

Gestión de la generación y almacenamiento en una microrred a partir de redes neuronales

Anderson Yesid Diaz Galvis y Juan Camilo Vega Porras

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones

Ingeniería Eléctrica

Bucaramanga

2023

Gestión de la generación y almacenamiento en una Microrred a partir de redes neuronales

Anderson Yesid Diaz Galvis y Juan Camilo Vega Porras

Trabajo de grado para optar por el título de ingeniero electricista

Director:

Juan Manuel Rey López

Doctor en Ingeniería Electrónica

Codirectores:

Iván Edgardo Jiménez Vargas

Magíster En Ingeniería Eléctrica

Gabriel Ordóñez Plata

Doctor en Ingeniería

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniarías Eléctrica, Electrónica y de Telecomunicaciones

Ingeniería Eléctrica

Bucaramanga

2023

Dedicatoria

Este trabajo de grado está dedicado a mi mamá Aidee Porras Echeverria, mi hermano Sergio Andrés Vega Porras, a mi padre Nelson Vega Rodríguez y a toda mi familia por estar en cada momento de mi vida.

-Juan Camilo Vega Porras-

Agradecimientos

En primer lugar, agradezco a Dios. Agradezco al Doctor Juan Manuel Rey, al Magister Iván Jiménez y al Doctor Gabriel Ordoñez por todo su acompañamiento en la construcción de este trabajo de grado. También agradezco a todo el equipo de trabajo de la E3T y a todos mis compañeros que compartieron de su tiempo en este periodo como estudiante de pregrado profesional.

-Juan Camilo Vega Porras-

Contenido

	Pág.
Introducción	11
1. Dimensionamiento	14
2. Objetivos	21
2.1 Objetivo General	21
2.2 Objetivos Específicos.....	21
3. Propuesta.....	21
4. Pruebas	30
4.1 Elaboración del código.	30
4.2 Estrategias de desarrollo.	36
4.2.1 Porcentaje de datos tomados para el entrenamiento.	36
4.2.2 Selección de los datos para el entrenamiento.....	41
4.2.3 Estructura de la red neuronal.....	44
5. Análisis	46
6. Conclusiones.....	51
Referencias.....	54

Lista de Figuras

	Pág.
Figura 1. <i>Topología de la microrred del caso de estudio.</i>	15
Figura 2. <i>Dimensionamiento basado en reglas.</i>	16
Figura 3. <i>Alternativa de desarrollo del modelo propuesto para el despacho de las fuentes controladas.</i>	20
Figura 4. <i>Arquitectura de una red neuronal.</i>	23
Figura 5. <i>Alternativas para la red neuronal.</i>	25
Figura 6. <i>Representación de la ubicación de los cuartiles.</i>	26
Figura 7. <i>Ubicación de los cuartiles al ser calculados.</i>	27
Figura 8. <i>Proceso de conversión de datos.</i>	28
Figura 9. <i>Conjunto de datos para cada red neuronal.</i>	29
Figura 10. <i>Redes neuronales del proyecto.</i>	29
Figura 11. <i>Modelo desarrollado en el trabajo de grado.</i>	30
Figura 12. <i>Data set – Generadores Diésel</i>	31
Figura 13. <i>Datos Hora 1. Generadores Diésel</i>	32
Figura 14. <i>Google Drive – Data sets por hora – Generadores Diésel</i>	32
Figura 15. <i>Esquema procedimiento para realizar entrenamiento</i>	33
Figura 16. <i>Visualización predicción individual</i>	36
Figura 17. <i>Gráfica de precisión de cada descriptor.</i>	38
Figura 18. <i>Gráfica de precisión promedio de todos los descriptores.</i>	39
Figura 19. <i>Indicadores para prueba 1 del 5%.</i>	39
Figura 20. <i>Indicadores para prueba 2 del 5%.</i>	40

Figura 21. <i>Indicadores para prueba 3 del 5%.</i>	40
Figura 22. <i>Indicadores promedio para evaluación del 5%.</i>	40
Figura 23. <i>Métodos para la selección de datos.</i>	42
Figura 24. <i>Precisión por criterio de selección de datos</i>	43
Figura 25. <i>Precisión y tiempo por estructura de la red neuronal.</i>	45
Figura 26. <i>Tiempo de entrenamiento para diferentes cantidades de neuronas.</i>	46
Figura 27. <i>Mapa de calor descriptores para las 24 horas generadores diésel</i>	47
Figura 28. <i>Mapa de calor descriptores para las 24 horas generadores diésel.</i>	48
Figura 29. <i>Error individual y evaluación.</i>	49

Lista de Tablas

	Pág.
Tabla 1. <i>Precisión Red Neuronal-Hora 1-Generadores Diésel</i>	35

Resumen

Título: Gestión de la generación y almacenamiento en una microrred a partir de redes neuronales*

Autores: Anderson Yesid Diaz Galvis & Juan Camilo Vega Porras**

Palabras Clave: Despacho, Fuentes controlables, Gestión de energía, Microrred, Red neuronal.

Descripción:

Las microrredes eléctricas son una alternativa para electrificar regiones que no tienen acceso a la red eléctrica convencional por motivos de infraestructura o geográficos; para poder determinar la capacidad nominal de los elementos que componen dichas redes se realiza el dimensionamiento. Este trabajo de grado propone un modelo del despacho de las fuentes controlables para una microrred compuesta por paneles fotovoltaicos, aerogeneradores, baterías y generadores diésel basado en redes neuronales, obteniendo así un conjunto de valores que describen el comportamiento de la potencia para un día tipo por cada clase de fuente de despacho. Dicho modelo se obtiene al implementar la siguiente metodología, primero, se define la estrategia de despacho para la red neuronal; segundo, se generan las bases de datos que permiten realizar el entrenamiento de la red neuronal; tercero, se entrena la red utilizando lenguaje de programación Python a través del recurso de Google Colab, desarrollando diferentes estrategias con el fin de escoger el método más adecuado para obtener los parámetros de diseño; por último, se evalúa la precisión del modelo comparando los resultados obtenidos por la red neuronal con los valores calculados al realizar el dimensionamiento basado en reglas para el mismo caso de estudio, con condiciones climáticas y de carga específicas.

* Trabajo de grado.

** Facultad de Ingenierías Fisicomecánicas. Escuela Eléctrica, Electrónica y de Telecomunicaciones. Director: Juan Manuel Rey López. Doctor en Ingeniería Electrónica. Codirectores: Gabriel Ordoñez Plata. PhD en Ingeniería e Iván Edgardo Jiménez Vargas. Mag en Ingeniería Eléctrica.

Abstract

Title: Management of generation and storage in a microgrid from neural networks*

Authors: Anderson Yesid Diaz Galvis & Juan Camilo Vega Porras**

Keywords: Dispatch, Controllable sources, Power Management, Microgrid, Neural Network.

Description:

Electrical microgrids are an alternative to electrify regions that do not have access to the conventional electrical network for infrastructure or geographical reasons; In order to determine the nominal capacity of the elements that make up said networks, dimensioning is carried out. This degree project proposes a controllable sources dispatch model for a microgrid composed of photovoltaic panels, wind turbines, batteries and diesel generators based on neural networks, thus obtaining a set of values that describe the behavior of power for a typical day by each class of dispatch source. Said model is obtained by implementing the following methodology, first, the dispatch strategy for the neural network is defined; second, the databases that allow the training of the neural network are generated; third, the network is trained using the Python programming language through the Google Colab resource, developing different strategies in order to choose the most appropriate method to obtain the design parameters; Finally, the accuracy of the model is evaluated by comparing the results obtained by the neural network with the values calculated when performing the rule-based dimensioning for the same case study, with specific climatic and load conditions.

* Degree Work

** Facultad de Ingenierías Fisicomecánicas. Escuela Eléctrica, Electrónica y de Telecomunicaciones. Director: Juan Manuel Rey López. Doctor en Ingeniería Electrónica. Codirectores: Gabriel Ordoñez Plata. PhD en Ingeniería e Iván Edgardo Jiménez Vargas. Mag en Ingeniería Eléctrica.

Introducción

Las Naciones Unidas (UN) plantean 17 objetivos de desarrollo sostenible con el fin de erradicar la pobreza, proteger el planeta y asegurar la prosperidad para todos, siendo necesario que todos los gobiernos, sector privado y sociedad civil participen de manera activa en la consecución de estos. Este trabajo de grado resalta cómo el área de la energía eléctrica juega un papel muy importante en el desarrollo del cumplimiento del objetivo siete (Energía asequible y no contaminante) y el trece (Acción por el clima) debido al crecimiento de demanda por energía eléctrica confiable y limpia, que puedan generar una cantidad menor de gases de efecto de invernadero (*Objetivos y Metas de Desarrollo Sostenible - Desarrollo Sostenible*, n.d.).

Se destaca que el tipo de tecnología utilizada para suplir la necesidad energética a nivel global durante los últimos 30 años son principalmente el petróleo, carbón y gas natural, sin embargo, las que presentan el menor aporte son las energías alternativas como eólica y solar. Para mitigar los impactos del calentamiento global, es necesario que las energías a base de combustibles fósiles reduzcan su participación en el mercado de manera paulatina, generando una transición energética amigable con el medio ambiente (*Energy Statistics Data Browser – Data Tools - IEA*, n.d.).

El crecimiento de las energías renovables como solar, eólica, hidráulica, biocombustibles y otras se debe a que representan un sistema energético menos intensivo en carbono y más sostenible. Gracias a las políticas implementadas por los gobiernos y las organizaciones no gubernamentales se ha intensificado su uso en los últimos años (Abdmouleh et al., 2015; Qadir et al., 2021). El sector eléctrico representa el mayor desarrollo de este tipo de energías.

Teniendo claro el papel de las energías renovables en el mundo se puede intuir que son estrategias viables para el sostenimiento energético de cualquier lugar en el planeta. Actualmente el estilo de vida de la humanidad exige un acceso a la energía eléctrica sin interrupciones, para ello se necesita de un sistema de abastecimiento que permita la generación y la distribución para poder transportarla al mayor número de lugares en el mundo y esté a disposición de cualquier persona cuando lo necesite. Debido a que obtener energía sostenible, fiable y rentable es un reto importante, se recurre a planes de contingencia para cuando el suministro falle ya sea por una tormenta, apagón o porque el lugar es inaccesible para el sistema interconectado nacional por razones económicas o del relieve de la región (Kumar et al., 2018; Ubilla et al., 2014). Algunos planes de contingencia consisten en implementar un sistema de energía a una escala menor a la de la red que alimente la carga de forma temporal o indefinidamente llamada microrred eléctrica.

Una microrred eléctrica es un conjunto de dispositivos que funcionan a partir de energías renovables con el objetivo de abastecer cargas en lugares remotos de difícil acceso para su uso independiente o cuando son desconectadas de la red principal como hospitales, centros de negocios, fábricas, etc. Este grupo puede estar conformado principalmente por paneles solares y aerogeneradores que se encargan de proporcionar la energía eléctrica, generalmente se combinan con unidades de almacenamiento tales como baterías. Cuando los tres elementos anteriores no puedan suplir la carga se recurre a un último dispositivo de generación a base de combustibles fósiles (Zambroni de Souza & Castilla, 2019).

Al utilizar la energía solar se debe tener en cuenta que no está presente durante las 24 horas del día y a su vez debido a las condiciones del lugar los niveles de irradiancia y temperatura pueden variar a lo largo del año, al mismo tiempo si se utiliza la energía eólica se debe considerar que la velocidad del viento varía en cada momento del día, por ende, es muy importante saber que la

potencia y la energía suministrada a la carga está en constante cambio a lo largo del tiempo (Ogunjuyigbe et al., 2016). Para poder realizar un correcto estudio de la zona se debe hacer un análisis de datos de los últimos años y así tener una percepción del comportamiento a futuro de los indicadores ya mencionados. Teniendo claro estas variables, se procede a determinar los umbrales donde la carga se abastece completamente y donde el suministro no es suficiente y si se llega a dar lo segundo se debe contrarrestar el problema con la unidad de almacenamiento. Este análisis se hace más complejo aún cuando se consideran los costos del proyecto dependiendo del número de elementos a utilizar, por ende, para determinar el número de equipos necesarios se necesita de herramientas que permitan cálculos precisos, proceso que se le conoce como “dimensionamiento de una microrred”.

En este documento se diseña un modelo para la gestión de energía en microrredes aisladas compuesta por paneles fotovoltaicos, aerogeneradores, baterías y generadores diésel, centrandó el análisis en el control de despacho de las fuentes controladas basado en redes neuronales. Para esto se toman los resultados de desarrollar el dimensionamiento basado en reglas para condiciones climáticas y de carga específica desarrollados en (Jiménez, 2022). Se extraen valores de potencia despachada por las unidades de baterías y generadores diésel necesarios para generar las bases de datos.

A partir de los valores que representan el despacho de la microrred, se obtienen los conjuntos de entrada y salida para realizar el entrenamiento de la red neuronal, para esto se utilizan bibliotecas de Python y la herramienta Google Colab. Durante el entrenamiento se ejecutan tres estrategias que permiten elegir la opción adecuada para la construcción de la red, se obtienen resultados con una precisión mayor al 0.9 para el modelo entrenado.

Dichos resultados permiten concluir que la alternativa propuesta basada en redes neuronales es factible para obtener valores representativos para las baterías y generadores diésel. Es necesario retomar los valores de salida para obtener los indicadores de confiabilidad y concluir el dimensionamiento, siendo así el punto de partida para un nuevo trabajo de grado.

Finalmente, este trabajo de grado se estructura así: el Capítulo 1 contextualiza el motivo de realizar dimensionamiento, la gestión de energía, tomando de referencia la potencia despachada por las fuentes controlables y la alternativa propuesta para dar solución al campo de estudio. El Capítulo 2 presenta los objetivos general y específicos. El Capítulo 3 expone la metodología para obtener las bases de datos. El Capítulo 4 presenta las estrategias para realizar las pruebas y los resultados generados. El Capítulo 5 recoge el análisis, discusión de los valores generados en el capítulo anterior y recomendaciones para trabajo futuro. Por último, se presentan las conclusiones y las referencias.

1. Dimensionamiento de una microrred y gestión de energía

El dimensionamiento de una microrred se realiza con el fin de seleccionar la mejor opción del conjunto de combinaciones de los elementos que componen el sistema. Para este trabajo, se considerará una microrred aislada compuesta por paneles fotovoltaicos, aerogeneradores, generadores diésel y baterías tal como se muestra en la Figura 1. Al tener establecido la cantidad de combinaciones se procede a obtener los indicadores LPSP (lost power supply probability), LOLH (lost of load hour) y costo para cada combinación y con una serie de pautas se escoge la más indicada (Upadhyay & Sharma, 2014).

Los indicadores LPSP y LOLH se utilizan con el fin de expresar en término de porcentajes la confiabilidad del sistema de distribución eléctrica que presenta la microrred. El primero expresa la probabilidad en que la demanda de potencia requerida por la carga no se satisfizo por las unidades de generación, siendo esta la relación entre la potencia no suministrada a la carga y la demanda en un periodo de tiempo determinado. El segundo indicador representa el porcentaje de horas en que la capacidad de generación es superada por la carga demandada (Rey et al., 2022).

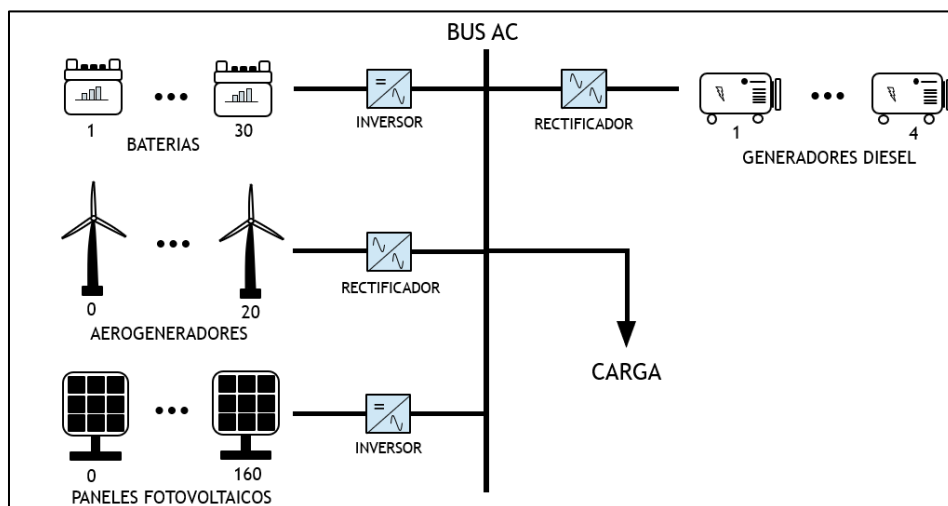
$$\mathbf{LPSP} = \frac{\sum LPS}{\sum P_{carga}} \quad (1)$$

$$\mathbf{LOLH} = \frac{HLPS}{N} * 100\% \quad (2)$$

Donde, LPS es la carga por hora no suministrada si la generación y el almacenamiento de energía no pueden satisfacer la demanda de carga, P_{carga} es la demanda de carga por hora, $HLPS$ es el total de horas cuando LPS tiene un valor positivo y N es el total de horas consideradas en el tiempo de análisis.

Figura 1.

Topología de la microrred del caso de estudio.

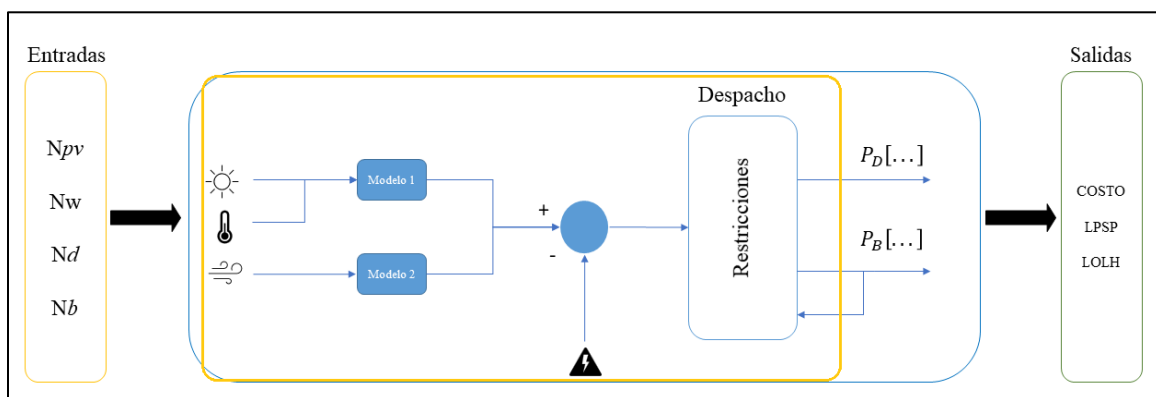


Nota: Microrred compuesta por cuatro elementos para suplir la demanda.

Este trabajo de grado de Ingeniería Eléctrica toma como guía el trabajo de investigación de Maestría en Ingeniería Eléctrica de la Universidad Industrial de Santander titulado “Dimensionamiento de Microrredes Considerando Análisis de Ciclo de Vida” (Jiménez, 2022), donde se realiza el dimensionamiento de la microrred basado en reglas, se implementan los modelos de cada etapa para condiciones climáticas y de carga definidos. En el desarrollo implementado en este trabajo de investigación, se resalta el análisis de las posibles configuraciones que se podrían diseñar de acuerdo con un número específico de equipos variando la cantidad de cada elemento como se muestra en la Figura 1, multiplicando la cantidad de cada uno ($161 \times 21 \times 30 \times 4$) se obtiene un total de 405.720 combinaciones. El esquema que representa el dimensionamiento tradicional basado en reglas y la etapa del proceso en donde se implementa la red neuronal se puede observar en la Figura 2.

Figura 2.

Dimensionamiento basado en reglas.



Nota: Esquema de dimensionamiento de la microrred y gestión de energía.

Etapa del proceso donde se desarrolla el trabajo de grado.

☀️ Valores de irradiancia por hora para ingresar al Modelo 1 (Modelo para calcular la potencia entregada por los Paneles fotovoltaicos).

🌡️ Valores de temperatura por hora para ingresar al Modelo 1.

🌀 Valores de velocidad del viento por hora para ingresar al Modelo 2 (Modelo para calcular la potencia entregada por los aerogeneradores).

⚡ Valores del perfil de potencia por hora de la carga que se desea suplir con la microrred.

En la Figura 2, se visualizan bloques con los nombres Modelo 1, Modelo 2 y Restricciones, estos contienen las fórmulas que permiten realizar el dimensionamiento de una microrred basado en reglas. En (Rey et al., 2022) se presentan algunos de los modelos y sus respectivas ecuaciones.

$$\text{Modelo 1: Paneles Fotovoltáicos. } P_{PV}(t) = N_{PV}P_{PVunit}(t) \quad (3)$$

$$\text{Modelo 2: Aerogeneradores. } P_{WT}(t) = N_{WT}P_{WTunit}(t) \quad (4)$$

$$\text{Restricciones: Generador Diésel. } N_D P_{Dmin} \leq P_D(t) \leq N_D P_{Dmax} \quad (5)$$

$$\text{Baterías: } SOC_{min} \leq SOC(t) \leq SOC_{max} \quad (6)$$

En las ecuaciones (3) y (4) se expone una manera de plantear la potencia entregada por las fuentes de energía solar y eólica. Básicamente, consiste en encontrar la potencia generada por un panel fotovoltaico o un aerogenerador y multiplicarla por la cantidad de unidades a instalar. En la literatura se presentan diferentes maneras y planteamientos para encontrar dichos valores (Ilyushin et al., 2022; Rey et al., 2022; Yaqoob et al., 2022). A continuación, se muestra una manera de encontrar la potencia unitaria de los paneles fotovoltaicos y los aerogeneradores.

Para los paneles fotovoltaicos P_{pv_unit} se puede calcular así:

El modelo usado para los paneles solares considera la irradiancia solar I y la temperatura ambiente T_a como variables de entrada. Primero, la temperatura de la celda T_c se calcula de la siguiente forma:

$$T_c(t) = T_a(t) + I(t) \left(\frac{NOCT-20}{0.8} \right) \quad (7)$$

Donde $NOCT$ es la temperatura nominal de operación de las celdas fotovoltaicas. Usando este valor, la potencia de un solo panel se calcula de la siguiente forma:

$$P_{PVunit} = Y_d n_{PV} A_{PV} I(t) \left(1 - \frac{K_p}{100} (T_c(t) - 25) \right) \quad (8)$$

Donde Y_d es el factor de reducción de acumulación de polvo, n_{PV} es la eficiencia de conversión del panel fotovoltaico, A_{PV} es el área superficial del panel fotovoltaico y K_p es el coeficiente de temperatura de potencia.

Para los aerogeneradores P_{wt_unit} se puede calcular así:

$$P_{WTunit}(t) = 0, V(t) < V_{corte-in} \quad (9)$$

$$P_{WTunit}(t) = \left(\frac{P_{WT}(V^3 - V_{corte-in}^3)}{V_{nominal}^3 - V_{corte-in}^3} \right), V_{corte-in} \leq V(t) < V_{nominal} \quad (10)$$

$$P_{WTunit}(t) = P_{WT}, V_{nominal} \leq V(t) < V_{corte-in} \quad (11)$$

$$P_{WTunit}(t) = 0, V_{corte-out} \leq V(t) \quad (12)$$

P_{WT} es la potencia nominal de la turbina, V es la velocidad del viento y $V_{corte-in}$, $V_{nominal}$ y $V_{corte-out}$ son las velocidades de la turbina.

En (5) y (6) se establecen las condiciones para el despacho de potencia del conjunto de baterías y generadores diésel.

El método basado en reglas presenta deficiencias a la hora de ejecutarlo ya que el almacenamiento y tratamiento de los datos puede tener un alto grado de complejidad, esto debido a la numerosa cantidad de cálculos necesarios para determinar la potencia de cada dispositivo

durante 24 horas por cada día en un lapso de 5 años, obteniendo 43.800 valores para cada grupo de elementos, resultando 175.200 datos por cada combinación y en total 71.082'144.000. Luego para determinar los indicadores descritos anteriormente (LPSP, LOLH y costo) se realizan cálculos que resultan en estos tres valores para cada combinación, obteniendo un total de 1'217.160 de datos adicionales. Para llegar a los indicadores finales se necesita actualizar los parámetros en el momento que se evalúa cada conjunto de elementos, por lo que solo es posible almacenar los resultados, pero no las variables durante el proceso de cálculo, debido a esto surge la necesidad de implementar estrategias que permitan generar las bases de datos no almacenadas cuando sean requeridas.

En la etapa resaltada en color amarillo de la Figura 2 se desarrolla el cálculo de potencias de los dispositivos, primero las de los equipos que utilizan energías renovables (paneles solares y aerogeneradores), luego las de las unidades de almacenamiento (baterías) y finalmente de los equipos a base de energías no renovables (generadores diésel). Se le denomina despacho al conjunto de elementos de la gestión de energía conformado por generadores diésel y baterías, para calcular la potencia generada por este grupo se toma como punto de partida las potencias de los paneles y aerogeneradores, la carga a alimentar para cada hora y las restricciones planteadas anteriormente:

$$P_{PV} + P_W + P_D + P_B = Carga \quad (13)$$

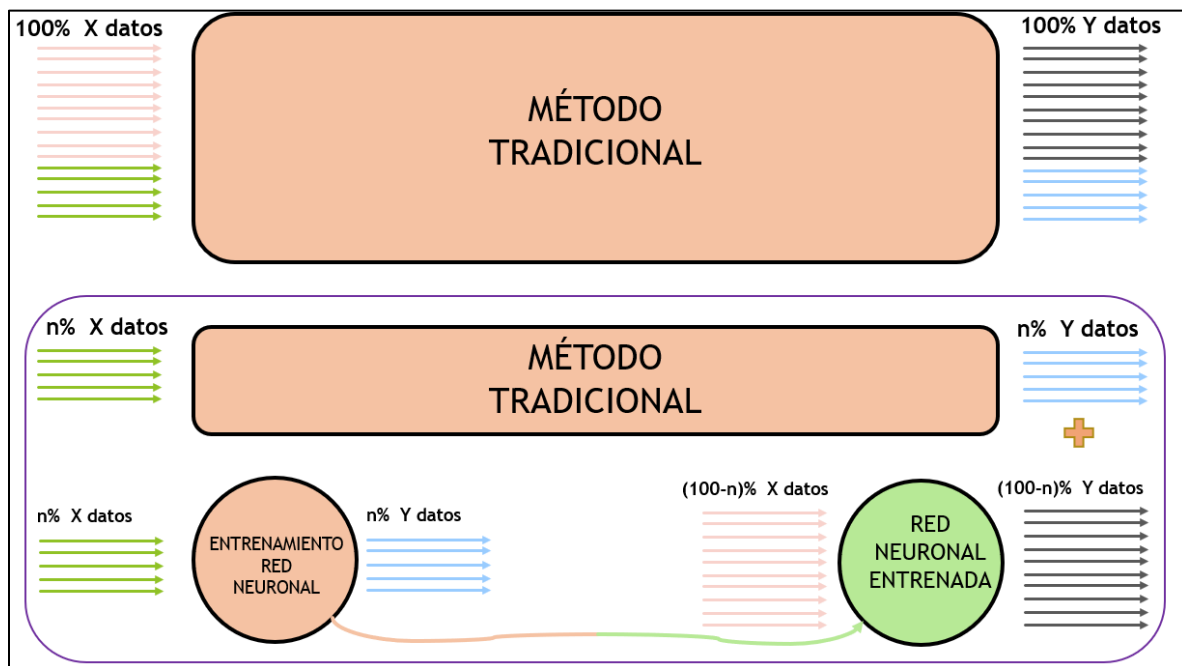
$$Carga - P_{PV} - P_W = P_D + P_B \quad (14)$$

Este trabajo de grado busca obtener un modelo basado en redes neuronales que permita generar el conjunto de datos del despacho, utilizando solo una cantidad determinada del método basado en reglas. Si se obtiene una precisión considerable entre las dos estrategias se podría implementar el

aprendizaje automático para generar otros conjuntos de datos no almacenados de la gestión de energía.

Figura 3.

Alternativa de desarrollo del modelo propuesto para el despacho de las fuentes controladas.



Nota: Esquema de la aplicación de las redes neuronales como una solución alternativa .

Para el desarrollo de obtener los valores de que describan la potencia despachada por las fuentes controlables utilizando herramientas de aprendizaje automático, se obtienen resultados trabajando un porcentaje menor de combinaciones con el método tradicional. Con estos se procede con el entrenamiento de la red neuronal. Una vez lista, se calculan el conjunto complementario de los valores que representen la gestión de energía obteniendo el cien por ciento del conjunto final.

2. Objetivos

2.1 Objetivo General

Diseñar un modelo basado en redes neuronales para la gestión de energía en microrredes aisladas para condiciones climáticas y de carga específicas.

2.2 Objetivos Específicos

Definir la estrategia de gestión de energía para una red neuronal y los respectivos modelos de la microrred.

Generar una base de datos con la información de las variables de entrada y salida para el entrenamiento y prueba de la red neuronal.

Entrenar el modelo implementado basado en redes neuronales con la información de entrada y salida de la base de datos.

Evaluar la precisión del modelo entrenado respecto a la estrategia de gestión de energía desarrollada de manera convencional.

3. Propuesta

Tras contemplar el dimensionamiento y el despacho de potencia de las fuentes controlables de la microrred expuesto anteriormente se propone buscar un método alternativo que permita desarrollarlo de forma rápida y sencilla, esto debido a que para poder ejecutar los cálculos del despacho se desarrolla un proceso matemático complejo que puede tardar un tiempo significativo para poder procesar los datos. Un método que permita reducir el tiempo de ejecución y la dificultad del tratamiento de las muestras, así como predecir de forma efectiva la misma información

recolectada solo teniendo como base un pequeño número de datos. En ese caso se contemplan las redes neuronales como una opción adecuada para determinar los valores que representan la potencia generada o almacenada por los generadores diésel y baterías.

Una red neuronal es un modelo que utiliza algoritmos de aprendizaje basados en el principio de funcionamiento del cerebro humano para almacenar información, siendo esto de mucha practicidad para ser implementado en aplicaciones donde la relación entre las entradas y salidas de un problema son desconocidas. Se trata de un proceso de aprendizaje automático que, usando nodos y capas e interconectándolas aprende comparando los resultados obtenidos con los valores reales asignando pesos que permiten mejorar su precisión (Keijsers, 2010).

Haciendo una comparación con el cerebro humano las redes neuronales utilizan módulos que cumplen la función de neuronas interconectadas entre si pasándose información en cascada, estos módulos también llamados pesos generan funciones matemáticas complejas que operan de forma oculta con los datos ingresados por el usuario y arrojando resultados según las indicaciones especificadas. Las neuronas están divididas en regiones denominadas capas que permiten un mejor desarrollo del algoritmo, las capas principales utilizadas por una red neuronal son:

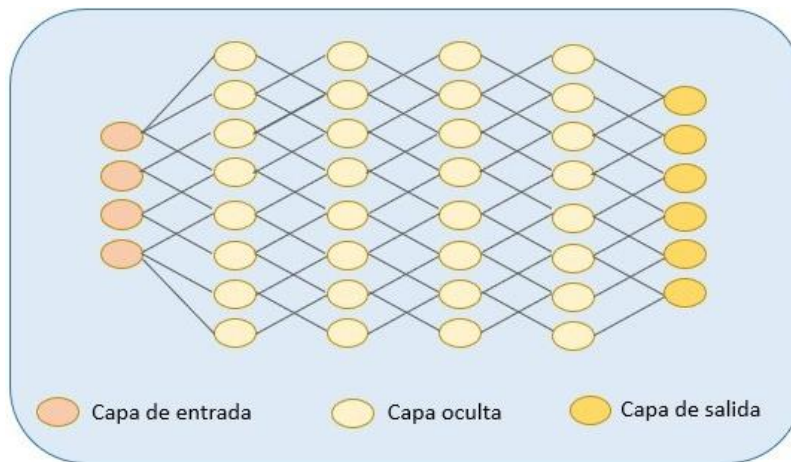
Capa de entrada: Los datos ingresados por el usuario o cualquier agente externo son procesados por las neuronas de entrada, los analizan o clasifican y los pasan a la siguiente capa.

Capa oculta: Toma los datos de la salida de la capa de entrada o de otra capa oculta, las analiza aún más y pasa la información a la siguiente capa. Una red neuronal puede tener más de una capa de este tipo.

Capa de salida: Proporciona el resultado final o los datos de salida solicitados por el usuario previamente según el número de neuronas que disponga la capa.

Figura 4.

Arquitectura de una red neuronal.



Nota: Esquema básico de una red neuronal capas y neuronas.

Las redes neuronales más complejas pueden tener millones de capas ocultas que permiten un aprendizaje más preciso conocido como aprendizaje profundo. El diseño de una red neuronal es fundamental para la obtención de resultados ya que, dependiendo del número de neuronas y capas asignadas, puede variar el tiempo de aprendizaje, además el número de datos elegidos como datos de entrada para el entrenamiento de la red es determinante en la precisión del modelo (Kalogirou, 2004; Marini, 2009).

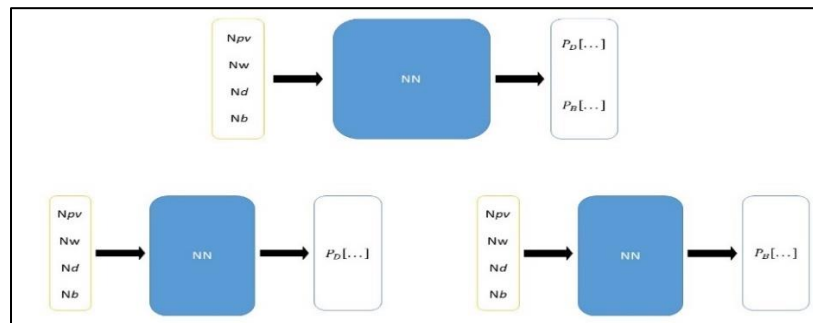
Se procede a tomar un grupo de datos de la base creada y se intenta predecir el resto del conjunto de la forma más precisa posible usando una red neuronal.

Como punto de partida el trabajo de grado se enfoca en la etapa de la gestión de energía y almacenamiento en el proceso de dimensionamiento de microrredes, se toma como referencia las estrategias expuestas en (Jiménez, 2022) y como base los siguientes elementos de la microrred: paneles fotovoltaicos (Nf), aerogeneradores (Nw), baterías (Nb) y generadores diésel (Nd).

Se extraen del algoritmo diseñado en Matlab los valores de la potencia despachada por las baterías (P_B) y los generadores diésel (P_D) por cada hora durante cinco años para cada combinación de los modelos de microrred establecidos, para luego almacenar en una base de datos y disponer de estos para el entrenamiento de la red neuronal.

Para realizar el entrenamiento se definen como entradas las combinaciones de la cantidad de elementos que la componen y como salidas los valores de P_D y P_B para un tiempo determinado. Este proyecto tiene como resultado el entrenamiento de una red neuronal que permite obtener un conjunto de datos que representen los vectores P_D y P_B a partir de técnicas de aprendizaje automático.

En la Figura 5 se muestran las distintas alternativas de la red neuronal que permiten obtener los valores de gestión de energía de la microrred, en esta propuesta las salidas son el conjunto de datos que describen el comportamiento de la potencia para las unidades de generadores diésel y baterías (NN representa la red neuronal entrenada). Cada alternativa de red neuronal propuesta tiene como entradas una combinación de cantidad de N_{pv} , N_w , N_d y N_b y como salida descriptores de la potencia despachada por las baterías (P_B) y los generadores diésel (P_D) por cada hora durante cinco años, esta información de salida se representa como vectores, donde se desarrollan hora a hora la gestión de energía, que la potencia demandada por la carga sea igual a la suma de potencia entregada por los paneles fotovoltaicos, aerogeneradores, baterías y generadores diésel, estos valores se extraen de (Jiménez, 2022) . Se propone que la red neuronal visualizada en la parte superior de la Figura 5 obtenga los vectores P_D y P_B de manera simultánea. Para realizar el entrenamiento con bases de datos más pequeñas se propone entrenar dos redes neuronales independientes.

Figura 5.*Alternativas para la red neuronal.*

Nota: Estrategia para la formulación de las entradas y salidas de la red neuronal.

La alternativa de una red neuronal que se muestra en la parte superior de la Figura 5, presenta 4 datos de entrada, es decir, la combinación de elementos que conforman la microrred y 87.600 datos de salida que representan el despacho por hora durante cinco años presentado por cada unidad de las fuentes controladas es decir $(24 \cdot 365 \cdot 5 \cdot 2)$. Un posible ajuste que se podría realizar es reducir el tiempo de análisis a un solo año, trabajando con una cantidad de datos de salida de 17.520.

La alternativa de dos redes neuronales que se muestra en la parte inferior de la Figura 5, permite reducir a la mitad los datos de salida planteados en la alternativa mencionada anteriormente. En esta se realizaría una red neuronal por el tipo de fuente que interviene en el despacho, convirtiendo los datos a trabajar por cada red de 43.800 para un lapso de cinco años, es decir, 8.760 para un año de análisis.

Al momento de obtener las bases de datos con este tipo de distribución se debería conseguir una matriz cuyas dimensiones serían de 405.720×87.600 y los valores contenidos en esta son $3.5541e+10$, un tamaño complejo de manejar en el campo de la informática, tomando como referencia una hoja de cálculo de Excel que tiene una capacidad para $1.7180e+10$ datos. Debido a

esto es necesario representar los valores de salida con descriptores que puedan modelar el conjunto de los vectores de la gestión de energía de la microrred.


En estadística una herramienta que permite ilustrar el conjunto de datos es el diagrama de caja y bigotes, en este se pueden visualizar el valor mínimo, máximo, promedio y los cuartiles 1, 2 y 3.

Los descriptores permiten obtener una visión del conjunto de datos que se tienen inicialmente, cada uno de ellos está ubicado en puntos clave y en las fronteras de la información que se tiene a la mano. Los primeros 3 descriptores son sencillos de calcular ya que se deben obtener los valores frontera (máximo y mínimo) y el promedio del conjunto. Los otros tres descriptores representan zonas del vector que van a dar una imagen de las muestras sin necesidad de tenerlas todas a la mano. El nombre de estos últimos descriptores es cuartiles.

Un conjunto de datos puede ser dividido en tres cuartiles que representan una porción de los datos, el cuartil 1 representa el valor que ocupa la posición correspondiente al 25 % de los datos, el cuartil 2 el valor de la posición correspondiente al 50% y el cuartil 3 el valor correspondiente al 75 %. Para poder obtener estos valores es necesario ordenar los datos de menor a mayor como se muestra en la Figura 6.

Figura 6.

Representación de la ubicación de los cuartiles.



Nota: Cantidad de datos para la implementación del diagrama de caja y bigotes.

Para hallar cada cuartil se procede a realizar cálculos matemáticos que permitan posicionarlos en el vector general de datos.

$$Q_a = L_i + \frac{\frac{aN}{4} - f_{i-1}}{f_i} A_i \quad (13)$$

N = Es la cantidad de datos de la muestra. En este caso N es 1825.

a = Es el número del cuartil.

f_i = Es la frecuencia absoluta, representada en la cantidad de datos que se encuentran en el rango especificado.

f_{i-1} = Es la sumatoria de la frecuencia absoluta acumulada y la del rango especificado.


L_i = Es el límite inferior del intervalo de trabajo.

A = Es la amplitud del intervalo de trabajo.

Una vez calculados los cuartiles son ubicados en una gráfica que nos muestra las fronteras del vector que aún sigue organizado de menor a mayor como se ve en la Figura 7.

Figura 7.

Ubicación de los cuartiles al ser calculados.



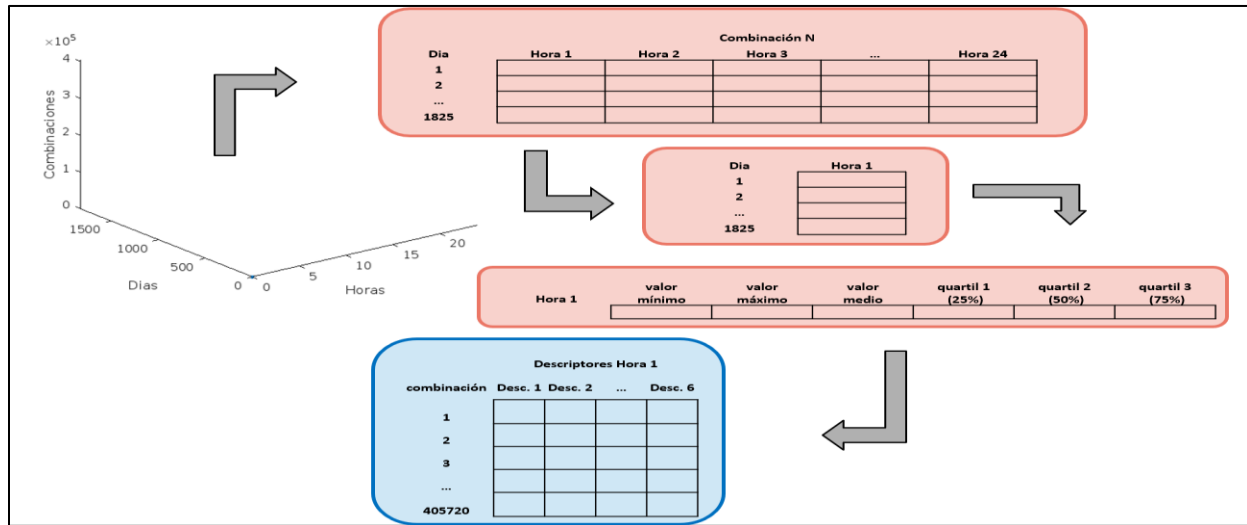
Nota: Diagrama de Caja y Bigotes.

Después de plantear los descriptores que permiten representar el vector de gestión de energía para los generadores diésel y baterías, se procede a generar los sets de datos que permiten

realizar el entrenamiento de las redes neuronales. Con la asesoría del ingeniero Iván Jiménez se obtienen los datos como se muestra en la Figura 8.

Figura 8.

Proceso de conversión de datos.



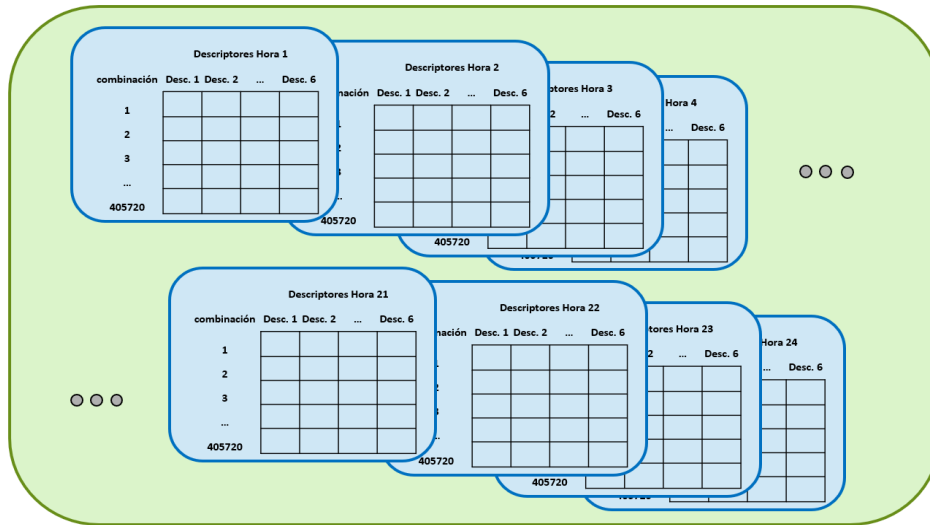
Nota: Manejo de datos en 3D para obtención de datos en 2D (matriz azul) .

Se obtiene una matriz en 3 dimensiones donde el eje vertical corresponde a las combinaciones y en el plano de planta se visualiza una matriz en 2 dimensiones correspondiente a los días en un lapso de 5 años y las 24 horas de cada día. Al tener de esa forma la información se procede a calcular los descriptores por hora del día, pasando de 1825 datos a 6 datos. Finalmente se acomodan los datos de tal forma que los de entrada y salida sean como se muestran en la matriz de color azul.

En la Figura 9 se muestra la alternativa utilizada para el entrenamiento de las redes neuronales, se plantea realizar una red neuronal por cada hora del día, obteniendo así 24 redes neuronales para cada ítem de la gestión de la generación (generadores diésel y baterías).

Figura 9.

Conjunto de datos para cada red neuronal.

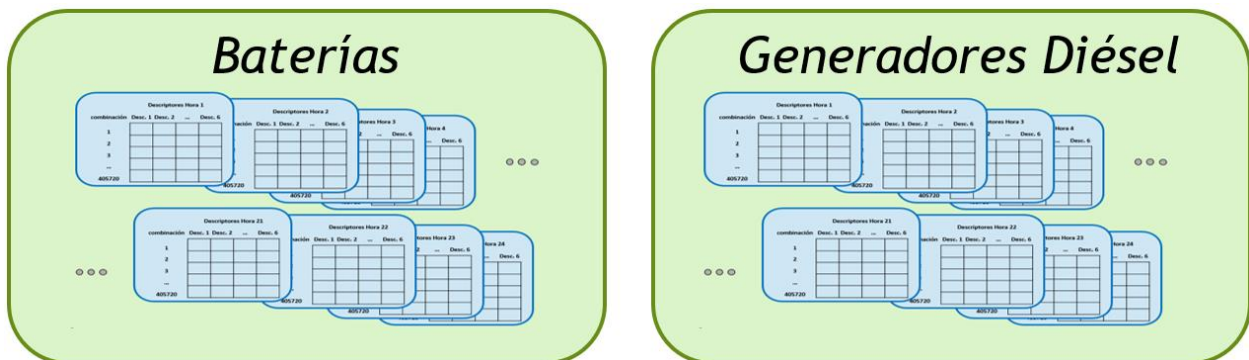


Nota: Representación de las 24 matrices de 405.720 x 6 por fuente de despacho.

La Figura 10 muestra la alternativa de 48 redes neuronales que permitan obtener el conjunto de descriptores que representen la gestión de energía de las fuentes controlables desarrollada en (Jiménez, 2022).

Figura 10.

Redes neuronales del trabajo de grado.

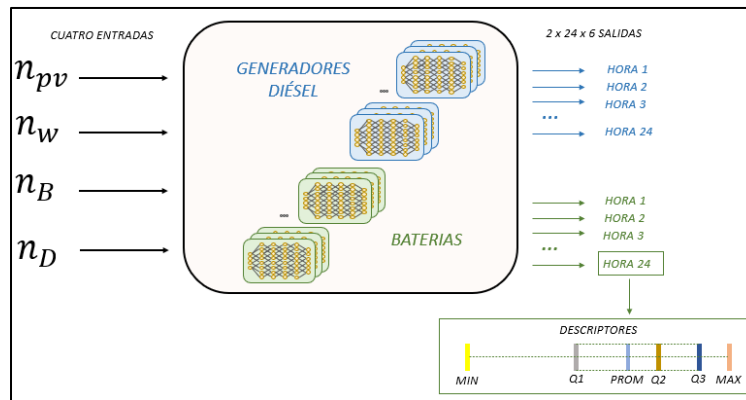


Nota: Representación de los dos conjuntos de 24 matrices por cada fuente de despacho.

La Figura 11 muestra el modelo de la red neuronal que permite obtener los descriptores que representan la potencia despachada por las baterías y los generadores diésel para un día tipo.

Figura 11.

Modelo desarrollado en el trabajo de grado.



Nota: Definición de la cantidad de entradas y salidas del modelo entrenado.

4. Pruebas

Este capítulo presenta la metodología desarrollada para elaborar el código y realizar el entrenamiento de las redes neuronales, la organización de los conjuntos de entradas y salidas, además del algoritmo a realizar en Google Colab. También se presentan tres estrategias de desarrollo que permiten obtener el modelo con un grado de precisión superior a un límite establecido.

4.1 Elaboración del código.

En el capítulo anterior se menciona que los grupos de datos para el desarrollo del proyecto se obtuvieron a partir del código desarrollado en (Jiménez, 2022). Se obtuvieron dos matrices en 3 dimensiones cada una de $24 \times 6 \times 405.720$ y que representan las horas del día, los descriptores y

las combinaciones respectivamente. Teniendo estas matrices almacenadas en una variable de Matlab se procede a convertirlas en matrices de 2 dimensiones cada una de 405.720 x 144 para que Google Colab pueda llamar el conjunto desde solo una hoja de cálculo de Excel. Este proceso se muestra en la Figura 8. Las últimas matrices se exportan a Excel añadiendo en las columnas 145-148 la combinación de los elementos de la microrred que permiten obtener los descriptores por su respectiva hora. La Figura 12 muestra cómo se distribuyen los datos en el archivo de Excel para generadores diésel de igual forma se tiene otro archivo para baterías.

Figura 12.

Data set – Generadores Diésel

1	2	3	4	5	6	7	8	9	10	11	12	...	139	140	141	142	143	144	145	146	147	148
Hora 1						Hora 2						...	Hora 24						Combinación			
D1	D2	D3	D4	D5	D6	D1	D2	D3	D4	D5	D6	...	D1	D2	D3	D4	D5	D6	N° D	N° W	N° PV	N° B
2.7	5.5	5	4.4	5.5	5.5	3.2	5.5	5.1	4.9	5.5	5.5	...	5.5	5.5	5.5	5.5	5.5	5.5	1	0	0	1
2.7	5.5	5	4.4	5.5	5.5	3.2	5.5	5.1	4.9	5.5	5.5	...	5.5	5.5	5.5	5.5	5.5	5.5	1	0	0	2
2.7	5.5	5	4.4	5.5	5.5	3.2	5.5	5.1	4.9	5.5	5.5	...	5.5	5.5	5.5	5.5	5.5	5.5	1	0	0	3
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	...	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
0	9.3	0.1	0	0	0	0	9.7	0.1	0	0	0	...	0	13	0.1	0	0	0	4	20	160	29
0	9.3	0.1	0	0	0	0	9.7	0.1	0	0	0	...	0	13	0.1	0	0	0	4	20	160	30

Nota: Distribución de los datos para el entrenamiento de las redes de los generadores diésel.

Este proyecto utiliza la herramienta Google Colab, los datos están disponibles en Google Drive distribuidos en carpetas por separado, una para los datos de las baterías y la otra para los datos de los generadores diésel. Cada elemento de estos grupos cuenta con los datos por cada hora obteniendo 24 conjuntos por cada uno para un total de 48. El archivo de Excel para cada hora lleva la distribución que se muestra en la Figura 13. La Figura 14 muestra la organización en el Google Drive para los datos de cada hora de los generadores diésel.

Figura 13.*Datos Hora 1. Generadores Diésel*

Descriptor 1	Descriptor 2	Descriptor 3	Descriptor 4	Descriptor 5	Descriptor 6	N° Gen-Diesel	N° Aero-generadores	N° Paneles Fotovoltaicos	N° Baterías
2.68512678	5.5	4.96211587	4.43458184	5.5	5.5	1	0	0	1
2.68512678	5.5	4.96211587	4.43458184	5.5	5.5	1	0	0	2
2.68512678	5.5	4.96198617	4.43458184	5.5	5.5	1	0	0	3
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
0	9.33781977	0.07536439	0	0	0	4	20	160	29
0	9.33781977	0.07040644	0	0	0	4	20	160	30

Nota: Distribución de los datos para el entrenamiento de la red de la hora 1 del generador diésel.

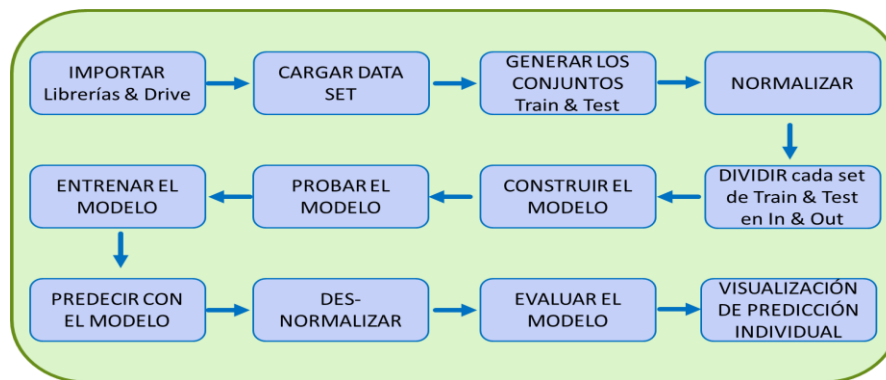
Figura 14.*Google Drive – Data sets por hora – Generadores Diésel*

Nota: Bases de datos para realizar el entrenamiento, 24 matrices para generadores diésel.

Una vez organizados los conjuntos de datos se procede a realizar el entrenamiento de las redes neuronales que permitan encontrar los descriptores que representen la gestión de energía de las fuentes controlables de la microrred. El procedimiento que se implementa para desarrollar dicho entrenamiento se muestra en la Figura 15.

Figura 15.

Esquema procedimiento para realizar entrenamiento



Nota: Diagrama de flujo para la elaboración del código.

En la sección de “importar” se cargan librerías o toolbox de Python como numpy, pandas, tensorflow, entre otras. Además, se importa el Google Drive donde están almacenados los grupos de datos de Excel mencionados anteriormente.

En “cargar data set” se utiliza una herramienta de pandas para ingresar los datos al entorno de trabajo de Google Colab.

El entrenamiento de redes neuronales en Python tiene como pauta definir el grupo de datos en dos conjuntos, entrenamiento y testeo. Los criterios para establecer el método de selección de dichos datos que se plantean en este trabajo de grado son de forma aleatoria y de manera ordenada, más adelante se detalla cómo se aplica este criterio.

En “normalizar” se utiliza la herramienta (sklearn) para que los datos se manejen con una escala común, sin distorsionar las diferencias de los intervalos de valores ni perder información. Esto se realiza para tener uniformidad y que el manejo de las funciones de aprendizaje automático sea más preciso. También se realiza para que los datos se modelen correctamente. En esta etapa se

crea la función que permite más adelante desnormalizar los datos para analizarlos con su valor real.

Una vez normalizados los datos de entrenamiento y testeo, se procede a definir de cada uno los conjuntos de entrada y salida. Esto se hace en “dividir cada set de Train & Test en In & Out”.

En “construcción de modelo” se definen el tipo de capa y la función de activación que tendrá el modelo a entrenar. También se definen la cantidad y disposición de la red, es decir la arquitectura, siendo este un criterio para el desarrollo de las pruebas.

La “prueba del modelo” se desarrolla con un conjunto pequeño de datos para ejecutar el modelo y prepararlo para el siguiente paso.

Se procede al “entrenamiento del modelo” en este se definen los criterios para el error permisible y la cantidad de etapas límite para detener el entrenamiento.

Con el entrenamiento terminado se empieza a “predecir con el modelo”, se predicen los valores correspondientes a las entradas de testeo prueba y se obtienen salidas de prueba que posteriormente se comparan con los salidas reales para visualizar la precisión del modelo.

Como se mencionó anteriormente se procede a “desnormalizar” con la función definida en el tercer bloque.

Para “evaluar el modelo” se procede a calcular el error general de todo el conjunto de datos por cada descriptor obtenidos del modelo de la red neuronal. Para ello se usa un método de precisión expresado por la siguiente ecuación:

$$R^2 = 1 - \frac{RSS}{TSS} \quad (14)$$

Donde RSS y TSS se calculan de la siguiente manera.

$$RSS = \sum_{i=1}^n (y_i - f(x_i))^2 \quad (15)$$

$$TSS = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (16)$$

Donde: y_l son los valores de testeo.

$f(x_i)$ son los valores de prueba.

\bar{y} es el valor promedio de los valores de testeo.

Después de calcular el error usando este método de precisión se procede a imprimir los resultados de cada descriptor, la cercanía de cada resultado a 1 demuestra la precisión de los datos obtenidos por el modelo.

Tabla 1.

Precisión Red Neuronal-Hora 1-Generadores Diésel

Descriptor	R2
Descriptor 1	0.990378338
Descriptor 2	0.999912422
Descriptor 3	0.999001244
Descriptor 4	0.996621615
Descriptor 5	0.998616568
Descriptor 6	0.995829178

Nota: Valor de la precisión para los seis descriptores, hora 1 de los generadores diésel.

Por último, con el fin de una “visualización de predicción individual” se realiza la programación para que se pueda ingresar una combinación en específico. En esta parte del código el usuario debe ingresar la cantidad de cada elemento que compone la microrred y el porcentaje de error aceptable. El programa imprime el número de la combinación que generan los números ingresados y una tabla con los valores reales y valores generados de los descriptores de la configuración, además del error relativo para cada uno y la evaluación de dicho error. Se muestra “ok” debido a que el error es menor al digitado por el usuario, de no ser el caso imprime un “No”.

Figura 16.*Visualización predicción individual*

```

Ingrese cantidad de paneles = 2
Ingrese cantidad de aerogeneradores = 4
Ingrese cantidad de generadores diesel = 5
Ingrese cantidad de baterias = 15
Ingrese porcentaje de error permisible = 2
[120913]
-----
valor real [0.          9.43709466 1.68415794 0.          0.          3.48703327]
valor red  [[-8.05378808e-04  9.43723025e+00  1.67532982e+00  2.49359169e-02
 2.11817657e-02  3.51209318e+00]]
Error      [0, -0.0014367757509768924, 0.5241857184661409, 0, 0, -0.7186600662641801]
Evaluación ['ok', 'ok', 'ok', 'ok', 'ok', 'ok']
-----

```

Nota: Parte del código que presenta la predicción y evaluación del error de manera individual.

4.2 Estrategias de desarrollo.

Tras haber definido el entrenamiento de la red neuronal y el cálculo del error de un conjunto de datos se observa que los resultados del proceso están sujetos a un grupo de parámetros que al variarlos cambiaran las muestras de salida, por ende, se determinan tres estrategias de desarrollo donde se prueban distintas condiciones para encontrar una ruta que permita obtener el menor error posible. Estas evaluaciones se ejecutan con los datos almacenados de la hora 1. La estrategia más viable se utiliza para calcular los datos de salida de las demás horas almacenadas.

4.2.1 Porcentaje de datos tomados para el entrenamiento.

Esta forma de desarrollo consiste en mantener la estructura y aleatoriedad de los datos de forma fija y variar los porcentajes de datos que se usan para el entrenamiento del modelo. Debido a que la selección de los datos para el entrenamiento es aleatoria, los valores arrojados por la red van a cambiar cada vez que se entrene el modelo, por lo tanto, se decide entrenar e imprimir los resultados de evaluación tres veces para cada porcentaje de datos elegido.

Para comenzar esta prueba se debe determinar la estructura de la red que está conformada por un número de capas y neuronas fijas de la siguiente manera:

- Cuatro capas (entrada, salida, 2 capas ocultas).
- Neuronas:
 - ✓ Capa de entrada: 4 de entrada y 6 de salida.
 - ✓ Capa oculta: 6 de entrada y 60 de salida.
 - ✓ Capa oculta: 60 de entrada y 60 de salida.
 - ✓ Capa de salida: 60 de entrada y 6 de salida.

Teniendo estos parámetros establecidos se realizan las pruebas tomando los siguientes porcentajes de datos para el entrenamiento: 80%, 60%, 40%, 20%, 10%, 5%, 1%, 0,5%, 0,1%. Para evaluar los datos de salida del modelo se tienen en cuenta para cada porcentaje cinco indicadores que describan los resultados:

Precisión: Valor que representa el error del conjunto de datos de salida.

Tiempo Train: Tiempo evaluado en minutos que toma la red para determinar el modelo.

Tiempo Error: Tiempo evaluado en minutos que toma Colab para determinar el error del conjunto.

Epoch: Número de iteraciones que realiza la red para converger en los resultados.

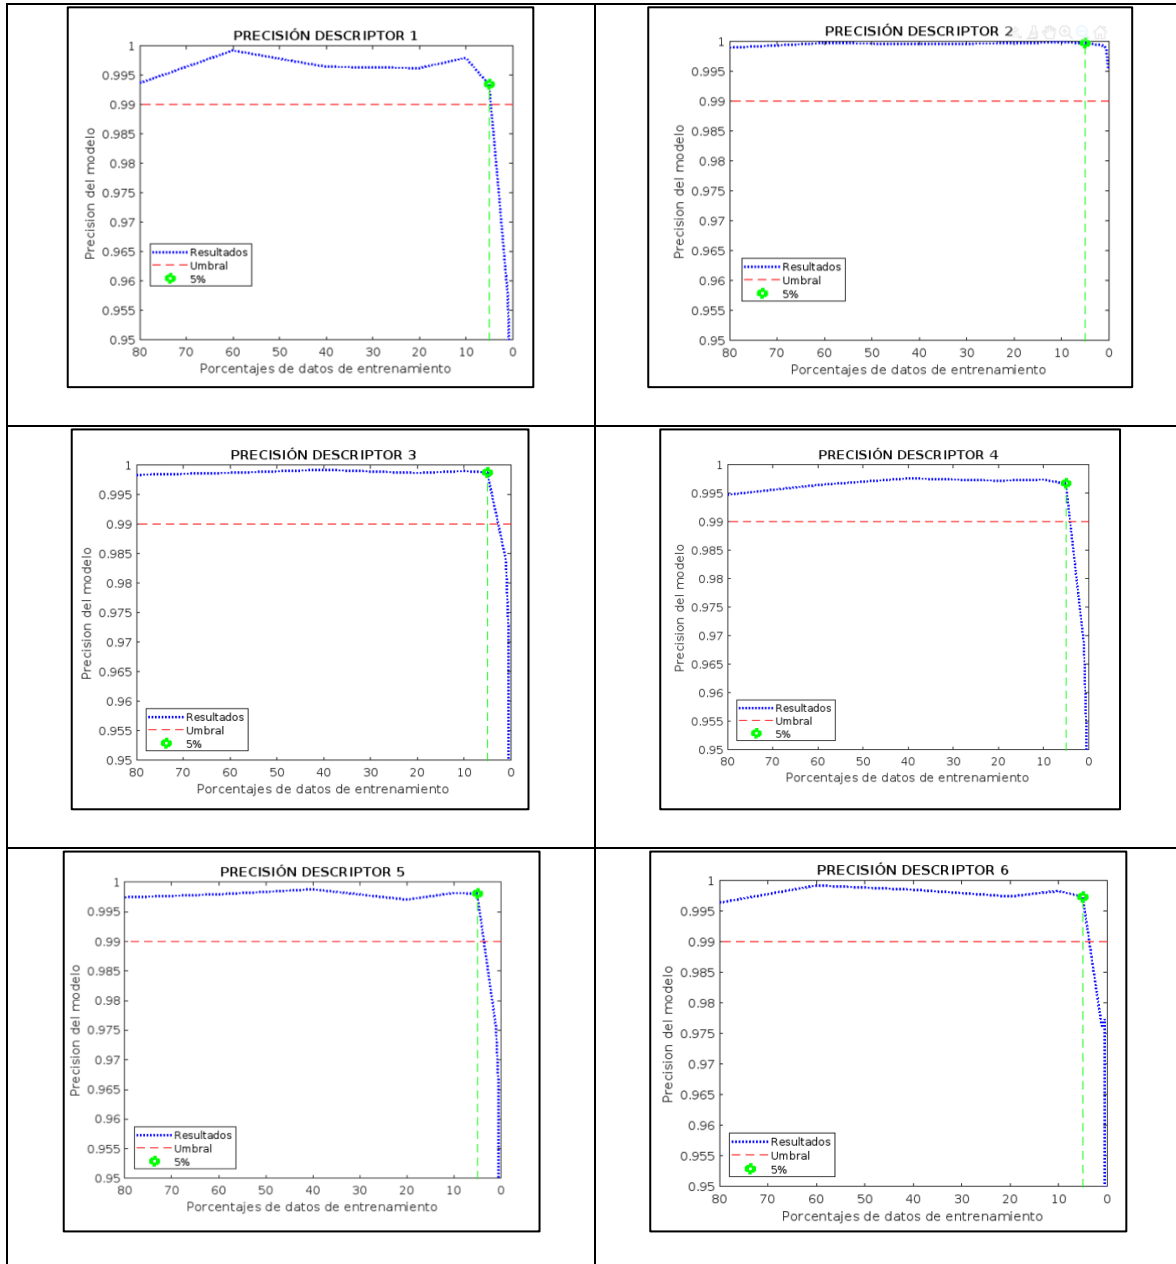
Accuracy: Precisión calculada directamente por una función de Python.

Al realizar las pruebas se determina una precisión permisible con un umbral de 0,99, siendo así, todas las pruebas que lo superen se consideran aceptables. Para visualizar mejor los resultados se decide graficar los valores de precisión de cada descriptor por cada porcentaje evaluado como se muestra en la Figura 17, este valor surge de promediar los datos de cada uno de los tres entrenamientos realizados en cada prueba. Finalmente, la gráfica con los valores promedio de

todos los descriptores por cada porcentaje se puede apreciar en la Figura 18 siendo el 5% de los datos de entrenamiento el menor conjunto con el que se supera el umbral.

Figura 17.

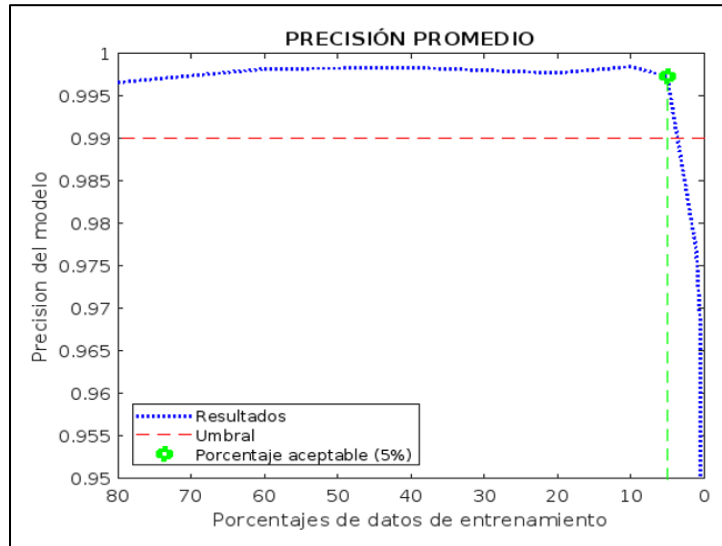
Gráfica de precisión de cada descriptor.



Nota: Precisión para los seis descriptores al realizar las pruebas con los respectivos porcentajes.

Figura 18.

Gráfica de precisión promedio de todos los descriptores.



Nota: Precisión promedio para los seis descriptores al realizar las pruebas con los respectivos porcentajes.

Los indicadores que describen los resultados para la evaluación del 5% de los datos para el entrenamiento se muestran en las figuras 19,20,21 y 22.

Figura 19.

Indicadores para prueba 1 del 5%.

		Prueba 1				
Porcentaje de Train	Descriptor	Precisión	Tiempo Train [min]	Tiempo Error [min]	Epoch	Accuracy
5%	Descriptor 1	0.98606276	2	6	202	0.9657
	Descriptor 2	0.99984182				
	Descriptor 3	0.99914079				
	Descriptor 4	0.99761234				
	Descriptor 5	0.99818809				
	Descriptor 6	0.99704794				

Nota: Distribución de resultados para la prueba 1 con sus cinco indicadores.

Figura 20.*Indicadores para prueba 2 del 5%.*

Porcentaje de Train	Prueba 1		Prueba 2			
	Descriptor	Precisión	Tiempo Train [min]	Tiempo Error [min]	Epoch	Accuracy
5%	Descriptor 1	0.99533621	4	7	281	0.9638
	Descriptor 2	0.99966579				
	Descriptor 3	0.99818943				
	Descriptor 4	0.99624486				
	Descriptor 5	0.99755663				
	Descriptor 6	0.9968113				

Nota: Distribución de resultados para la prueba 2 con sus cinco indicadores.**Figura 21.***Indicadores para prueba 3 del 5%.*

Porcentaje de Train	Prueba 3					
	Descriptor	Precisión	Tiempo Train [min]	Tiempo Error [min]	Epoch	Accuracy
5%	Descriptor 1	0.99893603	2	6	161	0.969
	Descriptor 2	0.9998599				
	Descriptor 3	0.99907551				
	Descriptor 4	0.99631461				
	Descriptor 5	0.99861084				
	Descriptor 6	0.99829658				

Nota: Distribución de resultados para la prueba 3 con sus cinco indicadores.**Figura 22.***Indicadores promedio para evaluación del 5%.*

Porcentaje de Train	Prueba 1		Promedio			
	Descriptor	Precisión	Tiempo Train [min]	Tiempo Error [min]	Epoch	Accuracy
5%	Descriptor 1	0.993445	2.66666667	6.33333333	214.666667	0.96616667
	Descriptor 2	0.99978917				
	Descriptor 3	0.99880191				
	Descriptor 4	0.99672394				
	Descriptor 5	0.99811852				
	Descriptor 6	0.99738527				

Nota: Distribución de resultados para el promedio de las pruebas con sus cinco indicadores.

4.2.2 Selección de los datos para el entrenamiento.

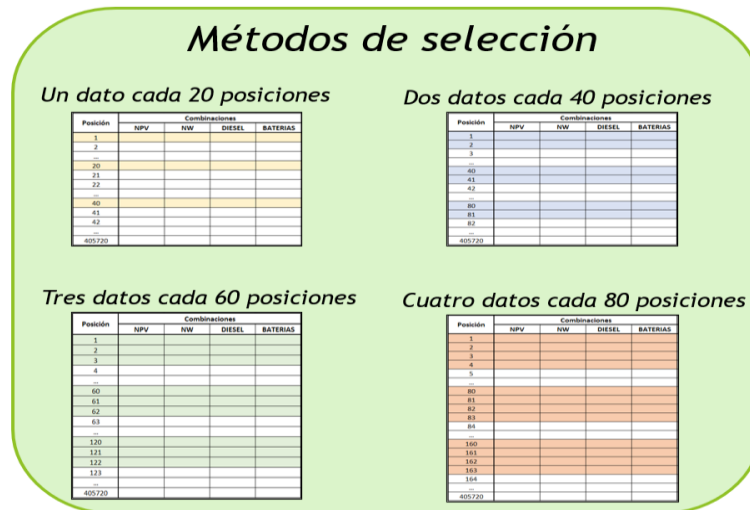
Tras definir el 5% de las combinaciones como base para entrenar el modelo se procede a realizar la segunda estrategia de desarrollo que consiste en evaluar diferentes métodos de selección de datos. La cantidad de combinaciones que se utilizan para el entrenamiento se debe respetar en cada prueba para que el número de datos sea consistente con el porcentaje seleccionado.

$$405.720 * 5\% = 20.286$$

La red neuronal se ha trabajado hasta el momento con el método aleatorio generando los conjuntos Train y Test usando la función Sample (), este módulo genera números aleatorios con diferentes posibles distribuciones, siendo necesario que se deban realizar pruebas con diferentes metodologías para la selección de los datos.

En esta estrategia de desarrollo se busca una manera de elegir los datos siguiendo un patrón que permita obtener una precisión mayor a la que se consiguió con el método aleatorio. Los métodos que se utilizan consisten en tomar combinaciones dando saltos cada cierto número de posiciones según la cantidad de datos que se tomen en cada uno de ellos:

- Una combinación por cada 20 posiciones.
- Dos combinaciones por cada 40 posiciones.
- Tres combinaciones por cada 60 posiciones.
- Cuatro combinaciones por cada 80 posiciones.

Figura 23.*Métodos para la selección de datos.*

Nota: Estrategia para realizar las 16 pruebas del método ordenado.

Como un segundo parámetro a tener en cuenta a la hora de ejecutar cada método es el punto de partida, ya que al variar la posición inicial los datos son distintos. Para mantener las 20.286 combinaciones se procede a realizar pruebas que comiencen en puntos iniciales dentro de un rango de la posición 1 a la 20 para evitar afectar el porcentaje de datos:

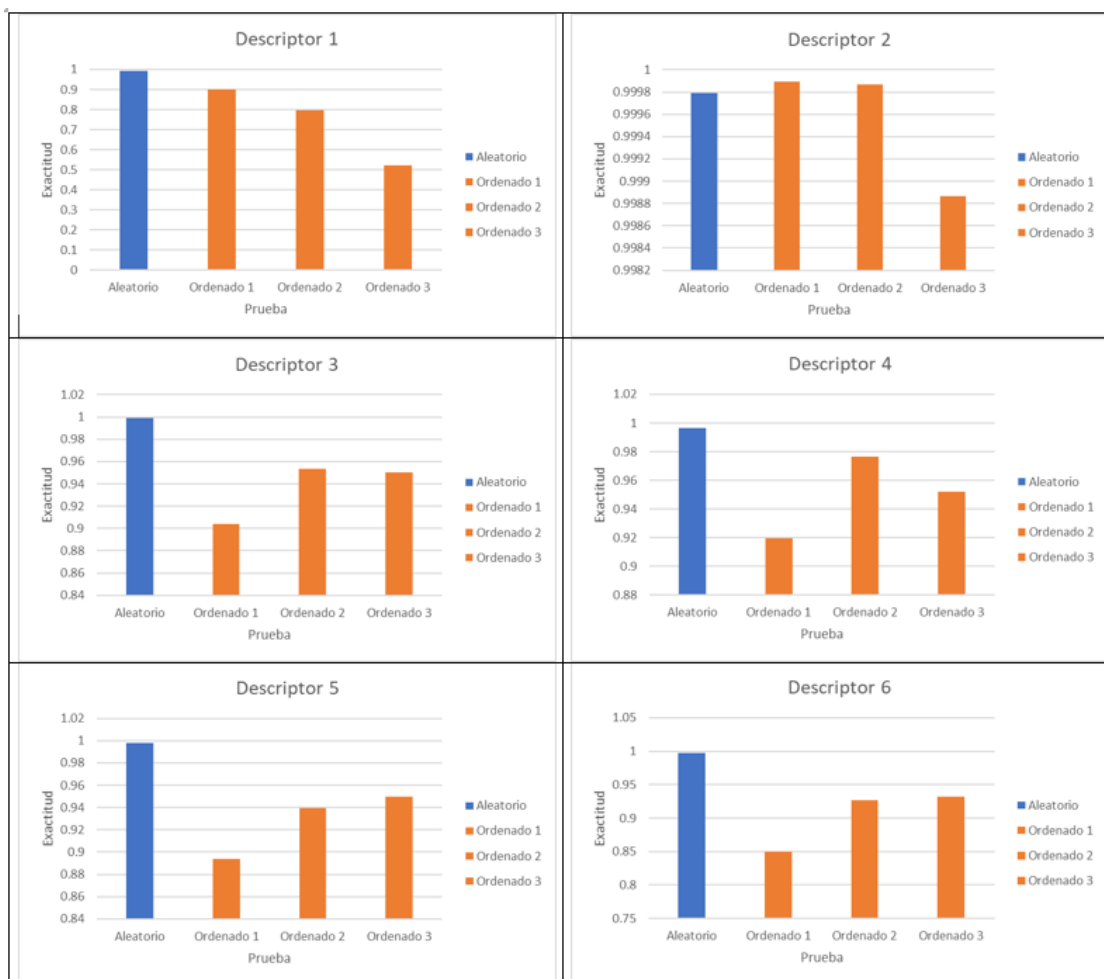
- Combinación 1.
- Combinación 5.
- Combinación 10.
- Combinación 15.

Para realizar las pruebas se mantiene la misma estructura de la red y los mismos indicadores utilizados en la sección 4.2.1, esta vez solo se realiza una prueba por método ya que los valores de salida son los mismos mientras no se varíen los parámetros ya mencionados.

En la Figura 24 se visualiza la comparación entre el método de selección de manera aleatoria (color azul) y de manera ordenada (color naranja). Con la estrategia mencionada anteriormente se calcula la precisión para el conjunto de descriptores 16 veces. Dichas posibilidades resultan de agrupar los datos, la distribución de los saltos y el punto de partida. Se relacionan los resultados con los valores obtenidos en la sección 4.2.1. y se grafican aquellas comparaciones que presentan mayor diferencia.

Figura 24.

Precisión por criterio de selección de datos



Nota: Comparación resultados de precisión método aleatoria y método ordenado.

Al comparar los valores obtenidos se observa que el método con la mayor precisión es el aleatorio usando las funciones de Python en Colab. De la precisión mostrada por cada descriptor el método de selección de manera aleatoria presenta mejores resultados, sin embargo, se visualiza que en dos pruebas del descriptor 2 presenta mejor precisión pero se recalca que no es superior a 0,0002.

4.2.3 Estructura de la red neuronal.

Teniendo un porcentaje de datos de entrenamiento y un método para seleccionarlos ya definidos, se realiza la última estrategia de desarrollo que consiste en variar la estructura de la red neuronal cambiando el número de capas y neuronas en cada prueba. Esta evaluación se desarrolla ejecutando el entrenamiento de la red variando la cantidad de neuronas para un grupo de capas ocultas fijo, las pruebas que se realizan son las siguientes:

- 30 neuronas por capa oculta.
- 60 neuronas por capa oculta.
- 100 neuronas por capa oculta.
- 160 neuronas por capa oculta.
- 240 neuronas por capa oculta.

Este proceso se repite para una red neuronal con una, dos y tres capas ocultas. Los resultados de las pruebas donde se visualizan los mismos indicadores de los dos capítulos anteriores se muestran en la Figura 25.

Figura 25.

Precisión y tiempo por estructura de la red neuronal.

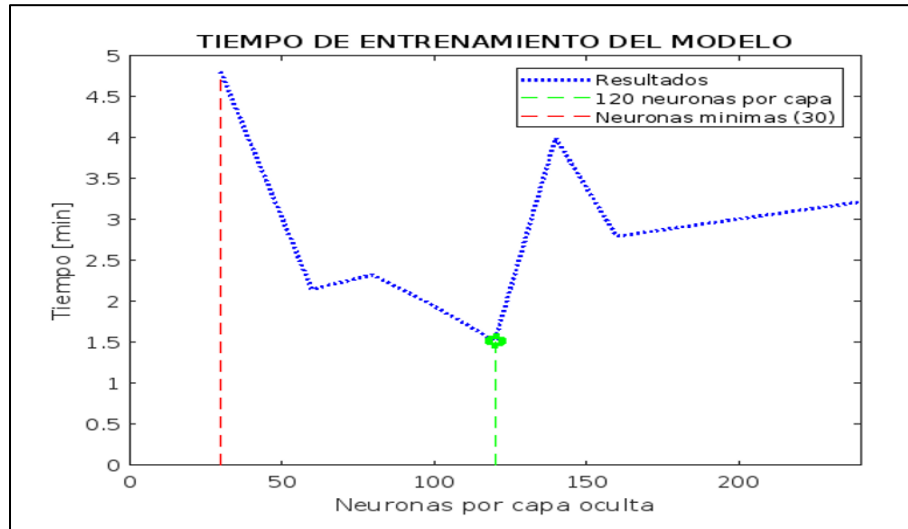
5% - Aleatorio - 2 capas ocultas														
Estructura	Precisión	T Train [min]	Estructura	Precisión	T Train [min]	Estructura	Precisión	T Train [min]	Estructura	Precisión	T Train [min]	Estructura	Precisión	T Train [min]
4-6-60-60-6	0.99516567	2'9"	4-6-100-100-6	0.98280102	1'59"	4-6-30-30-6	0.98265886	4'49"	4-6-160-160-6	0.99794516	2'48"	4-6-240-240-6	0.99847197	3'13"
	0.99974344			0.99948468			0.99971343			0.9997341			0.99964659	
	0.99686509			0.99759537			0.99865729			0.99865635			0.99895677	
	0.99097603			0.99459308			0.99314575			0.99363171			0.99619564	
	0.99389044			0.99269423			0.99708692			0.99756112			0.99804139	
	0.99499641			0.99767644			0.99707016			0.99743506			0.99794921	
5% - Aleatorio - 1 capas oculta														
4-6-60-6	0.99516567	4'2"	4-6-100-6	0.99568474	4'34"	4-6-30-6	0.98340574	4'10"	4-6-160-6	0.99834806	2'41"	4-6-240-6	0.99563262	3'34"
	0.99974344			0.9997161			0.99897291			0.99944267			0.99980998	
	0.99686509			0.99778233			0.98875951			0.99658771			0.9923643	
	0.99097603			0.99406935			0.97943801			0.98768388			0.98337384	
	0.99389044			0.99338736			0.99163607			0.99477203			0.98779463	
	0.99499641			0.99410085			0.97047502			0.99336975			0.98449611	
5% - Aleatorio - 3 capas oculta														
4-6-60-60-60-6	0.99294243	1'58"	4-6-100-100-100-6	0.99632448	2'55"	4-6-30-30-30-6	0.99265252	3'4"	4-6-160-160-160-6	0.97348179	3'37"	4-6-240-240-240-6	0.88662556	7'1"
	0.99984293			0.99965589			0.99976507			0.99801135			0.99971922	
	0.99819961			0.99801451			0.99608517			0.99210913			0.98895543	
	0.99420382			0.99698076			0.99494106			0.99472076			0.98448921	
	0.9975215			0.99452332			0.99343306			0.99564498			0.98694787	
	0.99746853			0.99382704			0.99585797			0.98068709			0.99006735	

Nota: Comparativo de precisión y tiempo para la estrategia de estructura (capas y neuronas).

Después de comparar los valores de precisión de cada uno de los descriptores en las diferentes pruebas se observa que son similares en su mayoría para cada número de capas ocultas seleccionado, por ende, no es un parámetro que permite determinar la utilidad de la estrategia por lo que se toma en cuenta el tiempo de entrenamiento para la elección de una estructura. Comparando los tiempos entre cada prueba se obtiene que las redes neuronales compuestas por dos capas toman menor tiempo para ser entrenadas, también en esta misma el tiempo disminuye al acercarse a las 100 neuronas. Si este número es mayor o menor el tiempo aumentará, es decir, que esta cantidad es una convergencia. Para corroborar lo visto se realizan tres pruebas más con dos capas ocultas usando 80, 120 y 140 neuronas, los resultados se muestran en la Figura 26.

Figura 26.

Tiempo de entrenamiento para diferentes cantidades de neuronas.



Nota: Comparativo de tiempo para la estrategia de estructura (2 capas fijas y neuronas varían).

Después de analizar la gráfica se puede concluir que el menor tiempo se consigue utilizando dos capas ocultas y 120 neuronas por cada una, por lo que se define como la estructura de la red neuronal con la que se desarrollan los respectivos entrenamientos para cada una de las horas de análisis.

5. Análisis

Una vez realizadas las diferentes pruebas se procede a implementar el entrenamiento de las redes neuronales para las demás horas, tanto para generadores diésel como baterías. Se obtienen los mapas de calor mostrados en las Figuras 27 y 28. En ellos se puede observar la transición de color verde, pasar por amarillo y terminar en rojo, la variedad de tonos que se visualizan representa

la precisión obtenida para cada descriptor. El color verde oscuro es el valor más alto, el rojo oscuro es el más bajo y los tonos amarillos valores medios.

De estos mapas de calor se puede resaltar que la mínima precisión obtenida es mayor a 0,9 para la hora 4 del conjunto de baterías en el descriptor 4. El valor de precisión máximo fue de 0,999921277 para la hora 4 del conjunto de generadores diésel en el descriptor 2.

Figura 27.

Mapa de calor descriptores para las 24 horas generadores diésel

Diésel	Descriptor 1	Descriptor 2	Descriptor 3	Descriptor 4	Descriptor 5	Descriptor 6
Hora 1	0,997320138	0,998797221	0,996930633	0,995426962	0,996778209	0,998022229
Hora 2	0,999526548	0,999895	0,998939646	0,998188989	0,998244913	0,998633156
Hora 3	0,993144035	0,999686487	0,998481612	0,996435539	0,997660011	0,997083929
Hora 4	0,993443538	0,999921277	0,999330237	0,997518756	0,998761157	0,997942116
Hora 5	0,98411076	0,999241605	0,998470272	0,995878428	0,997948145	0,998056907
Hora 6	0,987046039	0,999780861	0,99771033	0,995000754	0,996604552	0,99354645
Hora 7	0,993143763	0,999407854	0,998694187	0,997004888	0,997669428	0,994815571
Hora 8	0,994972165	0,99783848	0,997887719	0,998287648	0,999167249	0,998966992
Hora 9	0,985674803	0,995860925	0,999174183	0,998267761	0,994790716	0,998190372
Hora 10	0,99359851	0,981018646	0,998652847	0,995312274	0,997443644	0,997996512
Hora 11	0,99236517	0,999361884	0,999046041	0,99669983	0,995514406	0,996979924
Hora 12	0,987780668	0,998690038	0,998281336	0,993333733	0,995571597	0,994028322
Hora 13	0,986042997	0,997605657	0,994508267	0,967462797	0,987103678	0,984337959
Hora 14	0,963322532	0,997843654	0,997980456	0,990799824	0,995563627	0,997373014
Hora 15	0,983256709	0,998575616	0,997617388	0,996258398	0,995105641	0,996813067
Hora 16	0,975313208	0,997719857	0,996429946	0,991765121	0,994089626	0,996206242
Hora 17	0,979451462	0,993374912	0,995999985	0,972111141	0,992943991	0,995180254
Hora 18	0,98966782	0,993828016	0,997246687	0,987895092	0,98881025	0,992549231
Hora 19	0,978445181	0,998654868	0,994523373	0,986599508	0,987973091	0,990783396
Hora 20	0,993873239	0,999580641	0,996890324	0,993752918	0,990472874	0,995087376
Hora 21	0,932707903	0,999488703	0,98739461	0,96512238	0,979016414	0,98033954
Hora 22	0,992899899	0,999429041	0,996698651	0,993819994	0,991658559	0,996717202
Hora 23	0,994024987	0,999343073	0,998096836	0,994754934	0,995580177	0,994062345
Hora 24	0,979144176	0,998735284	0,997367264	0,987346893	0,991678454	0,994003562

Nota: Representación de los valores de precisión para cada hora de los generadores diésel.

Figura 28.

Mapa de calor descriptores para las 24 horas generadores diésel.

Baterías	Descriptor 1	Descriptor 2	Descriptor 3	Descriptor 4	Descriptor 5	Descriptor 6
Hora 1	0,996402892	0,993939168	0,99476825	0,983123639	0,989645223	0,995713848
Hora 2	0,996968368	0,992735297	0,991278743	0,96805976	0,992671303	0,986222687
Hora 3	0,990966091	0,99153135	0,982096618	0,962076945	0,928579622	0,973141618
Hora 4	0,991888233	0,990707438	0,983698128	0,904714588	0,984289575	0,981970157
Hora 5	0,983471859	0,980618549	0,987276251	0,956728111	0,974517992	0,982676809
Hora 6	0,971124855	0,983175497	0,988645702	0,963113127	0,977209998	0,993619065
Hora 7	0,991368239	0,992440751	0,994718926	0,95284874	0,984269605	0,995073277
Hora 8	0,996658203	0,99241058	0,996644919	0,996773458	0,995429296	0,98483304
Hora 9	0,993660351	0,98704889	0,998505205	0,99845943	0,997610886	0,98151819
Hora 10	0,995660038	0,986541132	0,994954368	0,996832155	0,996595607	0,994801159
Hora 11	0,995181594	0,988998369	0,998937949	0,998728026	0,998795119	0,997914568
Hora 12	0,995138386	0,996013063	0,99673118	0,998181517	0,997729251	0,995574677
Hora 13	0,993896608	0,988043518	0,997469878	0,998365641	0,997458406	0,992988297
Hora 14	0,990384821	0,983374019	0,993736927	0,988186942	0,938859129	0,964697878
Hora 15	0,986705171	0,984671204	0,994255932	0,993488212	0,9906256	0,97394596
Hora 16	0,987256056	0,98185357	0,990865151	0,993245582	0,985712322	0,972718376
Hora 17	0,982653777	0,981235548	0,994442081	0,958900669	0,987561589	0,997079154
Hora 18	0,992870874	0,996258492	0,999425899	0,998989064	0,99926881	0,998810228
Hora 19	0,969550922	0,997485421	0,998845126	0,998335802	0,999363893	0,998103448
Hora 20	0,973309735	0,996364373	0,998965535	0,998898441	0,999266884	0,998186047
Hora 21	0,9858646	0,994777185	0,998484411	0,992803016	0,997352576	0,997248518
Hora 22	0,987411913	0,994696241	0,998610736	0,99219242	0,997982876	0,997959006
Hora 23	0,989638137	0,989505163	0,992689938	0,982597684	0,986808886	0,991910008
Hora 24	0,992532205	0,995248502	0,997233451	0,988826663	0,995239044	0,996541862

Nota: Representación de los valores de precisión para cada hora de los baterías.

Se puede comprobar que la estrategia para la selección del conjunto de datos y estructura de la red planteada en la sección anterior permite obtener resultados positivos. Si bien la precisión tomada como umbral en la sección 4.2.1. fue de 0,99 se obtuvo una precisión mínima de 0,904714588 al finalizar el entrenamiento de las 48 redes neuronales. Esto indica que las redes neuronales son una buena estrategia para aplicar a este caso de estudio. En la Figura 29 se muestran cinco configuraciones de microrred, en esta se detalla individualmente el valor real, valor de la

red, error y una evaluación como se presentó en la Figura 16. Se realiza para el conjunto de la hora 1 del conjunto de generadores diésel y se establece un error permisible del 5%.

Figura 29.

Error individual y evaluación.

COMBINACIÓN	CRITERIO	D1	D2	D3	D4	D5	D6	
Nd	2	Valor Real	0	9.43709466	1.68415794	0	0	3.48703327
Nw	4	Valor Red	9.20E-04	9.41774604	1.76040306	-6.21E-03	1.33E-02	3.75684673
Npv	5	Error	0	0.20502727	4.52719548	0	0	7.73762226
Nb	15	Evaluación	Ok	Ok	Ok	Ok	Ok	No
Nd	3	Valor Real	0	9.43709466	1.12224085	0	0	0
Nw	16	Valor Red	8.25E-04	9.4199788	1.13682557	-1.02E-03	-2.90E-03	9.88E-03
Npv	87	Error	0	0.18116572	1.28447467	0	0	0
Nb	12	Evaluación	Ok	Ok	Ok	Ok	Ok	Ok
Nd	2	Valor Real	0	9.43709466	1.13358219	0	0	0
Nw	13	Valor Red	8.84E-04	9.42244968	1.16192242	-1.32E-03	-2.89E-03	1.01E-02
Npv	96	Error	0	0.15518529	2.50006018	0	0	0
Nb	14	Evaluación	Ok	Ok	Ok	Ok	Ok	Ok
Nd	2	Valor Real	0	9.43709466	0.98487074	0	0	0
Nw	17	Valor Red	7.04E-04	9.42842835	1.01622767	-6.17E-04	-3.76E-03	9.63E-03
Npv	29	Error	0	0.09182911	3.18386246	0	0	0
Nb	22	Evaluación	Ok	Ok	Ok	Ok	Ok	Ok
Nd	3	Valor Real	0	9.43709466	1.11579761	0	0	0
Nw	17	Valor Red	8.31E-04	9.42143419	1.13475065	-1.23E-03	-2.73E-03	1.03E-02
Npv	143	Error	0	0.16594584	1.69860876	0	0	0
Nb	9	Evaluación	Ok	Ok	Ok	Ok	Ok	Ok

Nota: Presentación individual del error y la evaluación para cinco combinaciones de microrred.

En la Figura 29 se confirma que los valores calculados por la red neuronal aplicada al caso de estudio dan resultados aceptables, de las cinco combinaciones seleccionadas para calcular el error y mostrar su evaluación solo el descriptor 6 de la combinación “2 4 5 15” no cumple con el error permitido, este es de 7,73762225985084% siendo casi un 3% más.

Como se explica en el Capítulo 3, el análisis del dimensionamiento está enfocado en el despacho de una microrred y el tratamiento de la información usando un menor número de datos con la ayuda de redes neuronales. Se verifica que es una buena opción implementar esta estrategia para mejorar el procesamiento de las variables de potencia de las baterías y generadores diésel

durante las siguientes etapas del proceso. A simple vista, la técnica de entrenamiento usada para este conjunto de datos no permite encontrar de forma directa una aplicación práctica para su uso en otros proyectos de investigación, sin embargo, dados los resultados, es un estudio importante para gestionar de una mejor manera el dimensionamiento de una microrred.

En la siguiente etapa de desarrollo se realizan los cálculos de los tres indicadores claves para el proyecto mencionado en el Capítulo 1. Se toman los datos de las potencias de los equipos de energías renovables y se unen con el conjunto obtenido del entrenamiento de la red neuronal. Tras implementar el nuevo método, ya no es necesario utilizar los modelos y restricciones planteadas anteriormente para calcular el despacho, es decir, se usa en su lugar la información obtenida del aprendizaje automático. El tiempo de ejecución podría disminuir y se puede reducir el tamaño de la unidad de almacenamiento facilitando el tratamiento de las muestras que se utilizan para definir la estructura de una microrred.

Este trabajo de grado demuestra la posibilidad de predecir un conjunto de datos partiendo de un porcentaje ya establecido. Se debe resaltar que el entrenamiento fue posible debido al ajuste de la información de tal manera que pudo ser leída por el lenguaje de programación de una forma más sencilla. Esto se lleva a cabo comprimiendo los datos en valores representativos llamados descriptores que muestran una idea de las variables almacenadas y tras utilizar la herramienta de aprendizaje automático se logra una predicción confiable. Los datos de salida que entrega la red neuronal también son una representación de un conjunto de datos que a pesar de ser analizados siguen siendo desconocidos, por lo tanto, no son aún compatibles con el resto de la información desarrollada en el proceso de dimensionamiento.

Este trabajo de grado propone la idea de desarrollar a futuro una estrategia que permita una descompresión de los descriptores obtenidos en el entrenamiento con una alta precisión y ejecutar el empalme para la siguiente etapa de desarrollo.

6. Conclusiones

Este trabajo de grado permite establecer la efectividad de las redes neuronales para predecir valores representativos de la gestión de energía despachada por las fuentes controlables en el dimensionamiento de una microrred para condiciones climáticas y de carga específicas. Se evidencia que la implementación de este tipo de alternativas es factible en el campo de la Ingeniería Eléctrica. Los valores entregados por las redes neuronales permiten describir el despacho de las unidades de baterías y generadores diésel de la configuración de microrred por hora, dando información que podría ser tabulada y analizada con el fin de encontrar la configuración que supla la demanda de energía eléctrica.

En el desarrollo del trabajo de grado se toma la decisión de trabajar las bases de datos por separado, cada fuente de despacho cuenta con su propia carpeta en Google Drive con los datos de entrada y salida como se describe en el Capítulo 3. La generación de las bases de datos se realiza exportando los datos de Matlab a Excel y luego se cargan al Google Drive para importarlos al aplicativo de Google Colab, siendo esto muy práctico debido a la similitud del lenguaje de programación y los comandos de compatibilidad que tienen estos entornos entre sí. Además, según la disparidad entre los datos de entrada y salida se realiza un proceso de normalización utilizando la herramienta “Preprocessing” de la biblioteca sklearn llegando a obtener resultados satisfactorios como se evidencia en el Capítulo 5.

Para ejecutar el entrenamiento de una red neuronal es necesario contemplar el mayor número de parámetros y escenarios posibles, esto con el fin de disminuir la incertidumbre en los resultados predichos por la inteligencia artificial. En este trabajo de grado se tienen en cuenta algunos porcentajes de datos de entrada tomados al azar y se comprueba que la precisión no tiene cambios significativos cuando se usa el 5% de los valores reales para el entrenamiento, aun así, es importante proponer una estrategia que permita encontrar un valor que represente un punto crítico entre un porcentaje útil y otro que demuestre una precisión por debajo del umbral, ya que puede existir la posibilidad de entrenar la red neuronal con un menor conjunto de datos y obtener resultados similares.

Al momento de elegir los datos que son usados para el aprendizaje automático se proponen cuatro estrategias de selección en las cuales su precisión está por debajo del método aleatorio utilizado por el lenguaje de programación Python. A pesar de ello, aún se pueden probar otras forma basadas en el mismo principio (saltos y puntos de inicio) e intentar encontrar una estrategia que supere la predicción del método ya mencionado.

Existen infinitas combinaciones posibles entre el número de capas de una red neuronal y las neuronas que las conforman, ignorando la capacidad de procesamiento de datos al cual está sujeto Google Colab se puede desarrollar un plan para determinar la combinación más conveniente variando los dos parámetros al mismo tiempo, con esto se evita buscar de manera aleatoria la estructura más adecuada para el entrenamiento.

Tras finalizar la etapa de pruebas, se puede observar que cualquier cambio en algún parámetro o escenario altera la precisión del modelo, por lo tanto, representa un alto grado de complejidad determinar la estrategia más adecuada para el entrenamiento. Resulta útil a futuro diseñar un método que permita encontrar una combinación confiable entre todas las variables.

Los mapas de calor permiten observar la precisión obtenida con el modelo entrenado, basados en un umbral elegido previamente y se obtienen resultados cercanos a los valores reales obtenidos de manera convencional. Algunos descriptores calculados presentan diferencias considerables probablemente causadas por los criterios anteriormente mencionados que son utilizados para el entrenamiento del modelo. Los datos obtenidos para los generadores diésel tienen una mayor precisión que los de las baterías.

Referencias

- Abdmouleh, Z., Alammari, R. A. M., & Gastli, A. (2015). Review of policies encouraging renewable energy integration & best practices. *Renewable and Sustainable Energy Reviews*, 45, 249–262. <https://doi.org/10.1016/J.RSER.2015.01.035>
- Energy Statistics Data Browser – Data Tools - IEA*. (n.d.). Retrieved February 11, 2023, from <https://www.iea.org/data-and-statistics/data-tools/energy-statistics-data-browser?country=WORLD&fuel=Energy%20supply&indicator=TESbySource>
- Ilyushin, P. v., Shepovalova, O. v., Filippov, S. P., & Nekrasov, A. A. (2022). The effect of complex load on the reliable operation of solar photovoltaic and wind power stations integrated into energy systems and into off-grid energy areas. *Energy Reports*, 8, 1515–1529. <https://doi.org/10.1016/J.EGYR.2022.08.218>
- Jiménez, I. (2022). *Dimensionamiento de Microrredes Considerando Análisis de Ciclo de Vida* [Tesis de maestría en Ingeniería Eléctrica]. Universidad Industrial de Santander, Colombia.
- Kalogirou, S. A. (2004). Neural Network Modeling of Energy Systems. In *Encyclopedia of Energy* (pp. 291–299). Elsevier. <https://doi.org/10.1016/B0-12-176480-X/00536-2>
- Keijsers, N. L. W. (2010). Neural Networks. *Encyclopedia of Movement Disorders*, 257–259. <https://doi.org/10.1016/B978-0-12-374105-9.00493-7>
- Kumar, A., Singh, A. R., Deng, Y., He, X., Kumar, P., & Bansal, R. C. (2018). A Novel Methodological Framework for the Design of Sustainable Rural Microgrid for Developing Nations. *IEEE Access*, 6, 24925–24951. <https://doi.org/10.1109/ACCESS.2018.2832460>

- Marini, F. (2009). Neural Networks. In *Comprehensive Chemometrics* (Vol. 3, pp. 477–505). Elsevier. <https://doi.org/10.1016/B978-044452701-1.00128-9>
- Objetivos y metas de desarrollo sostenible - Desarrollo Sostenible*. (n.d.). Retrieved February 11, 2023, from <https://www.un.org/sustainabledevelopment/es/sustainable-development-goals/>
- Ogunjuyigbe, A. S. O., Ayodele, T. R., & Akinola, O. A. (2016). Optimal allocation and sizing of PV/Wind/Split-diesel/Battery hybrid energy system for minimizing life cycle cost, carbon emission and dump energy of remote residential building. *Applied Energy*, *171*, 153–171. <https://doi.org/10.1016/j.apenergy.2016.03.051>
- Qadir, S. A., Al-Motairi, H., Tahir, F., & Al-Fagih, L. (2021). Incentives and strategies for financing the renewable energy transition: A review. *Energy Reports*, *7*, 3590–3606. <https://doi.org/10.1016/j.egyr.2021.06.041>
- Rey, J. M., Jiménez-Vargas, I., Vergara, P. P., Osma-Pinto, G., & Solano, J. (2022). Sizing of an autonomous microgrid considering droop control. *International Journal of Electrical Power & Energy Systems*, *136*, 107634. <https://doi.org/10.1016/j.ijepes.2021.107634>
- Ubilla, K., Jiménez-Estévez, G. A., Hernández, R., Reyes-Chamorro, L., Irigoyen, C. H., Severino, B., & Palma-Behnke, R. (2014). Smart microgrids as a solution for rural electrification: Ensuring long-term sustainability through cadastre and business models. *IEEE Transactions on Sustainable Energy*, *5*(4), 1310–1318. <https://doi.org/10.1109/TSTE.2014.2315651>
- Upadhyay, S., & Sharma, M. P. (2014). A review on configurations, control and sizing methodologies of hybrid energy systems. *Renewable and Sustainable Energy Reviews*, *38*, 47–63. <https://doi.org/10.1016/J.RSER.2014.05.057>

Yaqoob, S. J., Motahhir, S., & Agyekum, E. B. (2022). A new model for a photovoltaic panel using Proteus software tool under arbitrary environmental conditions. *Journal of Cleaner Production*, 333, 130074. <https://doi.org/10.1016/J.JCLEPRO.2021.130074>

Zambroni de Souza, A. C., & Castilla, M. (2019). Microgrids Design and Implementation. In A. C. Zambroni de Souza & M. Castilla (Eds.), *Microgrids Design and Implementation*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-98687-6>