

Análisis del empleo de redes de reconocimiento de patrones en la aplicación de redes eléctricas inteligentes

Analysis of the use of pattern recognition networks in the application of intelligent electrical networks

Análise do uso de redes de reconhecimento de padrões na aplicação de redes elétricas inteligentes

Raúl Andrés García Talledo

rgarcia7890@utm.edu.ec

<https://orcid.org/0000-0001-8351-6704>

Maestría en Electricidad Mención Sistemas Eléctricos de Potencia - Universidad Técnica de Manabí, Ecuador.

Lenin Cuenca Álava

lcuenca@utm.edu.ec

<https://orcid.org/0000-0002-5079-9469>

Universidad Técnica de Manabí, Ecuador

RESUMEN

El reconocimiento de patrones se basa en el reconocer las propiedades únicas que identifican un individuo de los otros de la misma especie. La metodología se basó en conocer la carga y el consumo de energía que genera la facultad de Matemática, Física y Química de la Universidad Técnica de Manabí, de la misma forma se utilizó la estructura de "The Neural Net Pattern Recognition", los cuales se entrenaron para clasificar las entradas según sus clases, realizado mediante el software Matlab R2017b, con el cual se hizo el entrenamiento de la red con diferentes números de neuronas en la capa oculta, donde se usaron valores de 10,15,20,25 y 30 para lograr obtener el error más bajo, se plantearon los siguientes objetivos: Conocer la carga y el consumo de energía que genera en la FCMFQ, seleccionar la variable que se van a establecer como entradas a la red, entrenamiento de la red inteligente mediante el software Matlab y analizar los resultados obtenidos con el entrenamiento, se realizó la comparación entre los diferentes entrenamientos de la red con los valores mencionados de las neuronas, optando por escoger 30 neuronas, obteniendo el error de más bajo (0). Se concluye que la utilización de una red eléctrica inteligente con la implementación de la técnica de RNA es beneficiosa, ya que, si se implementa una red eléctrica inteligente a lo largo del campus de la UTM, se va a poder obtener una eficiencia energética más rentable.

Palabras claves / Descriptores: Variables de entrada, Consumo energético, The Neural Net Pattern Recognition.

ABSTRACT

Pattern recognition is based on recognizing the unique properties that identify an individual from others of the same species. The methodology was based on knowing the load and energy consumption generated by the Faculty of Mathematics, Physics and Chemistry of the Technical University of Manabí, in the same way the structure of "The Neural Net Pattern Recognition" was used. pattern recognition), which were trained to classify the inputs according to their classes, carried out using the Matlab R2017b software, with which the training of the network was done with different numbers of neurons in the hidden layer, where values of 10,15,20,25 and 30 were used to obtain the lowest error, the following objectives were set: Know the load and the energy consumption that it generates in the FCMFQ, select the variable that will be established as inputs to the network, training of the smart network using the Matlab software and analyzing the results obtained with the training, The comparison between the different trainings of the network with the mentioned values of the neurons was made, choosing to choose 30 neurons, obtaining the lowest error (0). In conclusion, the use of an intelligent electrical network with the implementation of the ANN technique is beneficial, since, if an intelligent electrical network is implemented throughout the UTM campus, it will be possible to obtain more profitable energy efficiency.

Keywords: Input variables, energy consumption, The Neural Net Pattern Recognition.

RESUMO

O reconhecimento de padrões baseia-se no reconhecimento das propriedades únicas que identificam um indivíduo de outros da mesma espécie. A metodologia foi baseada em conhecer a carga e o consumo de energia gerados pela Faculdade de Matemática, Física e Química da Universidade Técnica de Manabí, da mesma forma que foi utilizada a estrutura de "Reconhecimento de padrões de rede neural", que foram treinados para classificar as entradas de acordo com suas classes, realizadas utilizando o software Matlab R2017b, com o qual a rede foi treinada com diferentes números de neurônios na camada oculta, onde foram utilizados valores de 10,15,20,25 e 30. Em ordem para obter o menor erro foram estabelecidos os seguintes objetivos: Conhecer a carga e o consumo de energia que ela gera no FCMFQ, selecionar a variável que será estabelecida como entradas para a rede, treinar a rede inteligente através do software Matlab e analisar os resultados obtidos com o treinamento, foi feita a comparação entre os diferentes treinamentos da rede com os valores mencionados dos neurônios, optando por escolher 30 neurônios, obtendo o menor erro (0). Conclui-se que a utilização de uma rede elétrica inteligente com a implementação da técnica RNA é benéfica, pois, se uma rede elétrica inteligente for implementada em todo o campus UTM, será possível obter eficiência energética mais rentável.

Palavras-chave / Descriptores: Variáveis de entrada, Consumo de energia, Reconhecimento de padrões da rede neural.

1. Introducción

Una red neuronal se define como un sistema que permite establecer una relación entre entradas y salidas inspiradas en el sistema nervioso y diferenciándose de la computación tradicional, ya que estos no utilizan una algoritmia secuencial (Moreno s. f.). Las redes neuronales artificiales se comportan como un cerebro humano, en donde se procesa la información en paralelo, con la posibilidad de aprender y generalizar situaciones no incluidas en procesos de entrenamiento (Alber et al. 2019). Pueden considerarse como un método computacional usado con el objetivo de resolver problemas complejos y con la capacidad de realizar predicciones en sistemas relacionales no lineales (Dick 2019).

Su funcionamiento se da gracias a elementos que se comportan como una neurona biológica en sus funciones principales. Para comprender cuáles con los elementos básicos que compone una red neuronal, primero es necesario conocer el funcionamiento de una neurona (Silva-González s. f.). Las neuronas tienen tres componentes principales, las cuales son denominadas dendritas, el cuerpo de la célula o soma y el axón, el punto de conexión entre el axón de una célula y una dendrita de otra célula se llama sinapsis, en términos computacionales las dendritas son las receptoras de la red que cargan de señales eléctricas el cuerpo de la célula dicho cuerpo realiza la suma de esas señales de entrada, el axón es una fibra larga que lleva la señal desde el cuerpo de la célula hasta otras neuronas (Q. Zhang et al. 2019).

Una neurona como tal es diminuta en sí, pero cuando muchas se encuentran interconectadas, pueden formar toda una red de comunicaciones que pueden resolver problemas muy complejos, por ejemplo, el cerebro de una persona contiene billones de neuronas, a esta comunicación entre neuronas se le denomina entonces una red neuronal, se puede decir, por tanto, que una red neuronal está conformada por neuronas que se encuentran interconectadas y organizadas en tres capas (Corona, Diez, y Morell 2020). Los datos ingresan por medio de la “capa de entrada” (input), que pasan a través de la “capa oculta” (layer1, layer2) y salen por la “capa de salida” (output) (Rizzo y Caracoglia 2020).

El proceso de aprendizaje de las redes neuronales artificiales es de carácter secuencial, de esta forma, el aprendizaje se da en todo momento adquiriendo conocimiento a través de las experiencias ocurridas (Jalali et al. 2021). El conjunto de aprendizaje de una red neuronal artificial contiene dos características denominadas “ser significativo” y “ser representativo” en donde, para que haya aprendizaje, debe existir un número significativos de ejemplos durante el proceso de aprendizaje y estos deben ser diversos y equilibrados (Flores et al. 2021). Una red neuronal debe utilizar un tipo específico en la etapa de aprendizaje, realizando un entrenamiento para optimizar la función que analiza la salida de la red y poder determinar la eficiencia del aprendizaje (Coaquira 2021).

Mediante la recopilación de información obtenida a través de revisión bibliográfica, se determinó que una de las mejores técnicas que se puede aplicar para el estudio de la inteligencia artificial en sistemas eléctricos es la red neuronal, ya que estas RNA contemplan una topología estructurada que es muy sencilla (Li et al. 2020), lo cual garantiza un tiempo de aprendizaje corto, ya que posee una gran flexibilidad para atender los diferentes requerimientos de los sistemas eléctricos en general (Luna Perejón 2020). Con base en estos antecedentes se escoge la topología de RNA para realizar el trabajo de esta investigación, ya que cuenta con herramientas como es el Matlab, que posee bosquejos armados para el entrenamiento de la red, haciendo que sea muy versátil.

La metodología se basó en conocer la carga y el consumo de energía que genera la FCMFQ, cuyos datos fueron usados en la estructura “The Neural Net Pattern Recognition” (Las redes de reconocimiento de patrones) (Abiodun et al. 2019), la cual se entrenó para clasificar las entradas según sus clases, el procesamiento de los datos se realizó mediante el software Matlab R2017b, con el cual se hizo el entrenamiento de la red con diferentes números de neuronas en la capa oculta. Se

realizó la comparación entre los diferentes entrenamientos de la red con los valores de las neuronas, optando por escoger 30 neuronas, obteniendo el error de más bajo (0), generando el valor de salida deseado, en comparación con otras neuronas cuyo valor de error fue elevado para la predicción. Por lo tanto, se plantearon los siguientes objetivos: Conocer la carga y el consumo de energía que genera en la FCMFQ, seleccionar la variable que se van a establecer como entradas a la red, entrenamiento de la red inteligente mediante el software Matlab y analizar los resultados obtenidos con el entrenamiento.

2. Materias y Métodos

El siguiente estudio tiene la intención de generar evidencias sobre el Análisis del empleo de redes de reconocimiento de patrones en la aplicación de redes eléctricas inteligentes, Para esto se presenta a continuación la metodología de trabajo que busca alcanzar los objetivos propuestos. En el abordaje de este capítulo se detalla el camino que se usó en la investigación, que conlleva un orden sistemático que le proporcione validez científica a los hallazgos.

Se implementaron cuatro criterios para realizar el caso de estudio como son:

1. Conocer la carga y el consumo de energía que genera en la facultad.
2. Establecer la estructura red de reconocimiento de patrones que se adecue al caso de estudio.
3. Seleccionar la variable que se van a establecer como entradas y salidas a la red.
4. Entrenamiento de la red inteligente mediante el software Matlab.
5. Analizar los resultados obtenidos con el entrenamiento.

La recolección de los datos se llevó a cabo en algunas etapas, partiendo por la observación directa y registro de cada una de las cargas conectadas a los circuitos eléctricos de la FCMFQ, después de llevar a cabo una secuencia de mediciones de los terminales eléctricos con el analizador de RED Modelos PQ-Box 150, equipo de medición y registro de consumo de energía.

En este sentido se utilizó el analizador de red PQ-Box 150, que se conectó en el breakers principal de la FCMFQ, donde se obtuvo información precisa del consumo de energía eléctrica, se realizará un registro correspondiente a 7 meses el desempeño se guardando en la base de datos los valores corriente y tensión. El registro de data realizado se realizó a lo largo de un tiempo de evaluación de 12 meses, a partir de enero de 2019 a las 8:11 am, hasta diciembre de 2019 a las 7:30 am; todos los datos fueron valorados a través del programa propio del equipo WinPQ mobile.

Una vez determinados los consumos energéticos cotidianos productos del sistema de iluminación, sistema de aire acondicionado, toma corriente y otras cargas especiales; se calculó los consumos semanales y mensuales para cada tipo de cargas eléctricas analizada anteriormente, en este sentido la energía mensual consumida de la FCMFQ es de alrededor de 14132,09262 KWh. En la Tabla 1 se presenta los valores de consumo que se obtuvieron en el edificio de la facultad con el analizador de red.

Tabla 1. Distribución del Consumo de energético actual de la FCMFQ.

Tipo de Cargas Eléctricas	Consumo Energético (KWh)								
	Lunes	Martes	Miércoles	Jueves	Viernes	Sábado	Domingo	Semanal	Mensual
Sistemas de Luminarias	281,368	253,726	267,858	271,707	242,184	66,743	59,321	1442,907	5771,628
Aires Acondicionados	351,673	317,124	334,787	339,598	302,697	0	0	1645,879	6583,516
Toma Corrientes	91,575	82,579	87,178	88,431	78,822	0,572	0,508	429,665	1718,66
Cargas Especiales	21,718	19,585	20,676	20,973	18,694	20,601	18,31	140,557	562,228
Central fotovoltaica (aporte)	18	18	18	18	18	18	18	126	504
Total consumo actual de energía	728,334	655,014	692,499	702,709	624,397	69,916	60,139	3533,008	14132,032

2.1. Estructura RNA

Para esta investigación se usó The Neural Net Pattern Recognition (Las redes de reconocimiento de patrones.), son redes de avance de dos capas que se pueden entrenar para clasificar las entradas según las clases, le ayuda a seleccionar datos, dividirlos en conjuntos de entrenamiento, validación y prueba, la red usa el algoritmo de Retropropagacion de Gradiente Conjugado Escalado (Scaled Conjugated Gradient Backpropagation-SCGB) por ser simple y rápido al momento del entrenamiento y genera resultado aceptables, este algoritmo se basa en direcciones conjugadas pero no realiza una búsqueda de línea en cada iteración (Z. Zhang et al. 2019).

Después de que se llevó a cabo diferentes arquitecturas, partiendo de la más elemental, se llegó a la conclusión que la arquitectura óptima para solucionar este problema consto de 1 capa oculta con 30 neuronas en ella, usando la capacidad de activación sigmooidal para la capa de salida, se establece cada valor objetivo escalar en (0) o (1), lo que indica a qué clase pertenece la entrada correspondiente.

2.2 Variables de entras y salida

2.2.1 Variables de entras

Las variables de entrada de la red que se usaron para este caso son los parámetros de consumo de la demanda energética obtenido que son: radiación solar que se genera en el día, el factor de potencia, la conexión a la red pública, el generador diésel y las baterías. Para mayor facilidad se optó por tomar los valores de los parámetros previamente mencionados y se los normaliza entre (0 – 1), por otro lado, la adecuada interpretación de dichos valores ayudo a comprender los resultados que se obtuvieron con la RNA, en la Tabla 2 se presentan los valores de entrada que fueron analizados por la red.

Tabla 2. Rango de los valores de los parámetros

RANGO DE CONSUMO		PANEL FV	
Mayor a 3kwh	Menor a 3kwh	Con radiacion solar	Sin radiacion solar
1	0	1	0

RED ELECTRICA		GENERADOR DIESEL	
Red energisada	Red desenergisada	Conestado	Desconectado
1	0	1	0

BATERIAS		FACTOR DE POTENCIA	
Cargadas	Descargadas al 60%	Mayor o igual a 0,92	Menor a 0,92
1	0	1	0

2.2.2 Salidas de la RNA

Para el desarrollo de este trabajo se expuso como resultado de la topología obtenida por el sistema que dio cinco salidas cuyos parámetros son: Conectar Central fotovoltaica/ Mantener RED/ Conectar Baterías, Mantener RED/Desconectar Central fotovoltaica/ Desconectar Baterías, Aislar RED/Conectar Baterías, Conectar RED/Desconectar BAT (descargadas), Conectar Generador/Aislar RED. Estos vectores se clasificaron en 5 clases cuya codificación será (1 0 0 0 0), (0 1 0 0 0), (0 0 1 0 0), (0 0 0 1 0) y (0 0 0 0 1), como se muestra en la Tabla 3.

Tabla 3. Parámetros de salida de la red

Conectar CV/ Mantener RED/ Conectar BAT para cargar	Mantener RED/Desconectar CV/ Desconectar BAT	Aislar RED/Conectar BAT	Conectar RED/Desconectar BAT (descargadas)	Conectar GEN/Aislar RED
1	0	0	0	0
0	1	0	0	0
0	0	1	0	0
0	0	0	1	0
0	0	0	0	1

2.3. Entrenamiento de la RNA

El software con el que se hizo el proceso de entrenamiento fue el Matlab R2017b que es capaz de producir un modelo de red neuronal bastante sencillo si se usa varias herramientas de ayuda de las que dispone el programa, a través de la herramienta neural network pattern recognition tool (nprtool) de MATLAB, se realizó el entrenamiento de la red neuronal usando las muestras recolectadas. La red neuronal propuesta se basó en 6 entradas correspondientes a los 24 datos de los parámetros mencionados, 30 neuronas en la capa oculta y 5 neuronas en la capa de salida que corresponden a los patrones, una vez finalizado el entrenamiento se puede observar la primera grafica en la Figura 1.

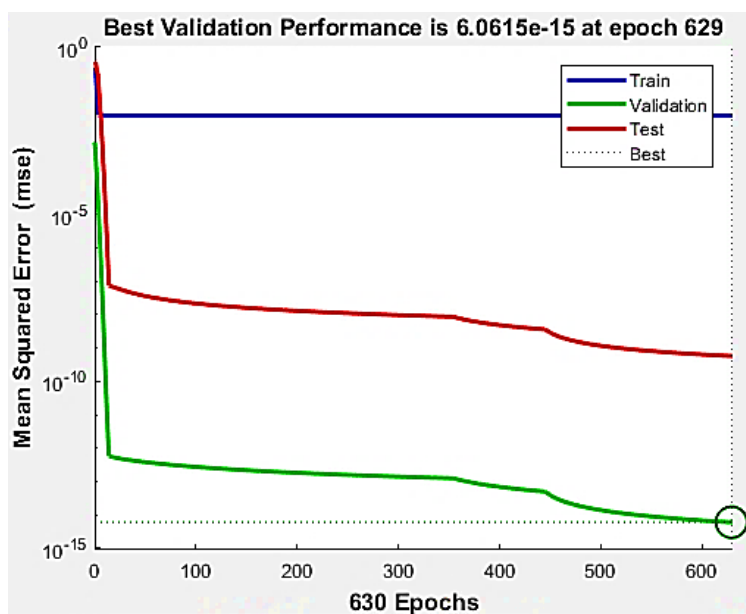


Figura 1. Mean Squared Error (mse) vs número de iteracione

Performance: traza el error frente a la época para el entrenamiento, la validación y el rendimiento de las pruebas del registro de entrenamiento TR devuelto por la función train, se muestra el error cuadrático medio en funcionalidad del número de iteraciones que para esta situación fueron 630 iteraciones con un Mean Squared Error (mse) de 6.0615 e-15. Generalmente, el error se reduce después de más épocas de entrenamiento, pero podría comenzar a aumentar en el conjunto de datos de validación a medida que la red comienza a sobre ajustar los datos de entrenamiento. En la configuración predeterminada, el entrenamiento se detiene después de seis aumentos consecutivos en el error de validación y el mejor rendimiento se toma de la época con el error de validación más bajo.

Confusión: La figura 2 muestra las matrices de confusión para entrenamiento, prueba y validación, y los tres tipos de datos combinados. Los resultados de la red son muy precisos, como puede ver por el alto número de respuestas correctas en los cuadrados verdes y el bajo número de respuestas incorrectas en los cuadrados rojos, los cuadrados azules inferiores a la derecha ilustran las precisiones generales.

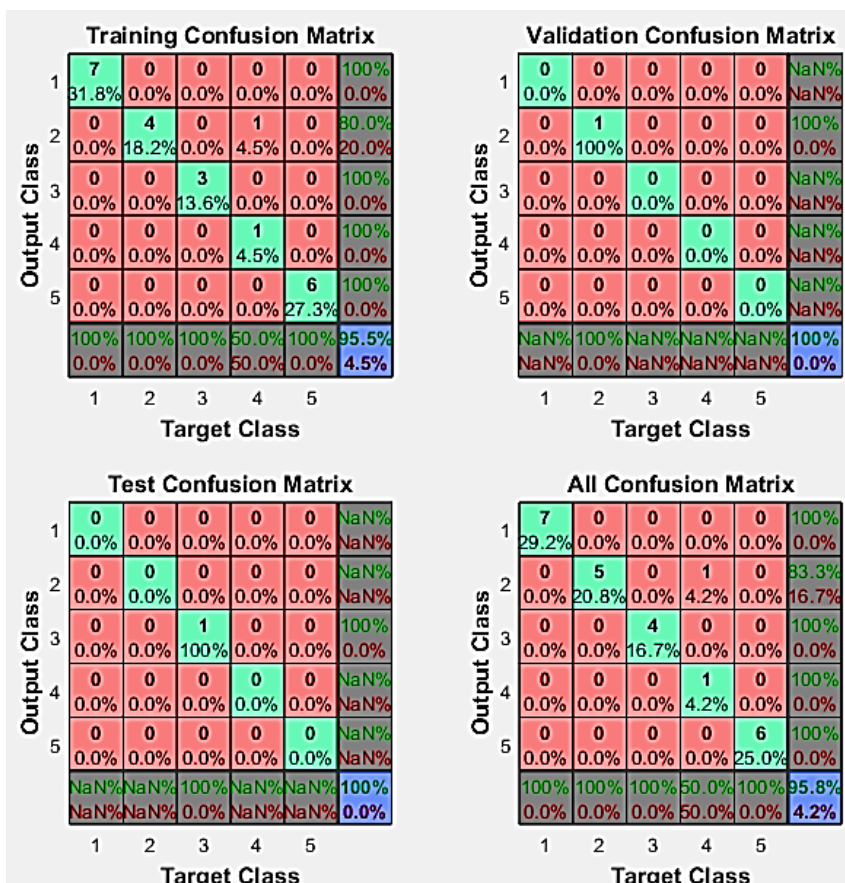


Figura 2. matrices de confusión.

Receiver operating characteristic: En la Figura 3 se observar el trazo de la característica operativa del receptor para cada clase de salida, cuanto más se acerque cada curva a los bordes izquierdo y superior del gráfico, mejor será la clasificación. Las líneas coloreadas en cada eje representan las curvas ROC. La curva ROC es un gráfico de la tasa de verdaderos positivos (sensibilidad) frente a la tasa de falsos positivos (1 - especificidad) a medida que se varía el umbral. Una prueba perfecta mostraría puntos en la esquina superior izquierda, con 100 % de sensibilidad y 100 % de especificidad, para este problema, la red funciona muy bien.

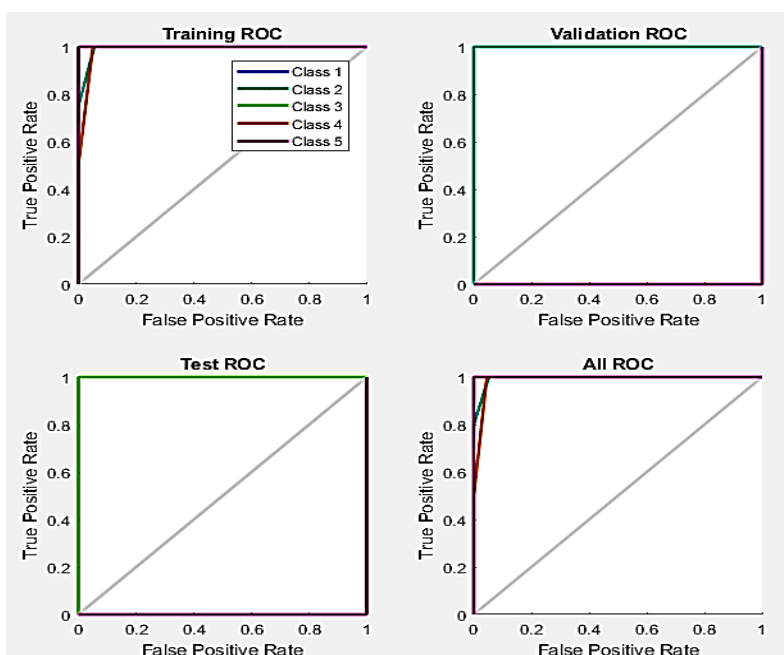


Figura 3. curva característica operativa del receptor (ROC).

Error histogram: Muestra el histograma del error, del cual se prueba que está compartido en torno al cero y con pequeñas dispersiones, de la matriz de error calculada por el programa que se generó en la cual se verifica lo dicho antes que la media aritmética del error de cada salida está cerca a cero y que también sus valores de dispersión (desviación estándar y varianza) poseen valores bastante pequeños que se puede visualizar en la Figura 4.

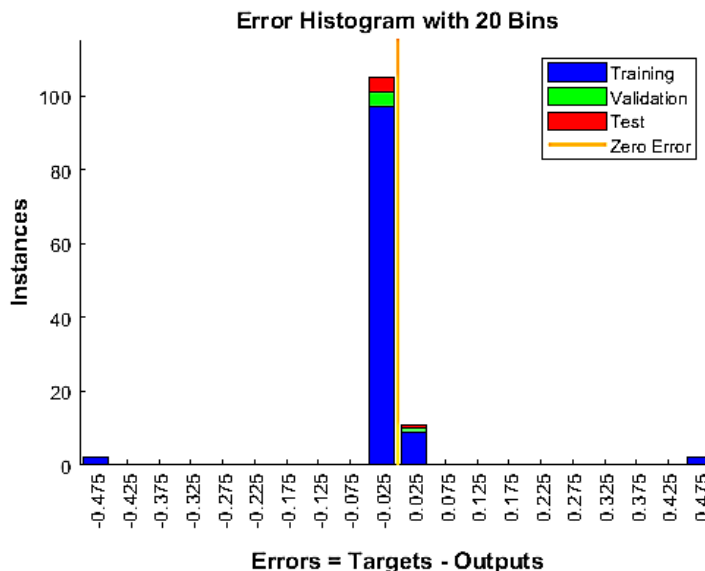


Figura4. Histograma del error de la RN.

El flujograma que se presenta en la Figura 5, muestra cómo se comporta la RNA, dejando un bosquejo bastante claro sobre la conducta que tuvo la red eléctrica inteligente. En esta situación si se le ingresa las entradas pertinentes para que se otorgue la salida que corresponda a dichos valores ingresados, en aquel momento entra funcionando el sistema previamente dimensionado para cubrir con dichas entradas en aquel instante.

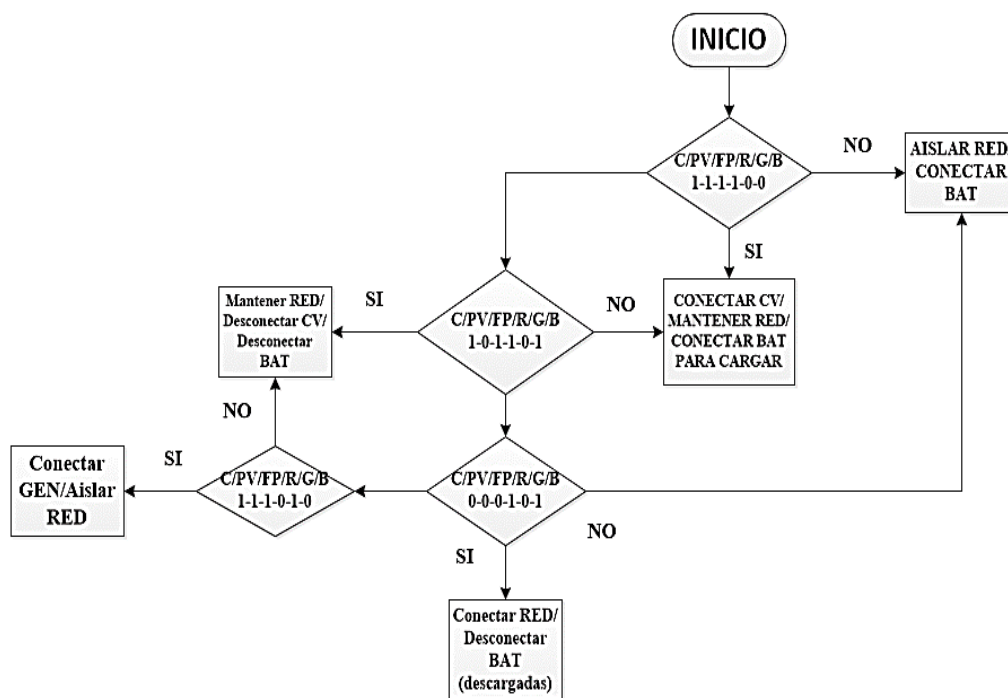


Figura 5 . Flujograma para la toma de decisión

3. Análisis de los resultados

Como se puede observar en la Tabla 4 con los diferentes valores de las neuronas que se ingresó con los que se realizó el entrenamiento se pueden ver como el número de iteración variaron al igual que su error cuadrático con el incremento de las neuronas donde se hizo la comparación de los diferentes entrenamientos que se le pudo realizar a la red neuronal.

Tabla 4. Tabla de errores de los entrenamientos.

TABLA DEL ERROR		
ITERACIONES	ERROR CUADRATICO	No DE NEURONAS
1000	1,0868E-09	10
1000	4,9887E-23	15
118	1,1846E-08	20
626	7,5199E-11	25
667	5,1832E-11	30

Después de realizar la comparación entre los diferentes entrenamientos de la red con valores de neuronas de la capa oculta se escogió la red con el entrenamiento de 30 neuronas lo que dio un valor en la salida que era el deseado con un porcentaje de %0, cumpliendo correctamente con su manejo debido a que tiene una varianza y desviación estándar del error con en relación a la media aceptables.

Además de que la media del error está en un valor de cero, así se puede brindar un caso muestra a la sociedad para hacer conciencia de los gigantes beneficios que contrae la implementación de sistemas eléctricos capaces.

Luego de haber desarrollado, entrenado y examinado qué tipo de red es la mejor, con cuantas capas ocultas y predeterminado el número de neuronas, se obtuvieron las predicciones y sus respectivos errores entre los targets y salidas logradas de los diferentes entrenamientos con los diferentes números de neuronas como se muestra en la Tabla 5.

Tabla 5. Errores obtenidos

SALIDA DESEADA	No DE NEURONAS	ERROR %
Conectar CV/ Mantener RED/ Conectar BAT para cargar	10	0,5
Conectar CV/ Mantener RED/ Conectar BAT para cargar	15	0,4
Conectar CV/ Mantener RED/ Conectar BAT para cargar	20	0,2
Conectar CV/ Mantener RED/ Conectar BAT para cargar	25	0,1
Conectar CV/ Mantener RED/ Conectar BAT para cargar	30	0

Como se observa en la Tabla 5 que con 30 neuronas se logra obtener el error de más bajo en este caso es (0), que genera un valor de salida deseado, en cambio con las otras neuronas su valor del error que se produjo es elevado para la predicción lo que quiere decir que no es una red adecuada ya que siempre se busca que la salida sea más próxima a la deseada.

4. Conclusiones

En el trabajo presentado se pone en prueba como a partir del trabajo de las redes neuronales artificiales tenemos la posibilidad de elaborar y diseñar sistemas decisores que nos garanticen una operatividad eficiente y robusta de los sistemas eléctrico.

The Neural Pattern Recognition necesita menor experiencia con en relación a otros procedimientos de predicción, debido a que es el propio algoritmo de aprendizaje el que establece cuales son los pesos sinápticos, desde los datos históricos.

Para esta investigación se hizo el entrenamiento con diferentes números de neuronas en la cual se terminó usando una capa oculta de 30 neuronas y cinco capas de salida lo que genero un porcentaje de error de 0% con 667 iteraciones y con un error cuadrático de $5.1832e-11$ al momento de realizar el funcionamiento de la red ya que con los otros valores su porcentaje de los errores se alejaba de 0, al aumentar el número de capas hace que el error cuadrático se aumente. Mientras tanto que al incrementar el número de neuronas con las capas mencionadas previamente el error cuadrático no posee una alteración significativa.

En base a los resultados de la Tabla 5 podemos concluir que la red neuronal obtenida cumple correctamente con su funcionamiento ya que tiene una varianza y desviación estándar del error con respecto a la media aceptables. Además de que la media del error se encuentra en un valor de cero.

La efectividad de respuesta de la *The Neural Pattern Recognition* es dependiente especialmente de la base de datos con la que se entrene, esta debería ser lo suficientemente vasta, con la más grande proporción de escenarios probables, con la intención de que la RNA aprenda y mejore sus predicciones.

Referencias Bibliográficas

- Abiodun, Oludare Isaac, Aman Jantan, Abiodun Esther Omolara, Kemi Victoria Dada, Abubakar Malah Umar, Okafor Uchenwa Linus, Humaira Arshad, Abdullahi Aminu Kazaure, Usman Gana, y Muhammad Ubale Kiru. 2019. «Comprehensive review of artificial neural network applications to pattern recognition». *IEEE Access* 7:158820-46.
- Alber, Maximilian, Sebastian Lapuschkin, Philipp Seegerer, Miriam Hägele, Kristof T. Schütt, Grégoire Montavon, Wojciech Samek, Klaus-Robert Müller, Sven Dähne, y Pieter-Jan Kindermans. 2019. «iNNvestigate neural networks!» *J. Mach. Learn. Res.* 20(93):1-8.
- Coaquira, Carlos. 2021. «Sílabo de Inteligencia Artificial».
- Corona, Julio Camejo, Hector Gonzalez Diez, y Carlos Morell. 2020. «Un estudio empírico del modelo de red neuronal MLP para problemas de predicción con salidas múltiples.» *Serie Científica de la Universidad de las Ciencias Informáticas* 13(6):1-14.
- Dick, Stephanie. 2019. «Artificial intelligence».
- Flores, Fernando Alain Incio, Dulce Lucero Capuñay Sanchez, Ronald Omar Estela Urbina, Jorge Antonio Delgado Soto, y Segundo Edilberto Vergara Medrano. 2021. «Diseño e implementación de una red neuronal artificial para predecir el rendimiento académico en estudiantes de Ingeniería Civil de la UNIFSLB». *REVISTA VERITAS ET SCIENTIA-UPT* 10(1):107-17.

- Jalali, Seyed Mohammad Jafar, Sajad Ahmadian, Abbas Khosravi, Miadreza Shafie-khah, Saeid Nahavandi, y Joao PS Catalao. 2021. «A novel evolutionary-based deep convolutional neural network model for intelligent load forecasting». *IEEE Transactions on Industrial Informatics*.
- Li, Xinyi, Jianshi Tang, Qingtian Zhang, Bin Gao, J. Joshua Yang, Sen Song, Wei Wu, Wenqiang Zhang, Peng Yao, y Ning Deng. 2020. «Power-efficient neural network with artificial dendrites». *Nature Nanotechnology* 15(9):776-82.
- Luna Perejón, Francisco. 2020. «Estudio e integración en sistemas empotrados de algoritmos de Aprendizaje Supervisado basados en Redes Neuronales Artificiales para el análisis de perturbaciones y eventos asociados a la marcha».
- Moreno, Andrea Navarro. s. f. «Introducción a las Redes Neuronales aplicadas al Aprendizaje Supervisado».
- Rizzo, Fabio, y Luca Caracoglia. 2020. «Artificial Neural Network model to predict the flutter velocity of suspension bridges». *Computers & Structures* 233:106236.
- Silva-González, Sheyla Maleny. s. f. «Implementación de una red neuronal artificial como módulo de dominio de un sistema de». *Dilemas Contemporáneos: Educación, Política y Valores*. <http://www.dilemascontemporaneoseduccionpoliticayvalores.com/>.
- Zhang, Qiming, Haoyi Yu, Martina Barbiero, Baokai Wang, y Min Gu. 2019. «Artificial neural networks enabled by nanophotonics». *Light: Science & Applications* 8(1):1-14.
- Zhang, Zhen, Kuo Yang, Jinwu Qian, y Lunwei Zhang. 2019. «Real-time surface EMG pattern recognition for hand gestures based on an artificial neural network». *Sensors* 19(14):3170.