

Comparación de Metaheurísticas para Determinar la Estructura Óptima de una Red Neuronal para Simular el Consumo Eléctrico en Salta-Argentina

Franco Zaneck

zaneckfranco@gmail.com

Departamento de Informática, Universidad Nacional de Salta, Salta, Argentina

Resumen: El suministro eléctrico representa un pilar fundamental en la sociedad contemporánea, donde la demanda varía constantemente, requiriendo una oferta estable. Esto implica una coordinación meticulosa en la producción, distribución, y desarrollo de infraestructuras que soporten esta situación. La capacidad de prever con precisión la demanda es crucial para guiar estas decisiones. Aunque las redes neuronales han demostrado eficacia en este ámbito, encontrar la estructura óptima de capas ocultas y neuronas para abordar este desafío sigue siendo una tarea compleja. Por lo tanto, este estudio se centra en investigar dos heurísticas para optimizar la configuración de una red neuronal capaz de prever el consumo eléctrico; en particular, este estudio se centra en el consumo eléctrico de la Ciudad de Salta, Argentina. Este enfoque no solo busca mejorar la precisión de las estimaciones, sino también aumentar la eficiencia del sistema eléctrico en su conjunto. El objetivo último es contribuir al desarrollo sostenible y a la estabilidad energética, garantizando un suministro confiable y equitativo para todos los ciudadanos. Al desarrollar y comparar los resultados brindados por la heurística de Algoritmo Genético y Colonia de Abejas, se pretende encontrar un equilibrio entre la precisión de las predicciones y la eficiencia computacional, lo que permitirá una mejor planificación y gestión del suministro eléctrico. Este enfoque no solo beneficiará a los consumidores finales al garantizar un suministro estable y justo, sino que también proporcionará a los responsables de la toma de decisiones información valiosa para optimizar la infraestructura y los recursos disponibles. En última instancia, este estudio busca no solo mejorar la capacidad predictiva de las redes neuronales en el contexto específico de la Ciudad de Salta, Argentina, sino también sentar las bases para futuras investigaciones y aplicaciones en el campo de la gestión energética y la planificación del suministro eléctrico a nivel global.

Palabras Clave: Redes Neuronales; Consumo Eléctrico; Algoritmo Genético; Colonia de Abejas; Optimización.

Abstract: Electric supply represents a fundamental pillar in contemporary society, where demand constantly varies, requiring a stable supply. This entails meticulous coordination in the production, distribution, and development of infrastructure to support this situation. The ability to accurately forecast demand is crucial for guiding these decisions. Although neural networks have shown effectiveness in this area, finding the optimal structure of hidden layers and neurons to address this challenge remains a complex task. Therefore, this study focuses on investigating two heuristics to optimize the configuration of a neural network capable of predicting electrical consumption; specifically, this study focuses on electrical consumption in the City of Salta, Argentina. This approach not only aims to improve the accuracy of estimates but also to increase the efficiency of the electrical system as a whole. The ultimate goal is to contribute to sustainable development and energy stability, ensuring a reliable and equitable supply for all citizens. By developing and comparing the results provided by the Genetic Algorithm and Bee Colony heuristic, the aim is to strike a balance between prediction accuracy and computational efficiency, enabling better planning and management of electrical supply. This approach will not only benefit end consumers by ensuring a stable and fair supply but will also provide decision-makers with valuable information to optimize infrastructure and available resources. Ultimately, this study aims not only to enhance the predictive capacity of neural networks in the specific context of the City of Salta, Argentina, but also to lay the groundwork for future research and applications in the field of energy management and electrical supply planning globally.

Keywords: Neural Networks; Electrical Consumption; Genetic Algorithm; Bee Colony; Optimization.

I. INTRODUCCIÓN

El suministro eléctrico es un pilar fundamental en el funcionamiento de la sociedad moderna. Desde la iluminación

hasta la alimentación de dispositivos electrónicos esenciales, la electricidad se ha convertido en una necesidad básica en nuestra vida diaria. La dependencia de la electricidad es tan significativa que cualquier interrupción en el suministro puede

tener repercusiones graves en múltiples aspectos de la sociedad, desde la economía hasta la salud pública.

En el contexto actual, caracterizado por un aumento constante en el uso de la tecnología y la digitalización de numerosos procesos, la demanda de energía eléctrica está en constante crecimiento. Esta creciente demanda plantea desafíos significativos para los proveedores de energía, quienes deben garantizar un suministro estable y confiable en todo momento, a pesar de las fluctuaciones en el consumo.

Además, la naturaleza misma de la electricidad, que no puede almacenarse fácilmente en grandes cantidades, agrega una capa adicional de complejidad al sistema eléctrico. Esto significa que la oferta de electricidad debe estar en equilibrio con la demanda en todo momento, lo que requiere una coordinación cuidadosa entre la producción, la distribución y el consumo de energía.

En este contexto, la capacidad de predecir con precisión la demanda eléctrica se vuelve crucial. Una estimación precisa de la demanda no solo permite a los proveedores de energía planificar y gestionar mejor sus recursos, sino que también contribuye a garantizar un suministro continuo y eficiente de electricidad para los consumidores.

Es en este punto donde entran en juego las redes neuronales artificiales (RNN). Estas herramientas de inteligencia artificial han demostrado ser altamente efectivas en una variedad de aplicaciones, incluida la predicción de la demanda eléctrica. Al utilizar datos históricos de consumo, patrones climáticos y otras variables relevantes, las RNN pueden generar modelos predictivos precisos que ayudan a anticipar las necesidades futuras de energía y a tomar decisiones informadas sobre la infraestructura y la inversión en el sector eléctrico.

Por lo tanto, para abordar este desafío, diversos autores [1-6] han desarrollado una variedad de modelos de predicción de la demanda eléctrica a corto plazo en diferentes ubicaciones alrededor del mundo. Estos modelos incorporan una amplia gama de variables de entrada, incluidos datos climáticos específicos de las regiones en cuestión, así como registros históricos detallados del consumo eléctrico. Esta inclusión de múltiples factores permite una aproximación más precisa a la predicción de la demanda.

Al analizar estos trabajos, se puede observar que, en promedio, el valor del error cuadrático medio se sitúa alrededor del 4%. Sin embargo, es importante destacar que este valor puede variar según la complejidad del modelo, la calidad de los datos utilizados y la precisión de los métodos de predicción empleados. Además, se ha observado que la precisión de las predicciones puede verse influenciada por factores externos impredecibles, como cambios repentinos en el clima o eventos inesperados que afecten el comportamiento del consumo eléctrico.

Por otro lado, un grupo de investigadores (referenciados como [7-9]) ha centrado su atención en el desarrollo de modelos basados en redes neuronales para predecir la demanda eléctrica en un horizonte de tiempo más amplio, específicamente, en el mediano plazo. Estos modelos, que han sido aplicados en diversas ubicaciones geográficas alrededor del mundo, comparten similitudes con los modelos mencionados anteriormente en términos de las variables de entrada

consideradas. No obstante, se observa una diferencia significativa en cuanto a los resultados obtenidos.

En contraste con los modelos de predicción a corto plazo, estos modelos neuronales para el mediano plazo muestran un valor del Error Cuadrático Medio que oscila en torno al 7%. Esta discrepancia en la precisión de las predicciones sugiere la existencia de desafíos adicionales al proyectar la demanda eléctrica en un horizonte temporal más extenso.

La complejidad inherente al comportamiento de la demanda eléctrica a mediano plazo puede atribuirse a una serie de factores, como cambios estacionales, tendencias de consumo a largo plazo y la influencia de variables socioeconómicas y políticas. Estos elementos pueden introducir una mayor incertidumbre en los modelos predictivos basados en redes neuronales, lo que se refleja en un aumento del Error Cuadrático Medio.

Además, otro grupo de investigadores (referenciados como [10-16]) se ha dedicado al desarrollo de modelos destinados a prever la demanda eléctrica en un horizonte temporal a largo plazo. Estos modelos representan un esfuerzo por anticipar las necesidades futuras de energía eléctrica en un contexto más amplio y extendido en el tiempo. Al contrario de los modelos de corto y mediano plazo, la predicción a largo plazo implica una consideración más profunda de factores de influencia de largo alcance, que abarcan desde tendencias demográficas hasta indicadores económicos clave.

En este sentido, además de las variables climáticas y los datos históricos de consumo eléctrico que se han utilizado en los modelos previamente mencionados, se incorporan otras variables fundamentales como el tamaño de la población y el producto bruto interno (PBI). Estos factores socioeconómicos ofrecen una perspectiva más completa y detallada sobre las condiciones que influyen en la demanda eléctrica a largo plazo.

Los modelos de predicción a largo plazo se enfrentan a un conjunto único de desafíos y complejidades. Por un lado, deben considerar las tendencias de crecimiento de la población, así como los cambios en los patrones de consumo asociados con el desarrollo económico y tecnológico. Por otro lado, deben tener en cuenta las fluctuaciones a largo plazo en las condiciones climáticas y las políticas energéticas que pueden afectar la demanda eléctrica en el futuro. A pesar de estas dificultades, los modelos desarrollados por estos investigadores han logrado alcanzar un nivel de precisión notable, de acuerdo a lo mencionado en cada uno de los artículos y las conclusiones de los mismos.

Sin embargo, al trabajar con Redes Neuronales Recurrentes (RNN), surge un detalle crucial: el número de capas ocultas y el número de neuronas por capa varían según el problema específico en estudio, sin disponer de una fórmula matemática universal para su cálculo. No obstante, abordar el problema de determinar la estructura óptima de una red neuronal puede conceptualizarse como un problema de optimización combinatoria. En este enfoque, la función objetivo busca minimizar el error entre las predicciones de la red neuronal y los valores reales para cada uno de los patrones de entrada, mientras que las restricciones se centran en garantizar que el número de capas ocultas sea mayor que cero, al igual que el número de neuronas en cada una de estas capas.

El desafío de determinar la estructura óptima de una red neuronal ha sido un tema de interés constante, dado que no existe una fórmula matemática que permita definir de manera exacta cada uno de los elementos involucrados en su configuración. Por esta razón, diversos autores han propuesto diferentes enfoques para encontrar modelos que se adapten a los problemas específicos de cada caso. Un ejemplo de esto se encuentra en los artículos [17-19] donde se emplea el algoritmo genético, una metaheurística, para determinar los parámetros de la red neuronal. En otro enfoque, los autores [20] proponen la optimización de los parámetros de la red neuronal utilizando Metaheurísticas basadas en la inteligencia de enjambre mejorada, que consiste en un método automático para optimizar los hiperparámetros y diseñar estructuras a través de la implementación de algoritmos metaheurísticos mejorados. El objetivo de este artículo es doble. Primero, presentan versiones mejoradas de los algoritmos de crecimiento de árboles y luciérnagas que optimizan las implementaciones originales. En segundo lugar, adaptan estos algoritmos mejorados para la optimización de los hiperparámetros. Inicialmente, las metaheurísticas modificadas se evalúan en funciones de referencia estándar sin restricciones y se comparan con las versiones originales. Luego, los algoritmos mejorados se utilizan para el diseño de la red neuronal.

En este estudio, se desarrollan y comparan dos metaheurísticas, el Algoritmo Genético y la Colonia de Abejas Artificial, con el propósito de optimizar la estructura de una red neuronal orientada a la estimación del consumo eléctrico en la ciudad de Salta, Argentina. La optimización de redes neuronales representa un desafío significativo debido a la alta dimensionalidad y no linealidad del espacio de búsqueda asociado a su configuración. Problemas como la determinación del número óptimo de capas ocultas, la cantidad adecuada de neuronas por capa y las funciones de activación requeridas exigen la exploración de combinaciones de hiperparámetros que maximicen el desempeño del modelo.

En este contexto, se eligieron el algoritmo Genéticos y el algoritmo basado en Colonia de Abejas Artificial por sus ventajas frente a métodos tradicionales y técnicas más recientes basadas en gradiente. Estas metaheurísticas destacan por su capacidad para evitar mínimos locales, una limitación común en métodos como Adam o RMSProp, que dependen de derivadas y funciones continuas y diferenciables. La independencia de estas restricciones hace que el AG y el ABC sean particularmente efectivos en espacios de búsqueda no convexos, una característica frecuente en configuraciones complejas de redes neuronales.

Los métodos de búsqueda exhaustiva, si bien garantizan encontrar la mejor solución, resultan computacionalmente inviables en problemas con muchos hiperparámetros debido al crecimiento exponencial del espacio de búsqueda. Por su parte, técnicas basadas en gradientes, como Grid Search o Random Search, son más rápidas pero menos eficaces en espacios no convexos o con parámetros no diferenciables, como el número de capas ocultas o las funciones de activación. Aunque la optimización bayesiana es moderna y eficiente, su implementación puede ser más compleja y requiere suposiciones específicas sobre la función objetivo, como continuidad o correlaciones entre hiperparámetros, que

no siempre son aplicables en configuraciones de redes neuronales.

Entre las técnicas inspiradas en la naturaleza, como el Enjambre de Partículas (PSO), la Optimización por Búsqueda de Cuckoo (CS) y los Algoritmos de Evolución Diferencial (DE), el AG y el ABC se seleccionaron por su comprobado balance entre exploración y explotación. Además, ambas cuentan con amplia documentación y demostrada eficacia en problemas similares de optimización de redes neuronales.

El uso de AG y ABC no solo permite identificar configuraciones óptimas para redes neuronales aplicadas a la predicción del consumo eléctrico en Salta, sino que también establece un marco adaptable a otros dominios. Este enfoque abre la puerta al desarrollo de técnicas híbridas que combinen lo mejor de ambas estrategias o integren métodos más recientes, como la optimización bayesiana o el PSO, en contextos de metaheurísticas colaborativas.

Además, este enfoque sobresale en el manejo de la complejidad inherente al diseño de redes neuronales, facilitando una exploración eficiente del espacio de soluciones, reduciendo los errores de predicción y maximizando la aplicabilidad práctica de las configuraciones obtenidas. De este modo, sienta un precedente para futuras investigaciones en la optimización de modelos predictivos.

El presente trabajo detalla la metodología adoptada en su desarrollo, organizada de la siguiente manera: en la Sección II, se describe exhaustivamente la metodología empleada, abordando tanto los fundamentos teóricos como los procedimientos prácticos aplicados; en la Sección III, se presentan y analizan los resultados obtenidos con las heurísticas propuestas, destacando las implicaciones de los hallazgos y las comparaciones entre los enfoques; y, finalmente, en la Sección IV, se extraen las conclusiones más significativas del estudio y se identifican posibles líneas de investigación futura, aportando nuevas perspectivas para el desarrollo de técnicas optimizadas en la predicción del consumo eléctrico.

II. METODOLOGÍA DE TRABAJO

En esta sección se describen detalladamente los componentes utilizados en cada heurística, así como los datos y variables empleados en RNN. Este enfoque facilita una comprensión profunda de los procesos implicados en la determinación de la estructura óptima de la red neuronal, permitiendo además una evaluación crítica de la eficacia y eficiencia de las distintas estrategias heurísticas implementadas. Con esta información, se busca optimizar la capacidad predictiva del modelo y respaldar la toma de decisiones en la gestión y planificación del suministro eléctrico.

Es importante señalar que todas las estructuras de red analizadas con cada algoritmo mantendrán el mismo número de neuronas en las capas de entrada y salida. Por lo tanto, estas capas no se consideran al definir la estructura óptima de cada modelo.

A. Algoritmo Genético

El algoritmo genético es una metaheurística inspirada en los procesos de evolución natural. Su funcionamiento se basa en la generación y evolución de una población de soluciones

candidatas, llamadas individuos, representadas generalmente como cadenas (cromosomas) que codifican posibles soluciones a un problema. En cada iteración o generación, se evalúa la calidad de cada individuo mediante una función objetivo (fitness). Los mejores individuos se seleccionan para formar una nueva población mediante operadores genéticos como la **reproducción**, que combina características de dos padres (crossover), y la **mutación**, que introduce pequeñas modificaciones aleatorias para explorar nuevas soluciones. Este proceso iterativo favorece la supervivencia de las soluciones más prometedoras y permite a la población converger hacia una solución óptima o cercana a óptima del problema planteado.

Codificación de Individuos

En este proceso, se ha definido que cada individuo representa una red neuronal, y el objetivo es encontrar la configuración óptima de capas ocultas y neuronas. Para ello, se ha establecido la siguiente codificación: cada individuo consta de tantos genes como capas ocultas tiene la red neuronal en cuestión. Cada gen está compuesto por una secuencia de ceros y unos, que corresponde a un número expresado en el sistema binario. Este número, al ser convertido a su equivalente en base 10, indica la cantidad de neuronas presentes en la capa correspondiente. Se utiliza la codificación binaria porque facilita los procesos de reproducción y mutación, ya que las operaciones de cruce y modificación en los algoritmos evolutivos se manejan de manera eficiente con secuencias binarias

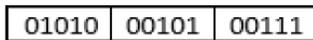


Figura 1: Ejemplo de Codificación de un Individuo

Por ejemplo, considerando la Figura 1, tenemos un individuo con tres genes, esto significa que representa una red neuronal con tres capas ocultas. Al examinar las secuencias binarias de cada gen y convertirlas a base 10, obtenemos valores como 10, 5 y 7, lo que indica que las capas ocultas tienen 10, 5 y 7 neuronas, respectivamente.

Población Inicial

El proceso de generación de la población inicial en el algoritmo genético se divide en dos etapas clave. En la primera, fase de generación inicial, la población de tamaño n se crea aleatoriamente. Luego, en la fase de verificación y reparación, se asegura que los individuos generados sean factibles. Esta fase es crucial, ya que algunos individuos pueden no cumplir con los requisitos necesarios para ser considerados viables. Para garantizar su validez, se implementan dos procesos de reparación: primero, se verifica que no haya capas con cero neuronas intercaladas entre capas que sí tengan neuronas; segundo, se asegura que cada individuo tenga al menos una capa oculta. Estos pasos permiten que la población inicial esté compuesta por individuos que cumplen con los criterios establecidos, listos para el proceso evolutivo del algoritmo.

Proceso de Reproducción

En el proceso de reproducción, se emplea un método de cruzamiento de un punto. En este método, los genes del primer padre se copian hasta un punto de corte aleatorio, y el resto de

los genes se completan con los del segundo padre. Para seleccionar los individuos que serán reproducidos, se utiliza el método de torneo binario. En este proceso, se eligen aleatoriamente dos individuos de la población, se comparan sus valores de aptitud y el individuo con la mejor aptitud es seleccionado como ganador del torneo. Este método se seleccionó por su simplicidad, su capacidad para incluir individuos menos aptos, facilitar la transferencia genética y su eficiencia computacional, ya que solo requiere comparar la aptitud de dos individuos por torneo. Estos enfoques de trabajo están respaldados por la literatura relacionada con el problema, que ha demostrado su eficacia en contextos similares [21-23].



Figura 2: Reproducción de Dos Individuos

La Figura 2 proporciona un ejemplo que detalla el proceso de cruzamiento utilizado en este estudio, ilustrando cómo se combinan los genes de los padres para generar descendencia.

Tras la etapa de reproducción, no se realiza inmediatamente el proceso de verificación y reparación de factibilidad, ya que se espera que la mutación posterior pueda restaurar la factibilidad de las soluciones generadas. Si la mutación no logra restaurar la factibilidad, entonces se aplica el proceso de verificación y reparación, garantizando que todas las soluciones sean viables y cumplan con los requisitos del problema.

Proceso de Mutación

En el proceso de mutación, cada individuo tiene asignada una probabilidad de experimentar una modificación en sus genes. Si se decide que un individuo debe mutar, se selecciona aleatoriamente la cantidad de genes que se modificarán. Para cada gen seleccionado, se altera una cantidad específica de ceros por unos y viceversa, lo que genera variabilidad genética en la población. La Figura 3 ilustra este proceso de mutación.

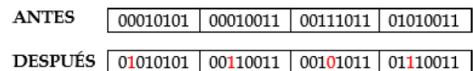


Figura 3: Ejemplo de Aplicación del Operador de Mutación

B. Colonia de Abejas

La metaheurística basada en colonia de abejas (ABC, por sus siglas en inglés) se inspira en el comportamiento colectivo de las abejas en busca de alimento. En este enfoque, se simula una población de abejas que exploran y explotan recursos (soluciones) en un espacio de búsqueda. Estas abejas se dividen en tres grupos principales:

Abejas Empleadas: representan soluciones actuales y están asociadas a fuentes de alimento específicas (posibles soluciones). Cada abeja empleada explora su vecindad para mejorar su fuente actual, evaluando la calidad de la solución mediante una función objetivo.

Abejas Observadoras: estas abejas permanecen en la colmena y eligen fuentes de alimento basándose en la calidad comunicada por las abejas empleadas a través de una “danza”. Las fuentes con mejor calidad tienen mayor probabilidad de ser seleccionadas.

Abejas Exploradoras: si una fuente de alimento no mejora después de un número determinado de iteraciones, las abejas empleadas asociadas a esa fuente la abandonan y se convierten en exploradoras. Estas abejas buscan nuevas fuentes de alimento en regiones aleatorias del espacio de búsqueda, promoviendo la diversidad y evitando el estancamiento en óptimos locales.

El proceso iterativo continúa hasta alcanzar un criterio de parada, como un número máximo de iteraciones o una solución aceptable. Este modelo logra un equilibrio entre exploración (búsqueda de nuevas soluciones) y explotación (mejora de soluciones actuales), permitiendo encontrar soluciones cercanas al óptimo para problemas complejos.

De acuerdo con el procedimiento descrito anteriormente, el primer paso para desarrollar el algoritmo destinado a resolver el problema es definir el tamaño de la población. En este contexto, esto implica determinar el número de fuentes de alimentos, así como la estructura de cada una de estas fuentes.

El siguiente paso es definir las fuentes de alimentos. En este caso, cada fuente de alimento se define como un vector n -dimensional. Cada elemento de este vector representa una posible solución para el problema en cuestión. Similar al caso anterior, cada uno de estos elementos se representa como un vector m -dimensional, donde cada dimensión representa una capa de una posible solución expresada en formato binario.

Este enfoque nos permite generar una variedad de soluciones potenciales dentro de la población inicial, explorando diferentes configuraciones de capas y neuronas en el contexto del problema abordado. La representación en forma de vector facilita la manipulación y la aplicación de operadores genéticos durante el proceso de evolución del algoritmo, lo que contribuye a la eficacia y eficiencia de la búsqueda de soluciones óptimas.

Las abejas empleadas actualizan continuamente las soluciones en función de su experiencia individual y del valor de aptitud de las soluciones recién encontradas. Si encuentran una solución con un costo menor, esta reemplaza a la solución actual. La actualización de la posición para la dimensión j del i -ésimo candidato se calcula utilizando la siguiente ecuación:

$$V_{ij} = x_{ij} + \varphi_{ij}(x_{ij} - x_{kj}) \quad (1)$$

De esta última ecuación, x_{ij} representa la posición actual en la j -ésima dimensión del i -ésimo candidato, φ_{ij} es un valor aleatorio entre 0 y 1, y x_{kj} es la posición del j -ésimo candidato seleccionado aleatoriamente de la población, y por último $\varphi_{ij}(x_{ij} - x_{kj})$ Representa el tamaño del paso entre dos soluciones determinadas. Esta ecuación refleja el proceso de búsqueda local que realizan las abejas empleadas para mejorar las soluciones existentes.

Además, es crucial considerar el papel de las abejas espectadoras, cuyo objetivo principal es calcular la probabilidad de selección de cada fuente de alimento generada

por las abejas empleadas. Durante esta fase, el número de fuentes de alimento para las abejas espectadoras es el mismo que el empleado por las abejas trabajadoras. Durante esta fase, todas las abejas empleadas comparten información sobre la aptitud de las nuevas fuentes de alimentos con las abejas espectadoras. Luego, cada espectador selecciona la mejor fuente de alimento más apta utilizando la siguiente ecuación:

$$Probabilidad\ Selección = \frac{f_{aptitud}}{\sum f_{aptitud-i}} \quad (2)$$

Donde $f_{aptitud}$ representa la aptitud de la fuente de alimento y $f_{aptitud-i}$ es la aptitud de la fuente de alimento i -ésima. Esta ecuación proporciona una medida de la calidad relativa de cada fuente de alimento, lo que permite a las abejas espectadoras tomar decisiones informadas sobre cuál explorar.

Por último, si la ubicación de una fuente de alimento no se actualiza durante un número predefinido de ciclos, se asume que la fuente de alimento se ha descuidado y se activa la fase de abejas exploradoras. Durante esta fase, la abeja asociada con la fuente de alimento olvidada se convierte en abeja exploradora y la fuente de alimento se reemplaza por otra generada aleatoriamente dentro del espacio de búsqueda. Se define un límite de rechazo como parámetro de control, y cuando este límite se alcanza, las abejas exploradoras generan aleatoriamente una nueva fuente de alimento.

Este proceso se repite hasta que se cumple un número fijo de iteraciones, que sirve como criterio de parada para el algoritmo. Este enfoque garantiza que se explore exhaustivamente el espacio de búsqueda y se encuentre una solución óptima o cercana a la óptima dentro de un número finito de iteraciones.

C. Función Objetivo

La función objetivo desempeña un papel fundamental en ambas heurísticas, ya que se utiliza para seleccionar a los mejores individuos de la población generada. Estos individuos seleccionados se convertirán en los padres de la siguiente generación o se utilizarán para actualizar las fuentes de alimento, según el contexto específico de cada heurística.

El problema que se busca resolver radica en determinar la estructura óptima de la red neuronal. Con este fin, se propone una función objetivo que busca minimizar la discrepancia entre los valores predichos por la red neuronal para un conjunto de datos de entrada y los valores reales correspondientes. En términos matemáticos, esta función objetivo puede definirse como:

$$\sum_{i=1}^N (y_{predicho-i} - y_{real-i})^2 \quad (3)$$

Donde N representa el número total de muestras en el conjunto de datos, $y_{predicho-i}$ denota el valor predicho por la red neuronal para la muestra i , y y_{real-i} representa el valor real correspondiente. La función objetivo busca minimizar la suma de los cuadrados de las diferencias entre los valores predichos y los valores reales para todas las muestras en el conjunto de datos.

Esta función objetivo proporciona una medida cuantitativa de la calidad de la solución generada por el algoritmo,

permitiendo así evaluar y comparar diferentes configuraciones de la red neuronal. El objetivo final es encontrar la estructura de red neuronal que minimice esta función objetivo, lo que se traduce en una capacidad predictiva óptima para el modelo.

D. Variables Involucradas

En esta sección se destacan las variables clave utilizadas para modelar el consumo de electricidad en los sectores residencial, comercial e industrial, subrayando por qué se eligieron ciertas variables como las más relevantes para la red neuronal en estudio. Las variables seleccionadas se agrupan según su contexto y sector, y su importancia se fundamenta en su capacidad para capturar los factores que impactan directamente en el comportamiento energético.

Para el sector residencial contamos con las siguientes variables:

Variables Relacionadas con la Vivienda: Estas incluyen la antigüedad, características y equipamiento de la vivienda, ingresos del hogar, número de ocupantes y la descripción eléctrica de la vivienda (electrodomésticos presentes). Se eligieron porque permiten modelar la vivienda en términos físicos y económicos, lo que a su vez tiene una relación directa con la demanda eléctrica. Estas variables son fundamentales para entender cómo la infraestructura y las condiciones económicas de la vivienda influyen en el consumo de electricidad.

Variables Relacionadas con el Individuo: En esta categoría se incluyen características como edad, género, nivel educativo y situación laboral de los habitantes. La elección de estas variables se basa en la idea de que el comportamiento de los individuos dentro de la vivienda influye considerablemente en su consumo eléctrico, ya que factores como la rutina diaria o el uso de electrodomésticos pueden variar según estos aspectos demográficos.

Variables Socioeconómicas: Consideran el entorno social y económico de la vivienda, lo que es crucial para entender el contexto en el que se toman las decisiones relacionadas con el uso de la electricidad. Factores como el nivel de ingresos o la situación económica del hogar afectan el tipo de tecnología utilizada y el patrón de consumo.

Por otro lado para el sector comercial e industrial, contamos con las variables:

Variables Relacionadas con el Comportamiento del Individuo: En el sector comercial e industrial, se destaca el perfil eléctrico del edificio, que incluye el número de ocupantes, el tipo de equipamiento utilizado, la duración de la jornada laboral y el tipo de actividad económica. Estas variables son esenciales para comprender cómo las actividades de los individuos dentro de los edificios afectan el consumo energético, ya que las necesidades energéticas varían según el tipo de actividad y la intensidad de la jornada.

Variables Relacionadas con el Edificio: Incluyen el tipo de construcción, antigüedad, dimensiones y nivel de aislamiento del edificio. Estas variables fueron seleccionadas porque las características físicas del edificio tienen un impacto directo en la eficiencia energética y el consumo, ya que un edificio bien aislado o de reciente construcción puede requerir menos energía para calefacción o refrigeración.

Variables Relacionadas con el Entorno: Consideran el entorno físico y socioeconómico en el que se encuentra el edificio. Estas variables fueron elegidas para captar factores externos que pueden influir en el consumo de energía, como el clima local y las condiciones socioeconómicas del área.

Tras un análisis detallado y un estudio de las correlaciones entre estas variables, se determinó que las variables de entrada más representativas para la red neuronal son:

- Día del año (expresado en términos julianos): Esta variable es crucial porque captura los patrones de estacionalidad y variabilidad anual, lo que influye en el consumo energético.
- Hora del día: Es importante porque permite modelar la variabilidad del consumo a lo largo de las distintas horas del día, que está fuertemente influenciada por los hábitos de uso de la electricidad.
- Temperatura horaria: La temperatura tiene un efecto directo sobre el consumo de energía, especialmente en lo que respecta al uso de calefacción o refrigeración.
- Humedad relativa horaria: La humedad también influye en el consumo energético, especialmente en climas cálidos y en el uso de sistemas de control de la humedad.

Estas variables fueron seleccionadas porque proporcionan un conjunto de datos representativo que permite realizar predicciones precisas y útiles para la gestión de la demanda eléctrica, considerando tanto los aspectos temporales como los factores climáticos y de comportamiento. Además, estos datos fueron recopilados a lo largo de un período de seis años, lo que asegura una visión detallada y robusta para modelar el consumo energético.

E. Datos Utilizados

El conjunto de datos utilizado en este trabajo fue recopilado de diversas fuentes confiables: Compañía Administradora del Mercado Mayorista Eléctrico S.A. Argentino (CAMMESA) y Empresa Distribuidora de Electricidad de Salta (EDESA), que aportaron información sobre los consumos históricos de energía eléctrica, e Instituto Nacional de Tecnología Agropecuaria (INTA), que proporcionó datos climáticos. Estos datos, correspondientes a un período de 6 años con resolución horaria, fueron integrados y organizados para construir el conjunto de datos necesario para el estudio.

El objetivo principal fue determinar la estructura óptima del modelo utilizando algoritmo genético y la metaheurística basada en colonia de Abejas artificiales. Una vez definida esta estructura, se procedió al entrenamiento y validación del modelo sin emplear técnicas de cross-validation, ya que el enfoque adoptado buscaba evaluar directamente la capacidad de generalización de la red neuronal. Identificadas las variables de entrada y salida, se realizó una división estratégica del conjunto de datos para asignar los subconjuntos a las distintas etapas del proceso, garantizando así una evaluación objetiva del modelo y facilitando la toma de decisiones informadas sobre los resultados obtenidos.

El porcentaje de selección del 30% de los datos originales surgió como resultado de diversos ensayos realizados, especialmente durante la etapa final de entrenamiento.

Inicialmente, la capacidad de generalización de las redes no era óptima debido a la cantidad insuficiente de datos destinados al entrenamiento. A lo largo de varias ejecuciones del proceso completo –que incluyó desde la selección de la estructura óptima hasta el entrenamiento final de la red para pronosticar la demanda eléctrica– se fue ajustando progresivamente el número de registros utilizados en cada etapa hasta alcanzar una proporción que ofreciera un equilibrio adecuado entre los datos asignados al entrenamiento y a la evaluación.

Finalmente, este 30% de los datos originales se dividió equitativamente en subconjuntos para entrenamiento y evaluación. Esta distribución permitió utilizar un grupo independiente de datos para validar el modelo, lo que ayudó a identificar problemas como el sobreajuste (overfitting) o subajuste (underfitting), y contribuyó a garantizar una evaluación precisa y objetiva del desempeño del modelo.

En conclusión, el ajuste adecuado del número de datos en cada etapa del proceso fue fundamental para mejorar la generalización del modelo. Esta estrategia asegura que el modelo sea capaz de generar pronósticos precisos y robustos, mientras que la validación confiable de su desempeño facilita la toma de decisiones informadas sobre su implementación y ajuste.

III. RESULTADOS OBTENIDOS

El diseño y la implementación de un algoritmo destinado a estimar el consumo eléctrico en la Ciudad de Salta, Argentina, constituye una iniciativa de vital importancia en el contexto actual. Con el continuo avance tecnológico y la creciente relevancia de la electricidad en diversas esferas de la vida diaria, la gestión eficaz de la demanda eléctrica se vuelve una prioridad ineludible. Hasta este momento, la falta de herramientas específicas para abordar este desafío en Salta ha sido evidente, lo que resalta aún más la necesidad de contar con un modelo preciso y adaptado a las particularidades locales.

El fundamento de este modelo radica en el empleo de redes neuronales, las cuales son alimentadas con datos clave como el día del año, la hora del día, la temperatura y la humedad relativa. La ejecución del algoritmo se llevó a cabo en una computadora equipada con un procesador AMD Ryzen 5 3500U de 2.10 GHz y 8 GB de memoria RAM, lo que garantizó un rendimiento óptimo en la resolución del problema. Los tiempos de ejecución de las heurísticas utilizadas, tanto el algoritmo genético como la Colonia de Abejas, se situaron en un intervalo de 3 a 5 minutos, lo que evidencia una eficiencia aceptable en la implementación de las soluciones.

La selección de parámetros para el algoritmo genético se presenta en la Tabla I, mientras que los correspondientes al algoritmo basado en colonias de abejas se detallan en la Tabla II. Estos parámetros fueron cuidadosamente determinados mediante numerosos ensayos. Como punto de partida, se consideraron valores promedio reportados en la literatura, los cuales se ajustaron progresivamente hasta alcanzar los valores óptimos descritos.

Tabla I: Parámetros Utilizados Algoritmo Genético

Parámetro	Valor
Número de generación	50
Tamaño de la población	30
Probabilidad de mutación	10%
Número de reproductores	12

Tabla II: Parámetros Utilizados Colonia de Abejas

Parámetro	Valor
Fuentes de alimento	30
Número de abejas observadoras	12
Número de abejas empleadas	20
Error tolerable	0.05
Número de iteraciones	50

Así mismo, en las Tablas III y IV se presentan los resultados obtenidos por el Algoritmo Genético y el algoritmo basado en Colonia de Abejas, respectivamente. La estructura mostrada en dichas tablas corresponde al número de capas ocultas y al número de neuronas ocultas de cada red neuronal, dado que todas comparten la misma configuración en la capa de entrada y salida. La capa de entrada consta de 4 neuronas, una para cada variable mencionada en la sección Variables Involucradas, mientras que la capa de salida incluye una sola neurona, destinada a la estimación de la demanda eléctrica.

El error cuadrático medio mostrado en ambas tablas corresponde al valor de la función objetivo para cada modelo. Cabe resaltar que los resultados presentados en las Tablas III y IV reflejan los valores más óptimos alcanzados para el mes de marzo, lo que resalta la efectividad de los enfoques empleados durante ese período específico.

Tabla III: Resultados Obtenidos para el Algoritmo Genético para el Mes de Marzo

Estructura de Red Interna	Error Cuadrático Medio
17	1.256
2-5-6	2.498
8	2.351
5-8-6	1.727
4-7	2.101

Tabla IV: Resultados Obtenidos para el Algoritmo Basado en Colonia de Abejas para el Mes de Marzo

Estructura de Red Interna	Error Cuadrático Medio
7	1.19
6-2	3.423
3-4	1.64
1-5-3	2.472
8	2.369

En conclusión, el desarrollo e implementación de este algoritmo representan un avance significativo en la gestión eficiente de la demanda eléctrica en la Ciudad de Salta. Los modelos desarrollados no solo proporcionan predicciones precisas del consumo eléctrico, sino que también establecen

una base sólida para futuras investigaciones y aplicaciones en el ámbito de la energía y la planificación del suministro.

Dada la variabilidad del conjunto de datos utilizados, se decidió desarrollar 12 modelos de redes neuronales, uno para cada mes del año. Los modelos correspondientes a los meses de enero, febrero y abril fueron obtenidos mediante la ejecución del algoritmo genético, mientras que los modelos para el resto de los meses del año surgieron de la aplicación del algoritmo basado en colonias de abejas. Este enfoque permitió aprovechar las fortalezas de ambos métodos para generar redes neuronales que aprendieran de manera óptima las características específicas de cada mes, adaptándose a las condiciones cambiantes de cada período.

Para determinar los conjuntos de datos para entrenamiento, y considerando los doce meses del año y la variabilidad climática que existe a lo largo de cada uno de ellos, se aseguró que hubiera suficientes datos representativos de cada patrón climático en cada conjunto de datos. Esto garantizó que cada modelo tuviera la información necesaria para aprender y adaptarse a las diversas condiciones climáticas presentes en cada mes, evitando sesgos y asegurando una mayor precisión en el desempeño de los modelos. Como resultado, la ejecución de estos modelos finales a lo largo de todo el año arrojó un error cuadrático medio promedio de 2.304, lo que demuestra la efectividad del enfoque adoptado y su potencial para aplicaciones futuras.

IV. CONCLUSIONES

En este estudio, se han comparado y evaluado dos enfoques para la optimización de la estructura de redes neuronales: el algoritmo genético y el algoritmo basado en Colonia de Abejas. Ambos métodos fueron investigados con el objetivo de determinar la configuración óptima de una red neuronal para predecir el consumo eléctrico en la Ciudad de Salta, Argentina. Los resultados obtenidos revelan hallazgos significativos que aportan una comprensión más profunda sobre la eficacia y las aplicaciones potenciales de ambas técnicas.

El análisis de las Tablas III y IV destaca que la mejor estructura de red neuronal encontrada para abordar este problema consta de una sola capa oculta con siete neuronas. Este resultado es notable, ya que demuestra que una arquitectura relativamente sencilla puede capturar la complejidad inherente de los datos y proporcionar predicciones precisas del consumo eléctrico en Salta.

En cuanto a los tiempos de ejecución, se observa que estos oscilan entre 10 y 15 minutos, lo cual refleja una eficiencia computacional aceptable considerando la complejidad del problema y el volumen de datos procesados. Además, el algoritmo basado en Colonia de Abejas tiende a presentar tiempos ligeramente inferiores en comparación con el algoritmo genético, lo que sugiere una ventaja en términos de velocidad de convergencia.

A pesar de estos avances, es importante reconocer ciertas limitaciones del estudio. Por ejemplo, los modelos se desarrollaron bajo un conjunto de variables específicas y un alcance geográfico limitado a la Ciudad de Salta. Esto podría restringir la generalización de los resultados a otras regiones o contextos con características significativamente diferentes.

Asimismo, aunque se evaluaron dos técnicas metaheurísticas, la inclusión de otras metodologías o combinaciones de estas podría ampliar la perspectiva sobre las posibles configuraciones óptimas de redes neuronales.

Adicionalmente, los tiempos de ejecución, aunque aceptables, podrían representar una barrera para aplicaciones en tiempo real o escenarios con datos en constante actualización. Aunque no fue el enfoque principal del estudio, la optimización de los tiempos computacionales mediante técnicas como paralelización, procesamiento distribuido o el uso de hardware especializado (por ejemplo, GPU o TPU) podría ser una mejora importante.

Por último, la interpretación y aplicabilidad de los resultados ofrecen oportunidades valiosas para futuras investigaciones. Si bien los modelos desarrollados han demostrado su capacidad para predecir el consumo eléctrico con precisión, existe un gran potencial para explorar cómo estos resultados pueden integrarse de manera efectiva en sistemas de gestión energética actuales. Esto podría incluir aplicaciones prácticas como la planificación del suministro, el diseño de políticas tarifarias más equitativas o el desarrollo de estrategias de sostenibilidad energética.

Asimismo, un análisis más detallado de la sensibilidad de los modelos frente a escenarios futuros, como cambios climáticos, interrupciones en el suministro o transformaciones en los patrones de demanda, permitiría evaluar su robustez y adaptabilidad. Estos aspectos no solo ampliarían el alcance del estudio, sino que también contribuirían a fortalecer su utilidad en la toma de decisiones informadas en contextos dinámicos y en constante evolución.

Para futuras investigaciones, se recomienda abordar estas limitaciones de forma más concreta. Podría explorarse la incorporación de un conjunto de datos más amplio y diverso, así como variables adicionales relacionadas con factores socioeconómicos, climáticos y de infraestructura. También sería valioso profundizar en el análisis interpretativo de los resultados, lo que facilitaría una mejor comprensión de los factores que influyen en el consumo eléctrico y permitiría diseñar políticas energéticas más efectivas.

Finalmente, el estudio subraya el potencial de las metaheurísticas en la optimización de redes neuronales para problemas complejos como la estimación de la demanda eléctrica. Tanto el algoritmo genético como la Colonia de Abejas han demostrado ser herramientas útiles para este propósito, contribuyendo al avance en la toma de decisiones informadas en la gestión energética y la planificación urbana.

REFERENCIAS

- [1] H. Eskandari, I. Maryam, and P. Mohsen Moghaddam, *Convolutional and Recurrent Neural Network based model for Short-term Load forecasting*, Electric Power Systems Research 195 107173, 2021.
- [2] L. Wu, C. Kong, X. Hao, and W. Chen, *A Short-term Load Forecasting Method based on GRU-CNN Hybrid Neural Network Model*, Mathematical problems in engineering, 1-10, 2020.
- [3] L. Weixuan, D. Wu, and Benoit Boulet, *Spatial-temporal Residential Short-term Load Forecasting via Graph Neural Networks*, IEEE Transactions on Smart Grid 12.6, 5373-5384, 2021.
- [4] J. Lin, J. Ma, J. Zhu, and Y. Cui, *Short-term Load Forecasting Based on LSTM Networks Considering Attention Mechanism*, International Journal of Electrical Power & Energy Systems, 137, 107818, 2022.

- [5] Y. Wang, J. Chen, X. Chen, X. Zeng, Y. Kong, S. Sun, and Y. Liu, *Short-term Load Forecasting for Industrial Customers Based on TCN-LightGBM*, IEEE Transactions on Power Systems, 36(3), 1984-1997, 2020.
- [6] Y. Hong, Y. Zhou, Q. Li, W. Xu, and X. Zheng, *A Deep Learning Method for Short-term Residential Load Forecasting in Smart Grid*, IEEE Access, 8, 55785-55797, 2020.
- [7] B. N. Oreshkin, G. Dudek, P. Pelka, and E. Turkina, *N-BEATS Neural Network for Mid-term Electricity Load Forecasting*, Applied Energy, 293, 116918, 2021.
- [8] M. Askari and F. Keynia, *Mid-term Electricity Load Forecasting by a New Composite Method Based on Optimal Learning MLP Algorithm*, IET Generation, Transmission & Distribution, 14(5), 845-852, 2020.
- [9] S. M. Jung, S. Park, S. W. Jung, and E. Hwang, *Monthly Electric Load Forecasting Using Transfer Learning for Smart Cities*, Sustainability, 12(16), 6364, 2020.
- [10] M. R. Kazemzadeh, A. Amjadian, and T. Amrace, *A Hybrid Data Mining Driven Algorithm for Long Term Electric Peak Load and Energy Demand Forecasting*, Energy, 204, 117948, 2020.
- [11] M. K. M. Shapi, N. A. Ramli, and L. J. Awal, *Energy Consumption Prediction by Using Machine Learning for Smart Building: Case Study in Malaysia*, Developments in the Built Environment, 5, 100037, 2021.
- [12] J. Q. Wang, Y. Du, and J. Wang, *LSTM Based Long-term Energy Consumption Prediction with Periodicity*, Energy, 197, 117197, 2020.
- [13] Y. Liu, C. Gong, L. Yang, and Y. Chen, *DSTP-RNN: A Dual-stage Two-phase Attention-based Recurrent Neural Network for Long-term and Multivariate Time Series Prediction*, Expert Systems with Applications, 143, 113082, 2020.
- [14] M. Ilbeigi, M. Ghomeishi, and A. Dehghanbanadaki, *Prediction and Optimization of Energy Consumption in an Office Building Using Artificial Neural Network and a Genetic Algorithm*, Sustainable Cities and Society, 61, 102325, 2020.
- [15] R. Olu-Ajayi, H. Alaka, I. Sulaimon, F. Sunmola, and S. Ajayi, *Building Energy Consumption Prediction for Residential Buildings Using Deep Learning and other Machine Learning Techniques*, Journal of Building Engineering, 45, 103406, 2022.
- [16] J. Bedi and D. Toshniwal, *Deep Learning Framework to Forecast Electricity Demand*, Applied Energy, 238, 1312-1326, 2019.
- [17] G. Surendra, W. Samar, N. Md Tabrez, and P. Suraiya, *Optimizing Hyperparameters in Neural Networks Using Genetic Algorithms*, 2024.
- [18] S. Oh, J. Yoon, Y. Choi, Y. A. Jung, and J. Kim, *Genetic Algorithm for the Optimization of a Building Power Consumption Prediction Model*, Electronics, 2022.
- [19] A. Narmontas, R. Jankevičiūtė, T. Bliujus, E. Vaičekauskas, and V. Abromavičius, *Exploration of Genetic Algorithm-Driven Hyperparameter Optimization for Convolutional Neural Networks*, IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream), 2024.
- [20] N. Bacanin, T. Bezdán, E. Tuba, I. Strumberger, and M. Tuba, *Optimizing Convolutional Neural Network Hyperparameters by Enhanced Swarm Intelligence Metaheuristics*, Algorithms, 2020.
- [21] S. Nikbakht, C. Anitescu, and T. Rabczuk, *Optimizing the Neural Network Hyperparameters Utilizing Genetic Algorithm*, J. Zhejiang Univ. Sci. A 22, 407-426, 2021.
- [22] S. Lee, J. Kim, H. Kang, D. Y. Kang, and J. Park, *Genetic Algorithm Based Deep Learning Neural Network Structure and Hyperparameter Optimization*, Applied Sciences, 11(2), 744, 2021.
- [23] M. Abd Elaziz, A. Dahou, and L. Abualigah, *Advanced Metaheuristic Optimization Techniques in Applications of Deep Neural Networks: A Review*, Neural Comput & Applic 33, 14079-14099, 2021.