciales utilizando energías renovables, almacenamiento de energía y VE, mientras que nuestro modelo, aunque sin estas tecnologías, maneja una mayor cantidad de cargas controlables por usuario. Finalmente, en [29] propusieron la optimización de 200 usuarios con un número de CEC que varía entre 1 a 14 según preferencia del cliente, reportan ahorros de hasta el 20 % y una reducción de picos del 22.23 %, en una muestra de 5 usuarios obtienen ahorros entre el 9 % al 14 % mientras que nuestro modelo, alcanza ahorros del 12 % individualmente y una reducción de picos del 11.94 % en conjunto, se subraya la importancia de utilizar un algoritmo robusto como en [29] para múltiples usuarios, lo cual puede servir de referencia para próximos trabajos, teniendo en cuenta las características propias de nuestra investigación y las aportaciones de estudios como los mencionados anteriormente.

La implementación del modelo desarrollado en este artículo ha demostrado resultados positivos, en términos de costos y curva de demanda para todos los usuarios, no obstante, es necesario identificar aquellas limitaciones que presenta la metodología planteada. Una de ellas es el requerimiento en el procesamiento de datos, que puede llegar a tener el enfoque de búsqueda exhaustiva, producto de utilizar una cantidad considerable de CEFI durante un rango de tiempo extenso, y de evaluar un gran número de posibilidades para alcanzar la solución óptima, para ello, es indispensable no exceder la cantidad de CEC por usuario en la simulación; a pesar de esto, se logra un rendimiento satisfactorio al asignar entre 9 y 12 cargas controlables, considerando CEFNI, CES y CEFI por usuario. Por otro lado, una segunda limitación se presenta en la implementación de la variación del enfoque de búsqueda local, la cual no garantiza la solución global del problema, sino que se centra en encontrar una solución óptima local; sin embargo, para el modelado multiusuario, esta metodología suele ser más eficiente en términos de tiempo y recursos computacionales, en comparación a la búsqueda exhaustiva.

Finalmente, el manejo de métodos o técnicas con enfoques simples ha demostrado una mayor eficiencia en la resolución de problemas con múltiples restricciones, esto se refleja en este artículo, desarrollando la simulación en una computadora con procesador Intel(R) Core (TM) i5-8250U CPU @ 1.60GHz 1.80 GHz, una RAM de 12GB y un sistema operativo Microsoft Windows 11 Home Single Language, se logró resolver el problema para 60 usuarios en aproximadamente 25 minutos considerando la gran cantidad de variables y obteniendo soluciones adecuadas para los objetivos planteados. Cabe mencionar, que el tiempo necesario para resolver el problema puede variar según la capacidad de la computadora utilizada.

5. CONCLUSIONES

Esta investigación abordó el modelado de cargas residenciales de alto consumo, como lo son las CEC, que contemplan las CEFNI, las CEFI y las CES, así mismo, el modelo asignó un número significativamente mayor de tipos de CEC respecto a los estudios referenciados en la sección 1, y considera una gran variedad de intervalos de tiempo para cada CEC, como se mostró en las Tablas 9 y 10. La metodología desarrollada en este artículo, se basó en técnicas clásicas de optimización y se divide en dos etapas: en la primera, se implementó el método de búsqueda exhaustiva, la cual selecciona las opciones de programación de cargas más eficientes en términos de costo para cada usuario. En la segunda etapa, se empleó un método de búsqueda local que combina las soluciones de cada usuario previamente obtenidas de la etapa 1 y encuentra una solución conjunta, con una curva de consumo más plana y con el menor costo de energía.

La investigación evaluó dos escenarios: el caso base, donde los usuarios gestionan sus cargas a su conveniencia, sin identificar el comportamiento de los precios dinámicos de la energía, y el caso optimizado, que utiliza un algoritmo para reducir los picos de demanda y los costos para los clientes. Al comparar las curvas de demanda de ambos escenarios, se identificaron estrategias de respuesta a la demanda como el recorte de picos, el llenado de valles, la conservación estratégica y el desplazamiento de cargas desde las horas de mayor precio de la energía a horas de menor costo. También se identificó que, debido a la libertad dada a los clientes para seleccionar los rangos horarios en la programación diaria de sus cargas y el desplazamiento de estas a horas de menor precio, resultaron en un aumento del pico de demanda para el 58.33 % de los usuarios en el caso optimizado respecto al caso base. Sin embargo, las restricciones del modelo garantizaron que no hubiera problemas ni a nivel individual ni colectivo, logrando un aplanamiento moderado de la curva de carga según el indicador PAR, sin exceder los límites establecidos.

Asimismo, el MMCEC demostró óptimos resultados al reducir tanto los costos como los picos de demanda en horas de mayor precio de la energía a nivel individual y colectivo, lo cual se traduce en un impacto positivo a nivel general. En 25 minutos logró encontrar una solución considerando entre 9 a 12 CEC para 60 usuarios, un número de variables significativamente alto que no se ha abordado en otras investigaciones. Este desempeño resalta la importancia de utilizar un modelo simple como el desarrollado en este artículo, ya que afronta el desafío de gestionar múltiples usuarios y variables, con un mejor rendimiento visto desde un menor esfuerzo computacional, en comparación al procesamiento que requeriría un algoritmo más complejo. También es de destacar que, si el usuario busca minimizar aún más el coste o si el modelo implementado se excede en las restricciones, esto podría implicar un mayor nivel de sacrificio en términos de comodidad para el cliente o inclusive daños en la infraestructura eléctrica del hogar, pero como se ha dicho en el artículo, en este modelo no se busca afectar negativamente estos aspectos, por el contrario, se busca brindar flexibilidad en la programación de las cargas, permitiendo a los usuarios ajustar sus preferencias según sus necesidades y comodidad.

El modelo identificó algunas limitaciones, como el uso restrictivo del número de cargas CEC por hogar, y la selección de CEFI con un uso de tiempo prolongado, esto causa un exceso de datos en la búsqueda exhaustiva y, por ende, se reduce la velocidad de procesamiento de la información en la simulación, por tal razón, en la etapa multiusuario se emplea la búsqueda local en lugar de exhaustiva, siendo más eficaz en el proceso, a expensas de hallar solamente soluciones locales. En resumen, este estudio demostró que el MMCEC propuesto mediante la PCEC, puede ser una herramienta efectiva en la gestión la demanda de energía eléctrica en hogares inteligentes, logrando un aplanamiento de la curva de demanda con una

reducción del 11.49 % en la potencia máxima y generando ahorros en las facturas de energía con una disminución promedio del 4.94 %, sin afectar drásticamente los hábitos de consumo del cliente. Los resultados abren la puerta a nuevas investigaciones en el campo de la gestión de la energía residencial y destacan la importancia de involucrar a los usuarios de forma colectiva como agentes activos en la optimización de la demanda eléctrica.

Para futuros trabajos en este campo de investigación, se proponen las siguientes consideraciones: (i) incorporar un mayor número de usuarios (vecindario) manteniendo un equilibrio entre la reducción de costos en la factura eléctrica, el aplanamiento del perfil de carga y el nivel de comodidad del cliente, así como agregar otros tipos de cargas con características y variables diferentes, y plantear la posibilidad de incluir los sectores industrial y comercial en la PCEC, (ii) integrar en el algoritmo, la disponibilidad de conexión de vehículos eléctricos, el almacenamiento de baterías de energía y las fuentes no convencionales de energía, (iii) explorar la PCEC utilizando otros algoritmos de optimización para el caso multiusuario, y (iv) ampliar la programación de las cargas a periodos de tiempo más extensos (semanas, meses), incorporando las consideraciones anteriores. También, se sugiere explorar el marco normativo colombiano relacionado con el uso de fuentes no convencionales y los beneficios de la venta de energía excedente, junto con la adopción de tecnologías de redes eléctricas inteligentes en el país.

6. AGRADECIMIENTO Y FINANCIACIÓN

Este trabajo no recibió financiación de ninguna institución pública o privada. Se agradece a la Universidad Distrital Francisco José de Caldas por su apoyo en el acceso a material bibliográfico y a la licencia de MATLAB®.

CONFLICTOS DE INTERÉS DE LOS AUTORES

Los autores declaran no tener ningún conflicto de intereses financiero, profesional o personal derivado de la publicación de este artículo.

CONTRIBUCIÓN DE LOS AUTORES

Nelson Mauricio Bejarano Bejarano: Investigación, metodología, diseño y programación de los algoritmos de optimización, redacción, revisión y edición.

Francisco David Moya Chaves: Conceptualización, metodología, revisión, redacción, sugerencias y edición.

Óscar Danilo Montoya Giraldo: Conceptualización, redacción, sugerencias, edición y revisión final del escrito.

DECLARACIÓN IA

Durante la realización de esta investigación, los autores utilizaron ChatGPT para el proceso de escritura, que comprende mejorar aspectos en ortografía, gramática y redacción. Luego de emplear esta herramienta/servicio, los autores revisaron y editaron

cuidadosamente el contenido según sea necesario y asumen total responsabilidad por el contenido de la publicación.

7. REFERENCIAS

- [1] M. Pipattanasomporn, M. Kuzlu, and S. Rahman, “An Algorithm for Intelligent Home Energy Management and Demand Response Analysis,” *IEEE Trans Smart Grid*, vol. 3, no. 4, pp. 2166–2173, Jun. 2012. <https://doi.org/10.1109/TSG.2012.2201182>
- [2] R. Jovanovic, A. Bousselham, and I. S. Bayram, “Residential Demand Response Scheduling with Consideration of Consumer Preferences,” *Applied Sciences*, vol. 6, no. 1, p. 16, Jan. 2016. <https://doi.org/10.3390/app6010016>
- [3] S. Janocha B., S. S. Baum, and I. Stadler, “Cost minimization by optimization of electricity generation and demand side management,” in *2016 International Energy and Sustainability Conference (IESC)*, Cologne, Germany, 2016, pp. 1-7. <https://doi.org/10.1109/IESC.2016.7569489>
- [4] A. R. Jordehi, “Optimisation of demand response in electric power systems, a review,” *Renewable and Sustainable Energy Reviews*, vol. 103, pp. 308–319, Apr. 2019. <https://doi.org/10.1016/J.RSER.2018.12.054>
- [5] S. N. Bragagnolo, J. C. Vaschetti, and F. Magnago, “A Technical and Economic Criteria Comparison on Demand Side Management with Multi-Level Optimization Model,” *IEEE Latin America Transactions*, vol. 19, no. 9, pp. 1494–1501, Jun. 2021. <https://doi.org/10.1109/TLA.2021.9468442>
- [6] A. C. Duman, Ö. Güler, K. Deveci, and Ö. Gönül, “Residential load scheduling optimization for demand-side management under time-of-use rate,” in *2018 6th International Istanbul Smart Grids and Cities Congress and Fair (ICSG)*, Istanbul, Turkey, 2018, pp. 193-196. <https://doi.org/10.1109/SGCF.2018.8408971>
- [7] F. Y. Melhem, O. Grunder, Z. Hammoudan, and N. Moubayed, “Energy Management in Electrical Smart Grid Environment Using Robust Optimization Algorithm,” *IEEE Trans Ind Appl*, vol. 54, no. 3, pp. 2714–2726, Feb. 2018. <https://doi.org/10.1109/TIA.2018.2803728>
- [8] G. Huang, J. Yang, and C. Wei, “Cost-Effective and Comfort-Aware Electricity Scheduling for Home Energy Management System,” in *2016 IEEE International Conferences on Big Data and Cloud Computing (BDCloud), Social Computing and Networking (SocialCom), Sustainable Computing and Communications (SustainCom) (BDCloud-SocialCom-SustainCom)*, Atlanta, GA, USA, 2016, pp. 453-460. <https://doi.org/10.1109/BDCloud-SocialCom-SustainCom.2016.73>
- [9] A. M. Vega Escobar, “Gestión de la energía eléctrica domiciliaria con base en la gestión activa de la demanda,” Ph.D. tesis, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia, 2018. [Online]. Available: <http://hdl.handle.net/11349/7587>
- [10] A. Ouammi, “Optimal Power Scheduling for a Cooperative Network of Smart Residential Buildings,” *IEEE Trans Sustain Energy*, vol. 7, no. 3, pp. 1317–1326, Mar. 2016. <https://doi.org/10.1109/TSTE.2016.2525728>
- [11] A. R. S. Vidal, L. A. A. Jacobs, and L. S. Batista, “An evolutionary approach for the demand side management optimization in smart grid,” in *2014 IEEE Symposium on Computational Intelligence Applications in Smart Grid (CIASG)*, Orlando, FL, USA, 2014, pp. 1-7. <https://doi.org/10.1109/CIASG.2014.7011561>
- [12] Á. R. Restrepo, S. E. Nope, and D. E. Enríquez, “Beneficios Económicos de la Gestión de la Demanda y la Energía Autogenerada en el Contexto de la Regulación Colombiana,” *CIT Información tecnológica*, vol. 29, no. 1, pp. 105–116, Feb. 2018. <https://doi.org/10.4067/S0718-07642018000100105>
- [13] D. H. Ruiz Amaya, “Optimización de recursos energéticos a partir de la utilización de un der y de la integración de equipos de automatización,” M.S. tesis, Pontificia Universidad Javeriana, Bogotá, Colombia, 2015. [Online]. Available: <https://doi.org/10.11144/Javeriana.10554.16812>
- [14] M. Amer, A. Naaman, N. K. M'Sirdi, and A. M. El-Zonkoly, “Smart home energy management systems survey,” in *International Conference on Renewable Energies for Developing Countries 2014*, Beirut, Lebanon, 2014, pp. 167-173. <https://doi.org/10.1109/REDEC.2014.7038551>
- [15] I. Gupta, G. N. Anandini, and M. Gupta, “An hour wise device scheduling approach for demand side management in smart grid using particle swarm optimization,” in *2016 National Power Systems Conference (NPSC)*, Bhubaneswar, India, 2016, pp. 1-6. <https://doi.org/10.1109/NPSC.2016.7858965>
- [16] J. S. Gómez Marín, S. X. Carvajal, and A. Arango Manrique, “Programas de gestión de demanda de electricidad para el sector residencial en Colombia: Enfoque Sistémico,” *Energética*, Jul. 2015. <https://repositorio.unal.edu.co/handle/unal/64269>

- [17] L. Sheng-Kai, and C. Chao-Rong, "Optimal energy consumption scheduling in home energy management system," in *2016 International Conference on Machine Learning and Cybernetics (ICMLC)*, Jeju, Korea (South), 2016, pp. 638-643. <https://doi.org/10.1109/ICMLC.2016.7872962>
- [18] F. D. Moya Chavez, L. C. P. Da Silva, and J. C. Lopez A., "A Mathematical Model for the Optimal Scheduling of Smart Home Electrical Loads," *WSEAS Transactions on Power Systems*, Jan. 2018. <https://repositorio.usc.edu.co/items/cf5777b3-948e-4561-98a0-d01b30d47592>
- [19] Y. Wang, C. Hao, and T. Yoshimura, "A particle swarm optimization and branch and bound based algorithm for economical smart home scheduling," in *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*, Boston, MA, USA, 2017, pp. 213-216. <https://doi.org/10.1109/MWSCAS.2017.8052898>
- [20] E. Moreno Soto, "Análisis de la flexibilidad de la demanda en usuarios residenciales," M.S. tesis, Universidad Nacional de Colombia, Bogotá, Colombia, 2021. [Online]. Available: <https://repositorio.unal.edu.co/handle/unal/80431>
- [21] S. N. Bragagnolo, J. C. Vaschetti, F. Magnago, and J. C. Gomez-Targarona, "Gestión de la demanda en las redes inteligentes. Perspectiva y control desde el usuario y la distribuidora," *CIT Información tecnológica*, vol. 31, no. 3, pp. 159–170, Jun. 2020. <https://doi.org/10.4067/S0718-07642020000300159>
- [22] F. D. Moya Ch., J. C. Lopez A., and L. C. P. da Silva, "Model for smart building electrical loads scheduling," in *2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC)*, Florence, Italy, 2016, pp. 1-6. <https://doi.org/10.1109/EEEIC.2016.7555639>
- [23] F. D. Moya Ch., L. C. P. da Silva, J. C. Lopez A., and P. Vergara B., "GRASP model for smart home electrical loads scheduling," in *2015 International Energy and Sustainability Conference (IESC)*, Farmingdale, NY, USA, 2015, pp. 1-6. <https://doi.org/10.1109/IESC.2015.7384384>
- [24] M. J. Kochenderfer, and T. A. Wheeler, "Linear Constrained Optimization" in *Algorithms for Optimization*. London, England: The MIT Press, 2019, pp 189-206. <https://mitpress.mit.edu/9780262039420/algorithms-for-optimization/>
- [25] H. T. Dinh, and D. Kim, "An Optimal Energy-Saving Home Energy Management Supporting User Comfort and Electricity Selling with Different Prices," *IEEE Access*, vol. 9, pp. 9235–9249, Jan. 2021. <https://doi.org/10.1109/ACCESS.2021.3050757>
- [26] M. Á. Dávila, "Desarrollo de un algoritmo de gestión de la demanda energética de un cargador residencial de baterías para vehículos eléctricos en un escenario de tarificación en tiempo real," M.S. tesis, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia, 2021. [Online]. Available: <http://hdl.handle.net/11349/29308>
- [27] D. G. Rossit, S. Nesmachnow, J. Toutouh, and F. Luna, "Scheduling deferrable electric appliances in smart homes: a bi-objective stochastic optimization approach," *Mathematical Biosciences and Engineering*, vol. 19, no. 1, pp. 34–65, 2022. <https://doi.org/10.3934/mbe.2022002>
- [28] S. Montaña, and C. A. Correa-Florez, "Programación óptima de cargas eléctricas flexibles a nivel residencial en tiempos de Covid-19," *INGE CUC*, vol. 17, no. 1, pp. 49–68, 2021. <https://hdl.handle.net/11323/10286>
- [29] N. D. Rahate, and N. Kinhekar, "Demand side management for household equipment's," in *2017 International Conference on Information, Communication, Instrumentation and Control (ICICIC)*, Indore, India, 2017, pp. 1-5. <https://doi.org/10.1109/ICOMICON.2017.8279108>
- [30] O. Oladeji, and O. O. Olakanmi, "A genetic algorithm approach to energy consumption scheduling under demand response," *2014 IEEE 6th International Conference on Adaptive Science & Technology (ICAST)*, Ota, Nigeria, 2014, pp. 1-6. <https://doi.org/10.1109/ICASTECH.2014.7068096>
- [31] D. Borges Vasconcellos, P. Puch González, and G. Frías González, "Control de demanda eléctrica aplicando algoritmos genéticos," *Ingeniare, Revista chilena de ingeniería*, vol. 25, no. 3, pp. 389–398, sep. 2017. <https://doi.org/10.4067/S0718-33052017000300389>
- [32] N. Pavithra, and B. P. Esther, "Residential demand response using genetic algorithm," in *2017 Innovations in Power and Advanced Computing Technologies (i-PACT)*, Vellore, India, 2017, pp. 1-4. <https://doi.org/10.1109/IPACT.2017.8245143>
- [33] I. O. Essiet, Y. Sun, and Z. Wang, "Optimized energy consumption model for smart home using improved differential evolution algorithm," *Energy*, vol. 172, pp. 354–365, Apr. 2019. <https://doi.org/10.1016/j.energy.2019.01.137>
- [34] V. J. Gutierrez-Martinez, C. A. Moreno-Bautista, J. M. Lozano-Garcia, A. Pizano-Martinez, E. A. Zamora-Cardenas, and M. A. Gomez-Martinez, "A Heuristic Home Electric Energy Management System Considering Renewable Energy Availability," *Energies*, vol. 12, no. 4, p. 671, Feb. 2019. <https://doi.org/10.3390/en12040671>
- [35] W. Guzman, S. Osorio, and S. Rivera, "Modelado de cargas controlables en el despacho de sistemas con fuentes renovables y vehículos eléctricos," *Ingeniería y Región*, vol. 17, p. 49, Jun. 2017. <https://doi.org/10.25054/22161325.1535>

- [36] R. A. Hincapié Isaza, “Optimización binivel aplicada al problema de la planeación de redes eléctricas de media y baja tensión,” Ph.D. tesis, Universidad Tecnológica de Pereira, Pereira, Colombia, 2017. [Online]. Available: <https://repositorio.utp.edu.co/handle/11059/8479>
- [37] C. Henggeler Antunes, M. J. Alves, and B. Ecer, “Bilevel optimization to deal with demand response in power grids: models, methods and challenges,” *TOP*, vol. 28, no. 3, pp. 814–842, Oct. 2020. <https://doi.org/10.1007/s11750-020-00573-y>
- [38] P. Carrasqueira, M. J. Alves, and C. H. Antunes, “Bi-level particle swarm optimization and evolutionary algorithm approaches for residential demand response with different user profiles,” *Information Sciences*, vol. 418–419, pp. 405–420, Dec. 2017. <https://doi.org/10.1016/j.ins.2017.08.019>
- [39] M. Fan-Lin, and Z. Xiao-Jun, “An optimal real-time pricing for demand-side management: A Stackelberg game and genetic algorithm approach,” in *2014 International Joint Conference on Neural Networks (IJCNN)*, Beijing, China, 2014, pp. 1703-1710. <https://doi.org/10.1109/IJCNN.2014.6889608>
- [40] M. Fan-Lin, and Z. Xiao-Jun, “A bilevel optimization approach to demand response management for the smart grid,” in *2016 IEEE Congress on Evolutionary Computation (CEC)*, Vancouver, BC, Canada, 2016, pp. 287-294. <https://doi.org/10.1109/CEC.2016.7743807>
- [41] F. Wang *et al.*, “Multi-Objective Optimization Model of Source–Load–Storage Synergetic Dispatch for a Building Energy Management System Based on TOU Price Demand Response,” *IEEE Trans Ind Appl*, vol. 54, no. 2, pp. 1017–1028, Dec. 2017. <https://doi.org/10.1109/TIA.2017.2781639>
- [42] D. Ferrer Valencia, “Desarrollo de un algoritmo de optimización basado en búsqueda local guiada para el problema de minimización en la huella de carbono en el ruteo de vehículos heterogéneos,” M.S. tesis, Universidad Nacional de Colombia, Bogotá, Colombia, 2023. [Online]. Available: <https://repositorio.unal.edu.co/handle/unal/84862>
- [43] Comisión de Regulación de Energía y Gas (CREG), “Estrategias para la implementación de esquemas de señales de precios y cargos horarios a los usuarios finales en el SIN, para ser utilizados en programas de respuesta de la demanda,” creg.gov.co Accessed: Feb. 28, 2024. [Online]. Available: <https://creg.gov.co/publicaciones/15313/estrategias-para-la-implementacion-de-esquemas-de-senales-de-precios-y-cargos-horarios-a-los-usuarios-finales-en-el-sin-para-ser-utilizados-en-programas-de-respuesta-de-la-demanda/>
- [44] A. Gargallo Tatay, “Medición y análisis del consumo de energía eléctrica en los receptores domésticos en condiciones reales de funcionamiento: Aplicación a una vivienda unifamiliar,” Tesis de grado, Universitat Politècnica de Valencia, Valencia, España, 2018. [Online]. Available: <https://riunet.upv.es:443/handle/10251/106520>
- [45] Lucera. “Eficiencia Energética.” lucera.es. Accessed: Feb. 28, 2024. [Online]. Available: <https://lucera.es/blog/cuanto-consumen-electrodomesticos>
- [46] COPELCO. “CONOCÉ, AHORRÁ, CUIDÁ - Recomendaciones para el buen uso de energía eléctrica.” [copelco.coop](https://www.copelnet.com.ar). Accessed: Feb. 28, 2024. [Online]. Available: <https://www.copelnet.com.ar/informacion-de-interes/energia/consumo-de-artefactos-electricos>
- [47] Endesa. “Cuánta energía consume un termo eléctrico.” [endesa.com](https://www.endesa.com). Accessed: Feb. 28, 2024. [Online]. Available: <https://www.endesa.com/es/blog/blog-de-endesa/consejos-de-ahorro/cuanta-energia-consume-termo-electrico>
- [48] Ministerio de Economía. “Consumo básico de electrodomésticos.” [argentina.gob.ar](https://www.argentina.gob.ar). Accessed: Feb. 28, 2024. [Online]. Available: <https://www.argentina.gob.ar/enre/uso-eficiente-y-seguro/consumo-basico-electrodomesticos>
- [49] A. Daza Urrego, and L. M. Nieto Gutiérrez “Manual práctico de condiciones para instalaciones de sistemas solares fotovoltaicos para suplir cargas demandadas de estrato 3 a 6 en viviendas unifamiliares de Bogotá,” Tesis de grado, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia, 2019. [Online]. Available: <http://hdl.handle.net/11349/15575>
- [50] CIME Power Systems. “Tablas de consumo eléctrico.” [cimepowersystems.com.mx](https://www.cimepowersystems.com.mx). Accessed: Feb. 28, 2024. [Online]. Available: <http://www.cimepowersystems.com.mx/wp-content/uploads/2011/10/Tabla-de-consumos.pdf>
- [51] K. A. Hernández Hernández, and J. S. Carrillo Cruz, “Análisis de la curva de demanda eléctrica para usuarios residenciales estrato 4 en la ciudad de Bogotá ante diferentes escenarios de los hábitos de consumo,” Tesis de grado, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia, 2017. [Online]. Available: <http://hdl.handle.net/11349/5838>
- [52] E. D. Romero Villamil, and S. A. Osorio Huertas, “Curva de demanda de energía eléctrica en sector residencial estrato tres de Bogotá D.C. mediante caracterización por redes neuronales artificiales,” Tesis de grado, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia, 2021. [Online]. Available: <http://hdl.handle.net/11349/26755>

- [53] Reglamento Técnico de Instalaciones Eléctricas – RETIE, Resolución 9-0708 de 2013, Ministerio de Minas y Energía, Colombia, 2013. [Online]. Available: https://www.minenergia.gov.co/documents/3809/Anexo_General_del_RETIE_vigente_actualizado_a_2015-1.pdf