

# **ESCUELA POLITÉCNICA NACIONAL**

**FACULTAD DE INGENIERÍA ELÉCTRICA Y  
ELECTRÓNICA**

**ESTIMACIÓN DE CURVAS DIARIAS DE DEMANDA  
ELÉCTRICA EN TRANSFORMADORES DE  
DISTRIBUCIÓN**

**TESIS DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE MAGÍSTER EN  
INGENIERÍA ELÉCTRICA EN DISTRIBUCIÓN**

**DANIEL GERMÁNICO ORBE JÁTIVA**

**DIRECTOR: GABRIEL BENJAMÍN SALAZAR YÉPEZ**

**CODIRECTOR: PAÚL FABRICIO VÁSQUEZ MIRANDA**

**Quito, 2 de Septiembre de 2021**

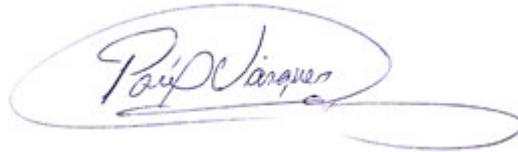
## **AVAL**

Certificamos que el presente trabajo fue desarrollado por Daniel Germánico Orbe Játiva, bajo nuestra supervisión.



---

**NOMBRE DIRECTOR**  
**GABRIEL BENJAMÍN SALAZAR YÉPEZ**



---

**NOMBRE CODIRECTOR**  
**PAÚL FABRICIO VÁSQUEZ MIRANDA**

## DECLARACIÓN DE AUTORÍA

Yo Daniel Germánico Orbe Játiva, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentada para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración cedo mis derechos de propiedad intelectual correspondientes a este trabajo, a la Escuela Politécnica Nacional, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.



---

Daniel Germánico Orbe Játiva

## DEDICATORIA

Resulta muy difícil nombrar en estas breves líneas, a todas las personas a las que me gustaría dedicar el esfuerzo puesto en este trabajo. La vida me ha bendecido al contar con personas extraordinarias a mi lado. A mi amada familia, soporte en los momentos duros de la vida, razón para cada día ser un mejor ser humano. A mi padre, a quien todos los días trato de enorgullecer, recordándolo y viviendo según su ejemplo y consejos. A mi madre, mi hermana y mi sobrino, lo más sagrado e importante que tengo en la vida.

A mis queridos amigos, a quienes siempre conservo en mi corazón y mi mente, gracias por compartir parte de su vida conmigo y enseñarme de mis errores y defectos.

Cambiar es de valientes, cada día se vuelve más fácil. Pero tienes que hacerlo todos los días, esa es la parte difícil.

## **AGRADECIMIENTO**

Un infinito agradecimiento a los doctores Gabriel Salazar y Paúl Vásquez por su dirección y guía durante la elaboración del presente trabajo, al Ing. Jorge Reyes por su invaluable ayuda y consejo.

A la Escuela Politécnica Nacional por la satisfacción y el orgullo de haberme cultivado en sus aulas y formado parte de su planta docente, al Departamento de Energía Eléctrica y en especial al Dr. Fabián Pérez por la oportunidad de desarrollarme profesionalmente.

## ÍNDICE DE CONTENIDO

AVAL .....	I
DECLARACIÓN DE AUTORÍA.....	II
DEDICATORIA.....	III
AGRADECIMIENTO.....	IV
ÍNDICE DE CONTENIDO.....	V
RESUMEN .....	VII
ABSTRACT .....	VIII
1. INTRODUCCIÓN.....	9
1.1. Pregunta de investigación.....	12
1.2. Objetivo General .....	12
1.3. Objetivos Específicos.....	12
1.4. Alcance .....	12
1.5. Marco Teórico .....	13
1.5.1. Redes Neuronales.....	13
1.5.2. Clasificación y Análisis de Grupos.....	25
1.5.3. Procesamiento, validación y transformación de datos.....	29
1.5.4. Criterios de validación .....	31
1.5.5. Curvas de demanda diaria en transformadores.....	32
1.5.6. Factor de Pérdidas .....	34
2. METODOLOGÍA.....	35
2.1. Descripción del planteamiento .....	35
2.2. Estratificación de clientes de la empresa CNEL Santo Domingo .....	37
2.3. Manejo de Información de base de datos .....	42
2.3.1. Demanda eléctrica de transformadores de distribución.....	42
2.3.2. Información topológica de redes primarias .....	43
2.3.3. Bases de Información Comercial.....	44
2.4. Procesamiento de datos.....	45
2.4.1. Curvas de demandas de transformadores.....	45
2.4.2. Análisis para el agrupamiento de curvas .....	51
2.5. Creación y entrenamiento de las Redes Neuronales .....	54
3. RESULTADOS Y DISCUSIÓN .....	59
3.1. Aplicación de los datos de entrenamiento a la Red Neuronal Artificial ...	59
3.1.1. Análisis de agrupamiento de curvas de demandas .....	59

3.2. Análisis de creación de redes neuronales y validación de curvas estimadas de demanda diaria .....	68
3.2.1. Creación de las redes neuronales .....	68
3.2.2. Proceso de Entrenamiento de las redes neuronales .....	72
3.2.3. Validación externa de las redes neuronales entrenadas .....	84
3.3. Análisis de la aplicación de las redes neuronales entrenadas en un alimentador real .....	90
4. CONCLUSIONES Y RECOMENDACIONES .....	98
5. REFERENCIAS BIBLIOGRÁFICAS .....	101
6. ANEXOS.....	105

## RESUMEN

En un futuro a corto plazo, el sistema eléctrico de distribución ecuatoriano requerirá irremediablemente de un manejo técnico y económico cada vez más eficiente. La implementación de redes inteligentes, generación distribuida, almacenamiento de energía y una serie de nuevas tecnologías a pesar de las múltiples ventajas que representan, también dificultan en gran medida la planificación, operación y control de las redes de distribución primaria y secundaria.

Las tecnologías contemporáneas se caracterizan por el manejo de grandes cantidades de datos e información. Actualmente la implementación de nuevas tecnologías en las empresas distribuidoras ha sido impulsada súbitamente por el involucramiento directo de los consumidores en el mercado energético, cambiando totalmente la dinámica empresa distribuidora de energía – cliente. La estimación de la demanda de los consumidores en las redes de distribución, es un problema complejo que hasta hace poco no ha necesitado ser abordado, al no tener una aplicación práctica clara. En la actualidad, el contar con un perfil de potencia a nivel de transformadores de distribución constituye una necesidad para la gestión de un sistema de distribución moderno.

Se ha desarrollado un algoritmo basado en redes neuronales artificiales que permite estimar la curva de demanda horaria de un transformador de distribución, a partir de los datos comerciales de los clientes pertenecientes a dicho transformador. La metodología fue implementada en la empresa CNEL Santo Domingo y su funcionamiento fue validado mediante la comparación entre las mediciones reales y las estimaciones de un alimentador.

**PALABRAS CLAVE:** Estimación de demanda eléctrica, Agrupamiento de curvas de demanda, Redes neuronales Artificiales, Curvas de demanda en transformadores de distribución.

## **ABSTRACT**

In short-term future, Ecuadorian electrical distribution system inevitably will require improve technical and economic management efficiency. Smart grids, distributed generation, energy storage and several new technologies implementation, despite advantages they represent, these technologies complicate distribution grids planning, operation and control.

Contemporary technologies are characterized by large amounts of data and information handling. New technologies implementation in distribution utilities happened suddenly, caused by consumers direct involvement in energy market, changing relationship between distribution utility and customers. Consumers electric demand estimation in distribution grids results in a complex problem, which had not needed to be addressed until recently, because it did not have a clear practical application. Currently, having an electric power profile at distribution transformers level is necessary to manage modern distribution systems.

An artificial neural networks-based algorithm has been developed, to estimate distribution transformers hourly demand curves, starting from consumers commercial data. Methodology was implemented in CNEL Santo Domingo electric utility and its use was validated by comparing between a real feeder measurement and its estimated curves.

**KEYWORDS:** Electricity demand estimation, Electric demand curves clustering, Artificial Neural Networks, Distribution transformers demand curves.

# 1. INTRODUCCIÓN

La estimación de demanda eléctrica en transformadores de distribución no es un estudio que se pueda realizar eficientemente mediante el procesamiento estadístico de datos históricos de mediciones. Esto se debe a que en el sistema de distribución y, más específicamente en sus transformadores no se colocan comúnmente equipos de medición por parte de las empresas distribuidoras. Es por esta razón que la capacidad de estimar la curva de demanda de dichos transformadores es de gran importancia para la operación y la planificación de las redes de distribución de energía.

El conocimiento de las curvas de demanda en transformadores de distribución es muy importante ya que las mismas son utilizadas en estudios de cuantificación de pérdidas, establecimiento de tarifas horarias, reducción del pico de demanda (gestión de demanda), mejoramiento de la operación del sistema mediante control en tiempo real (ADMS), optimización en la ubicación y dimensionamiento de transformadores, zonificación del consumo, etc [12]. En general la realización del presente proyecto es de mucha utilidad para las empresas distribuidoras pudiendo mejorar principalmente sus procesos de planificación, a la vez dotando de la información necesaria para adecuar sistemas modernos de administración de la distribución como el ADMS, y favoreciendo también a la operación del sistema de distribución.

La información obtenida de la estimación de demanda puede ser contrastada con los datos de medición provenientes de las subestaciones de distribución en las barras de medio voltaje y medidores totalizadores en los alimentadores; para así poder contar con una adecuada capacidad de distribución de carga y estimación de estado por parte del centro de control. La proliferación de los Sistemas de Gestión de Distribución (DMS), exige poseer una estimación horaria de la demanda en los nodos de medio voltaje de la red de distribución, justificando la necesidad de contar con una curva estimada para las 24 horas del día, mientras que en el pasado únicamente era necesario contar con una estimación de la demanda máxima coincidente.

Existe un alto grado de dificultad para resolver el problema de estimación de la curva de transformadores de distribución, debido principalmente a los siguientes factores:

- Gran cantidad y variedad de tipos de consumidores y hábitos de consumo
- Escaso nivel de mediciones

- Gran volumen de información a procesar
- Complejidad en los métodos de resolución

En la actualidad el problema radica en que las empresas distribuidoras únicamente realizan estimaciones de la demanda máxima en transformadores de distribución, para efectos de planificación, estimación de pérdidas, optimización de la utilización de transformadores y en general para el mejoramiento en la operación de la red. Consecuentemente se plantea en el presente proyecto brindar la posibilidad de contar con la estimación de curvas de demanda horaria en transformadores, incrementando la capacidad de análisis en el tiempo y en general permitiendo la implementación de la gestión inteligente de las redes de distribución por parte de los sistemas DMS.

Si el presente trabajo no se llevara a cabo, es decir al no conocerse la curva de demanda diaria de transformadores, las empresas distribuidoras seguirían utilizando métodos imprecisos de distribución de carga en base a las pocas mediciones presentes en las redes primarias, este problema también se vería reflejado en la imposibilidad de conocer los niveles reales de cargabilidad en los transformadores y alimentadores primarios, niveles de voltaje en la red y el cálculo inexacto de las pérdidas técnicas y no técnicas del sistema de distribución.

La estimación de curvas de demanda diaria en transformadores de distribución se ha realizado históricamente mediante diversos métodos, obteniendo aceptables niveles de precisión. Dentro de los métodos más exitosos han resaltado los basados en inteligencia artificial que se adaptan de mejor manera a la naturaleza estocástica de la demanda en sistemas de distribución. Se puede mencionar dentro de los métodos más utilizados: los métodos de medición, de agregación de curvas, de lógica difusa y de redes neuronales artificiales (RNA).

Los modelos de Redes Neuronales Artificiales (RNA) tienen el potencial de ser muy útiles y flexibles en la estimación de demanda, debido a sus características adaptativas [10], las redes neuronales son sistemas dinámicos y auto adaptativos. Son adaptables debido a la capacidad de autoajuste de los elementos procesales (neuronas) que componen el sistema y son dinámicos, pues son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones del problema.

Sin embargo, debido a ser consideradas “cajas negras”, resulta difícil comprender la naturaleza de las representaciones internas generadas por la red para responder ante una tarea determinada, transformando las entradas en salidas predichas. Por consiguiente, no resulta tan evidente conocer en una red neuronal el efecto que tiene cada variable de entrada sobre la variable respuesta.

Dentro de los métodos para obtener la curva de demanda en transformadores de distribución, el método de redes neuronales artificiales es el que presenta mayor capacidad de adaptación y un buen desempeño en el manejo de la gran cantidad de información disponible de los transformadores, lo que permite procesar todas las mediciones de la muestra de manera efectiva [3]. Además de su probada efectividad, la gran fortaleza de la metodología propuesta en el presente trabajo, radica en que permite estimar la curva de demanda de cualquier transformador de distribución y si se cambian las características de los usuarios del mismo, la red se entrena de nuevo para obtener nuevos patrones.

El criterio de estimación puede ir más allá y convertirse a la vez en un método de pronóstico de la demanda de energía eléctrica, el cual se ha convertido en uno de los principales campos de investigación en la ingeniería eléctrica, como se menciona en [14]. La planificación del sistema eléctrico requiere de estos pronósticos para cumplir con el objetivo de mantener la sustentabilidad y la eficiencia operativa y energética de las empresas eléctricas de distribución. Las previsiones a corto plazo, en particular, son cada vez más importantes especialmente si se aplican a mercados energéticos competitivos. Es importante que las empresas de distribución ecuatorianas comiencen a utilizar estas nuevas tecnologías que les permitan obtener mejores pronósticos, siempre encaminados a mejorar sus niveles de eficiencia.

El presente proyecto permitirá que las empresas distribuidoras realicen sus estudios en base a estimaciones de demanda de potencia eléctrica diaria más exactas, logrando la efectiva implementación y utilización de los sistemas de gestión de distribución en las mismas. Como se puede apreciar en [11], la implementación de los sistemas de gestión de distribución a nivel nacional se ha planteado como uno de los objetivos a alcanzar dentro del proyecto SIGDE (Sistema Integrado para la Gestión de la Distribución Eléctrica), orientado básicamente a definir e implantar un Modelo Único de Gestión para las Empresas de Distribución Eléctrica, sustentado en estándares de la industria eléctrica y de comunicaciones; que permita tener servicios de calidad, con eficiencia operativa y

energética y con una cultura enmarcada en el compromiso de la sustentabilidad y sostenibilidad social, económica y ambiental.

### **1.1. Pregunta de investigación**

¿Cómo se puede estimar adecuadamente las curvas de demanda eléctrica diaria en transformadores de distribución en el Ecuador?

### **1.2. Objetivo General**

Estimar la curva de demanda diaria de transformadores de distribución, a partir de la información disponible en la base de datos comercial de una empresa de distribución de energía eléctrica y de mediciones realizadas en una muestra de transformadores.

### **1.3. Objetivos Específicos**

- Implementar una metodología adecuada para el procesamiento de los datos de entrada de la red neuronal, obtenidos a partir de mediciones proporcionadas por la empresa distribuidora, mediante herramientas estadísticas y consolidarla con los datos comerciales de los clientes correspondientes.
- Entrenar una red neuronal artificial por medio del desarrollo de una herramienta computacional basada en MATLAB para la estimación de curvas de demanda de transformadores de distribución.
- Validar el modelo de red neuronal propuesto, mediante la comparación de curvas de demanda estimadas en transformadores distintos a los utilizados para el entrenamiento de la red neuronal y mediciones reales proporcionadas por la empresa distribuidora.

### **1.4. Alcance**

Se plantea entrenar una red neuronal por medio de una herramienta computacional desarrollada en MATLAB, a partir de mediciones realizadas en una muestra de transformadores y de la información disponible en la base de datos comercial de la Empresa Pública Corporación Nacional de Electricidad (CNEL EP) - Santo Domingo.

Se trabajará con una red neuronal artificial utilizando el algoritmo de aprendizaje supervisado denominado de Retropropagación (Backpropagation), como datos de entrada a la red neuronal se ingresará datos correspondientes a cada transformador como número de usuarios pertenecientes de cada tipo de consumo, consumo promedio, etc. Las 24 salidas corresponderán a la estimación horaria de demanda para cada modelo de transformador. Si es el caso, se identificarán parámetros adicionales de entrada a la red neuronal de acuerdo a la influencia que tengan ciertas características técnicas de los transformadores, condiciones ambientales, estacionales y consideraciones propias de días laborables y feriados.

El aprendizaje de la red neuronal y el método para la estimación de las curvas de demanda eléctrica se validará a través de la aplicación de la red en un conjunto de transformadores distintos a los utilizados para el entrenamiento de la red neuronal. Así mismo se comparará los resultados obtenidos de la estimación de carga de los transformadores presentes en un alimentador de la empresa CNEL EP Santo Domingo con los datos de mediciones totalizadoras en la cabecera del alimentador respectivo, realizando un análisis de resultados. Finalmente, en base a las curvas obtenidas por el modelo, se procederá a calcular el factor de pérdidas de dicho alimentador y se comparará los resultados con el procedimiento de cálculo actualmente utilizado por CNEL EP Santo Domingo, resaltando de ese modo las virtudes de contar con una curva de carga diaria y verificando de este modo la utilidad que representaría el proyecto para las empresas distribuidoras.

## **1.5. Marco Teórico**

### **1.5.1. Redes Neuronales**

Las Redes Neuronales se crearon para simular los sistemas nerviosos biológicos, constituidos por neuronas y nodos que interconectan las neuronas. El primer modelo de red neuronal fue propuesto en 1943 por McCulloch y Pitts. Era un modelo de neuronas binarias, donde cada neurona podía adoptar dos estados. Este modelo fue la base para el desarrollo de diferentes modelos posteriormente [4].

Las redes neuronales podrían clasificarse en dos grupos:

- Modelos basados en la Biología: Son un conjunto de redes que simulan los sistemas neuronales biológicos y funciones como la vista o la audición.
- Modelos artificiales aplicados: Diseñados para resolver algún problema en concreto que no tiene necesariamente que ver con los sistemas biológicos.

### 1.5.1.1 Neuronas Artificiales

Una neurona artificial es una unidad computacional simple utilizada para realizar un cálculo particular en conjunto con otras unidades computacionales o neuronas, a las que se encuentra interconectada. En la Figura 1.1 se muestra el esquema de una neurona artificial, la cual emula su estructura y funcionamiento a partir de una neurona biológica permitiéndole procesar información de manera similar.

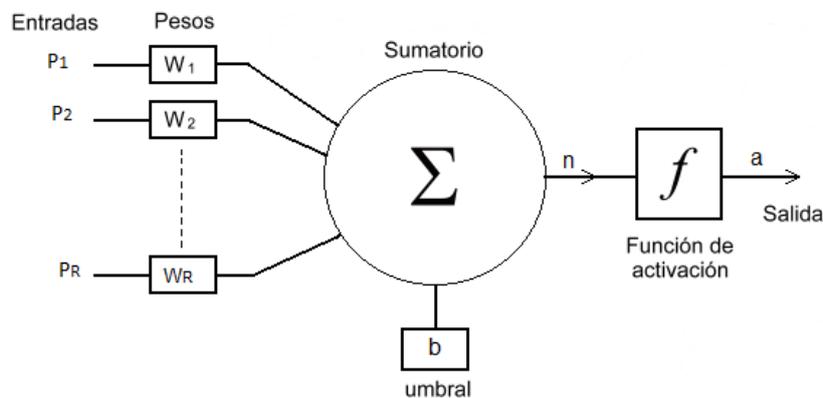


Figura 1.1 Esquema de una neurona artificial [Elaboración Propia]

Los elementos del vector  $P = (p_1, p_2, \dots, p_R)$  constituyen las entradas a la neurona, estas entradas son multiplicadas cada una de ellas por un peso sináptico que constituyen al vector  $W = (w_1, w_2, \dots, w_R)$ . El umbral constituye una entrada especial que tendrá un valor fijo unitario con un peso igual a la polarización de la neurona o  $b$ . El valor de la suma de los productos de las entradas y pesos sinápticos constituye la entrada neta ( $n$ ), la misma que pasa a través de la función de activación ( $f$ ) para resultar en una salida de la neurona ( $a$ ). La función de activación tiene como objetivo determinar o no la activación de la neurona.

La neurona artificial procesará la información de las entradas del vector  $P$  y realizará un cálculo particular que dictará su comportamiento y salida de acuerdo con las ecuaciones siguientes:

$$n = p_1 \cdot w_1 + \dots + p_R \cdot w_R + b = \bar{W} \bar{P} + b$$

Ecuación 1.1. Ecuación de preactivación de la neurona

$$a = f(\bar{W} \bar{P} + b)$$

## Ecuación 1.2. Ecuación de salida o activación de la neurona

Los tipos de redes neuronales más comúnmente utilizadas son:

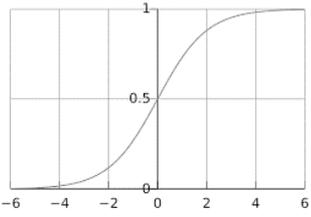
- Perceptrón Monocapa
- Perceptrón Multicapa
- Red Neuronal de Hopfield
- Red Neuronal de Base Radial
- Red Neuronal Probabilística
- Red Neuronal Convolucional
- Red Neuronal Recurrente

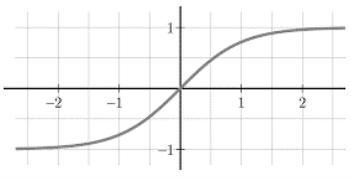
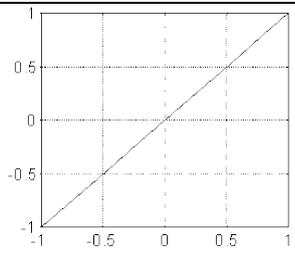
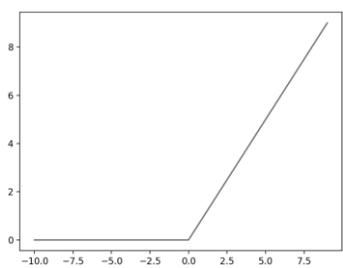
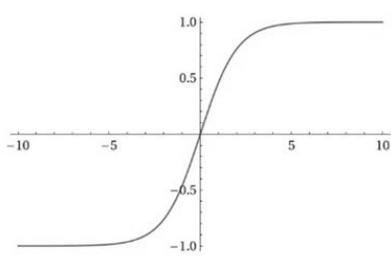
### 1.5.1.2 Funciones de Activación

Las funciones de activación ya sean lineales o no, calculan el estado de actividad de la neurona obteniendo un valor o estado de activación y limitando el rango de salida de la misma.

La función de activación es seleccionada de acuerdo con el problema a criterio del programador, en ocasiones mediante prueba y error. La función escogida también depende de la precisión y velocidad deseada y del algoritmo de aprendizaje escogido. Las funciones de activación más comúnmente utilizadas se detallan en la Tabla 1.1.

Tabla 1.1. Funciones de activación más comúnmente utilizadas [Elaboración Propia]

Función de Activación	Nomenclatura Matlab	Expresión Analítica	Representación gráfica
Sigmoidal (logística)	<i>logsig</i>	$f(n) = \frac{1}{1 + e^{-n}}$	

Tangente hiperbólica	<i>tansig</i>	$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Lineal	<i>purelin</i>	$f(n) = n$	
Rectificador (ReLU)	<i>poslin</i>	$f(n) = \max(0, n)$	
Softmax	<i>softmax</i>	$f(n) = \frac{e^n}{\sum e^n}$	

La elección de la función de activación en la capa oculta determinará la efectividad del modelo de red para aprender el conjunto de datos de entrenamiento, mientras la elección de la función de activación en la capa de salida definirá el tipo de predicciones que puede llevar a cabo el modelo.

La función de activación logística o sigmoide toma como valores de entrada valores reales y define valores de salida en el rango de 0 a 1. Cuanto más positivo sea el valor de entrada, el valor de salida tiende a 1, mientras que cuanto más negativo sea el valor de entrada, la salida tenderá a 0. Es por ello que si se desea restringir las salidas de una red (por ejemplo, entre 0 y 1), entonces la capa de salida que se debe usar es la función de activación sigmoidea (logsig).

La función de activación tangente hiperbólica tiene forma similar a la sigmoide, toma como valores de entrada valores reales y define valores de salida en el rango de -1 a 1. Cuanto más

positivo sea el valor de entrada, el valor de salida tiende a 1, mientras que cuanto más negativo sea el valor de entrada, la salida tenderá a -1. Esta función al igual que la logística tienen el inconveniente de causar el fenómeno conocido como anulación del gradiente.

La función de activación lineal es utilizada cuando se requiere que las salidas sean iguales que las entradas, esto significa que, si se cuenta con varias capas con funciones de activación lineal, estaríamos tratando de un problema de regresión lineal.

La función de activación softmax genera un vector de valores que suman 1 y que pueden interpretarse como probabilidades de pertenencia a una clase, es decir se usa para trabajar con clases múltiples, cuando se desea asignar las probabilidades de que cada elemento pertenezca a clases múltiples.

La función de activación rectificadora o ReLU es muy comúnmente utilizada para capas ocultas, ya que es menos susceptible a la anulación de gradientes que impiden el entrenamiento de modelos más profundos, aunque puede sufrir de otros problemas como unidades saturadas o "muertas". La anulación del gradiente se produce cuando en el proceso de entrenamiento aparece un error en el algoritmo de retropropagación, esto causa que el error se vaya propagando entre las capas de la red, y a medida que avanzan las iteraciones, el gradiente toma un valor cada vez más pequeño y la red no puede lograr un adecuado aprendizaje.

El proceso de escoger una función de activación adecuada constituye un paso crítico en el diseño de una red neuronal. En un principio el dilema se basa en escoger entre funciones de activación lineales o no lineales. Múltiples capas de neuronas con función de activación no lineal permiten que la red aprenda relaciones no lineales entre entradas y salidas. Las capas de funciones lineales se usan con mayor frecuencia para el ajuste de funciones (o problemas de regresión lineal).

El tipo de función de activación correspondiente a las capas ocultas depende del tipo de red en el que se esté trabajando, en la Figura 1.2 se puede observar las funciones de activación recomendadas para cada tipo de red neuronal. Se recomienda que todas las capas ocultas de una red neuronal cuenten siempre con la misma función de activación. La selección de la función de activación de la capa de salida en cambio se basa en el tipo de problema de predicción que se está resolviendo, de acuerdo con el esquema de la Figura 1.3.

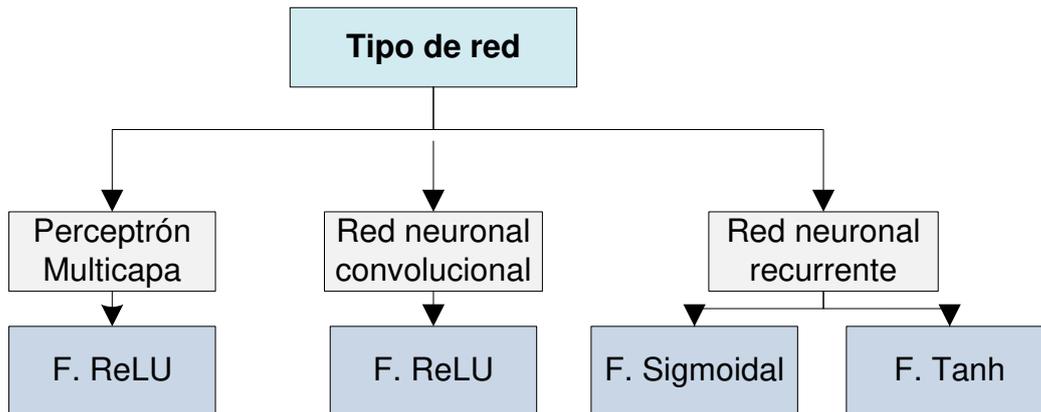


Figura 1.2 Funciones de activación de capas ocultas recomendadas de acuerdo al tipo de red neuronal [27].

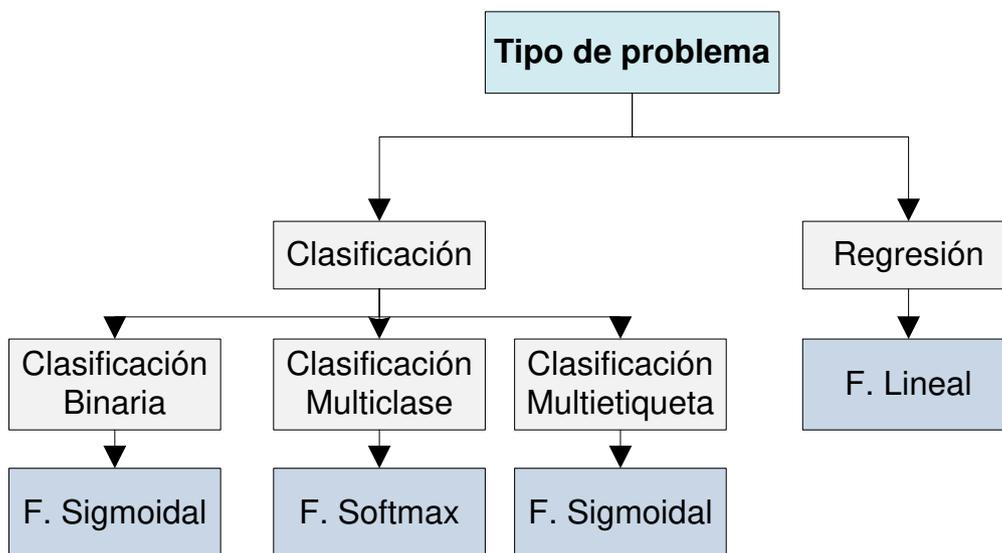


Figura 1.3 Funciones de activación de capas de salida recomendadas de acuerdo al tipo de problema de predicción que resuelve la red neuronal [27].

### 1.5.1.3 Redes Neuronales Monocapa

Una red neuronal se compone de un determinado número de neuronas las cuales pueden estar distribuidas en una o varias capas. La estructura de la red monocapa que se muestra en la Figura 1.4 se compone de “ $S$ ” neuronas y “ $R$ ” entradas. Las entradas se conectan a cada una de las neuronas a través de “ $S \times R$ ” pesos sinápticos.

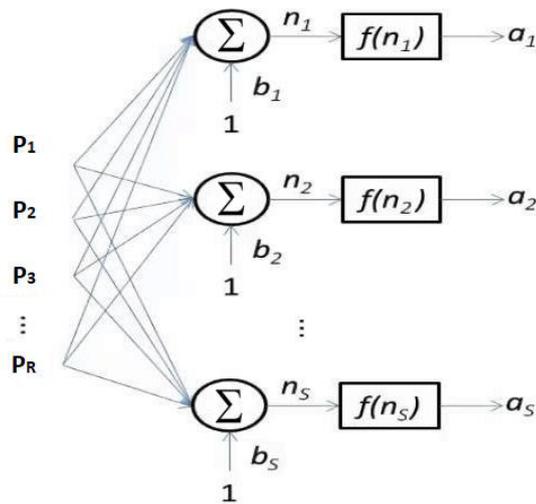


Figura 1.4 Esquema de una red neuronal monocapa [Elaboración Propia]

De manera general se puede plantear la ecuación de salida de la red neuronal en forma matricial de acuerdo con la Ecuación 1.3.

$$a = f \left( \begin{bmatrix} W_{11} & \cdots & W_{1R} \\ \vdots & \ddots & \vdots \\ W_{S1} & \cdots & W_{SR} \end{bmatrix} \begin{bmatrix} p_1 \\ \vdots \\ p_R \end{bmatrix} + \begin{bmatrix} b_1 \\ \vdots \\ b_S \end{bmatrix} \right) = f (\bar{W} \bar{P} + \bar{b})$$

Ecuación 1.3. Ecuación de salida o activación de la red neuronal monocapa

#### 1.5.1.4 Redes Neuronales Multicapa

Una red multicapa se compone de distintas neuronas conectadas en serie como se observa en la Figura 1.5, en donde la salida de una neurona constituye la entrada de la subsiguiente. La red puede estar constituida de múltiples capas entre ellas una capa de entrada, una de salida y una o varias capas intermedias denominadas ocultas, lo cual le otorga la capacidad de resolver problemas no lineales. Las ecuaciones de funcionamiento de estas redes multicapa se basan en las ecuaciones monocapa, con la diferencia de que se forman funciones anidadas dependiendo del número de capas. Las ecuaciones vectoriales 1.4 y 1.5 muestran la función de activación de una red de "M" capas, en donde los superíndices representan los números de cada capa.

$$a^M = f^M (W^M f^{M-1} (W^{M-1} \dots f^2 (W^2 f^1 (W^1 P + b^1) + b^2) \dots + b^{M-1}) + b^M)$$

Ecuación 1.4. Ecuación de salida o activación de la red neuronal multicapa

$$a^m = f^m (W^m a^{m-1} + b^m) \quad a^0 = P, \quad m \in [1, \dots, M]$$

Ecuación 1.5. Ecuación recursiva de la red neuronal multicapa

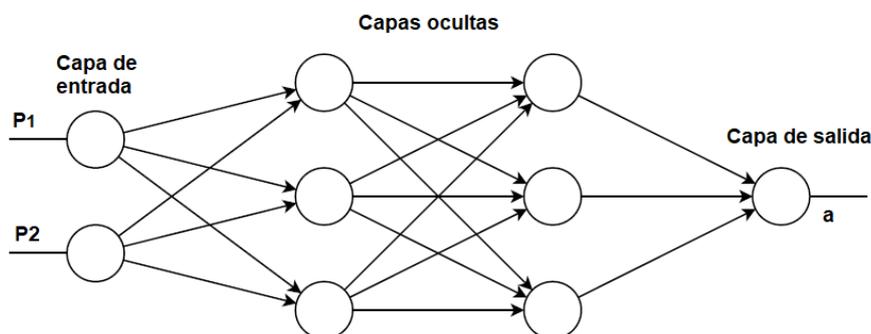


Figura 1.5 Esquema de una red neuronal multicapa [Elaboración Propia]

### 1.5.1.5 Algoritmos de Entrenamiento

Se manejan dos principales categorías de aprendizaje: El Aprendizaje supervisado y no supervisado.

- El Aprendizaje supervisado trata de encontrar un resultado o función a partir de datos de salida asignados a las variables de entrada, es decir se entrena con base a un histórico de datos y predice las salidas. Necesita de un humano que mida el funcionamiento del sistema. Se llama aprendizaje supervisado porque el algoritmo realiza predicciones de forma iterativa sobre los datos de entrenamiento y es corregido a partir de los mismos. El aprendizaje se detiene cuando el algoritmo alcanza un nivel aceptable de rendimiento. Los problemas de aprendizaje supervisado pueden agruparse en dos categorías: regresión y clasificación.
- El Aprendizaje no supervisado en cambio tiene un carácter exploratorio, en donde únicamente se dispone de datos de entrada sin que existan datos de salida que los correspondan. Los problemas de aprendizaje no supervisado pueden agruparse en dos categorías: agrupamiento y asociación.

Los algoritmos de entrenamiento más comúnmente usados para redes neuronales son:

- Descenso por gradiente
- Descenso por gradiente con momento
- Descenso por gradiente con tasa de aprendizaje variable
- Cuasi – Newtoniano

- Método de la Secante
- Levenberg-Marquardt
- Gradiente Conjugado

En relación a los algoritmos de entrenamiento de una red neuronal, muy a menudo el término “retropropagación” se utiliza para referirse específicamente al método de descenso por gradiente. Sin embargo, la connotación real del término se refiere al proceso de calcular el gradiente y el jacobiano mediante la realización de operaciones hacia atrás a través de la red, siendo así que todos los algoritmos de aprendizaje listados anteriormente utilizan el mecanismo de retropropagación para su funcionamiento. En tal virtud los nombres de los algoritmos de entrenamiento más bien hacen referencia al método de optimización de los resultados del aprendizaje.

#### 1.5.1.6 Algoritmo de Retropropagación

El Algoritmo de Retropropagación es utilizado para entrenar redes neuronales multicapas minimizando el error cuadrático iterativamente mediante algún método de optimización, como por ejemplo mediante el método de descenso por gradiente.

Para el proceso de entrenamiento se cuenta con los respectivos patrones (datos de entrenamiento):  $(p_1, t_1), (p_2, t_2), \dots, (p_q, t_q), \dots, (p_Q, t_Q)$

En principio el algoritmo inicializa aleatoriamente los pesos sinápticos y las polarizaciones para todas las capas de la red y realiza un procedimiento iterativo para cada época y dato de entrenamiento mediante el siguiente proceso de 3 pasos:

1.- Propagación hacia delante de los datos de entrada: A partir de un patrón de ejemplo, se utiliza la Ecuación 1.5 para el cálculo de las salidas correspondientes a cada una de las capas de la red. Una vez se ha terminado este proceso se obtiene el valor de salida de la última capa  $a_q^M$ .

2.- Propagación hacia atrás de las sensibilidades de las capas: A partir de la salida de la última capa, se calcula el error de la misma mediante la Ecuación 1.6. El vector de error “ $e$ ” se forma por la diferencia entre la respuesta deseada y la respuesta de la red neuronal.

$$e_q = t_q - a_q^M$$

Ecuación 1.6. Ecuación para cálculo de errores en el algoritmo de retropropagación

La función de error cuadrático que se quiere minimizar es la detallada en la Ecuación 1.7, en donde  $X$  se encuentra conformado por los pesos sinápticos y la polarización.

$$F(X) = e_q^T e_q \quad \text{donde } X = \begin{bmatrix} W^T \\ b^T \end{bmatrix}$$

Ecuación 1.7. Ecuación para cálculo de errores en el algoritmo de retropropagación

La sensibilidad se define como la variación de la función de error cuadrático con respecto a la entrada neta, de acuerdo a la Ecuación 1.8

$$s^m = \frac{\partial F}{\partial n^m}$$

Ecuación 1.8. Ecuación para cálculo de errores en el algoritmo de retropropagación

Posteriormente se procede a calcular la sensibilidad de la última capa mediante la Ecuación 1.9

$$s^M = -2\dot{f}^M(n^M)e_q$$

Ecuación 1.9. Ecuación para cálculo de sensibilidades en el algoritmo de retropropagación

Tomando en consideración el término  $\dot{f}^M(n^M)$  de la ecuación 1.9, se puede decir que el mismo equivale a la derivada de la función de activación con respecto a la entrada neta, de acuerdo a la Ecuación 1.10.

$$\dot{f}^M(n^M) = \frac{\partial f^m}{\partial n^m}$$

Ecuación 1.10. Ecuación para el desarrollo de sensibilidades

Desarrollando la ecuación 1.10 y dependiendo el tipo de función de activación con la que se trabaje, la misma tendrá un distinto resultado de acuerdo a la Tabla 1.2.

Tabla 1.2. Desarrollo de sensibilidades de acuerdo a la función de activación

<b>Función de Activación</b>	<b>Expresión Analítica</b>
Sigmoidal (logística)	$\dot{F}^M(n^M) = \text{diag}((1 - a_i^m)a_i^m)$
Tangente hiperbólica	$\dot{F}^M(n^M) = \text{diag}(1 - (a_i^m)^2)$
Lineal	$\dot{F}^M(n^M) = 1$

A partir del cálculo de sensibilidad de la última capa y mediante la Ecuación 1.11 se lleva a cabo el proceso de retropropagación para el cálculo de sensibilidades de todas las capas de la red hacia atrás, hasta concluir con la primera capa.

$$s^{m-1} = \dot{F}^{m-1}(n^{m-1})(W^m)^T s^m \quad \forall m \in [M, \dots, 2]$$

Ecuación 1.11. Ecuación de retropropagación de sensibilidades

3.- Actualización de pesos sinápticos: Mediante las Ecuaciones 1.12 y 1.13 se recalculan los pesos sinápticos y las polarizaciones de todas las capas.

$$W^m = W^m - \alpha s^m (a^{m-1})^T \quad \forall m$$

Ecuación 1.12. Ecuación de actualización de pesos sinápticos

$$b^m = b^m - \alpha s^m \quad \forall m$$

Ecuación 1.13. Ecuación de actualización de polarizaciones

En las Ecuaciones 1.12 y 1.13 se puede observar la aplicación directa del teorema del descenso por gradiente para hallar los pesos sinápticos y las polarizaciones que minimizan el error cuadrático. En este caso las sensibilidades calculadas anteriormente constituyen los gradientes que básicamente son matrices jacobianas que incluyen a las variaciones de la función de error con respecto a los pesos sinápticos y las polarizaciones. El factor  $\alpha$  se conoce como el índice de aprendizaje y debe ser seleccionado adecuadamente con la finalidad de que permita converger al algoritmo hacia el mínimo error. El índice de aprendizaje es un valor constante (generalmente muy pequeño), para forzar que los pesos y polarizaciones se actualicen de manera muy suave evitando un comportamiento caótico.

El proceso iterativo de entrenamiento culmina cuando se ha llegado a tener un error cuadrático adecuado para el programador o se alcance un criterio de convergencia de acuerdo al problema a resolver.

El desempeño del entrenamiento de la red neuronal depende del algoritmo de aprendizaje utilizado, del número de capas ocultas, del número de neuronas en cada capa oculta, de la conectividad o arquitectura de la red y también del tipo de función de activación que se elija para cada neurona.

### 1.5.1.7 Algoritmo de Retropropagación Levenberg-Marquardt

El Algoritmo de Levenberg-Marquardt (LM) es una técnica iterativa que localiza un mínimo local de una función multivariante que se expresa como la suma de cuadrados de varias funciones no lineales de valor real. El algoritmo LM se ha convertido en una técnica estándar para resolver problemas de mínimos cuadrados no lineales, además es ampliamente utilizado en varias disciplinas para tratar aplicaciones de ajuste de datos [28].

El algoritmo LM se forma por una combinación del método de Gauss-Newton y el descenso por gradiente. Si el algoritmo de retropropagación se expresa como descenso por gradiente, el algoritmo se vuelve lento y no da una solución óptima. Por otro lado, si se expresa como Gauss-Newton, el algoritmo tiene mayor probabilidad de dar una solución óptima. Este algoritmo resulta de gran utilidad en el entrenamiento de redes neuronales ya que puede garantizar la resolución de problemas muy complejos a través de su capacidad adaptativa [29].

Para aplicar este algoritmo se parte de la matriz de Hesse que se puede aproximar con la Ecuación 1.14.

$$H(f) = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1^2} & \dots & \frac{\partial^2 f}{\partial x_1 x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n x_1} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{pmatrix} = J^T J$$

Ecuación 1.14. Ecuación para el cálculo de la matriz de Hesse aproximada

Por ende, la Ecuación 1.15 determina el cálculo del gradiente:

$$g = J^T e$$

### Ecuación 1.15. Ecuación del gradiente en función de la matriz de Hesse

Donde  $J$  corresponde a la matriz jacobiana que incluye las derivadas de los errores de la red con respecto a los umbrales y pesos sinápticos, y  $e$  representa el vector de errores de la red.

El comportamiento del algoritmo LM se asemeja al algoritmo de Newton usando la aproximación de la matriz de Hesse de acuerdo a la ecuación 1.16.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e$$

### Ecuación 1.16. Ecuación de actualización de pesos sinápticos del algoritmo LM

Donde  $x_{k+1}$  y  $x_k$  son los nuevos y los actuales pesos sinápticos respectivamente, calculados con la aplicación del algoritmo de Newton.

El Índice o ganancia de aprendizaje ( $\mu$ ) es utilizado en el proceso de optimización para actualizar los parámetros en cada iteración. Cuando  $\mu$  es cero, el método LM se convierte en el método de Newton usando la matriz de Hesse aproximada. Si  $\mu$  es muy grande, el algoritmo se convierte en un descenso por gradiente con un tamaño de paso pequeño. El método de Newton es más rápido y preciso cerca del mínimo de error, por lo que el objetivo es cambiar hacia el método de Newton lo más rápido posible. Por lo tanto,  $\mu$  se reduce después de cada paso exitoso (reducción en la función de desempeño) y se incrementa solo cuando un paso tentativo aumentaría la función de desempeño. De esta forma, la función de rendimiento siempre se reduce en cada iteración del algoritmo.

## 1.5.2. Clasificación y Análisis de Grupos

La clasificación, análisis de grupos o "Clustering", es uno de los principales temas de estudio de la minería de datos que actualmente tiene diversas aplicaciones utilizadas en campos técnicos como la astronomía, arqueología, ingeniería, psiquiatría, investigación de mercados, etc.

La conceptualización de las cosas, u objetos, como pertenecientes a clases es el núcleo de todo conocimiento. Sin embargo, se debe advertir que las clases dependen del criterio del espectador y que a menudo hay muchos posibles atributos y formas de clasificar un conjunto de objetos [18].

Se llama clasificación al proceso de examinar una muestra de objetos de una población y dividirlos en subconjuntos o clases, de acuerdo con la similitud de ciertas de sus características. Este es un tipo de aprendizaje no supervisado de autoorganización denominado también análisis de grupos, conglomerados o “clustering”, su gran ventaja radica en la factibilidad de encontrar agrupamientos sin usar ningún conocimiento previo.

La principal característica del clustering es la utilización de una medida de similitud basada en atributos que describen a los objetos. Esta similitud se define generalmente mediante proximidad en un espacio multidimensional como se muestra en la Figura 1.6.

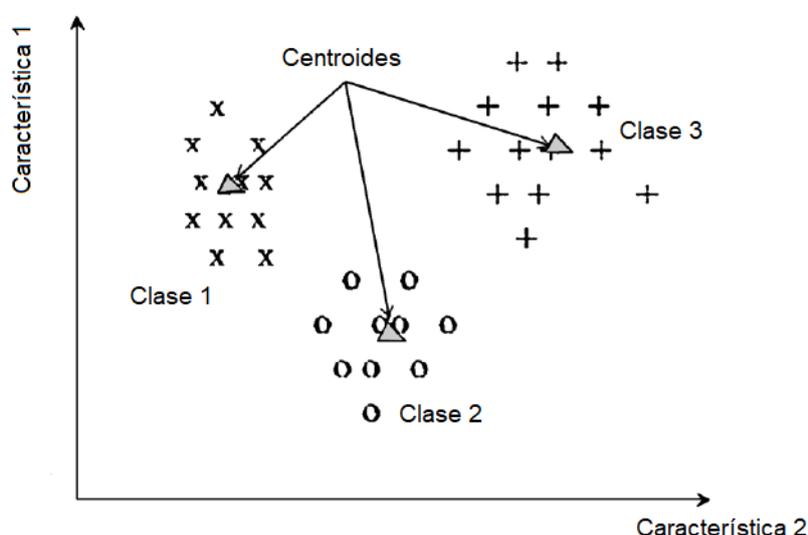


Figura 1.6 Ejemplo de Agrupación de datos basada en proximidad [Elaboración Propia]

Las técnicas de agrupamiento se clasifican en dos categorías: métodos jerárquicos y no jerárquicos, una ampliación de los métodos de agrupamiento se detalla en la Figura 1.7.

- Lo métodos jerárquicos agrupan elementos variando constantemente el número de grupos, de modo que se optimice alguna función de distancia o medida de similitud.
- Lo métodos no jerárquicos se caracterizan por clasificar los individuos en un número previamente determinado de grupos. El proceso de asignación se realiza mediante un proceso que optimice el criterio de selección.

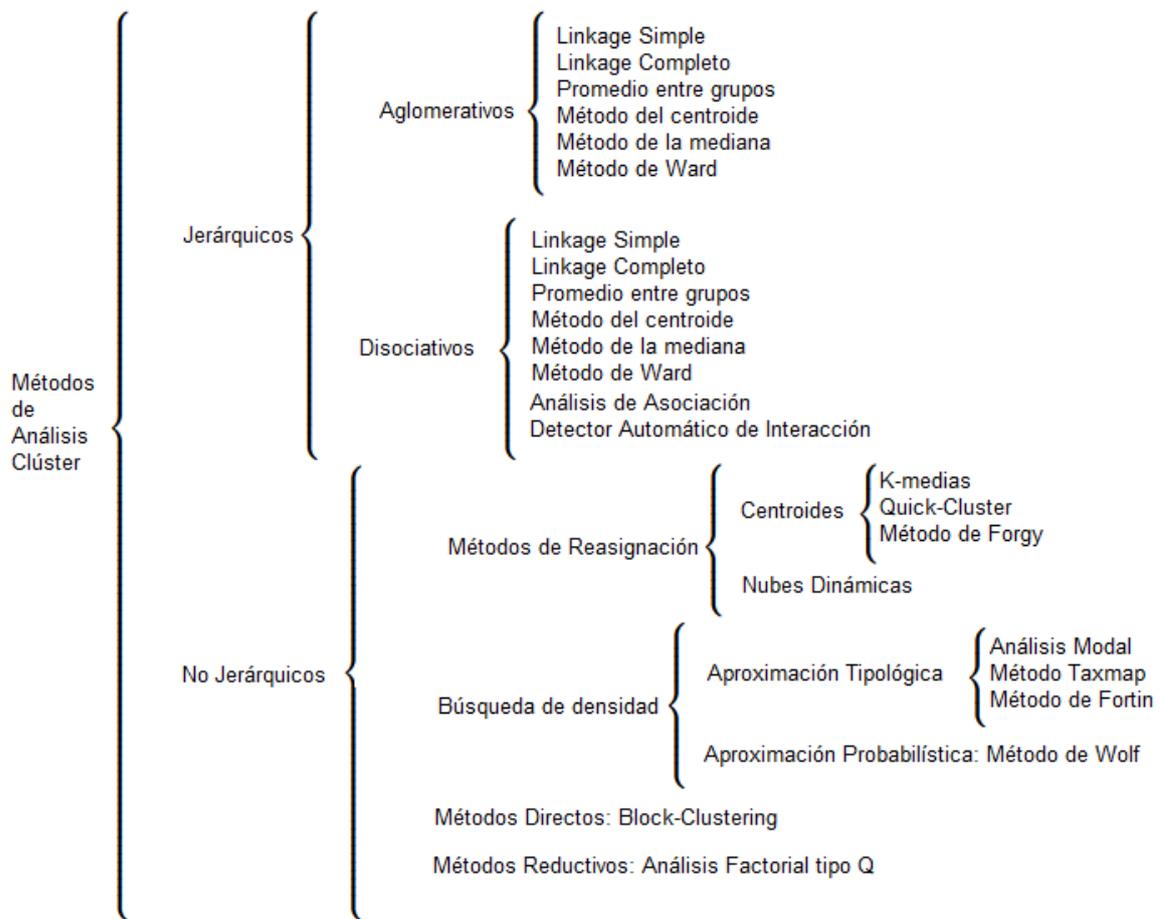


Figura 1.7 Clasificación de los métodos de análisis de grupos [19]

### 1.5.1.8 Algoritmo K-medias

El algoritmo K-medias (K-means) fue formulado en 1972 y se trata de un método no jerárquico que se basa en asignar cada individuo al grupo con el centroide más cercano.

Considerando que el número de clases  $k$  es escogido por el usuario, el algoritmo de k-medias cumple el siguiente procedimiento:

- 1) Seleccionar aleatoriamente los centroides correspondientes a cada una de las clases "k".
- 2) Asignar cada individuo al centroide más cercano.
- 3) Recalcular los centroides de cada clase obtenida.
- 4) Repetir los pasos 2 y 3 hasta que se cumpla el criterio de convergencia, es decir hasta que después de un ciclo completo no se produzca ningún cambio en los miembros de las clases.

Generalmente el criterio de error utilizado por el método es el determinado por la Ecuación 1.17, donde  $p$  es el punto en el espacio de un individuo y  $m_i$  son las coordenadas del centroide de la clase  $C_i$ , cabe indicar que estos dos puntos pueden ser multidimensionales.

$$E = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2$$

Ecuación 1.17. Ecuación de error cuadrático para el algoritmo k-medias

Existen diversas variantes del método de k-medias. Estas difieren en la selección de los k-valores iniciales, el cálculo de la similitud y las estrategias para calcular las medias de cada clúster o clase, sin embargo, cualquiera de las variantes cumple el diagrama de flujo básico mostrado en la Figura 1.8.

La medida de asociación entre individuos más utilizada es la distancia euclídea detallada a continuación en la Ecuación 1.18. Considerando dos individuos de la población:

$$\begin{aligned} x_i &= (x_{i1}, x_{i2}, \dots, x_{in})' \\ x_j &= (x_{j1}, x_{j2}, \dots, x_{jn})' \\ d_2(x_i, x_j) &= \|x_i - x_j\|_2 = \sqrt{(x_i - x_j)' (x_i - x_j)} = \sqrt{\sum_{l=1}^n (x_{il} - x_{jl})^2} \end{aligned}$$

Ecuación 1.18. Ecuación de distancia euclídea para el algoritmo k-medias

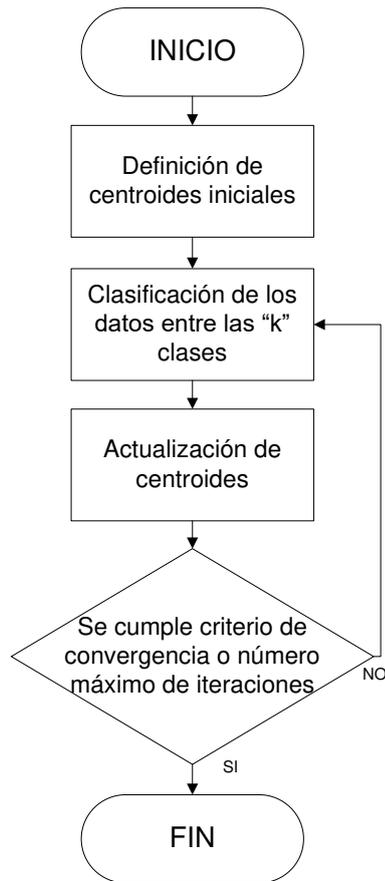


Figura 1.8 Diagrama de flujo del método de k-medias [Elaboración Propia].

### 1.5.3. Procesamiento, validación y transformación de datos

Tanto para el proceso de agrupamiento como para la aplicación de redes neuronales, que son materia de estudio en el presente trabajo, es necesario preparar los datos previamente, de manera que son sometidos a un proceso de estandarización.

Durante el proceso de estandarización de datos, los mismos son consolidados en formatos adecuados para su utilización en técnicas de minería de datos y/o inteligencia artificial. Algunos de los procesos siguientes pueden ser requeridos de acuerdo a la necesidad del programador [16]:

- Normalización: Procedimiento en el cual los datos son escalados dentro de un rango numérico específico, muy comúnmente (-1, 1) o (0, 1).
- Suavizado: Proceso utilizado para eliminar ruido de los datos creando una función que logre captar los patrones importantes en los mismos.

- Agregación: Proceso de recopilar datos y presentarlos en formato resumido. Los datos pueden recopilarse de múltiples fuentes con la intención de combinarlos para su posterior análisis.
- Generalización: Procedimiento por el cual se reemplazan datos primitivos por conceptos de alto nivel a través del uso de jerarquías [16].

### 1.5.3.1. Normalización de datos

La Normalización de datos se puede concebir como el proceso de comprimir o extender los valores de una variable de modo que los mismos se encuentren escalados en un rango específico. El procedimiento de normalización es particularmente útil para el entrenamiento de redes neuronales artificiales, algoritmos de clasificación basados en distancia y procesos de clustering en general.

Existen diversos métodos de normalización, entre los más utilizados actualmente se encuentran: Escalado de variables (Min-max), puntuación estándar (z-score), escalamiento decimal.

### 1.5.3.2. Normalización por escalado de variables

Este tipo de normalización realiza una transformación lineal de los datos originales, considerando como límites de la variable, los valores mínimo y máximo de los valores estudiados y escalándolos a nuevos límites definidos por el programador. Generalmente se toma como límites cero o uno. La ventaja de este método es que preserva una relación lineal con los datos originales. La Ecuación 1.19 permite escalar variables según este método.

$$v' = \frac{v - \text{mín}}{\text{máx} - \text{mín}} (\text{nuevo\_máx} - \text{nuevo\_mín}) + \text{nuevo\_mín}$$

Ecuación 1.19. Ecuación de normalización por escalado

Los valores: *nuevo\_máx* y *nuevo\_mín* representan los límites de escalamiento definidos por el programador, mientras los valores *mín* y *máx* son los límites de los datos recopilados. Una desventaja del método en cuestión es que puede existir errores de desbordamiento de límites si es el caso que se trate de normalizar nuevos datos.

### 1.5.3.3. Imputación de datos

En toda actividad que involucra el manejo de información se presentan habitualmente problemas en la calidad de las bases de datos, es por ello que las entidades que utilizan dicha información utilizan técnicas estadísticas para mejorar la calidad de la información utilizada. Los principales problemas que se presentan en las bases de datos son: datos erróneos, faltantes y desviaciones en la medición.

Los datos faltantes son valores vacíos o nulos dentro de una serie temporal y que no hay que confundirlos con cero, muchas veces estos pueden confundirse con desconexiones en el suministro eléctrico es por ello que los mismos deben ser previamente verificados con el historial de desconexiones. Los datos erróneos y desviaciones en cambio aparecen como mediciones numéricamente distintas al resto de datos o al historial de mediciones.

Con el fin de corregir los problemas anteriormente citados existen distintas técnicas de imputación para el reemplazo de datos erróneos.

### 1.5.3.4. Imputación por regresión

En este tipo de imputación los datos erróneos son reemplazados con valores obtenidos a partir de una regresión de los datos existentes, con esto se logra minimizar la pérdida de información al utilizar un número importante de datos existentes.

Considerando una variable  $Y_i$  que presenta  $n_a$  valores perdidos o ausentes. Se estima la regresión de la variable  $Y_i$  sobre las variables  $Y_j$  a partir de los  $n_i$  casos completos y se imputa cada valor perdido con la predicción dada por la Ecuación 1.12 [21].

$$Y_i = \beta_{0_{obs}} + \sum_{j \neq i} \beta_{j_{obs}} Y_j$$

Ecuación 1.20. Ecuación para imputación por regresión

Donde  $\beta_{0_{obs}}$  y  $\beta_{j_{obs}}$  son los coeficientes de la regresión  $Y_i$  sobre  $Y_j$  basada en las  $n_i$  observaciones completas.

### 1.5.4. Criterios de validación

Para validar el proceso de estimación de curvas que se realiza en el presente trabajo es necesario la utilización de alguna medida de evaluación entre los datos estimados y reales. Esta validación se realizará una vez la red neuronal haya sido entrenada y se desea medir su desempeño para su posterior utilización. Existen diversos índices de evaluación que se pueden utilizar, y se detallan en la Tabla 1.3.

Tabla 1.3. Métricas de validación de curvas

Medida de validación	Expresión de cálculo
Error Absoluto Medio	$MAE = \frac{1}{n} \sum_{i=1}^n  x_i - \bar{x} $
Error Cuadrático Medio	$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$
Raíz del Error Cuadrático Medio	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
Coefficiente de Determinación	$R^2 = \frac{\sum_{i=1}^n (\hat{x}_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$

### 1.5.5. Curvas de demanda diaria en transformadores

La demanda de potencia eléctrica se define como la cantidad de potencia requerida por un consumidor o un grupo de consumidores en un determinado tiempo. Este tiempo durante el cual la demanda se define, representa la potencia media, y se denomina intervalo de demanda. Generalmente los equipos de medición trabajan con frecuencias de toma de datos entre 10 y 15 minutos, esto de acuerdo al número de datos requeridos o a la capacidad de almacenamiento del equipo. La demanda puede ser expresada en distintas magnitudes de acuerdo al análisis que se lleve a cabo: en términos de potencia activa, reactiva, aparente o en corriente (kVA, kVAR, kW, A).

Las curvas de demanda diaria se forman por la variación horaria de la demanda en el tiempo, y la forma de esta curva indica claramente las características de los usuarios conectados aguas abajo, siendo la misma predominantemente residencial, comercial o industrial, como se

muestra en la Figura 1.9. El análisis de los picos de la curva de demanda resulta muy útil para determinar cargabilidades, patrones de consumo y en general diversos análisis de planificación.

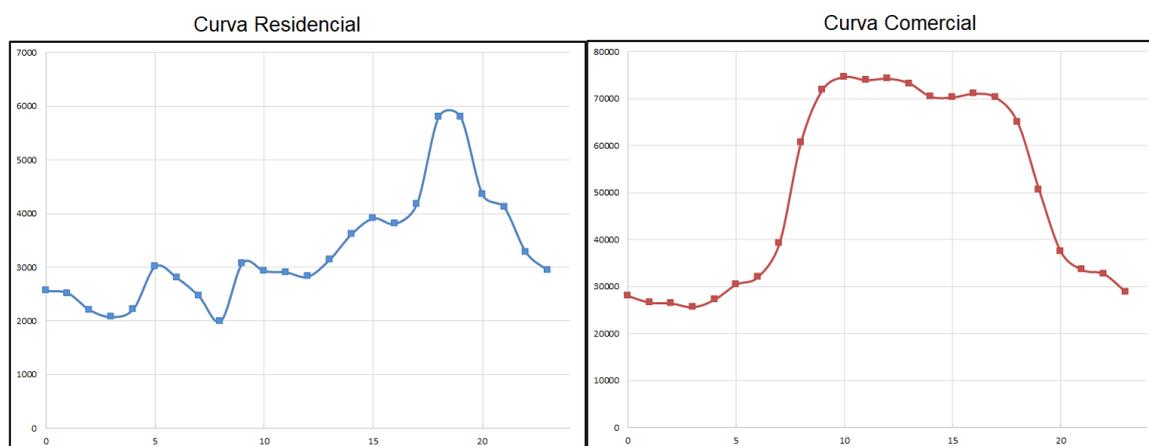


Figura 1.9 Curvas de demanda diaria típicas de predominancia residencial y comercial [Elaboración Propia].

Las empresas distribuidoras generalmente no realizan medición ni monitoreo en tiempo real de la red secundaria debido a su gran extensión y al costo que representaría hacerlo, es por ello que la estimación realizada en el presente trabajo tiene utilidad práctica.

La información de las curvas facilitadas por CNEL Santo Domingo, corresponden a campañas de medición de la empresa, medidas en el lado de baja del transformador de distribución mostrando la variación de la potencia activa en el tiempo durante una semana.

Existen diversos factores que inciden en el comportamiento de las curvas de demanda diaria en transformadores de distribución, los mismos que se nombran en la Figura 1.10.

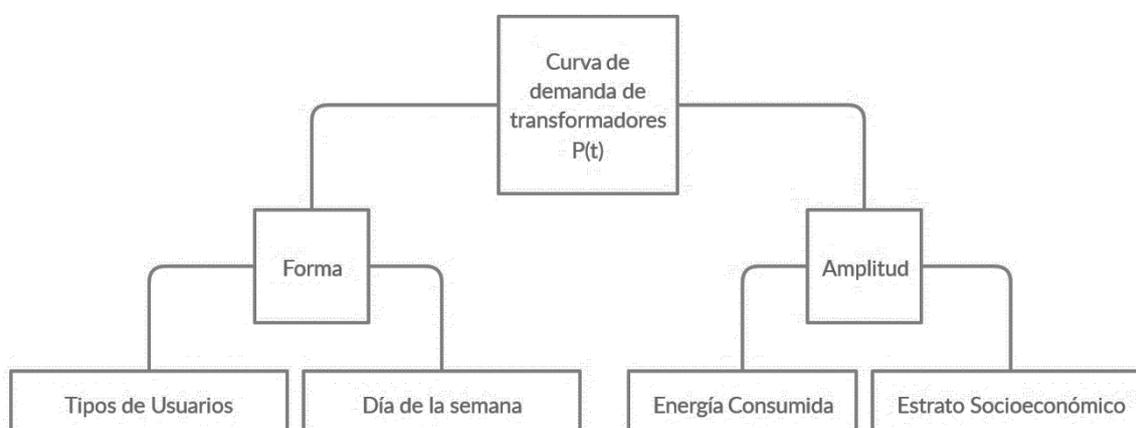


Figura 1.10 Factores incidentes en curvas de demanda de transformadores [3].

### 1.5.6. Factor de Pérdidas

Es un factor que indica el tiempo que requiere la demanda pico para producir las mismas pérdidas que la demanda real en un período de tiempo especificado, y se calcula según la Ecuación 1.21.

$$f_{per}(\%) = \frac{\sum D_i^2 h}{D_M^2 \times T} \times 100 = \frac{D_P^2}{D_M^2} \times 100$$

Ecuación 1.21. Ecuación para el cálculo del factor de pérdidas

Donde:

$D_i$ : es la demanda de cada intervalo de tiempo

$D_M$ : es la demanda máxima en el intervalo de tiempo

$D_P$ : es la demanda promedio en el intervalo de tiempo

$T$ : es el intervalo de tiempo considerado

El factor de pérdidas también puede calcularse a partir de las ecuaciones 1.22. y 1.23.

$$f_{per}(\%) = K f_{carga} + (1 - K) f_{carga}^2$$

Ecuación 1.22. Ecuación para el cálculo del factor de pérdidas

Donde:

$K$ : es el coeficiente variable que depende de aproximaciones estadísticas, para el caso de la CNEL Santo Domingo se utiliza 0.3.

$f_{carga}$ : es el factor de carga en el intervalo de tiempo deseado

$$f_{per}(\%) = \left( \frac{D_i f_{pDmax}}{D_{max} f_{pi}} \right)^2$$

Ecuación 1.23. Ecuación para el cálculo del factor de pérdidas

Donde:

$D_i$ : es la demanda en el intervalo de tiempo  $i$

$D_{max}$ : es la demanda máxima

$f_{pDmax}$ : es el factor de potencia a demanda máxima

$f_{pi}$ : es el factor de potencia en el intervalo de tiempo  $i$

## **2. METODOLOGÍA**

### **2.1. Descripción del planteamiento**

El planteamiento del problema se lo realiza mediante redes neuronales artificiales utilizando para su entrenamiento del algoritmo de aprendizaje supervisado denominado de Retropropagación (Backpropagation). Las salidas de la red representarán la demanda horaria del transformador, mientras el número de entradas estará determinado por los factores que influyen el comportamiento de la curva de demanda: tipo y consumo de clientes y día de la semana.

Para resolver el problema planteado mediante Redes Neuronales Artificiales, se realiza un proceso de entrenamiento a partir de los datos tomados de una muestra de curvas de demanda de transformadores obtenidos mediante mediciones. El proceso de entrenamiento permite el aprendizaje de la red neuronal mediante reglas de naturaleza compleja, luego se procesan los datos de dicha muestra, permitiendo que la red neuronal artificial encuentre patrones característicos, los cuales pueden aplicarse como un modelo general para transformadores de distribución [15].

En el presente trabajo se pretende combinar el uso de un modelo de agrupación por conglomerados y redes neuronales artificiales, para obtener buenos resultados con niveles de error satisfactorios de menos del 15% [1]. Previo al aprendizaje se realizará una etapa de validación y tratamiento estadístico de las mediciones que constituirán los datos de entrenamiento de la red neuronal. El modelo de red neuronal permite directamente obtener curvas de demanda a nivel de transformadores, lo que resulta beneficioso en comparación con métodos basados en la obtención de curvas típicas por cliente. Esto debido a que el comportamiento del cliente es impredecible en gran medida, lo que lleva a sobredimensionar las curvas de demanda al no considerar la aleatoriedad y coincidencia entre clientes.

La metodología desarrollada resulta muy compleja por la gran cantidad de procedimientos intrínsecos y la gran cantidad de datos involucrados, es por ello que se ha desarrollado un diagrama de flujo con funciones cruzadas, mostrado en la Figura 2.1.

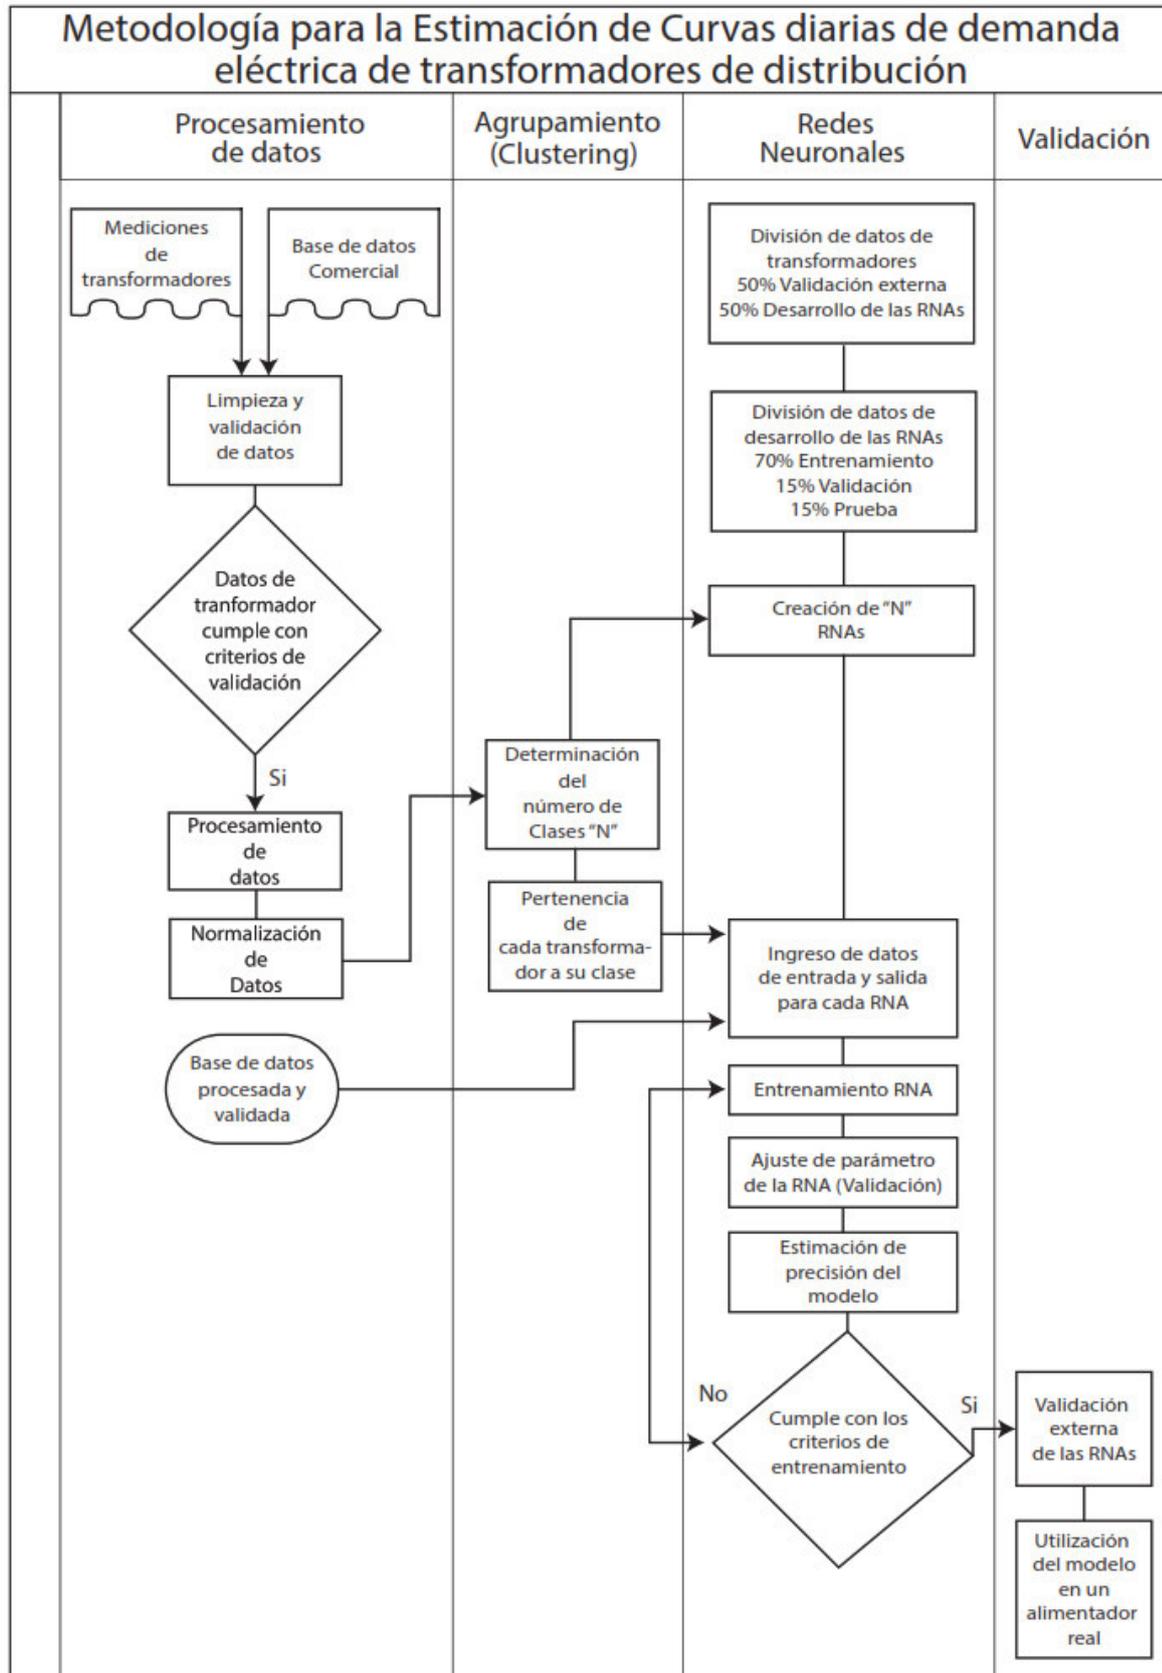


Figura 2.1 Diagrama de flujo de la metodología desarrollada [Elaboración Propia].

## 2.2. Estratificación de clientes de la empresa CNEL Santo Domingo

La CNEL EP Unidad de Negocio Santo Domingo tiene un área de concesión de 12.894,11 km<sup>2</sup>, equivalente al 5% del área nacional, y el 11% del área total de la CNEL, incluyendo territorios de las provincias de Santo Domingo de los Tsáchilas, Manabí, Pichincha, Esmeraldas, Los Ríos y Cotopaxi. La CNEL Santo Domingo dota de servicio eléctrico a un total de 253.032 usuarios regulados y no regulados, lo que representa el 9,6% de la totalidad de clientes de las empresas eléctricas de distribución a nivel nacional.

Como se puede observar en la Figura 2.2, el sistema de subtransmisión de la CNEL Santo Domingo es alimentado a partir de 3 puntos de entrega del SNT, las subestaciones Santo Domingo, Chone y Pedernales pertenecientes a CELEC EP. Además, su sistema posee 13 subestaciones reductoras propias, y 6 subestaciones reductoras privadas, 33 líneas de subtransmisión y 50 alimentadores primarios, propiedad de la Unidad de Negocio Santo Domingo, 8 alimentadores privados, la sumatoria de distancia total que recorre los alimentadores es de 10.119,56 (km).

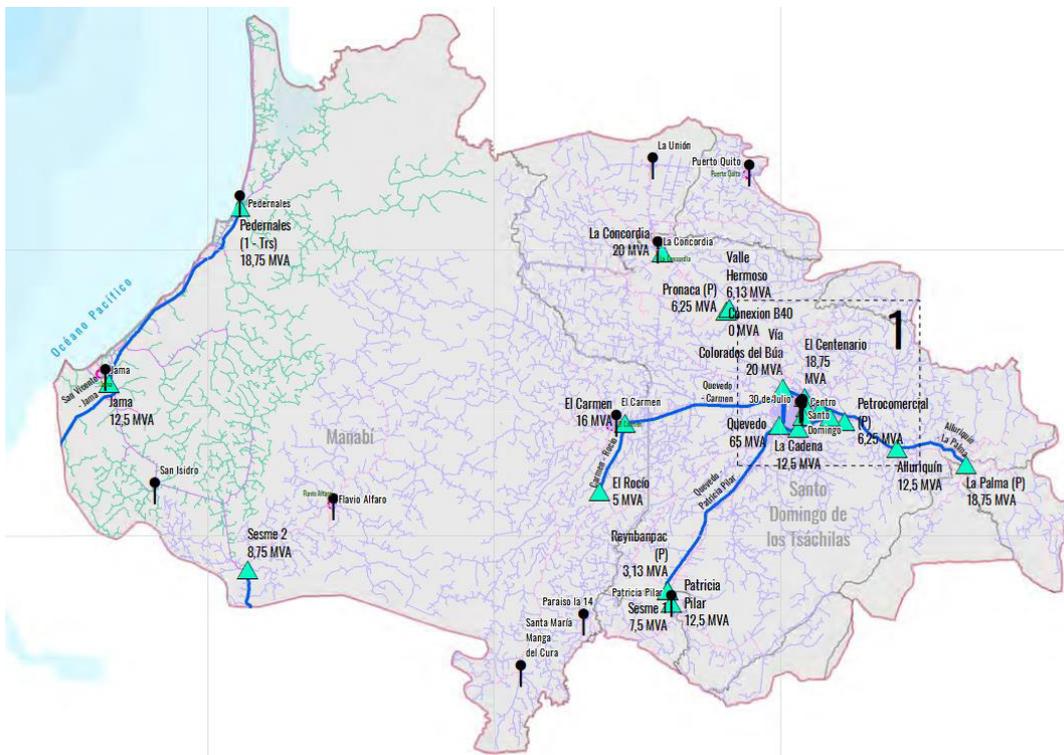


Figura 2.2 Área de concesión de CNEL Santo Domingo [20].

En la zona de Santo Domingo la potencia instalada es de 410,56 MVA, correspondiente a 19.085 transformadores de distribución (94% monofásicos y 6% trifásicos), mientras que en la zona norte de Manabí la potencia instalada es de 97,56 MVA, correspondientes a 5362 transformadores de distribución (98,5% monofásicos y 1,5% trifásicos).

De acuerdo a la base de datos manejada por CNEL Santo Domingo, la composición de sus clientes a diciembre 2017 es la mostrada en la Tabla 2.1.

Tabla 2.1. Clasificación de clientes de CNEL Santo Domingo

<b>Clasificación</b>	<b>Clientes</b>	<b>% Clientes</b>	<b>kWh-año</b>	<b>% kWh</b>
Residencial	169.029	74,3	211.075.888	36,2
Comercial	23.403	10,3	139.548.485	23,9
Industrial	213	0,1	85.763.646	14,7
PEC	31.081	13,7	51.223.477	8,8
Otros	3.003	1,3	50.446.771	8,6
Gran Cliente	79	0,0	45.681.919	7,8
Finiquitado	626	0,3	55.052	0,0
<b>Total</b>	<b>227.433</b>	<b>100</b>	<b>583.795.238</b>	<b>100</b>

Como se puede observar en la Tabla 2.1, los tipos de clientes preponderantes son los residenciales que involucran el 74% de clientes y el 36% de energía, y los consumidores comerciales que representan el 10,3% de clientes y el 24% de energía. El tipo de consumo PEC corresponden a clientes residenciales que se han acogido a los beneficios del Plan de Cocción Eficiente, mediante el uso de cocinas de inducción. Se notará durante el análisis posterior los consumidores PEC presentan una curva de carga residencial con picos característicos en horas de preparación de alimentos.

Una parte esencial del presente trabajo se basa en el estudio de estratificación de clientes elaborado por personal de la unidad de planificación de la CNEL Santo Domingo, en el mencionado estudio se logra identificar grupos característicos de consumidores por estratos y sus límites de energía para los clientes residenciales y comerciales.

La estratificación realizada se basa en el método de K-means, considerando 106.950 clientes en cinco estratos de consumo residencial y 15.382 clientes en cinco grupos de consumo comercial. Las variables utilizadas para el agrupamiento de los clientes son la energía promedio

mensual y la desviación estándar normalizada de los consumos. Los resultados obtenidos de la estratificación son mostrados gráficamente en la Figura 2.3 y la Figura 2.4. Se puede notar el centroide y la disposición de cada uno de los grupos encontrados durante el análisis.

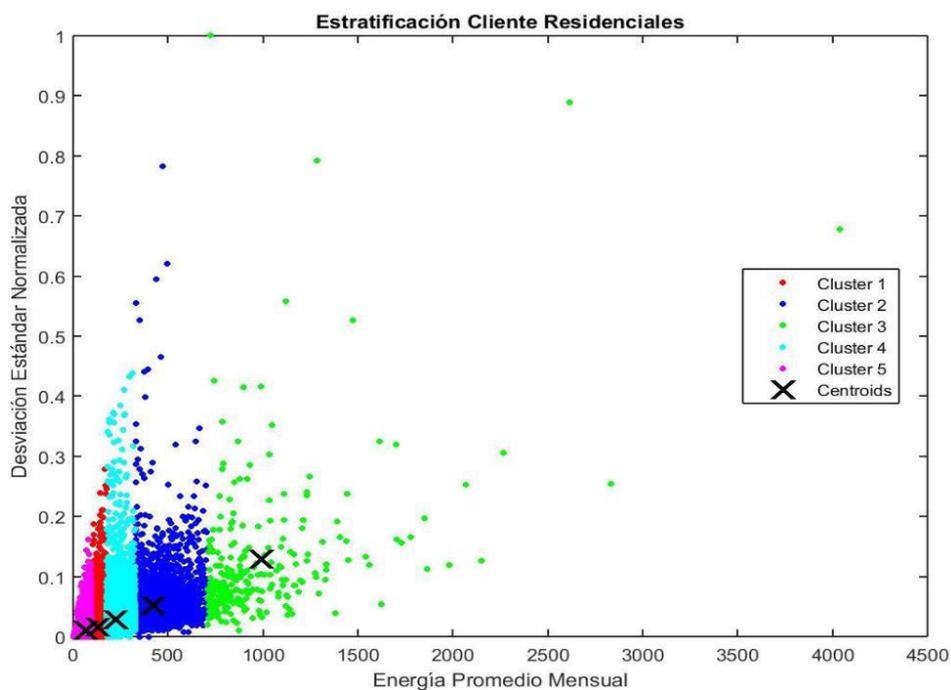


Figura 2.3 Estratificación de clientes residenciales de CNEL Santo Domingo [25].

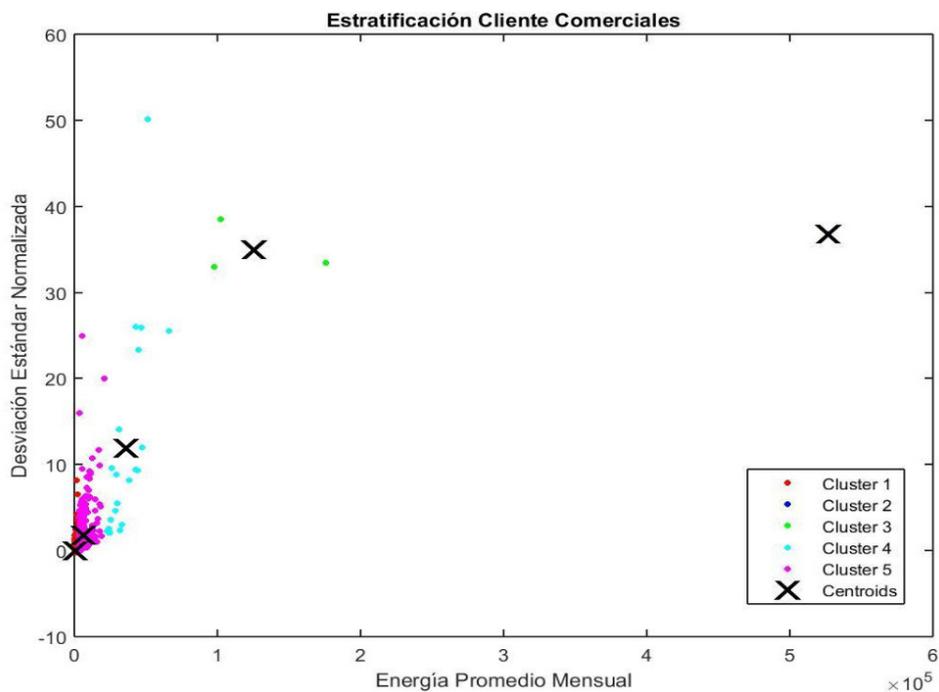


Figura 2.4 Estratificación de clientes comerciales de CNEL Santo Domingo [25].

Adicionalmente los datos obtenidos de la estratificación de los clientes residenciales y comerciales de la CNEL Santo Domingo resultará útil para validar la agrupación de curvas de demanda y para la selección y utilización de las redes neuronales una vez que hayan sido entrenadas adecuadamente.

Como se observa en la Figura 2.5 y Figura 2.6, se determina micro zonas de cobertura de clientes predominantes, de acuerdo a la Tabla 2.2. La zonificación geolocalizada realizada en ARCGIS tomada de [25], permitirá localizar geográficamente los transformadores del presente trabajo, verificar el tipo de cliente predominante en su zona, y comprobar la clase de curvas a la que corresponde.

**Tabla 2.2.** Estratificación de clientes de CNEL Santo Domingo [25].

<b>Clúster Residencial</b>					
<b>Clúster</b>	<b>Promedio kWh</b>	<b>Clientes</b>	<b>Min kWh</b>	<b>Max kWh</b>	<b>Estrato</b>
1	64,57	43450	1,00	95,92	E
2	127,27	45268	95,92	177,29	D
3	227,34	14497	177,29	325,79	C
4	424,26	3121	325,79	705,42	B
5	988,83	254	705,42	4036,04	A
<b>Clúster Comercial</b>					
1	378,18	15022	1,04	3232,21	Comercial Pequeño
2	6091,96	335	3232,21	20840,71	Comercial Medio
3	36052,48	21	20840,71	66328,71	Gran Comercial

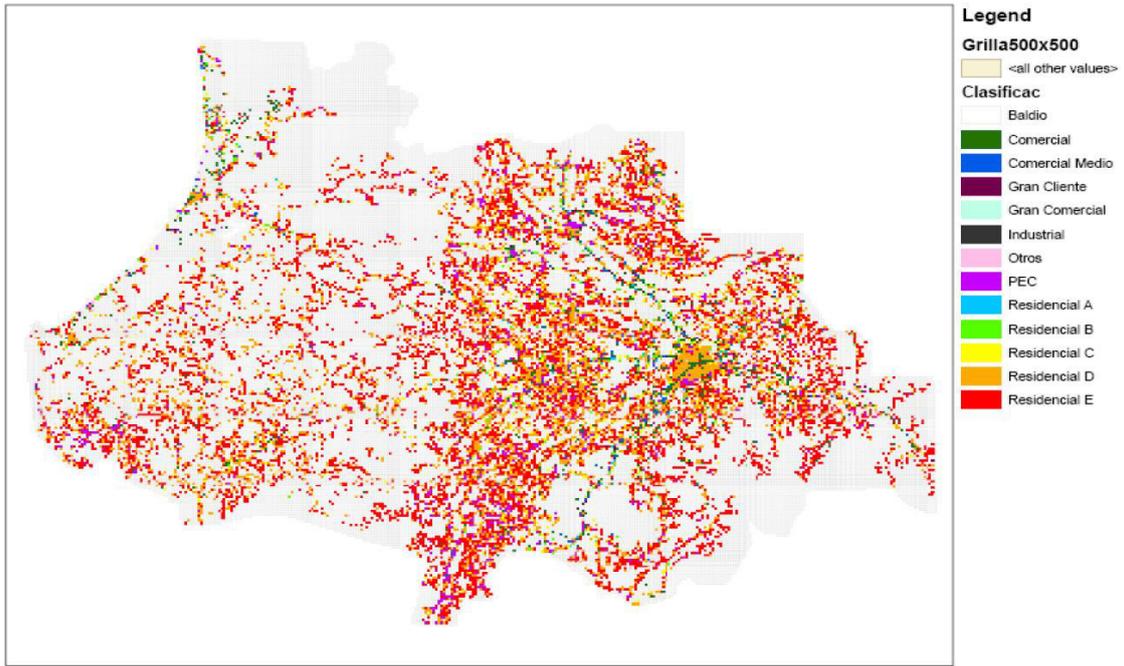


Figura 2.5 Zonificación de clientes de CNEL Santo Domingo [25].

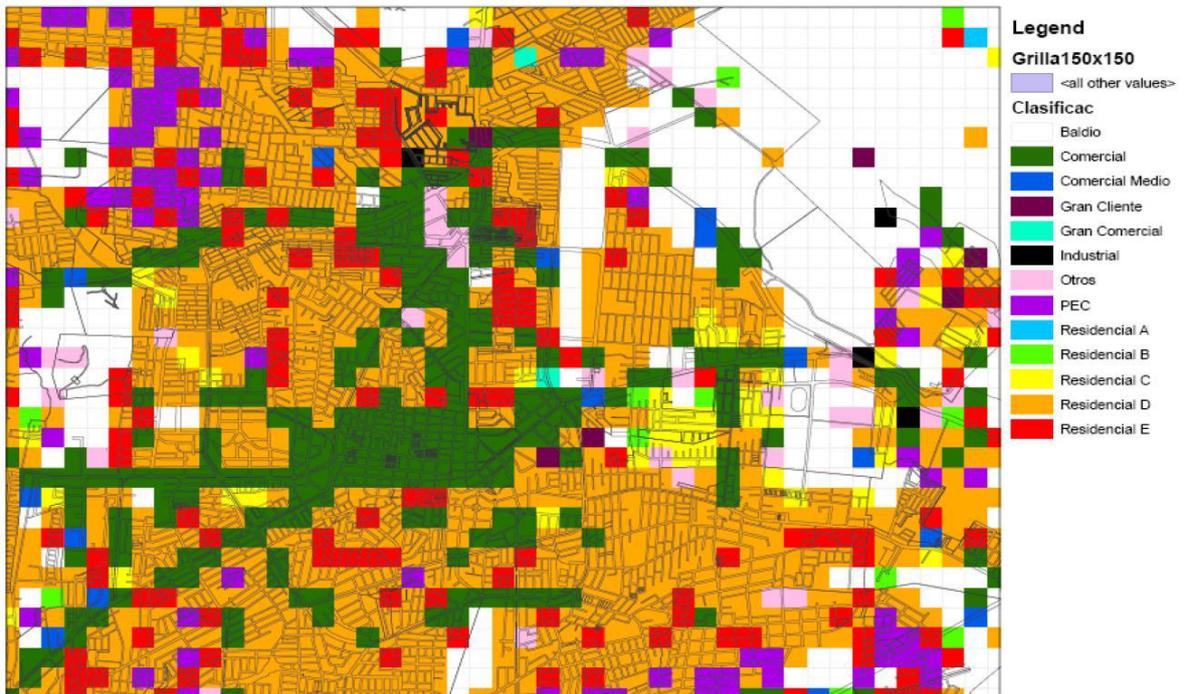


Figura 2.6 Zonificación de clientes de CNEL Santo Domingo [25].

## **2.3. Manejo de Información de base de datos**

La CNEL Santo Domingo al igual que la mayoría de empresas de distribución del país maneja distintas bases de datos: Comercial, Mediciones, Sistema Geográfico, CYMDIST y de planificación. Las mismas se encuentran interrelacionadas de modo que puedan ser utilizadas para los diversos estudios y proyectos que lleva a cabo la empresa.

Para el desarrollo del presente trabajo se ha hecho uso de diversas bases de datos que son explicadas a detalle en los siguientes numerales.

### **2.3.1. Demanda eléctrica de transformadores de distribución**

La información existente en la CNEL Santo Domingo de mediciones tomadas en transformadores de distribución, proviene principalmente de campañas de medición realizadas con fines de aseguramiento de la calidad de energía en las redes secundarias de distribución. Las mediciones utilizadas para el presente trabajo provienen de los años 2017-2019 y fueron obtenidas por medidores programados en intervalos de registro de 10 minutos. Dentro de la información adquirida están voltajes, corrientes, potencia activa y reactiva, energía y factor de potencia trifásico.

La Figura 2.7 muestra un ejemplo de datos de demanda recopilados durante 24 horas para un transformador de distribución con intervalos de medición de 10 minutos. Estas curvas serán utilizadas para el entrenamiento de la red neuronal luego de pasar por un procesamiento de datos que se explicará más adelante.

El tamaño de la muestra de los transformadores utilizados para la aplicación de la metodología del presente trabajo no fue seleccionada técnicamente, dada la limitada información disponible. Se trabajó con los datos puestos a disposición por parte de la empresa distribuidora, sin la posibilidad de sustentar estadísticamente las muestras utilizadas. Únicamente se validó los resultados dentro del conjunto de transformadores de los que se tenía información, sin analizar si la muestra de los mismos, representa al universo de transformadores de la empresa. Si se manejara un escenario ideal, los datos para el estudio deberían provenir de una campaña de medición independiente, que considere criterios de muestreo estadístico para la obtención de datos con suficiente calidad y cantidad para el correcto entrenamiento de la red neuronal.

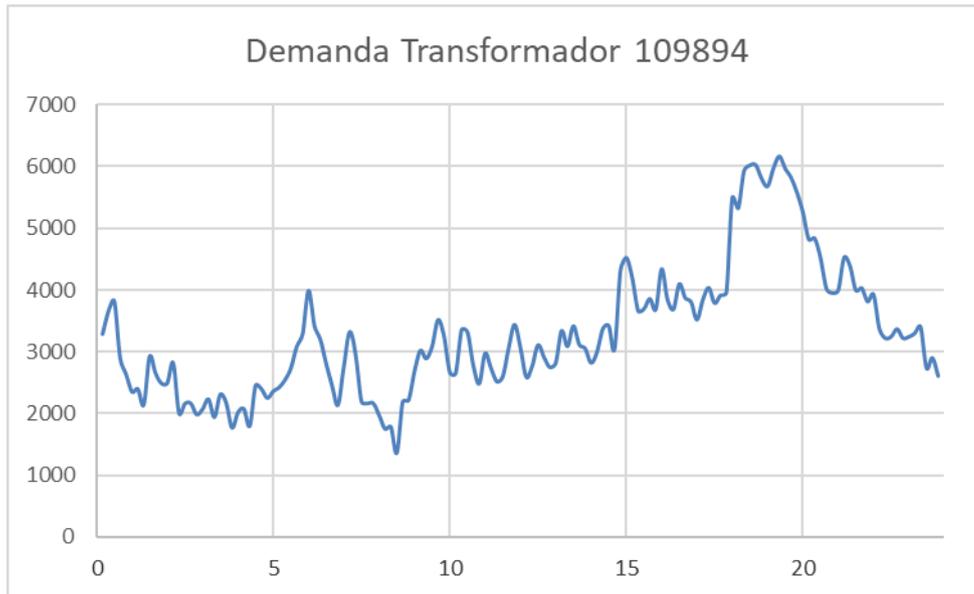


Figura 2.7 Demanda diaria transformador 109894 [Elaboración Propia].

### 2.3.2. Información topológica de redes primarias

La información topológica de las redes primarias se obtiene del software utilizado para el análisis técnico denominado CYMDIST, esta información es actualizada constantemente y tiene una interfaz de migración de datos con el software de información geográfica ARCGIS, de modo que los análisis que llevaremos a cabo tendrán sustento del sistema georreferenciado de la empresa. El software CYMDIST permite tener una vista geográfica y esquemática del sistema eléctrico de la empresa, como se observa en la Figura 2.8.

Esta información topológica se utilizará para la comprobación de las mediciones totalizadoras del alimentador de prueba, en donde se comparará con las estimaciones de los transformadores de distribución utilizando las redes neuronales entrenadas para este propósito.

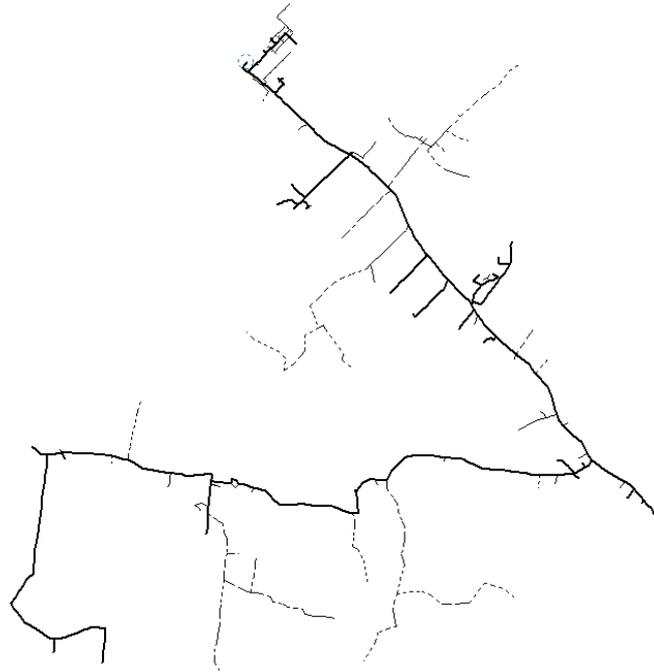


Figura 2.8 Alimentador 17CO030T15 [Elaboración Propia].

### **2.3.3. Bases de Información Comercial**

La base de datos comercial facilitada por CNEL Santo Domingo detalla a nivel de transformador y cliente, los consumos promedios y del último mes de todos los clientes registrados. Cada cliente se encuentra identificado de acuerdo a su tipo (residencial, comercial, PEC, industrial, luminarias y otros), y a la fase a la que se encuentran conectados. Los datos contenidos en esta base comercial se encuentran enlazados al sistema georreferenciado de la empresa de modo que cada cliente, transformador, poste o tramo puede ser identificado en ARCGIS o CYMDIST, según sea la necesidad del estudio a realizar. Un extracto de la base comercial se puede observar en la Figura 2.9.

La información comercial será utilizada en el proceso de entrenamiento de la red neuronal al contener la información clave acerca de la conformación de los transformadores por clientes, que constituye sus entradas. La base comercial utilizada durante el proceso de entrenamiento de la red neuronal se puede observar en el Anexo III.

PROMEDIOCON	OIDTRAMO	FASETRAMO	TIPORED	CLIENTE	USOENE	ULTCON	CONPRO	TRA_NUMTRAFO	POSTE	ALI_CODIGO
0.5	196224	B	MTA	1059922	RESIDENCIAL	117	75	10052	100290	17PP050T12
0.5	196224	B	MTA	153488	RESIDENCIAL	99	121	10052	100290	17PP050T12
0.5	196224	B	MTA	202464	RESIDENCIAL	114	107	10052	100290	17PP050T12
0.5	196224	B	MTA	153484	RESIDENCIAL	210	233	10052	100290	17PP050T12
0.5	196224	B	MTA	153483	RESIDENCIAL	77	73	10052	100290	17PP050T12
0.5	196224	B	MTA	153479	RESIDENCIAL	75	75	10052	100290	17PP050T12
0.68	214210	B	MTA	32801	RESIDENCIAL	18	21	123623	143689	17AL060T21
0.68	214210	B	MTA	32795	PEC	0	16	123623	143689	17AL060T21
0.68	214210	B	MTA	161982	RESIDENCIAL	123	158	123623	143689	17AL060T21
0.68	214210	B	MTA	255775	RESIDENCIAL	174	177	123623	143689	17AL060T21
0.68	214210	B	MTA	181756	RESIDENCIAL	83	97	123623	143689	17AL060T21
0.68	214210	B	MTA	32787	PEC	113	240	123623	143689	17AL060T21
0.68	214210	B	MTA	33245	RESIDENCIAL	39	43	123623	143689	17AL060T21
0.68	214210	B	MTA	96638	OTROS	80	88	123623	143689	17AL060T21
0.68	214210	B	MTA	1210079	RESIDENCIAL	285	102	123623	143689	17AL060T21
0.68	214210	B	MTA	160322	RESIDENCIAL	59	56	123623	143689	17AL060T21
0.68	214210	B	MTA	1291533	RESIDENCIAL	72	63	123623	143689	17AL060T21
0.68	214210	B	MTA	262451	PEC	131	130	123623	143689	17AL060T21
0.68	214210	B	MTA	1404326	RESIDENCIAL	202	0	123623	143689	17AL060T21
0.68	214210	B	MTA	96607	RESIDENCIAL	61	107	123623	143689	17AL060T21

Figura 2.9 Base de datos comercial por cliente [Elaboración Propia].

## 2.4. Procesamiento de datos

Previo a la creación y entrenamiento de las redes neuronales, se ha realizado un procesamiento de los datos recibidos por la empresa distribuidora. La gran cantidad de datos recabados han hecho que surjan diversos inconvenientes como valores nulos, valores inconsistentes o ruido en las mediciones, esto obliga a realizar una limpieza en los datos de entrada, que se ha realizado de aplicando técnicas de Minería de datos. De la misma forma se ha realizado procesos de integración y transformación de datos, con el objetivo de obtener los mejores resultados al final del entrenamiento.

### 2.4.1. Curvas de demandas de transformadores

Los datos proporcionados por CNEL Santo Domingo corresponden a mediciones realizadas en secundarios de transformadores de distribución, correspondientes a una semana y con intervalos de medición de 10 minutos. Para el desarrollo del presente trabajo se requirió únicamente los valores de demanda, por tanto, el resto de mediciones se tomará únicamente como referencia si en el caso existieran valores nulos o inconsistentes.

Una vez que se han importado los datos en Matlab, los mismos son analizados en matrices alfanuméricas. Se forma la matriz de fechas en forma de texto y los datos de energía forman una matriz numérica independiente. La matriz de demandas es tridimensional como se puede observar en la Figura 2.10.

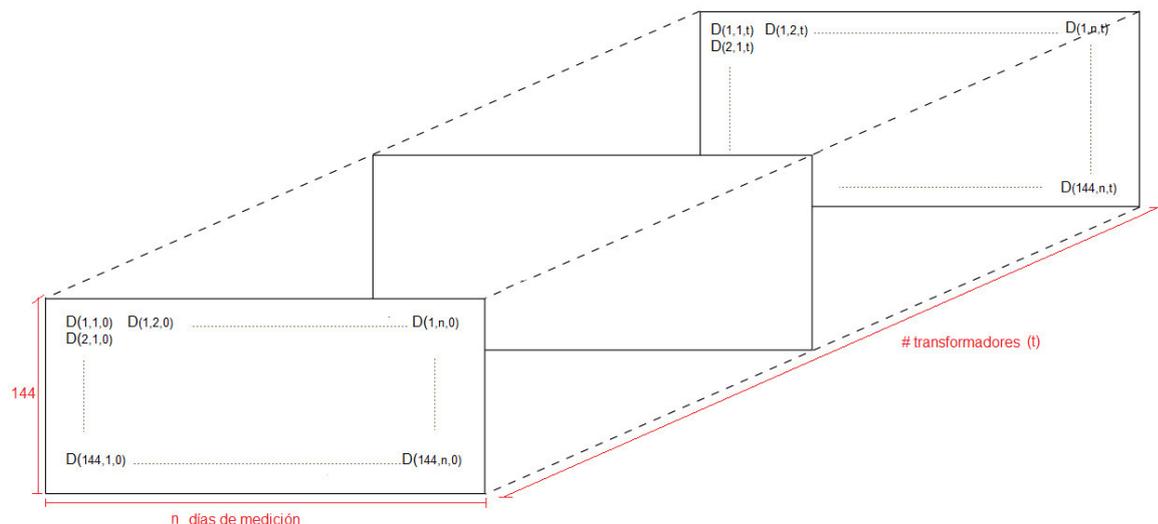


Figura 2.10 Estructura de matriz de demandas de transformadores [Elaboración Propia].

Las dimensiones de la matriz de demandas corresponden al número de datos por día (6x24), los días de medición (6) y el número de transformadores de la muestra. Debido a que en algunos transformadores no se dispone de datos para los 7 días completos, se decidió trabajar únicamente con 6 días a la semana.

#### 2.4.1.1. Limpieza y validación de datos

Los datos para el desarrollo del presente trabajo fueron recolectados por analizadores de redes digitales que muchas veces presentan errores en las mediciones, razón por la cual se realiza una limpieza de datos previo a su utilización. Los errores de medición pueden aparecer en dos formas principales: datos faltantes y atípicos.

Se planteó distintas soluciones para los errores de lectura: en primera instancia al tener redundancia en los datos de energía se procede a reemplazar la información errónea con los cálculos de demanda a partir de la energía medida, si el recurso anteriormente mencionado no resulta útil se plantea el uso de la técnica de imputación por regresión.

El procedimiento propuesto para la corrección de errores en las bases de datos es el siguiente:

- Identificar los datos atípicos o erróneos de acuerdo a lo citado en el apartado 1.5.
- Si en la fecha y hora identificadas se cuenta con medición confiable de energía, se procede a calcular la demanda a partir de la misma como se puede observar en las Tablas 2.3 y 2.4.

- Si no se dispone de datos confiables de energía se procede a realizar una imputación por regresión para los datos faltantes, a partir del entorno de datos cercanos a él o los valores erróneos.

Tabla 2.3. Datos erróneos de potencia del transformador 116314

Fecha	Hora	Tensiór	Tensid	Corriente	Corriente	Frecuenc	PT (W)	S1 (VA)	S2 (VA)	ST (VA)	PT (Wh)
							Poten	Appar	Appar	Appar	Wh
3/2/2017	11:40:00	116.4	116.25	16.992	21.68	60.01	6993.36	3178.02	3972.53	7309.45	1165.56
3/2/2017	14:40:00	115.85	115.75	24.609	28.008	60.006	9854.27	4608.13	5243.74	10010.8	26807.9
3/2/2017	14:50:00	115.45	115.3	24.727	28.477	60.014	9854.27	4608.13	5402.64	10169.7	28397.3
3/2/2017	15:00:00	115.55	115.45	24.492	28.242	60.025	9854.27	4608.13	5243.74	10010.8	29986.7
3/2/2017	15:10:00	114.85	114.75	22.383	26.25	60.009	8900.64	4131.43	4925.93	9216.26	31470.1
3/2/2017	15:20:00	115.6	115.45	21.563	25.664	60.014	8582.76	3972.53	4767.03	8898.46	32900.6
3/2/2017	15:30:00	116.2	116.1	21.68	26.25	60.018	8900.64	4131.43	4925.93	9216.26	34331
3/2/2017	15:40:00	116.45	116.3	25.313	31.875	60.01	0	4767.03	6038.24	10964.2	36079.4
3/2/2017	15:50:00	116.6	116.5	25.195	30.938	60.023	0	4767.03	5879.34	10646.4	37774.7
3/2/2017	16:00:00	117.8	117.65	25.781	35.156	60.009	0	4925.93	6832.75	11758.7	39682
3/2/2017	16:10:00	117.95	117.75	23.672	35.625	60.011	0	4608.13	6832.75	11440.9	41536.3
3/2/2017	16:20:00	118	117.8	21.68	33.281	60.015	0	4131.43	6356.04	10646.4	43178.7
3/2/2017	16:30:00	118.25	118.05	21.211	31.641	60.019	0	4131.43	6038.24	10328.6	44768.1
3/2/2017	16:40:00	118.85	118.65	18.867	27.188	60.015	8582.76	3654.73	5243.74	8898.46	46198.5

Tabla 2.4. Datos corregidos de potencia del transformador 116314

Fecha	Hora	Tensiór	Tensid	Corriente	Corriente	Frecuenc	PT (W)	S1 (VA)	S2 (VA)	ST (VA)	PT (Wh)
							Poten	Appar	Appar	Appar	Wh
3/2/2017	11:40:00	116.4	116.25	16.992	21.68	60.01	6993.36	3178.02	3972.53	7309.45	1165.56
3/2/2017	14:40:00	115.85	115.75	24.609	28.008	60.006	9854.27	4608.13	5243.74	10010.8	26807.9
3/2/2017	14:50:00	115.45	115.3	24.727	28.477	60.014	9854.27	4608.13	5402.64	10169.7	28397.3
3/2/2017	15:00:00	115.55	115.45	24.492	28.242	60.025	9854.27	4608.13	5243.74	10010.8	29986.7
3/2/2017	15:10:00	114.85	114.75	22.383	26.25	60.009	8900.64	4131.43	4925.93	9216.26	31470.1
3/2/2017	15:20:00	115.6	115.45	21.563	25.664	60.014	8582.76	3972.53	4767.03	8898.46	32900.6
3/2/2017	15:30:00	116.2	116.1	21.68	26.25	60.018	8900.64	4131.43	4925.93	9216.26	34331
3/2/2017	15:40:00	116.45	116.3	25.313	31.875	60.01	10489.8	4767.03	6038.24	10964.2	36079.4
3/2/2017	15:50:00	116.6	116.5	25.195	30.938	60.023	10172	4767.03	5879.34	10646.4	37774.7
3/2/2017	16:00:00	117.8	117.65	25.781	35.156	60.009	11443.4	4925.93	6832.75	11758.7	39682
3/2/2017	16:10:00	117.95	117.75	23.672	35.625	60.011	11125.6	4608.13	6832.75	11440.9	41536.3
3/2/2017	16:20:00	118	117.8	21.68	33.281	60.015	9854.08	4131.43	6356.04	10646.4	43178.7
3/2/2017	16:30:00	118.25	118.05	21.211	31.641	60.019	9536.2	4131.43	6038.24	10328.6	44768.1
3/2/2017	16:40:00	118.85	118.65	18.867	27.188	60.015	8582.76	3654.73	5243.74	8898.46	46198.5

Al ser ocasionales las mediciones que se realizan a nivel de transformadores de distribución, no es posible validarlas con datos históricos o con mediciones redundantes. Es por ello que en función de los datos que se posee y los objetivos que se pretende alcanzar, se ha realizado un tratamiento adicional a los datos que se detalla a continuación.

Se poseen datos con intervalos de medición de 10 minutos, sin embargo, el objetivo es lograr una estimación horaria, por tanto, se realiza un proceso de agregación de datos para convertir los datos de 10 minutos a horarios, sin comprometer la validez de los resultados y en lo posible evitar la pérdida de datos innecesariamente, a esta nueva demanda horaria calculada denominamos demanda agregada.

Al trabajar con Demandas agregadas, se conserva invariable el área de las curvas, es decir, los datos de energía de las mediciones. Esta forma de procesamiento resulta beneficiosa para los estudios de planificación, en los que CNEL Santo Domingo pretende ocupar las estimaciones de las curvas de los transformadores. En la Figura 2.11 se puede observar las curvas de demanda medida y agregada, siendo la segunda en mención la que se utilizará para el desarrollo del presente trabajo.

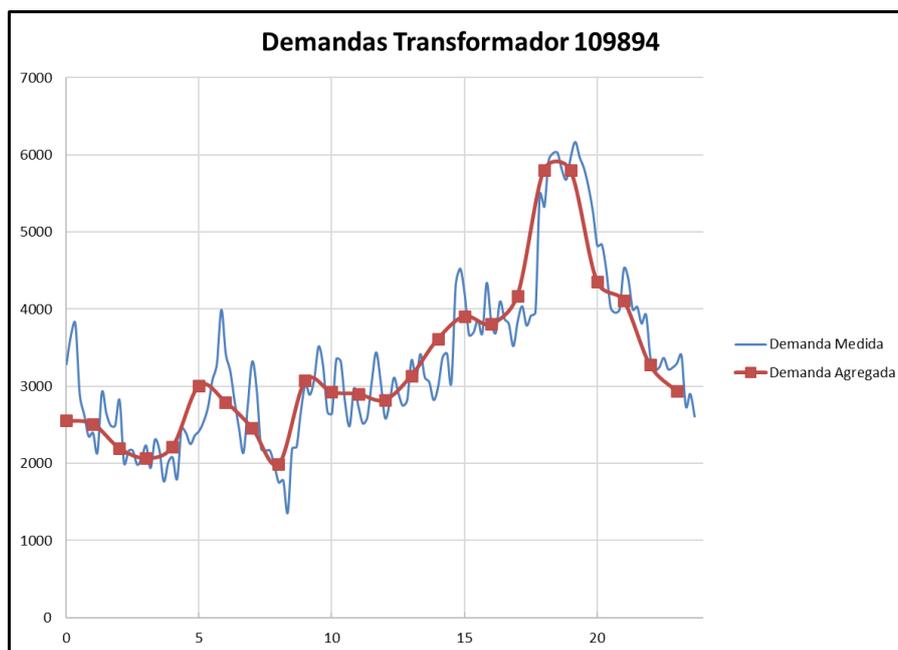


Figura 2.11 Demanda medida y agregada del transformador 109894 [Elaboración Propia].

Como otro mecanismo alternativo de validación y atenuación de valores atípicos se trabajará con curvas promedio semanales, eso quiere decir que se obtendrá una curva promedio característica para los días entre semana y una curva para los días fines de semana y feriados.

Como se puede observar en la Figura 2.12, las curvas de un transformador varían poco en su forma dependiendo del día de la semana, sin embargo, se encuentran diferencias de amplitud principalmente marcada en las horas pico. En la Figura 2.13 se encuentran las curvas promedio que se obtuvo del mismo transformador, una para días entre semana y otra para días del fin de semana. Esta reducción del número de curvas simplifica el proceso de agrupamiento y entrenamiento de las redes neuronales sin afectar significativamente a los objetivos de planificación de la empresa distribuidora.

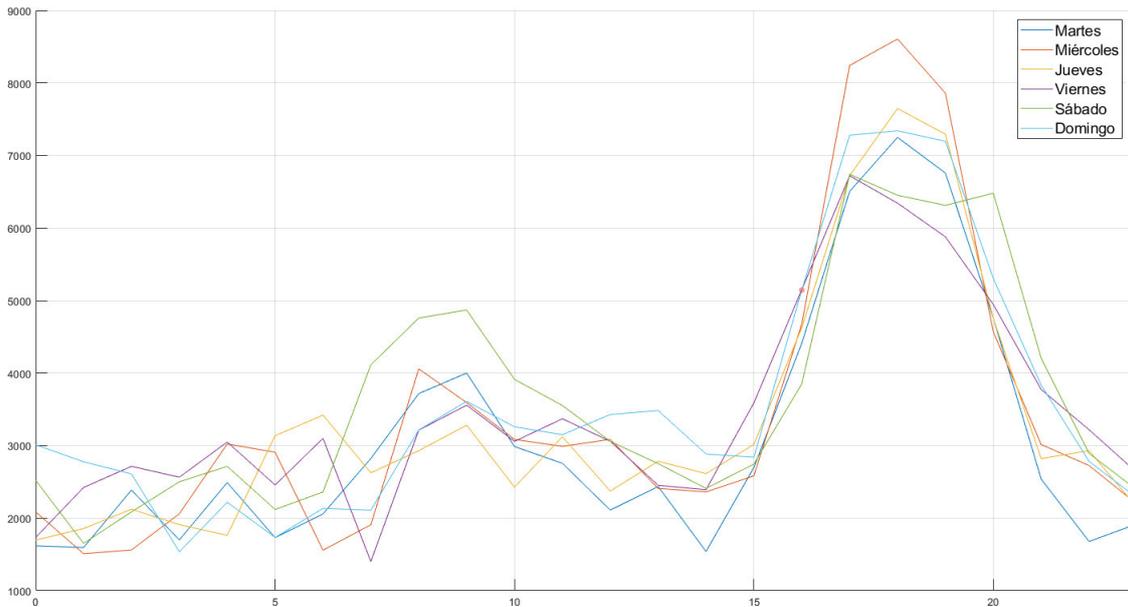


Figura 2.12 Curvas de demanda diaria del transformador 130357 [Elaboración Propia].

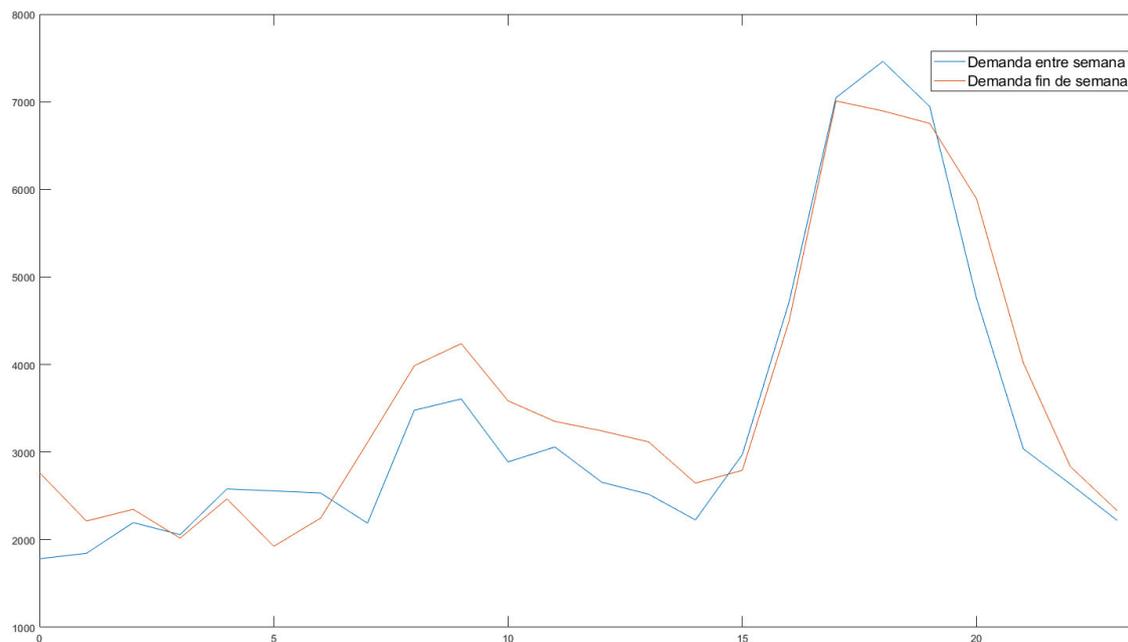


Figura 2.13 Curvas promedio calculadas del transformador 130357 [Elaboración Propia].

#### 2.4.1.2. Normalización de datos

El proceso de normalización de datos es necesario llevarlo a cabo, con el fin de estandarizar los datos para que pueda llevarse a cabo el agrupamiento o clustering de las curvas de demanda. Es importante mencionar que, el agrupamiento permite analizar el comportamiento de la curva independientemente del nivel de consumo de los transformadores, pudiendo de esta manera comparar transformadores de distinta capacidad sin problema.

Para la utilización de redes neuronales artificiales, es recomendable normalizar los datos de entrada y salida para mejorar y volver más eficiente el entrenamiento.

Generalmente, el proceso de normalización se aplica tanto a los vectores de entrada como a los vectores de salida. De esta manera, los resultados de la red neuronal siempre caen en un rango normalizado. Al final del entrenamiento, la salida de la red se puede transformar inversamente a las unidades de los datos de destino originales, de acuerdo con el esquema de la Figura 2.14 [22].

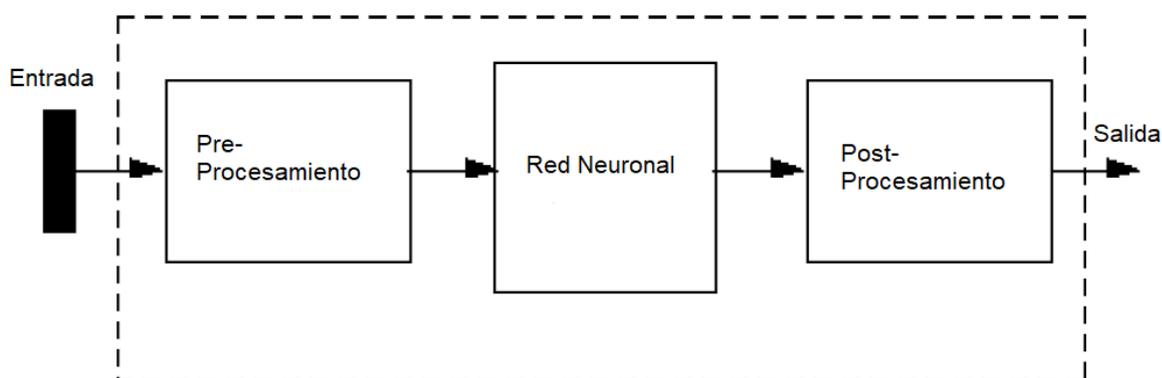


Figura 2.14 Procesamiento de datos para el entrenamiento de RNA [22].

Se lleva a cabo en las curvas de demanda eléctrica, un proceso de normalización mediante la técnica de escalado de variables con el objetivo de estandarizar sus valores entre 0 y 1. En la Figura 2.15 se puede apreciar la curva promedio del transformador de la Figura 2.13 después de pasar por el proceso de normalización.

Después del proceso de normalización, se puede llevar a cabo correctamente la agrupación por clases y su posterior utilización para el entrenamiento de redes neuronales artificiales.

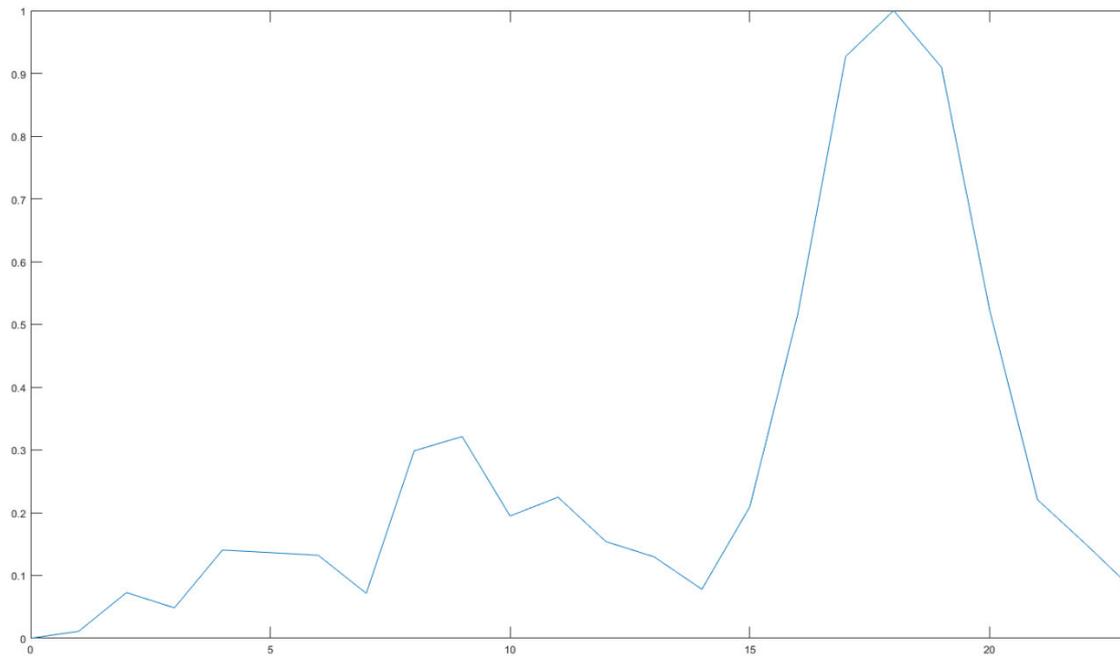


Figura 2.15 Curva promedio normalizada para días entre semana transformador 130357 [Elaboración Propia].

Se realiza el mismo procedimiento de normalización a los datos de consumo de los clientes de los transformadores, que constituirán las entradas de la red neuronal.

### 2.4.2. Análisis para el agrupamiento de curvas

El entrenamiento de redes neuronales tiene como objetivo la identificación de patrones, en el caso del presente trabajo, de la demanda horaria de un grupo de clientes correspondientes a un transformador de distribución. Para que la identificación de dicho patrón se realice de una manera eficiente y las redes neuronales durante su utilización, entreguen resultados con un alto índice de confiabilidad, se ha visto la necesidad de entrenar un grupo de redes neuronales, cada una correspondería a una composición típica de clientes.

Esta búsqueda de los grupos de composiciones típicas de clientes se realiza a partir del análisis de grupos o clustering, tratando de encontrar formas de curvas semejantes y agrupándolas. Esto a su vez debe ser validado con la composición de los clientes de los transformadores a partir de la base comercial de la empresa.

Considerando que:  $l = \{l_h, h = 1, \dots, H\}$  es el conjunto de datos de una curva de demanda y que:  $L = \{l^{(m)}, m = 1, \dots, M\}$  es el conjunto de curvas de un grupo de transformadores.

Teniendo como base que para aplicar el algoritmo de k-medias se debe conocer el número de clases “K”, se puede detallar el procedimiento a seguir:

Se llevará a cabo el proceso de asignación de cada curva de transformador a una clase característica, es decir, se pasará de tener M curvas iniciales, dividiéndolas en K clases correspondientes a un número de grupos  $L^{(k)} \subset L$ . Cada clase contiene  $n^{(k)}$  curvas para  $k = 1, \dots, K$  y cada transformador es asignado única y exclusivamente a una clase.

Para la programación del algoritmo de k-medias aparece el concepto de centroide, que en el caso del presente trabajo se tratará de curvas representativas de cada clase. Para cada una de las clases, la curva representativa  $r^{(k)}$  se obtiene mediante un proceso de promediar todas las curvas  $L^{(k)}$  correspondientes a la clase en cuestión. Como resultado de este proceso de cálculo de los centroides o curvas características se obtiene un grupo de curvas características:  $R = \{r^{(k)}, k = 1, \dots, K\}$  [23].

Las siguientes medidas serán utilizadas para la implementación del algoritmo de k-medias [24]:

- a) La distancia entre dos curvas  $l^{(i)}, l^{(j)}$  de la clase L.

$$d(l^{(i)}, l^{(j)}) = \sqrt{\frac{1}{H} \sum_{h=1}^H (l^{(i)} - l^{(j)})^2}$$

Ecuación 2.1. Ecuación para el cálculo de distancia entre curvas

- b) La distancia entre una curva representativa de una clase  $r^{(k)}$  y la clase  $L^{(k)}$ , la misma que es definida como la media geométrica de las distancias entre  $r^{(k)}$  y cada miembro de  $L^{(k)}$ .

$$d(r^{(k)}, L^{(k)}) = \sqrt{\frac{1}{n^{(k)}} \sum_{m=1}^{n^{(k)}} d^2(r^{(k)}, l^{(m)})}$$

Ecuación 2.2. Ecuación de distancia entre curva característica y una clase

- c) El promedio geométrico de las distancias de los M miembros del grupo L.

$$\hat{d}(L) = \sqrt{\frac{1}{2M} \sum_{m=1}^M d^2(l^{(m)}, L)}$$

Ecuación 2.3. Ecuación de distancias promedios para un grupo de curvas

### 2.4.2.1. Índices de desempeño

Para la implementación del algoritmo de k-medias se tienen que asumir algunos aspectos que afectan el funcionamiento del algoritmo y los resultados obtenidos. Es por ello que se requiere definir ciertos índices que indiquen numéricamente el desempeño del algoritmo, tomando en cuenta sus factores de incidencia.

Existen dos factores principales que serán analizados mediante los índices de desempeño:

- El número “k” de clases para el agrupamiento
- Los centroides o curvas representativas iniciales

Técnicamente los índices de desempeño mostrarán que tan bien separadas estén las clases (curvas características diferentes para cada clase) y que tan compactas sean (cada curva de una clase debe parecerse a su curva característica).

Se plantean la utilización de dos índices de desempeño:

a) Índice promedio de adecuación (MIA)

$$MIA = \sqrt{\frac{1}{K} \sum_{k=1}^K d^2(r^{(k)}, L^{(k)})}$$

Ecuación 2.4. Ecuación del Índice promedio de adecuación

b) Índice de dispersión de agrupamiento (CDI)

$$CDI = \frac{1}{\hat{d}(R)} \sqrt{\frac{1}{K} \sum_{m=1}^M \hat{d}^2(L^{(k)})}$$

Ecuación 2.5. Ecuación del Índice de dispersión de agrupamiento

A partir de estos índices se puede concluir que los agrupamientos con menores valores de MIA y CDI tendrán mejores propiedades discriminantes.

## **2.5. Creación y entrenamiento de las Redes Neuronales**

El proceso de diseño y utilización de una red neuronal debe cumplir todos y cada uno de los siguientes pasos:

- Recolección y tratamiento de datos
- Creación de la red neuronal
- Configuración de la red neuronal
- Inicialización de pesos sinápticos y umbrales
- Entrenamiento de la red neuronal
- Validación de la red neuronal
- Prueba de la red neuronal
- Utilización de la red neuronal

Una vez que los datos han pasado por la etapa de verificación y procesamiento, se los puede utilizar en la creación, entrenamiento y validación de las redes neuronales cuya metodología se ampliará a continuación.

Normalmente se debe realizar un proceso previo de división de los datos en 3 subgrupos: entrenamiento, validación y prueba. Esta división debe ser realizada correctamente para lograr una adecuada generalización de las neuronas. Es por ello que se utilizan funciones específicas de Matlab para dividir los datos aleatoriamente en los 3 grupos, según la proporción recomendada: 70% de los datos para entrenamiento, 15% para validación y 15% para prueba.

La metodología desarrollada en el presente trabajo plantea la creación, entrenamiento y utilización de varias redes neuronales, de acuerdo al número de agrupamientos encontrados en el clustering. Esto significa que para cada clase se contará con una red neuronal entrenada con datos de transformadores correspondientes a la misma, en tal virtud, primero se determinará el número de clases de transformadores, la composición de cada una de las clases, y luego se asignará los datos de entrenamiento a cada red neuronal.

La arquitectura para la creación de las redes neuronales planteadas consta de 3 capas como se puede observar en la Figura 2.16, una capa de entrada, una capa oculta y una capa de salida.

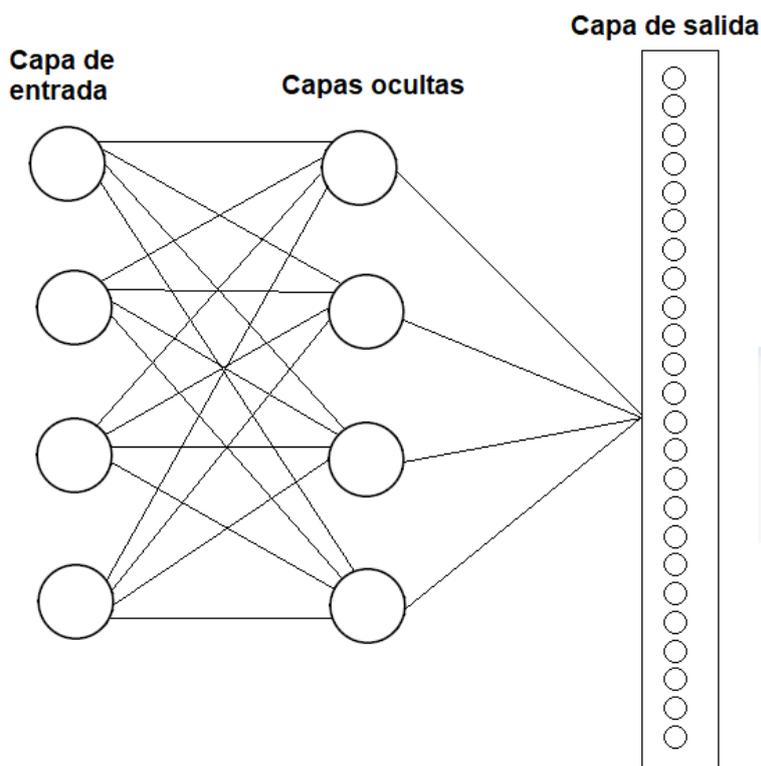


Figura 2.16 Estructura de la red neuronal planteada [Elaboración Propia].

Como se observa en la Figura 2.16, en un principio la red neuronal planteada cuenta con cuatro entradas normalizadas de los porcentajes de consumo residencial, comercial, PEC y alumbrado público de los transformadores bajo análisis. El número de capas ocultas y de neuronas en cada una de ellas, se determinará de acuerdo al comportamiento de la red y buscando obtener los mejores resultados por parte del programador. La capa de salida tendrá 24 neuronas que se convertirán en las 24 salidas correspondientes a los datos de demanda horaria, los datos de salida representan la estimación de la curva de demanda deseada.

Las capas ocultas tendrán un número variable de neuronas, las mismas se determinarán mediante un proceso de ensayo y error en cada entrenamiento. Su número debe ser el suficiente para poder aproximar las discontinuidades del problema. Si el problema lo requiere, se debe ir aumentando progresivamente el número de neuronas y capas, si por el contrario se coloca un número exagerado de neuronas o capas, se incurriría en un sobre entrenamiento de

la red (o “overfitting”), que afectará sus capacidades de generalización. Por otro lado, si el número de neuronas en la capa oculta o el número de capas ocultas se queda corto, se produce el fenómeno denominado como “underfitting”, es decir que la red neuronal no es capaz de aprender.

Una forma de estimar el número de neuronas necesarias en la capa oculta de una red neuronal es mediante la Ecuación 2.6.

$$h = \sqrt{i \cdot o}$$

Ecuación 2.6. Ecuación del número de neuronas en una capa oculta

En donde:

$h$ : representa las neuronas de la capa oculta,

$i$ : el número de neuronas de la capa de entrada

$o$ : el número de neuronas de la capa de salida

Es importante mencionar que la ecuación 2.6, si bien nos da una aproximación del número de neuronas que va a necesitar la capa oculta, el valor final dependerá del análisis de la respuesta de la red, mediante un proceso de prueba y error; es decir que, si no se obtiene buenos resultados, se puede ir aumentando el número de neuronas en la capa oculta incluso hasta llegar a añadir una segunda capa oculta.

En el presente trabajo se encontró que, para la resolución del problema se necesita de una sola capa oculta y que las funciones de activación sean de naturaleza rectificadora y lineal respectivamente para la capa oculta y de salida.

La velocidad de aprendizaje o factor “ $\alpha$ ” utilizado, será el valor típico de 0.1, esto tendrá directa incidencia en los resultados del algoritmo de aprendizaje con el método de descenso por gradiente. La función para evaluar el desempeño de aprendizaje mediante el algoritmo de retropropagación es el error medio cuadrático calculado entre las salidas de la red ( $t$ ) y las salidas deseadas o los valores reales de las demandas ( $a$ ), de acuerdo a la Ecuación 2.7.

$$E = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2$$

Ecuación 2.7. Ecuación de desempeño del entrenamiento

Una vez se hayan inicializado los pesos y umbrales, la red está lista para el entrenamiento que se realizará mediante el algoritmo de retropropagación detallado en 1.5.1.6. Este algoritmo fue escogido porque presenta un buen funcionamiento en redes multicapa con una capa oculta con una adecuada rapidez de procesamiento.

Durante la etapa de entrenamiento, al tratarse de un procedimiento de optimización basado en el método de Levenberg-Marquardt, se deben determinar los criterios de parada, los cuales se presentan en la tabla 2.5.

Tabla 2.5. Criterios de parada para entrenamiento de la red neuronal

<b>Criterio de Parada</b>	<b>Valores estándar utilizados</b>
Valor mínimo de Gradiente	$1e^{-7}$
Valor máximo de incremento de validación	$1e^{10}$
Tiempo máximo de procesamiento	15 minutos
Número máximo de épocas	100

La validación del aprendizaje de las redes neuronales se considera un procedimiento muy importante en el presente proyecto, es por ello que se la realiza 3 validaciones a distintos niveles. Se llevará a cabo una validación intrínseca al entrenamiento de la red, una validación externa y finalmente la validación de resultados en un alimentador real. La validación intrínseca es realizada internamente en la herramienta de Redes Neuronales de Matlab, posterior a un proceso de división de datos que se mencionará más adelante. La validación externa se basa en utilizar en la red neuronal, datos de entrada que no hayan sido utilizados durante el proceso de entrenamiento. Este procedimiento tiene como objetivo comprobar la respuesta de la red neuronal ante estos datos nuevos que no han sido utilizados durante su aprendizaje. La red neuronal debe tener la suficiente capacidad de generalización como para entregar salidas satisfactorias a datos de entrada que la red nunca ha utilizado en su fase de entrenamiento. Los datos utilizados para la validación externa representan el 50% de los datos disponibles, el restante 50%, se destinará al entrenamiento de las redes.

Para efectuar exitosamente el aprendizaje de la red neuronal se recomienda la separación de tres subgrupos de datos que se pueden obtenerse de manera aleatorias o determinista, dichos subgrupos se explican a continuación:

- El primer subgrupo es el de entrenamiento y se utiliza para realizar el cálculo de gradientes y para proceder con la actualización de los umbrales y pesos sinápticos iterativamente para cada época.
- El segundo subgrupo constituye el destinado a validación mediante el cálculo de errores entre la salida estimada vs la salida deseada, esta etapa se realiza con el objetivo de encontrar los ajustes óptimos de la red bajo entrenamiento, además los datos de validación se utilizan para el cálculo del error de validación que normalmente decrece en la etapa inicial del entrenamiento; sin embargo cuando la red se empieza a sobreentrenar el error de validación comienza a crecer, es por ello que los umbrales y pesos sinápticos son guardados al obtener el valor mínimo de error de validación, es decir se determina con esto un punto de parada para el algoritmo de entrenamiento.
- El tercer subgrupo de datos se denomina de prueba y no se utiliza durante el entrenamiento, ya que el mismo permite estimar la precisión del modelo de red ya entrenado. La aplicación de estos datos a la red neuronal permite conocer su funcionamiento ante información previamente invisible. A pesar de que el error del subgrupo de prueba no se utiliza en el proceso de entrenamiento, si el mismo alcanza el valor mínimo en una iteración significativamente diferente del error del subgrupo de validación, esto podría indicar una división deficiente del conjunto de datos.

Además de la validación intrínseca al entrenamiento de la red, realizada en la herramienta de Matlab, se lleva a cabo una validación externa con nuevos datos diferentes a partir de otros transformadores. Esta validación servirá para determinar el error de correlación o error cuadrático medio entre la curva estimada por la red neuronal y la curva real medida en el transformador, de acuerdo al esquema planteado en la Figura 2.17 y con la utilización de la fórmula de la Ecuación 2.7.

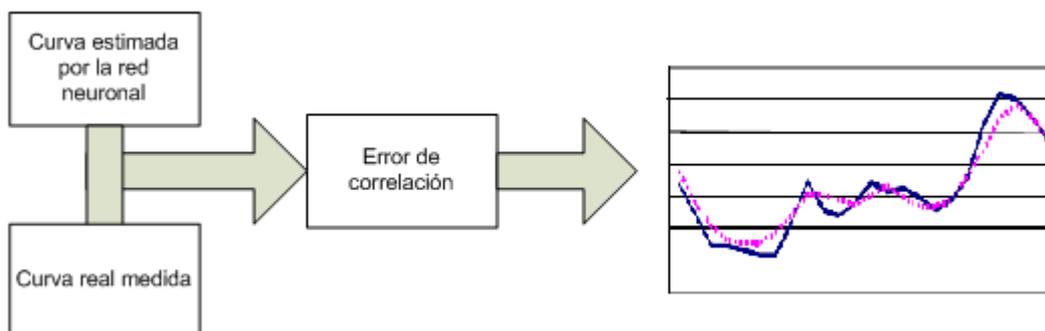


Figura 2.17 Esquema de validación externa de la red neuronal [Elaboración Propia].

### **3. RESULTADOS Y DISCUSIÓN**

#### **3.1. Aplicación de los datos de entrenamiento a la Red Neuronal Artificial**

##### **3.1.1. Análisis de agrupamiento de curvas de demandas**

Como resultado del proceso de agrupamiento de curvas realizado de acuerdo a la metodología detallada en el numeral 2.4.2, se determina el número ideal de clases de curvas. Con este número de clases o grupos se evalúan los resultados de los índices de desempeño (MIA y CDI).

Es preciso mencionar que debido a que algunas curvas no correspondían con ninguna clase, en este punto fue necesario eliminar los datos de varios transformadores, ya que su comportamiento muy posiblemente se vea afectado por consumidores con patrones de consumo inusuales muy difíciles de estimar.

Las clases de curvas que se pueden observar en las Figuras 3.1, 3.2, 3.3, 3.4, 3.5, 3.6, deben corresponder a su composición, de acuerdo al tipo de consumo de sus clientes, esto se puede constatar en la Tabla 3.1.

Como se puede observar en la Figura 3.6, la clase 6 corresponde a curvas típicas de consumidores comerciales nocturnos que geográficamente están ubicados en zonas de bares, discotecas y en general locales de diversión nocturna; sin embargo, se puede notar que dichas curvas, a pesar de estar normalizadas, no comparten una forma y magnitud uniforme, es por ello que se decidió prescindir de esta clase para el análisis futuro, al no tratarse de una clase que se pueda generalizar adecuadamente. Se comprobará posteriormente que la clase 6 tampoco cuenta con un número suficiente de curvas que permitan llevar a cabo el entrenamiento de una red neuronal, y que la misma entregue resultados adecuados.

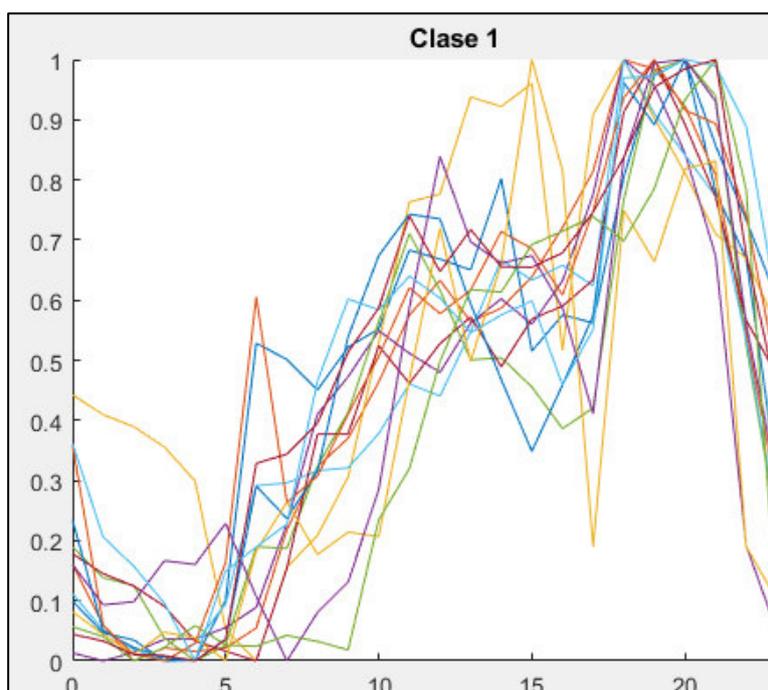


Figura 3.1 Curvas de demanda correspondientes a la Clase 1 [Elaboración Propia].

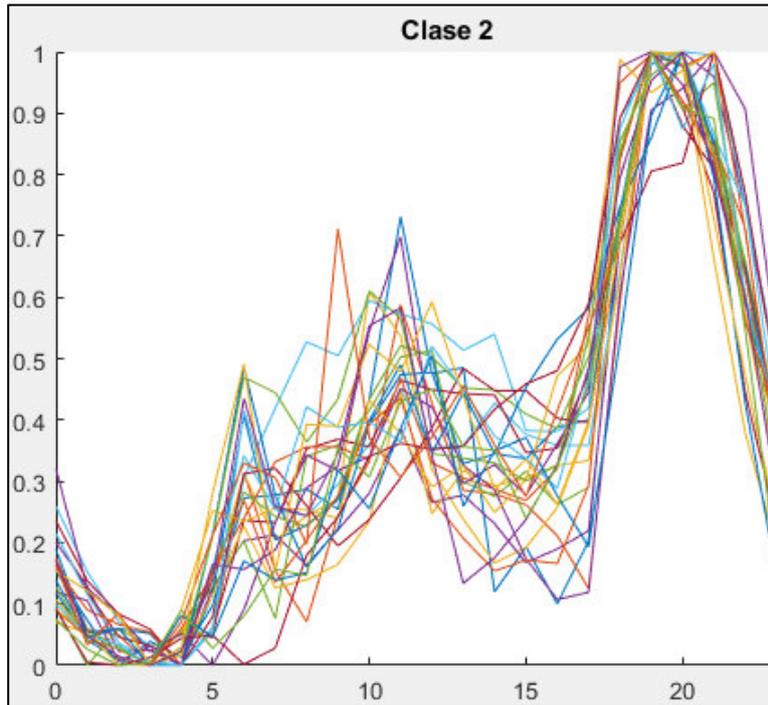


Figura 3.2 Curvas de demanda correspondientes a la Clase 2 [Elaboración Propia].

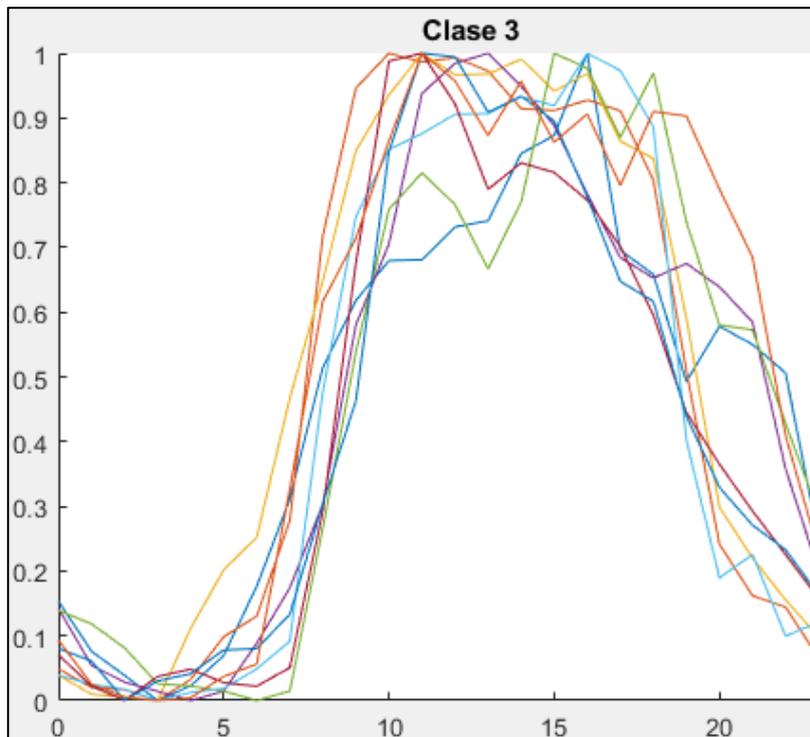


Figura 3.3 Curvas de demanda correspondientes a la Clase 3 [Elaboración Propia].

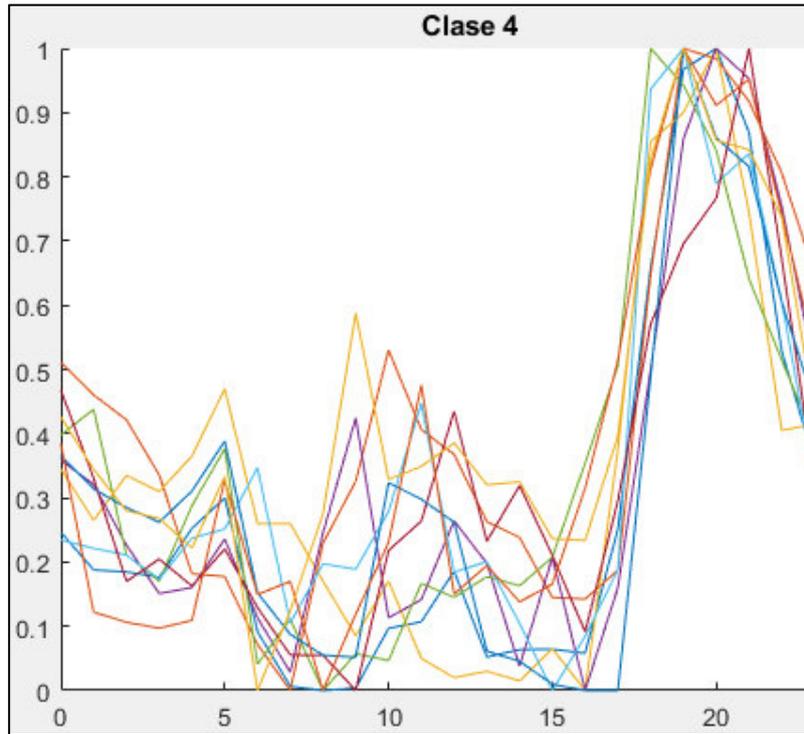


Figura 3.4 Curvas de demanda correspondientes a la Clase 4 [Elaboración Propia].

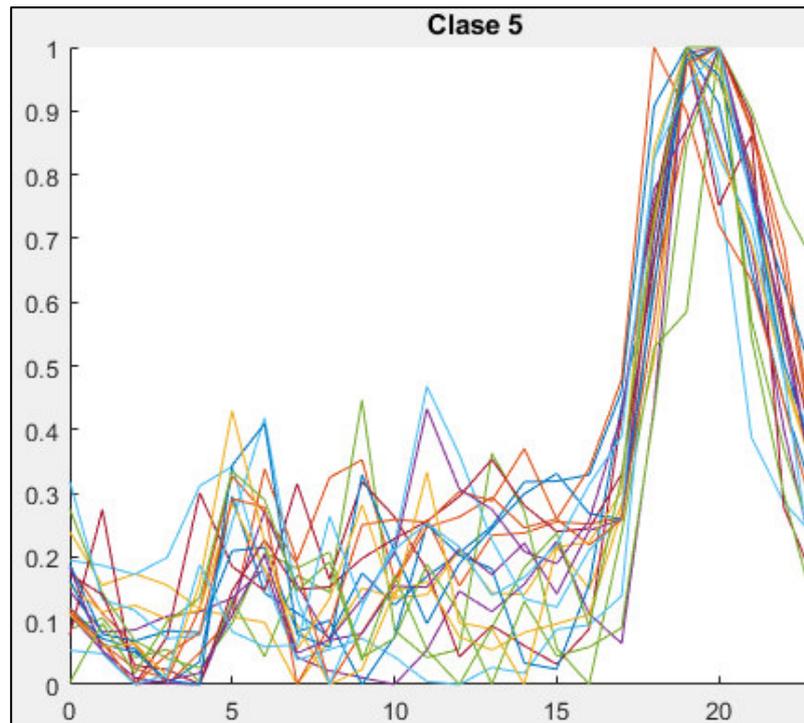


Figura 3.5 Curvas de demanda correspondientes a la Clase 5 [Elaboración Propia].

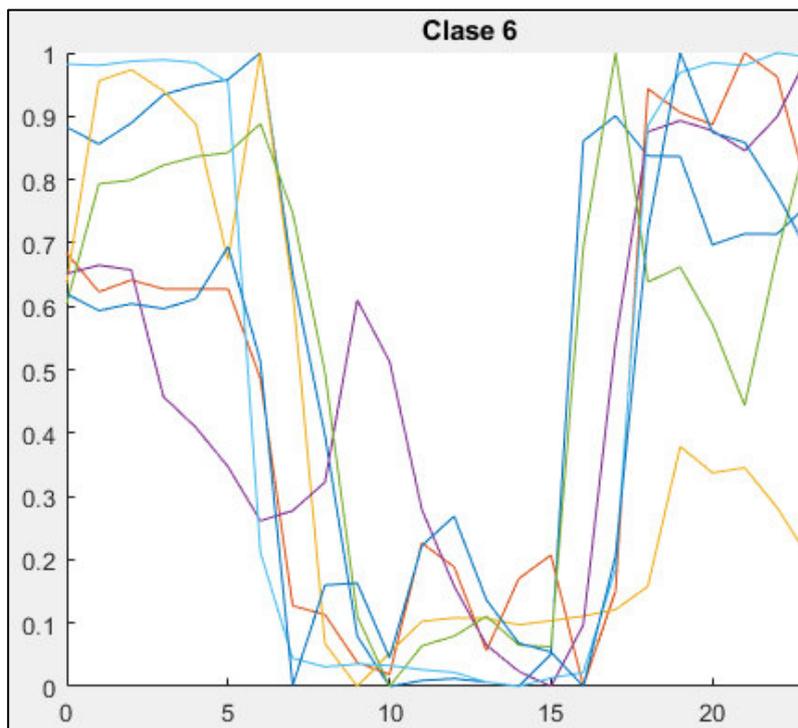


Figura 3.6 Curvas de demanda correspondientes a la Clase 6 [Elaboración Propia].

Como se muestra en las figuras 3.1, 3.2, 3.3, 3.4, 3.5, 3.6, dentro de las clases 1, 2 y 4 se establecen 3 tipos de consumidor comercial: Alto, Medio y Bajo, esto corresponde al nivel de impacto que la sumatoria del consumo promedio mensual comercial representa con respecto a la sumatoria del consumo promedio mensual residencial en cada transformador. Para el nivel comercial alto, el porcentaje comercial representa aproximadamente entre el 60% y el 90% del residencial, para el nivel comercial medio, el porcentaje comercial representa aproximadamente entre el 40% y el 60% del residencial y finalmente para el nivel comercial bajo, el porcentaje comercial representa aproximadamente entre el 20% y el 40% del residencial. Para el caso en el que el nivel de los clientes comerciales se encuentra por debajo del 20% del residencial, se considera que el transformador es netamente residencial.

**Tabla 3.1.** Criterio de composición de clientes para cada clase de agrupamiento

Clase	Composición de clientes
1	Residencial + Comercial Alto+ PEC
2	Residencial + Comercial Medio + PEC
3	Comercial
4	Residencial + Comercial Bajo + PEC
5	Residencial+ PEC

6	Comercial nocturno
---	--------------------

Los resultados de la agrupación de curvas, presentados con anterioridad son utilizados para el entrenamiento de las redes neuronales, esto quiere decir que se crearon 5 redes neuronales, cada una resultará útil de acuerdo a la composición de clientes de cada transformador, esta información se puede obtener a partir de la base comercial de la empresa distribuidora.

De la misma manera, una vez que se requiera utilizar las redes neuronales para estimar la curva de transformadores de distribución, se deberá analizar previamente ¿a qué clase pertenece cada transformador?; y por ende ¿con cuál de las redes neuronales se podrá estimar correctamente su comportamiento?

Como parte del análisis de agrupamiento de curvas, se ha llevado a cabo un proceso de evaluación de desempeño del algoritmo k-means utilizado, dicha evaluación se realizó mediante dos indicadores: el Índice promedio de adecuación (MIA) y el Índice de dispersión de agrupamiento (CDI). El comportamiento de estos indicadores muestra la correcta aplicación del método de clustering y a la vez permite la determinación de los valores más adecuados tanto de número de clases como de curvas representativas iniciales.

En las figuras 3.7, 3.8, 3.9 y 3.10 se puede observar el comportamiento de los índices de desempeño en función de las iteraciones del proceso de clustering. En las gráficas se puede constatar que, en cada uno de los casos mostrados, los índices tienden a disminuir a medida que avanza el proceso de agrupamiento, esto indica un correcto funcionamiento y aplicación del algoritmo. Se puede apreciar además en las gráficas que, para cada uno de los casos de análisis especificados en la Tabla 3.2, los índices toman un valor constante a partir de un número distinto de iteraciones.

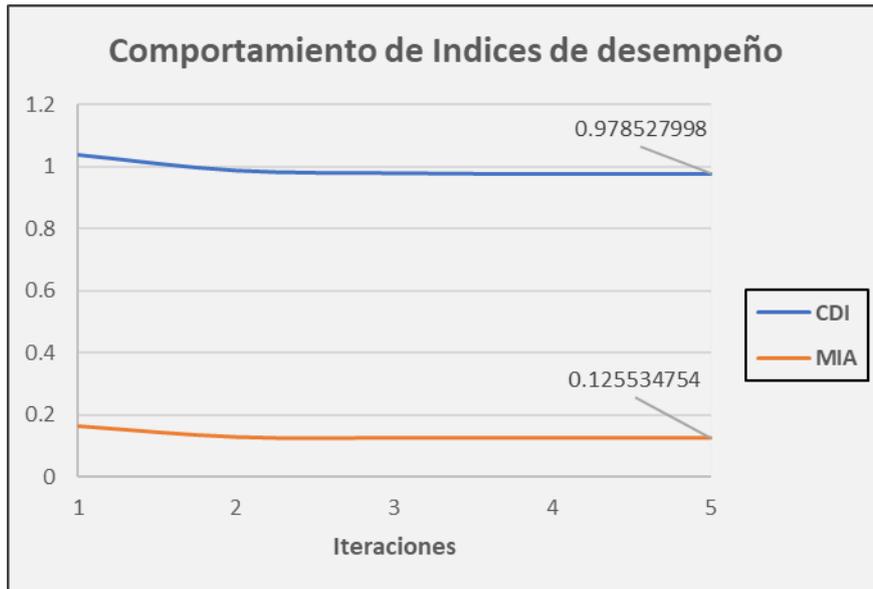


Figura 3.7 Comportamiento de los índices de desempeño de clustering Caso 1 [Elaboración Propia].

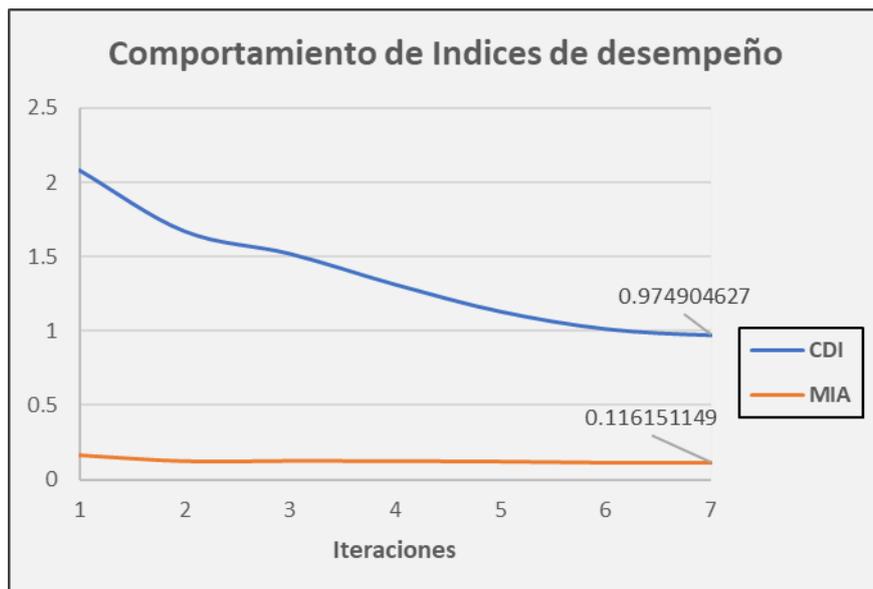


Figura 3.8 Comportamiento de los índices de desempeño de clustering Caso 2 [Elaboración Propia].

El comportamiento del algoritmo de agrupamiento depende de dos principales factores:

- El número de clases, cuyo valor fue evaluado no solamente con el fin de mejorar los índices, sino que también debe tener correspondencia a las composiciones de clientes de cada grupo de transformadores.
- Las curvas representativas iniciales que fueron determinadas mediante un proceso de búsqueda exhaustiva; es decir se evaluó todos los posibles grupos de curvas candidatas y se comparó los índices de desempeño de cada opción.

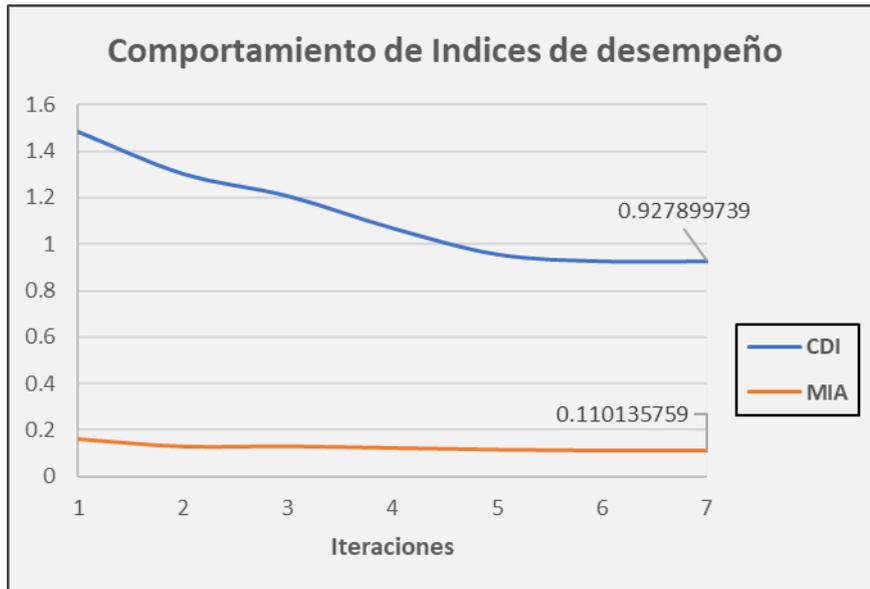


Figura 3.9 Comportamiento de los índices de desempeño de clustering Caso 3 [Elaboración Propia].

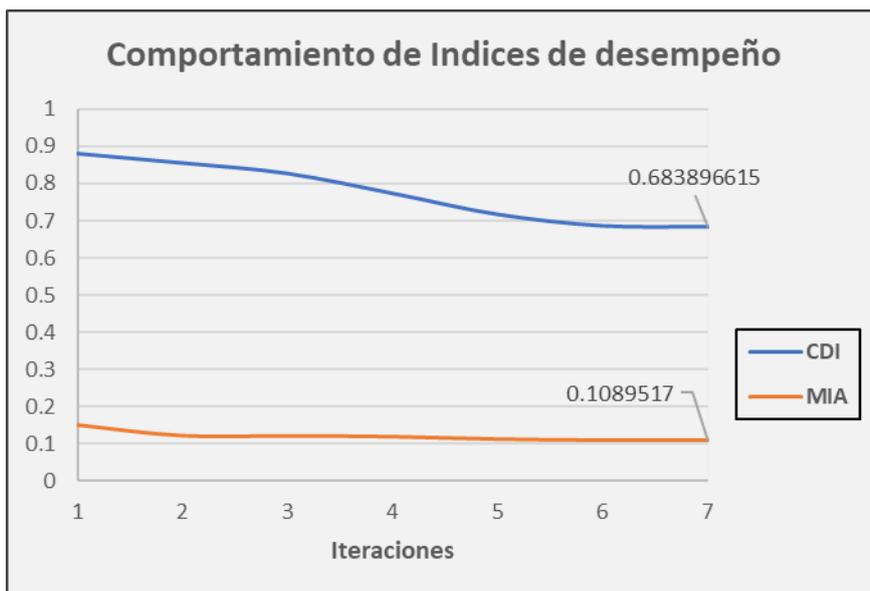


Figura 3.10 Comportamiento de los índices de desempeño de clustering Caso 4 [Elaboración Propia].

La Tabla 3.2 muestra la composición de un ejemplo de cuatro casos de estudio analizados para el ajuste adecuado de parámetros para el proceso de clustering. En la Figura 3.7 se observa el caso 1 de análisis, que consiste en 6 curvas representativas escogidas aleatoriamente para cada una de las 6 clases. Este caso constituye un resultado promedio del comportamiento del algoritmo y un supuesto resultado sin el procedimiento de búsqueda exhaustiva descrito con anterioridad.

**Tabla 3.2.** Casos de estudio planteados para la determinación de centroides o curvas iniciales del clustering

<b>Caso de estudio</b>	<b>Composición</b>
1	Grupo de curvas iniciales 1 con 6 clases
2	Grupo de curvas iniciales 2 con 6 clases
3	Grupo de curvas iniciales 1 con 7 clases
4	Grupo de curvas iniciales 2 con 7 clases

La Figura 3.8 muestra el comportamiento de los índices de desempeño del caso 2, que consiste en 6 clases con 6 curvas representativas escogidas durante el proceso de búsqueda exhaustiva, eso quiere decir que presenta mejores indicadores que el caso 1. Se puede comprobar que a medida que se prueba nuevos grupos de curvas representativas, se va encontrando mejores resultados para los índices. La Figura 3.9 muestra los resultados de un grupo de curvas aleatorias cualquiera para 7 clases. Finalmente, la Figura 3.10 contiene los resultados del caso 4, obteniéndose los mejores índices de desempeño para 7 clases o grupos de curvas.

De los resultados obtenidos del proceso de variar el número de grupos se puede concluir que, a medida que se aumentan los grupos, los índices de desempeño mejoran. A pesar de este comportamiento de los índices, se cree conveniente conservar el número de grupos en 6, debido al criterio de composición de clientes de las curvas de transformadores mencionado anteriormente.

Finalmente, en el proceso de agrupamiento del caso de estudio de 86 transformadores, se obtuvo 6 clústers o grupos de transformadores, que se distribuyeron según la información detallada en la Tabla 3.3.

**Tabla 3.3.** Tabla de frecuencias de grupos de transformadores para caso de estudio

<b>Clúster</b>	<b>Número de transformadores</b>	<b>Frecuencia Relativa</b>
1	19	0.2217
2	23	0.2674
3	7	0.0814
4	7	0.0814
5	27	0.3140

6	3	0.0349
TOTAL	86	1

### **3.2. Análisis de creación de redes neuronales y validación de curvas estimadas de demanda diaria**

Una vez se ha cumplido exitosamente el proceso de agrupamiento de las curvas de transformadores de entrenamiento, el siguiente paso constituye realizar la creación, entrenamiento, validación, prueba y utilización de las redes neuronales, necesarias para cumplir con los objetivos del presente proyecto. Como se mencionó en capítulos anteriores el funcionamiento de las redes neuronales será evaluado externamente, comparando las curvas estimadas con las curvas reales de transformadores provenientes de mediciones. Este procedimiento constituye un proceso que justifica y valida la utilización de las redes neuronales para resolver el problema de estimación de curvas de demanda horaria en transformadores de distribución.

#### **3.2.1. Creación de las redes neuronales**

En el análisis de clústers se determinó que 6 es el número adecuado de grupos para las curvas bajo análisis, esto significa que se implementarán 6 redes neuronales, cada una de ellas se entrenará con los datos provenientes de los transformadores agrupados bajo la misma clase.

A pesar de que los datos comerciales de composición de clientes por transformador contienen información de los siguientes grupos de clientes: Residencial, Comercial, PEC, Alumbrado Público, Industrial, Hurto y Otros; se tomó la decisión de trabajar únicamente con los 4 primeros grupos debido a que los clientes industriales en su mayoría tienen su propio transformador y su participación en los transformadores bajo análisis no es representativa, además en general ninguno de estos grupos de clientes tiene un comportamiento característico de demanda que pueda resultar predecible.

Se trabajó con dos opciones de datos de entrada a las redes, que se representan en la Figura 3.11 y Figura 3.12:

- A. Valores normalizados de la sumatoria en kWh del consumo promedio mensual de cada tipo de cliente.

B. Valores normalizados del número de clientes correspondientes a cada uno de los estratos de cada tipo de cliente.

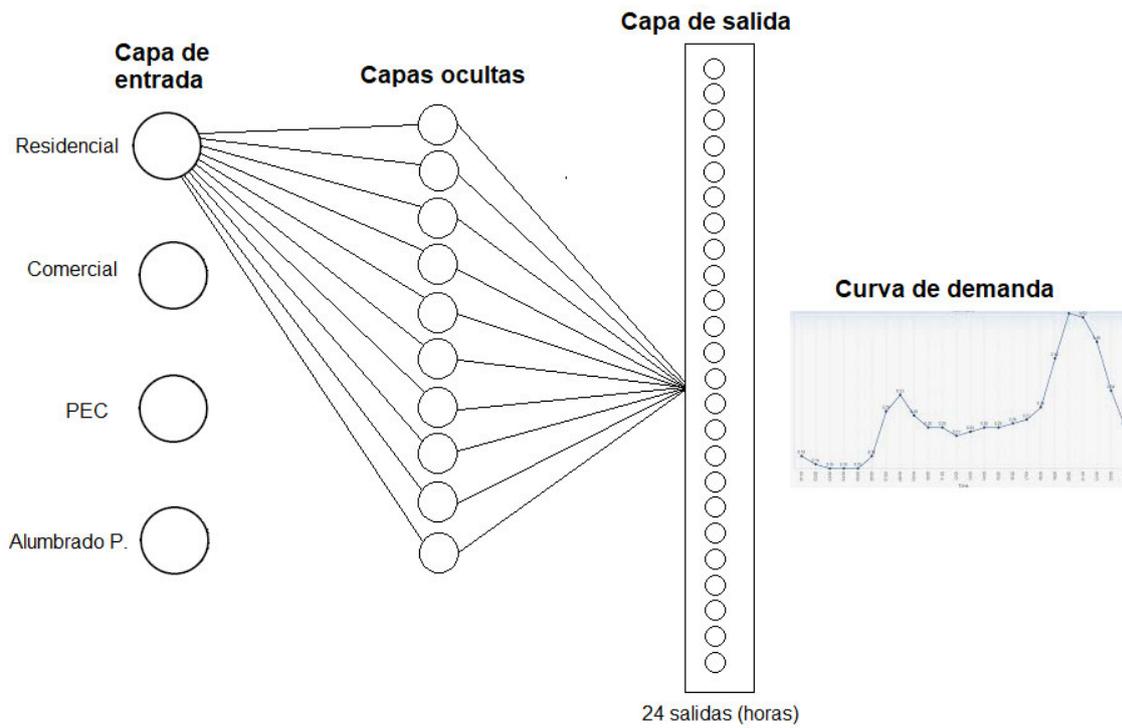


Figura 3.11 Estructura de las redes neuronales implementadas de la opción A [Elaboración Propia].

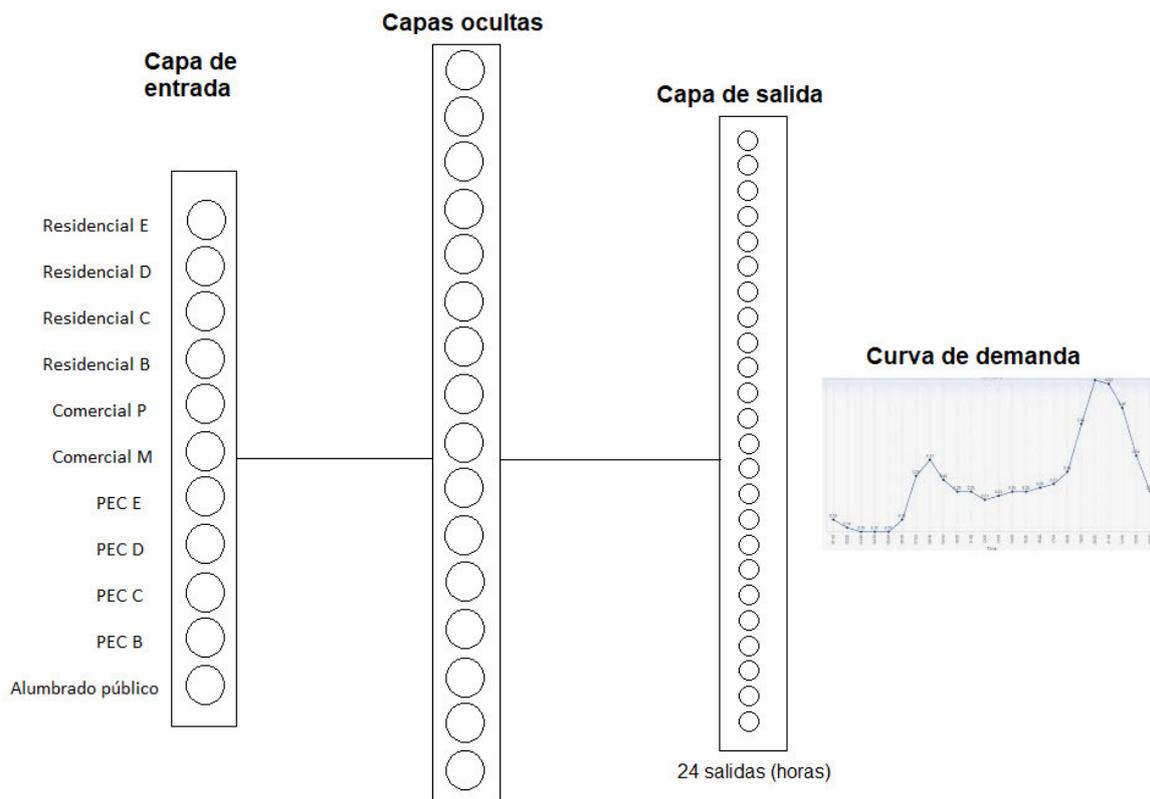


Figura 3.12 Estructura de las redes neuronales implementadas de la opción B [Elaboración Propia].

Como se puede observar en la Figura 3.12, las entradas de la red escogidas para la opción B corresponden a 4 estratos de consumo residencial (E, D, C, B), 4 estratos de consumo PEC (E, D, C, B), 2 estratos de consumo comercial (Pequeño y Mediano), de acuerdo a la Tabla 2.2 y una entrada de alumbrado público. Cada una de las entradas representan el número de clientes correspondiente al estrato y al tipo de cliente de la entrada.

La estructura de las redes que se observan en la Figura 3.11 y Figura 3.12, contiene una sola capa oculta, esto debido a que durante el proceso de entrenamiento no hubo la necesidad de incrementar el número de capas ocultas. El número inicial de neuronas de la capa oculta para ambos casos fue calculado a partir de la ecuación 2.6, su número final depende de la clase. La capa de salida consta de 24 neuronas que corresponden a la demanda en cada una de las horas del día.

De acuerdo a las consideraciones expuestas anteriormente, la estructura topológica de las redes neuronales de cada opción, es resumida en la Tabla 3.4.

**Tabla 3.4.** Resumen de la estructura topológica de las redes utilizadas

Opción	Entradas	Capa Oculta	Capa de salida
A	4	10 neuronas	24 neuronas
B	10	16 neuronas	24 neuronas

La elección del número y el tipo de entradas a la red se realizó mediante una comparación de resultados entre ambas opciones. Se cuenta con bibliografía que respalda la efectividad de ambas opciones, sin embargo, se pudo observar que, en el caso concreto del problema abordado en este trabajo, la opción B con 11 entradas es la que presenta mejores resultados, es por ello que se desechó la utilización de la opción A de 4 entradas. El mejor comportamiento de la red con la opción B se puede atribuir a que al trabajar con consumos mensuales de clientes individuales segmentados y no con la suma de consumos mensuales por grupo de clientes, la red neuronal puede aprender relaciones más complejas en donde se aproxime a considerar factores de simultaneidad y coincidencia entre clientes. Además, se considera que, para la etapa de utilización de las redes neuronales, resulta más práctico contar con el número de clientes por cada estrato para utilizar como datos de entrada.

El siguiente aspecto inherente al diseño de las redes neuronales que fue tomado en cuenta es la determinación de las funciones de activación de cada capa. Esta selección resulta importante ya que definirá el desempeño durante el entrenamiento de la red y el tipo de resultados que se obtendrá en la capa de salida de la misma. Es por ello que en el presente trabajo se han seguido las recomendaciones de expertos en aprendizaje automático o machine learning de acuerdo al tipo de problema que se aborda y se requiere solucionar.

Las redes neuronales que se plantean en el presente proyecto son del tipo Perceptrón multicapa, es por ello que se toma la recomendación de utilizar una función de activación del tipo rectificadora o ReLU, de acuerdo con lo mencionado en el apartado 1.5.1.2. Sin embargo, se probó el funcionamiento de la red con una función de activación tangente hiperbólica, lográndose los resultados detallados en la Tabla 3.5, comprobándose la mejor adecuación de resultados para la función de activación ReLU en la capa oculta.

**Tabla 3.5.** Comparación de resultados de errores de correlación según utilización de funciones de activación en la capa oculta

Clase	Errores de correlación	
	Tansig	ReLU
1	0.92773	0.95581
2	0.90719	0.96247
3	0.92899	0.93665
4	1	1
5	0.94685	0.88408
6	0.82361	0.84460

El problema de estimación de las curvas de demanda es básicamente un problema de regresión, ya que su objetivo consiste en predecir el valor de una variable numérica (Demanda Horaria de transformadores de distribución) en el tiempo, basándose en los valores de las horas del día que en este caso corresponderían a las variables predictoras. Por esta razón y de acuerdo con las recomendaciones mencionadas en el apartado 1.5.1.2, se ha escogido la función de activación lineal para la capa de salida de las redes del proyecto.

La implementación de las redes neuronales se las realizó mediante la herramienta propia de Matlab (Neural Network Toolbox), la misma que requiere para su funcionamiento una serie de ajustes por parte del usuario. Entre los ajustes que se hicieron en el presente trabajo se puede mencionar: vector de entradas, vector de salidas y distintos parámetros o configuraciones de la red neuronal como: la clase de red neuronal, número de capas, número de neuronas de cada capa, algoritmo de entrenamiento, funciones de activación, épocas e iteraciones. Un esquema resumido de la estructura del modelo de red implementado en Matlab para las 6 clases se puede observar en la Figura 3.13.

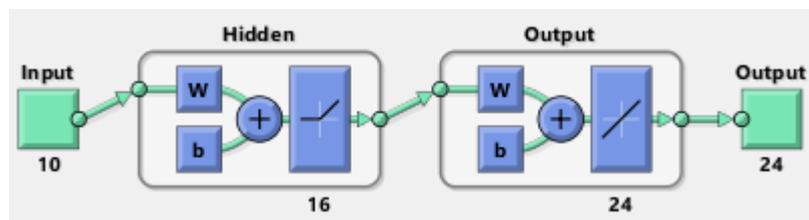


Figura 3.13 Estructura escogida para la programación de redes neuronales en Matlab [Elaboración Propia].

### 3.2.2. Proceso de Entrenamiento de las redes neuronales

Una vez se ha creado la red neuronal y establecido sus parámetros operacionales, le corresponde al programador considerar los aspectos concernientes a su entrenamiento,

validación y prueba. Cada uno de estos tres procedimientos constituye una etapa independiente que necesita de datos individuales y únicos. Por esta razón es una práctica generalizada dividir los datos en tres subgrupos que puedan ser utilizados por separado.

La herramienta Neural Networks Toolbox de Matlab contiene funciones específicas que permiten dividir adecuada y automáticamente los datos en los tres subgrupos requeridos. Dentro de estas funciones se ha escogido la división aleatoria para asegurar la validez del modelo neuronal indistintamente de los datos ingresados, sin embargo, esto conlleva una desventaja y es que cada vez que se entrene la red, se obtendrá parámetros de entrenamiento distintos, por lo que los resultados en la etapa de prueba diferirán de acuerdo a la distribución aleatoria de estos grupos de datos. Como parámetros requeridos para la división de datos están los porcentajes de datos asignados para cada grupo. Para el presente proyecto se utilizaron los valores recomendados por defecto: 70%, 15% y 15%, para el entrenamiento, validación y prueba respectivamente.

Una vez que se hayan inicializado los parámetros de la red: umbrales ( $b$ ) y pesos sinápticos ( $w$ ), la red neuronal está lista para su entrenamiento. En este punto resulta muy importante determinar el algoritmo de entrenamiento adecuado, que permita minimizar la diferencia entre las curvas de demanda real y las curvas de demanda calculada por la red neuronal, mediante el ajuste iterativo de los parámetros de la red.

La aplicación “Neural Network Toolbox” de Matlab tiene disponibles varios algoritmos de entrenamiento basados en el método del Jacobiano o calculando el gradiente iterativamente hacia atrás en la red (backpropagation). En la Tabla 3.6 se enumera los algoritmos disponibles en la aplicación.

**Tabla 3.6.** Algoritmos de entrenamiento disponibles en el Neural Network Toolbox

<b>Función de Matlab</b>	<b>Algoritmo</b>
traingd	Descenso por gradiente tradicional
traingdm	Descenso por gradiente con momento
trainlm	Levenberg-Marquardt
trainbr	Regularización bayesiana
trainbfg	BFGS Cuasi-Newtoniano
trainrp	Backpropagation Resiliente
trainscg	Gradiente conjugado escalado

traincgb	Gradiente conjugado con reinicios Powell / Beale
traincgf	Gradiente conjugado Fletcher-Powell
traincgp	Gradiente conjugado Polak-Ribière
trainoss	Secante de un paso
traingdx	Descenso por gradiente de tasa de aprendizaje variable

Resulta muy complicado saber cuál algoritmo de entrenamiento será el más rápido y eficiente para un problema determinado. La selección depende de muchos factores como la complejidad de la red, la cantidad de datos de entrenamiento y pesos sinápticos, el criterio de error objetivo y principalmente el propósito de la red entrenada, esto quiere decir que, se requerirá un método de entrenamiento diferente si la red se utiliza para reconocimiento de patrones (análisis discriminante) o aproximación de funciones (regresión).

La función de entrenamiento más rápida es la de Levenberg-Marquardt (LM), sin embargo, tiende a ser menos eficiente en redes de mayor envergadura, es decir que a medida que aumenta el tamaño de la red a entrenar, va requiriendo más recursos computacionales y se vuelve ineficiente. A pesar de sus desventajas, se puede decir que el algoritmo de Levenberg-Marquardt para resolver problemas de aproximación de funciones con no más de algunos cientos de pesos sinápticos, entrega los mejores resultados y la más rápida convergencia.

El algoritmo Backpropagation Resiliente (RP) es el método de entrenamiento más rápido para problemas de reconocimiento de patrones, no obstante su desempeño en problemas de aproximación de funciones no es bueno. Su rendimiento también disminuye a medida que se aproxima al error mínimo objetivo. Los requisitos de memoria para el algoritmo RP son relativamente pequeños en comparación con los otros algoritmos presentes en la Tabla 3.5.

Los algoritmos de gradiente conjugado (SCG), en particular el método del Gradiente conjugado escalado, funciona relativamente bien en una amplia variedad de problemas, particularmente si su uso es en redes con una gran cantidad de pesos sinápticos. El algoritmo SCG es casi tan rápido como el algoritmo LM en problemas de aproximación de funciones y es casi tan rápido como el RP en problemas de reconocimiento de patrones. Su rendimiento no se degrada tan rápidamente como lo hace el rendimiento de RP, cuando se reduce el error. Todas las variantes de algoritmos de gradiente conjugado tienen requisitos de memoria relativamente modestos.

En virtud de las ventajas y desventajas que presentan los distintos algoritmos detallados anteriormente, en el presente proyecto se comparó los algoritmos de Levenberg-Marquardt y

Gradiente conjugado escalado, obteniéndose diversos resultados. Evaluando los resultados obtenidos y en general el desempeño de ambos algoritmos, el método de Levenberg-Marquardt es el que mejores indicadores obtiene y por ello fue escogido para el entrenamiento de las redes del problema planteado.

El algoritmo de Levenberg-Marquardt, al igual que todos los otros algoritmos de entrenamiento, requiere de ciertos ajustes que permitan obtener los resultados deseados. En la Tabla 3.7 se detallan los valores utilizados en cada uno de los parámetros.

**Tabla 3.7.** Parámetros de entrenamiento del algoritmo Levenberg-Marquardt

<b>Nomenclatura Matlab</b>	<b>Parámetro</b>	<b>Valor</b>
epochs	Máximo número de épocas para entrenamiento	1000
goal	Objetivo de desempeño (Error)	0
max_fail	Comprobaciones máximas de validación	6
min_grad	Gradiente de rendimiento mínimo (Error)	1e-7
mu	Índice o ganancia de aprendizaje ( $\mu$ )	0,001
mu_dec	Factor de decremento de $\mu$	0,1
mu_inc	Factor de incremento de $\mu$	10
mu_max	Valor máximo de $\mu$	1e10
time	Tiempo máximo de entrenamiento	inf

A menudo no resulta necesario modificar los ajustes de los parámetros de entrenamiento, ya que los valores colocados por defecto en la aplicación de Matlab funcionan bien para una gran variedad de problemas, sin embargo, se identificó la necesidad de cambiar el método de entrenamiento y sus respectivos parámetros sólo si se aumenta la complejidad de la red y los datos de entrenamiento.

En las Figuras desde la 3.14 a la 3.19 se muestran las ventanas de resultados del entrenamiento de las 6 redes neuronales correspondientes a los 6 grupos de curvas logrados en la sección 3.1.1. Dentro de los resultados más importantes a destacar están: el número de épocas, en el que se terminó el entrenamiento, el rendimiento, la magnitud del gradiente de rendimiento y el número de comprobaciones de validación.

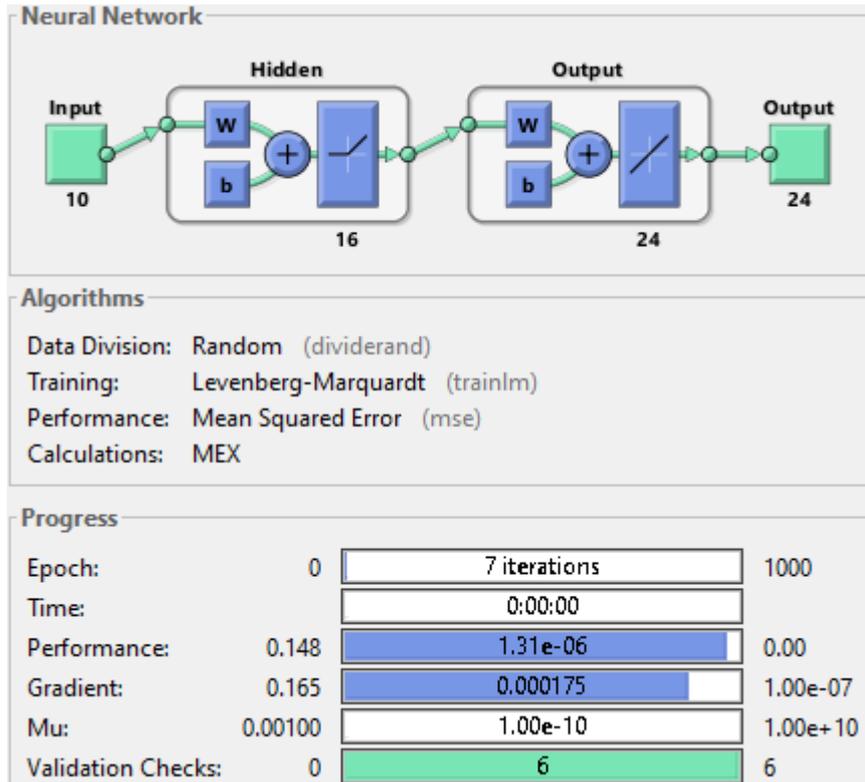


Figura 3.14 Resumen de resultados de entrenamiento de la Red Neuronal 1 [Elaboración Propia].

La magnitud del gradiente y el número de comprobaciones de validación, al constituir criterios de parada del entrenamiento, son muy importantes de analizar para diagnosticar problemas en el aprendizaje. A medida que las épocas del entrenamiento avancen, el gradiente comenzará a hacerse cada vez más pequeño y el rendimiento tenderá a acercarse al mínimo deseado. Por otro lado, el número de comprobaciones máximas de validación representa el número de iteraciones sucesivas que, durante la validación, no se logró disminuir el rendimiento.

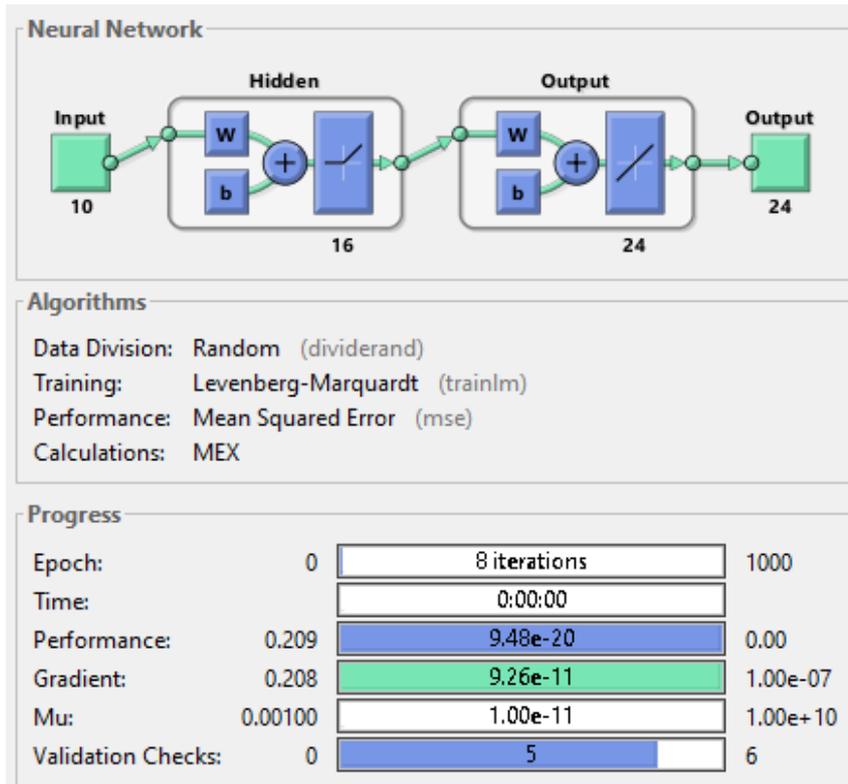


Figura 3.15 Resumen de resultados de entrenamiento de la Red Neuronal 2 [Elaboración Propia].

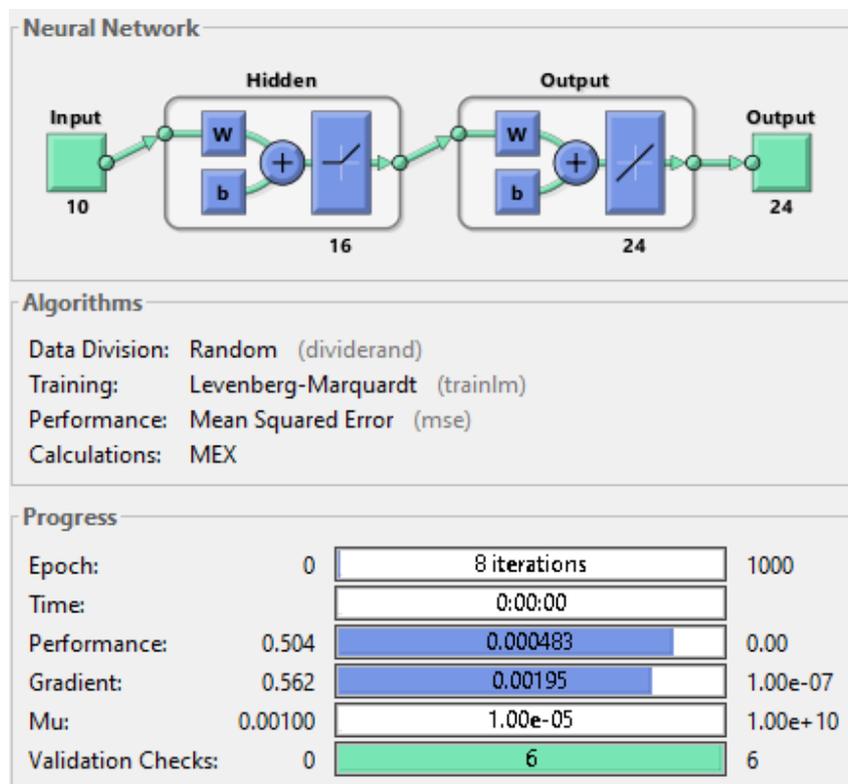


Figura 3.16 Resumen de resultados de entrenamiento de la Red Neuronal 3 [Elaboración Propia].

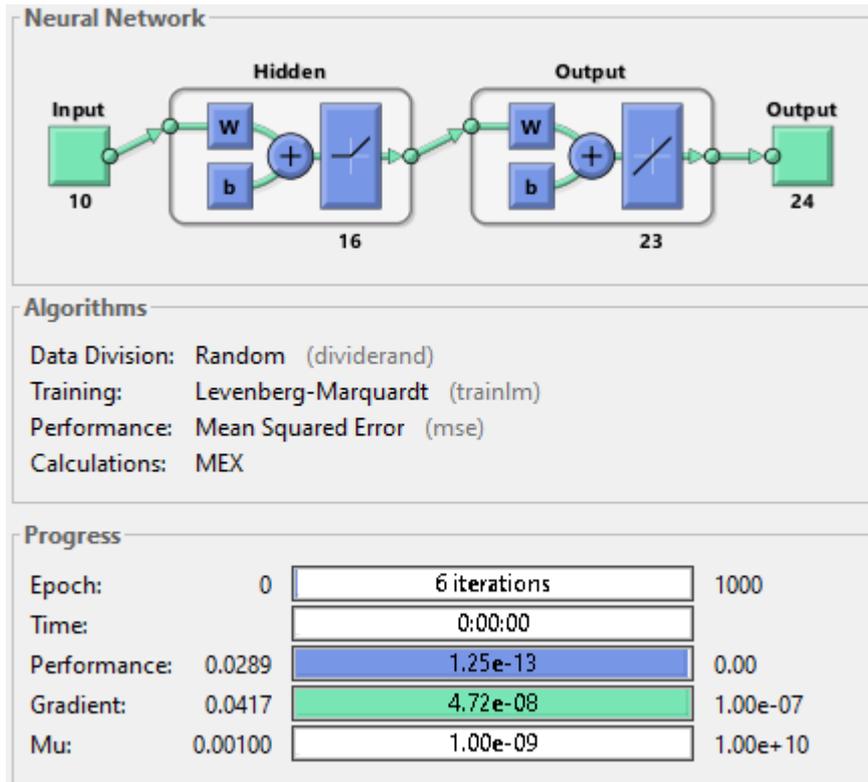


Figura 3.17 Resumen de resultados de entrenamiento de la Red Neuronal 4 [Elaboración Propia].

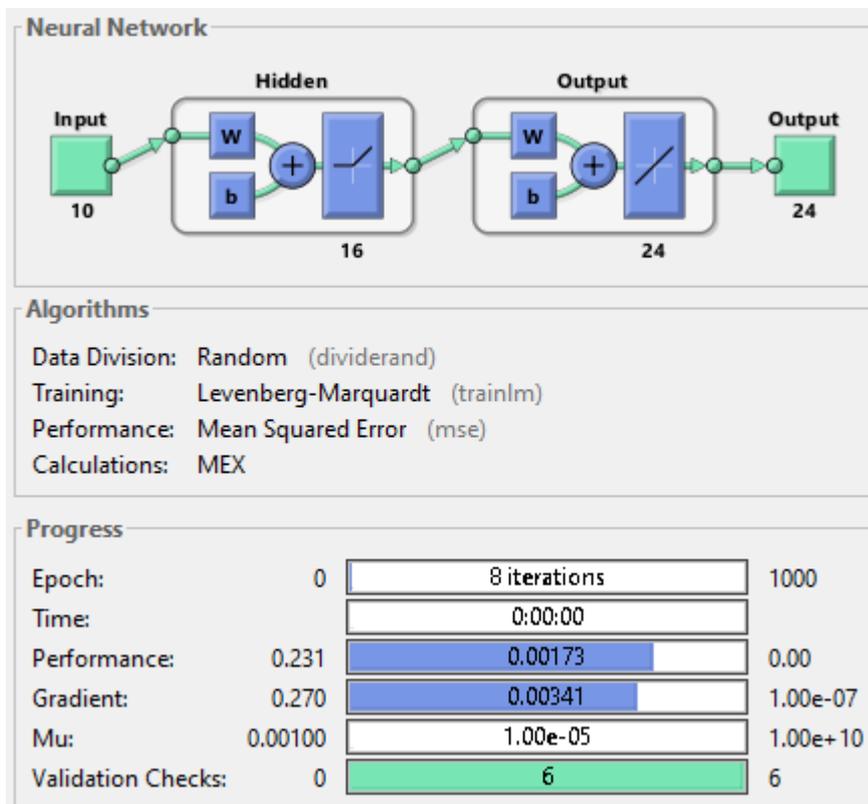


Figura 3.18 Resumen de resultados de entrenamiento de la Red Neuronal 5 [Elaboración Propia].

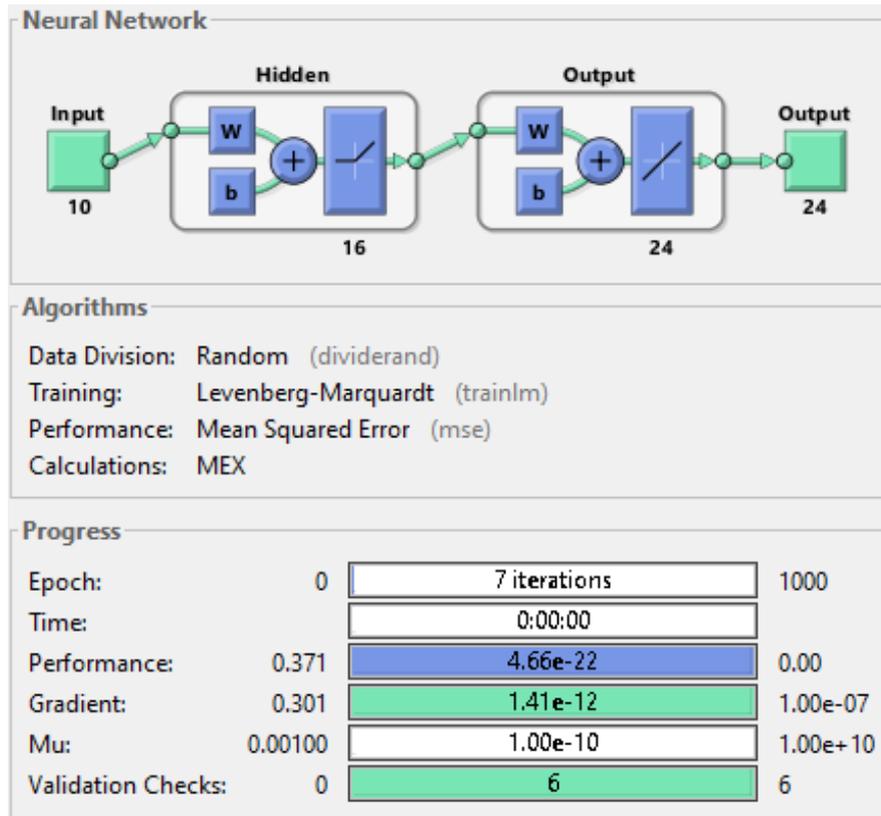


Figura 3.19 Resumen de resultados de entrenamiento de la Red Neuronal 6 [Elaboración Propia].

De acuerdo a los ajustes de la Tabla 3.7, el entrenamiento se detendrá en dos casos: si la magnitud del gradiente llega a ser menor que  $1e-7$  y si el número de comprobaciones máximas de validación llega a 6. En las Figuras desde la 3.14 a la 3.19 se observa de color verde, que cada una de las redes entrenadas cumple alguno de los dos criterios de parada y el entrenamiento se detuvo de manera correcta en tiempos y épocas adecuadas.

Es importante hacer notar en este punto que los valores de los resultados de entrenamiento, así como en general las estimaciones de la red variarán por cada vez que se compile el código del programa. Esto se debe a los procesos que conllevan valores aleatorios como son la selección de curvas patrón para el clustering y la división de los datos de entrenamiento, validación y prueba.

En la Figura 3.20 se presenta los resultados del desempeño de la red neuronal del grupo 1, se muestra una gráfica del comportamiento del error medio cuadrático durante las etapas de entrenamiento, validación y prueba, en función del número de iteraciones. Se puede notar resaltado en un círculo, la época en el que el rendimiento o error de validación alcanzó su mínimo, en este caso el entrenamiento continuó durante 6 iteraciones más antes de que se

detuviera. No se pudo encontrar ningún problema importante durante el entrenamiento de las redes neuronales planteadas, ya que las curvas de validación y prueba son muy similares. Si la curva de prueba aumenta significativamente antes de la curva de validación, entonces es posible que se haya producido algún problema de sobre entrenamiento.

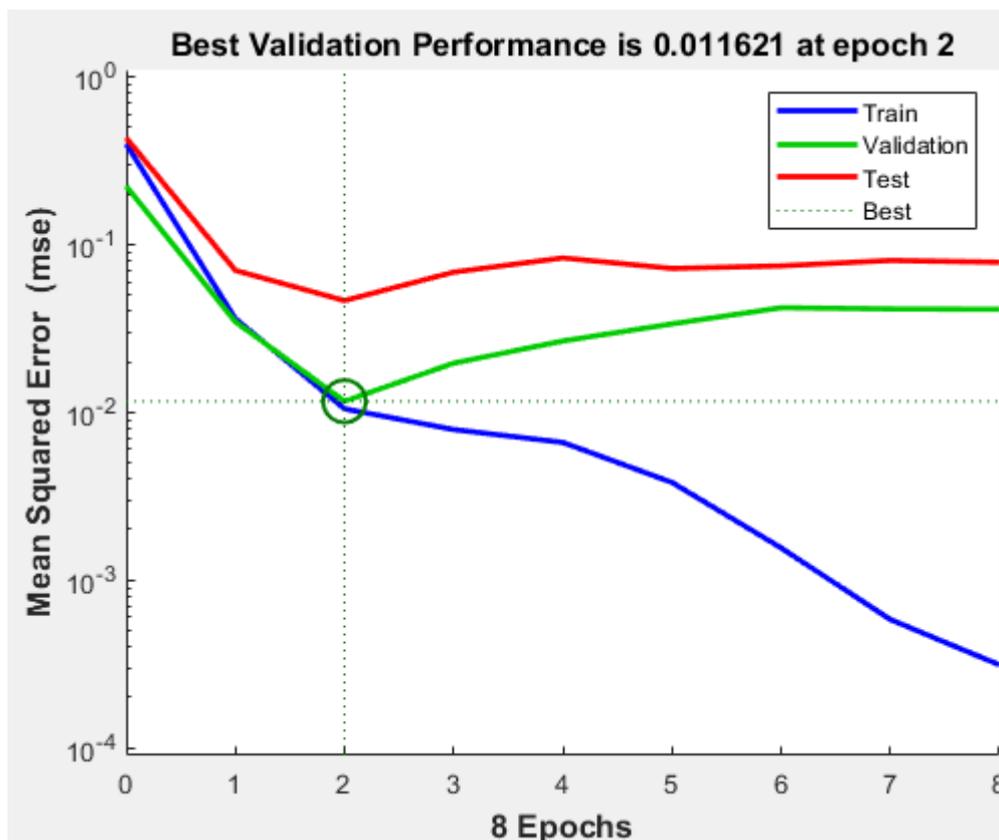


Figura 3.20 Resultados de desempeño de la Red Neuronal 1 [Elaboración Propia].

En el Anexo IV se presenta las gráficas de desempeño del entrenamiento de las 6 redes neuronales. En todos los casos no se encuentra indicadores de que se produzca un sobre entrenamiento, mermando las capacidades de generalización de la red. Sin embargo, se puede notar en la gráfica de la clase 6, en donde únicamente aparece la función de entrenamiento; esto se debe a que la clase no tiene suficientes curvas para cubrir la validación y prueba. Esta limitación hace que no se pueda tener la seguridad de la eficacia del entrenamiento, por lo que se decidió desistir de la utilización de la red 6.

En la Figura 3.21 se puede observar el gráfico del estado de entrenamiento de la red 1, en donde se evidencia el progreso de las variables de entrenamiento: la magnitud del gradiente, el número de comprobaciones de validación y la ganancia de aprendizaje. Se puede corroborar

gráficamente mediante esta figura, la evolución de las variables de entrenamiento a lo largo de las épocas y se evidencia al final el cumplimiento del criterio de parada en alguna o varias de ellas.

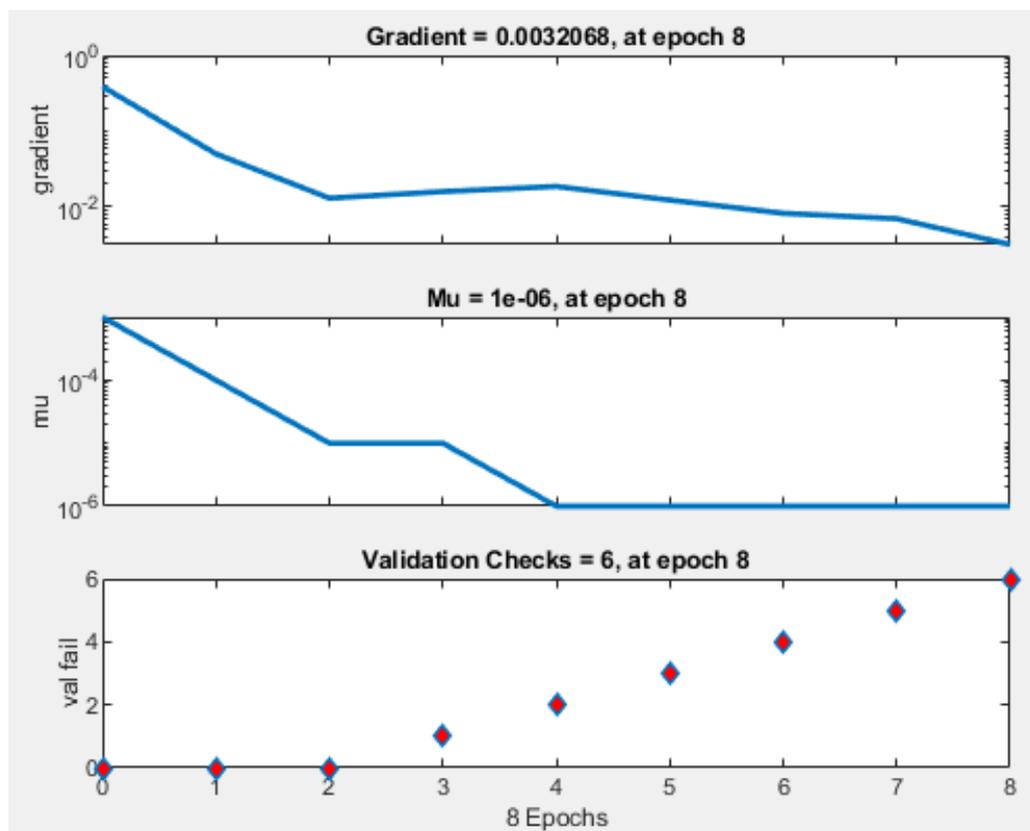


Figura 3.21 Parámetros de entrenamiento de la red neuronal 1 [Elaboración Propia].

En el Anexo V se muestra los gráficos de estado de entrenamiento de todas las redes neuronales planteadas. Se puede notar claramente en la gráfica el decrecimiento en diversas tasas, pero de manera sostenida del gradiente. El valor de  $\mu$  en cambio puede reducirse o incrementarse dependiendo de la evolución de la función de desempeño en cada iteración, sin embargo, su decrecimiento a largo plazo demuestra el avance exitoso del algoritmo de entrenamiento. Nuevamente en la red 6, al no disponer de elementos suficientes para realizar la validación, se puede observar resultados nulos en los chequeos de validación.

La Figura 3.22 muestra el histograma de la distribución de errores en la red 1 y el Anexo VI, los histogramas del resto de redes entrenadas. Estos histogramas representan las frecuencias de errores distribuidas en 20 intervalos. Se puede notar claramente el comportamiento normalizado de la variable de error, lo que indica un comportamiento satisfactorio del algoritmo

de entrenamiento. Se puede utilizar el histograma y los gráficos de regresión mostrados a continuación en la Figura 3.23, para validar el rendimiento de las redes planteadas.

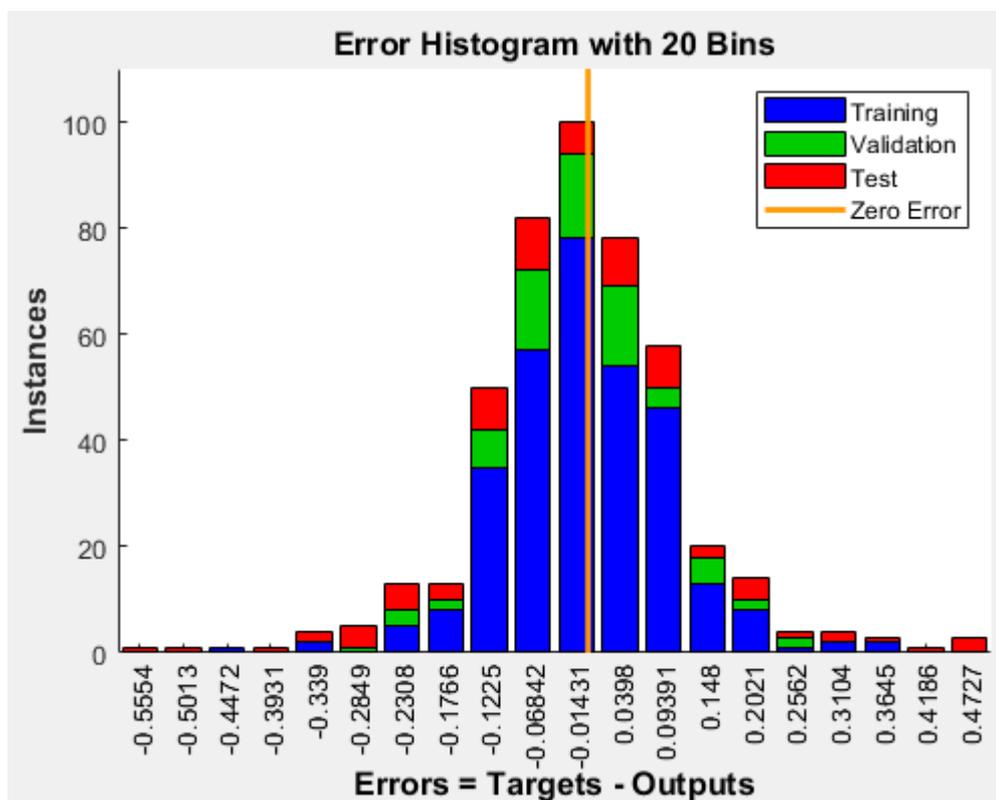


Figura 3.22 Histograma de errores de entrenamiento de la red neuronal 1 [Elaboración Propia].

En la Figura 3.23 se muestran los gráficos de regresión entre las Salidas vs. los Objetivos de la red neuronal 1, el resto de gráficos correspondientes a las redes neuronales restantes se presentan en el Anexo VII. Los tres gráficos (azul, verde y rojo) representan los datos de entrenamiento, validación y prueba respectivamente. La línea punteada en cada gráfico representa el resultado ideal, es decir cuando las Salidas son exactamente igual a los Objetivos. Si el entrenamiento fuera ideal, los resultados de la red y los objetivos serían exactamente iguales, pero esta relación rara vez es perfecta en la práctica. La línea continua representa la línea de regresión lineal que mejor se ajusta entre los resultados y los objetivos. El valor de R es el coeficiente de correlación entre las salidas y los objetivos. Si  $R = 1$ , indica que existe una relación lineal exacta. Si R está cerca de cero, entonces no existe una relación lineal entre los resultados y los objetivos.

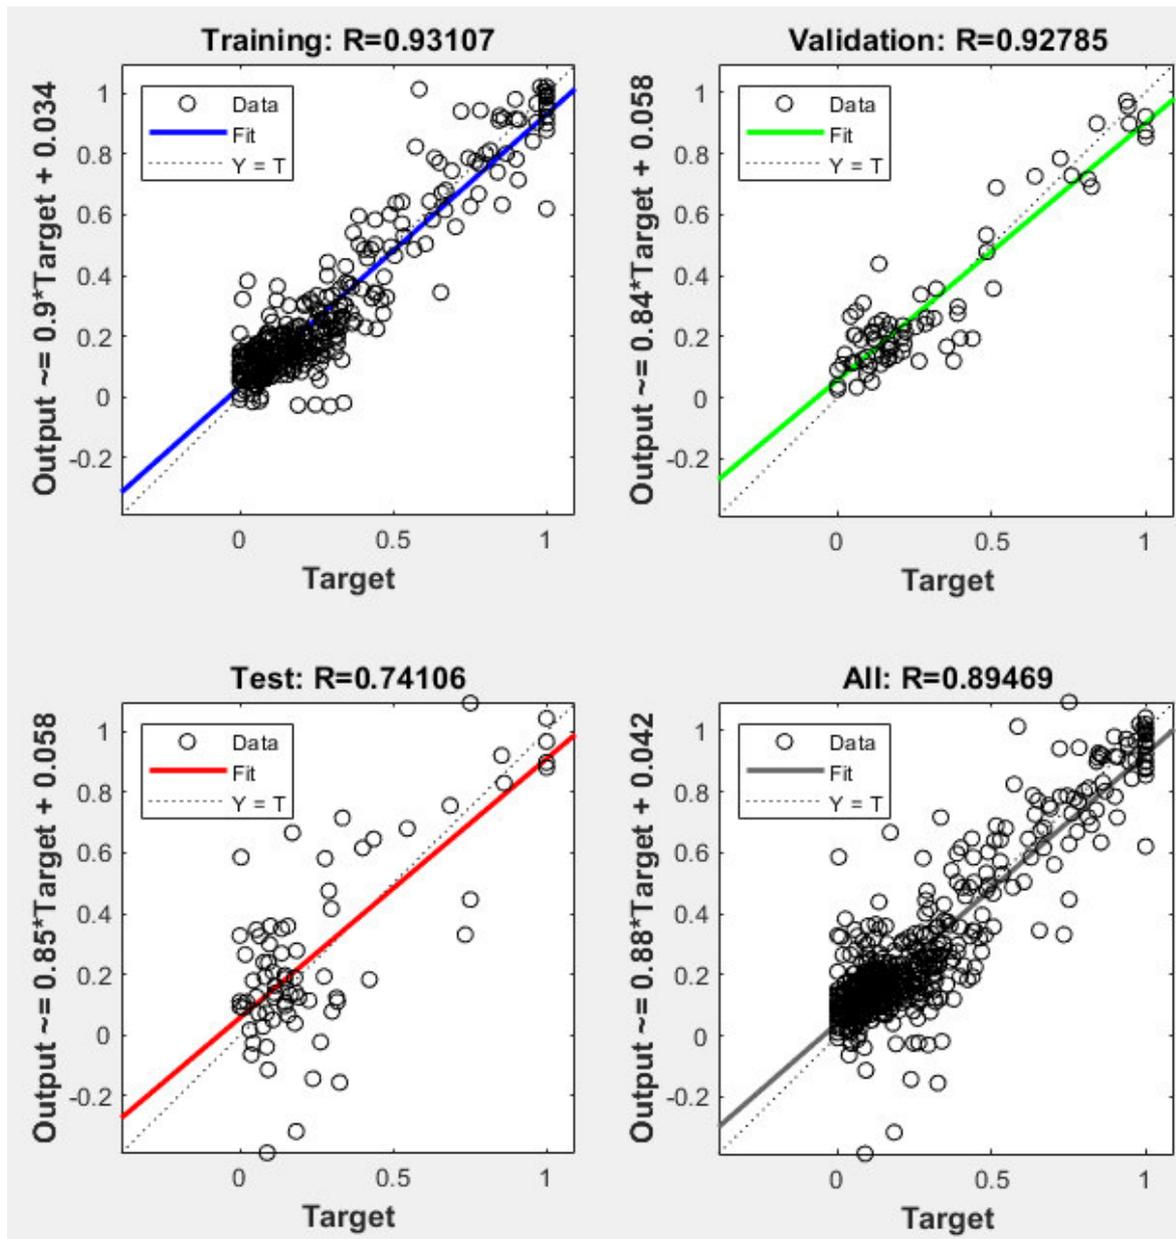


Figura 3.23 Regresión de resultados de la red neuronal 1 [Elaboración Propia].

Para el caso de las redes neuronales del problema, los resultados son variables entre las distintas redes. Los datos de entrenamiento indican en general un aceptable ajuste con valores superiores o iguales a 0,9, a excepción de la clase 4 que posee en coeficiente de correlación igual a 0,8. Los resultados de la validación y prueba, aunque muestran valores inferiores a los de entrenamiento, sus valores rondan a 0,7 en su gran mayoría. El promedio de los coeficientes de correlación se encuentra alrededor de 0,85 que es un valor aceptable para los propósitos del presente trabajo de titulación.

Mediante el diagrama de dispersión de la Figura 3.23, se identificó ciertos ajustes útiles en el entrenamiento, que mejoraron en cierta medida los resultados. Mediante la identificación de valores atípicos en la regresión, se puede modificar el conjunto de entrenamiento de la red, incluyendo dichos datos y así logrando mejorar el desempeño del algoritmo. Si se tuviera acceso a un mayor número de datos de transformadores se podría sustituir los conjuntos de entrenamiento, validación y prueba hasta lograr mejores resultados que los presentados.

### **3.2.3. Validación externa de las redes neuronales entrenadas**

Como se había mencionado en capítulos anteriores, adicional al proceso de validación intrínseco al entrenamiento en Matlab, se realizó una validación externa con datos de transformadores que no hayan sido utilizados en el entrenamiento. Este proceso verificará la utilidad de cada una de las redes neuronales creadas previo a su utilización y análisis en un alimentador real.

Para la validación externa, se trabajó con una muestra de 86 transformadores con diversas composiciones de clientes, la única restricción es que no cuenten con clientes del tipo industrial, comercial grande o comercial nocturno, esto debido a que, al contar con insuficientes datos de entrenamiento, no se pudo generar modelos de redes neuronales para transformadores con los mencionados tipos de clientes.

En la Figura 3.24 se muestra ejemplos de curvas estimadas y reales para los transformadores pertenecientes a la clase 1, es decir para los transformadores Residenciales con alta incidencia comercial. El coeficiente de correlación promedio de todos los transformadores de esta clase, calculado entre las curvas reales y estimadas, resultó ser de 0,91055. Este resultado se encuentra dentro de las expectativas ya que el error resulta ser inferior al 15%. Se puede notar claramente que la curva estimada sigue perfectamente la tendencia de la curva real, a excepción de horas en las que la demanda real muestra un comportamiento más volátil. Se puede notar una moderada subestimación de la demanda máxima de las curvas

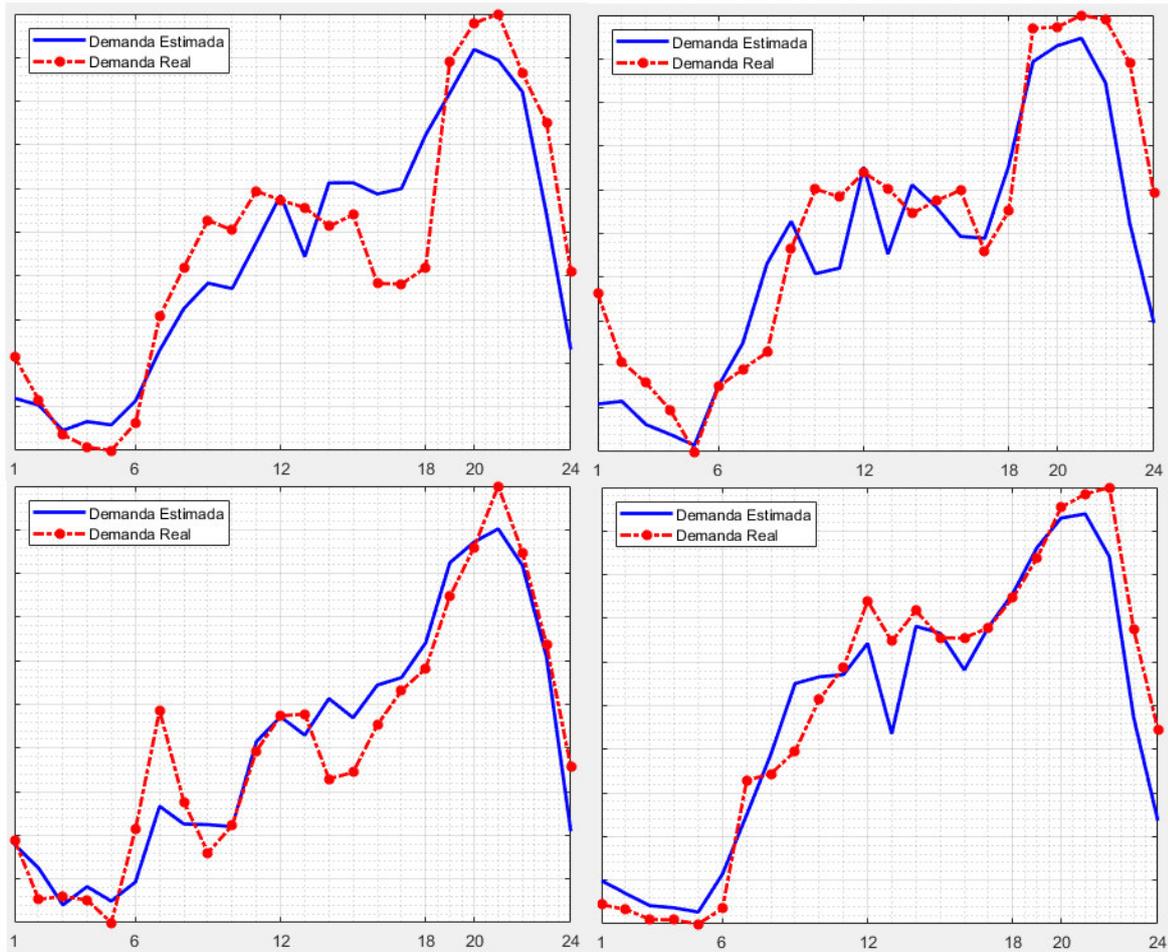


Figura 3.24 Curvas estimadas vs Curvas reales de la red neuronal 1 [Elaboración Propia].

En la Figura 3.25 se observa varios ejemplos de curvas estimadas y reales de transformadores pertenecientes a la clase 2, es decir para los transformadores Residenciales con incidencia comercial media. El coeficiente de correlación promedio de todos los transformadores de esta clase, calculado entre las curvas reales y estimadas, asciende a 0,93895. Este valor de coeficiente resulta muy adecuado para esta clase y constituye una garantía de que la red neuronal 2 pueda generar curvas muy parecidas a las curvas reales.

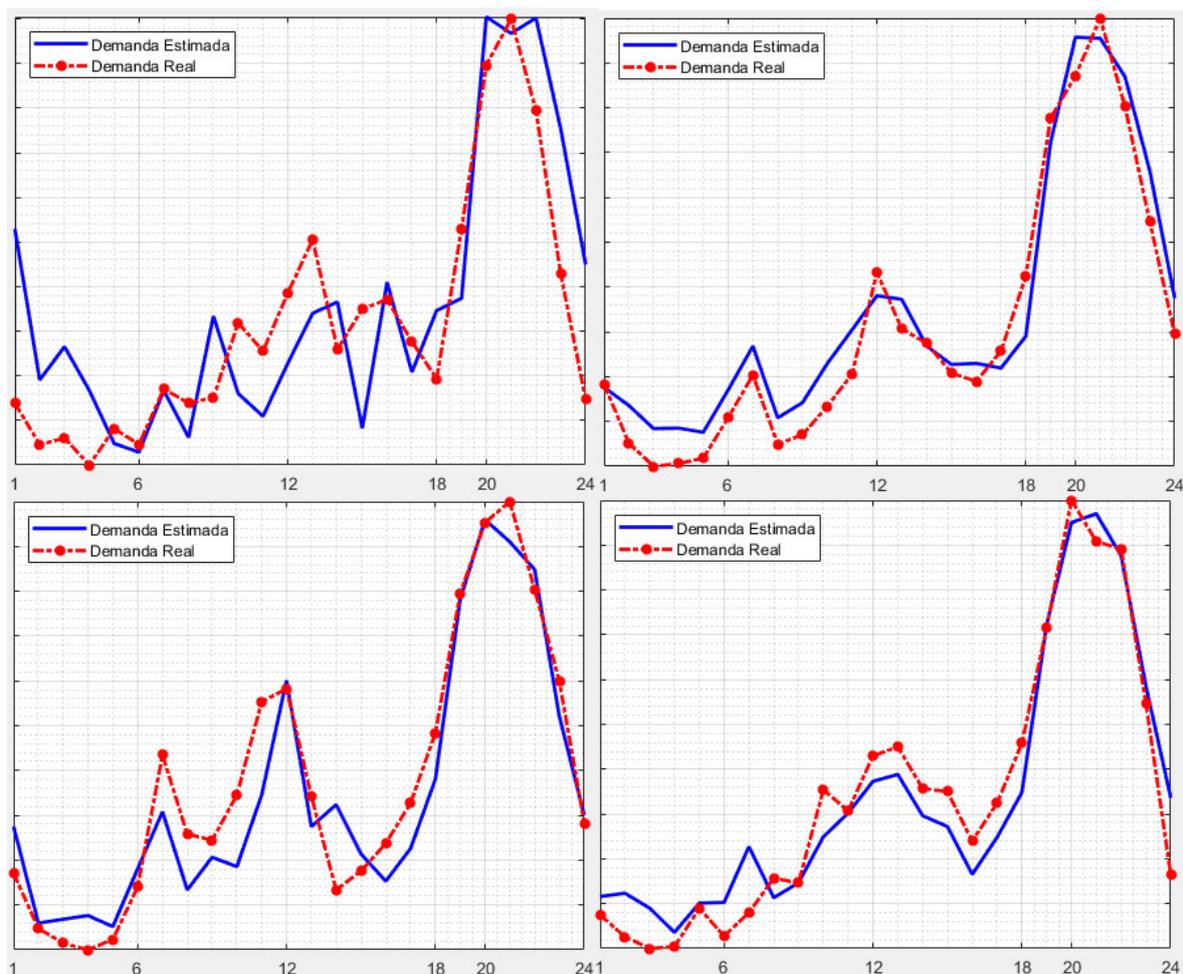


Figura 3.25 Curvas estimadas vs Curvas reales de la red neuronal 2 [Elaboración Propia].

En la Figura 3.26 se observa las curvas estimadas y reales de transformadores pertenecientes a la clase 3, es decir para transformadores netamente Comerciales. El coeficiente de correlación promedio de los transformadores de esta clase, calculado entre las curvas reales y estimadas es de 0,79597. Este coeficiente de correlación es el más bajo de todas las redes entrenadas y puede atribuirse a la falta de suficientes datos de entrenamiento. Esto causa que la red no tenga la suficiente información para lograr un aprendizaje generalizado y se confunda con las singularidades propias de los pocos datos a disposición.

La falta de información para entrenar esta red se debe principalmente a que los transformadores netamente comerciales en su mayoría pertenecen al estrato comercial medio y alto, por lo que muchos de estos clientes tienen sus propios transformadores de los cuales la CNEL Santo Domingo no dispone de mediciones de calidad de energía.

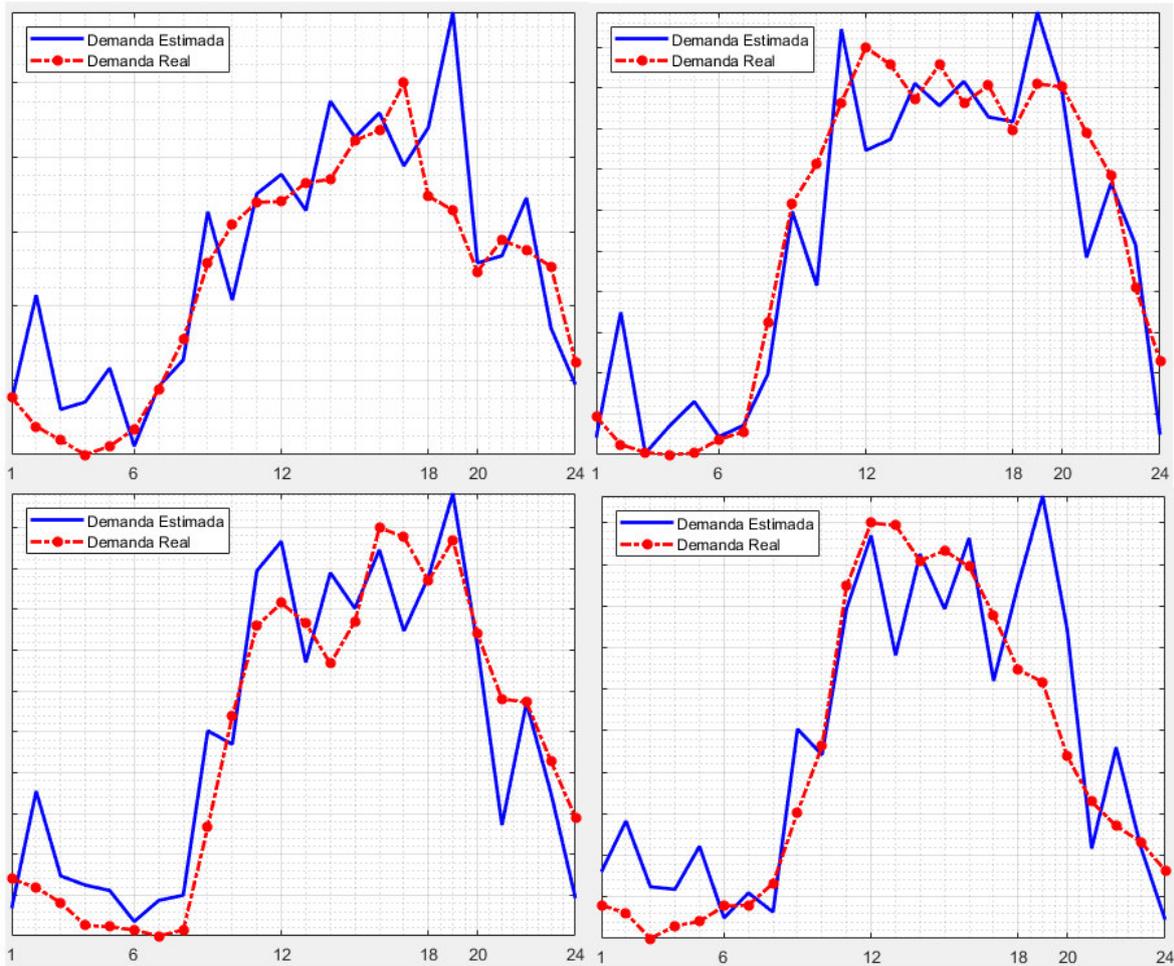


Figura 3.26 Curvas estimadas vs Curvas reales de la red neuronal 3 [Elaboración Propia].

En la Figura 3.27 se observa varios ejemplos de curvas estimadas y reales de transformadores pertenecientes a la clase 4, es decir para los transformadores Residenciales con incidencia comercial baja. El coeficiente de correlación promedio de todos los transformadores de esta clase, calculado entre las curvas reales y estimadas, asciende a 0,82031. El valor de error resulta aceptable y puede atribuirse a la falta de datos de entrenamiento y a la baja calidad de los mismos.

Se pudo evidenciar que la base de datos comercial de la CNEL Santo Domingo presenta errores de asignación de tipo de cliente, principalmente causado por usuarios comerciales pequeños que se encuentran registrados como usuarios residenciales. Esta situación se hace más evidente e influye claramente en el entrenamiento de esta red en específico, ya que la misma en su mayoría engloba clientes comerciales de bajo consumo energético, que son los que sufren de este inconveniente.

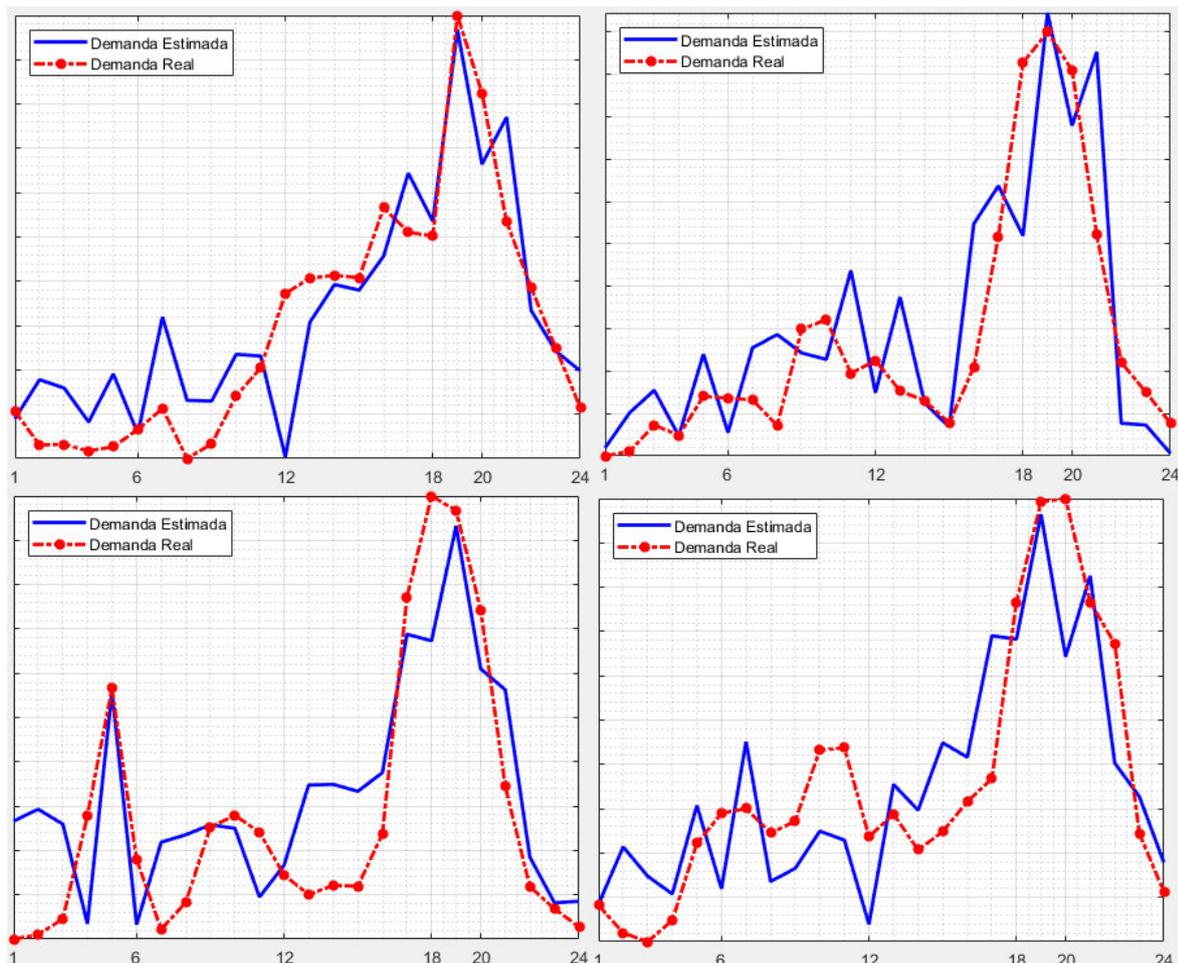


Figura 3.27 Curvas estimadas vs Curvas reales de la red neuronal 4 [Elaboración Propia].

En la Figura 3.28 se puede observar varios ejemplos de curvas estimadas y reales de transformadores pertenecientes a la clase 5, es decir para transformadores netamente Residenciales.

El coeficiente de correlación promedio de todos los transformadores de esta clase, calculado entre las curvas reales y estimadas resulta ser 0,94134. Este resultado demuestra un nivel de estimación bastante preciso para los transformadores pertenecientes a este grupo. Se puede notar en las gráficas, diferencias muy pequeñas entre ambas curvas, esto se atribuye al alto número de datos de entrenamiento pertenecientes a esta clase, y a que se comprobó in situ que los usuarios pertenecientes a los transformadores de esta clase efectivamente sean residenciales.

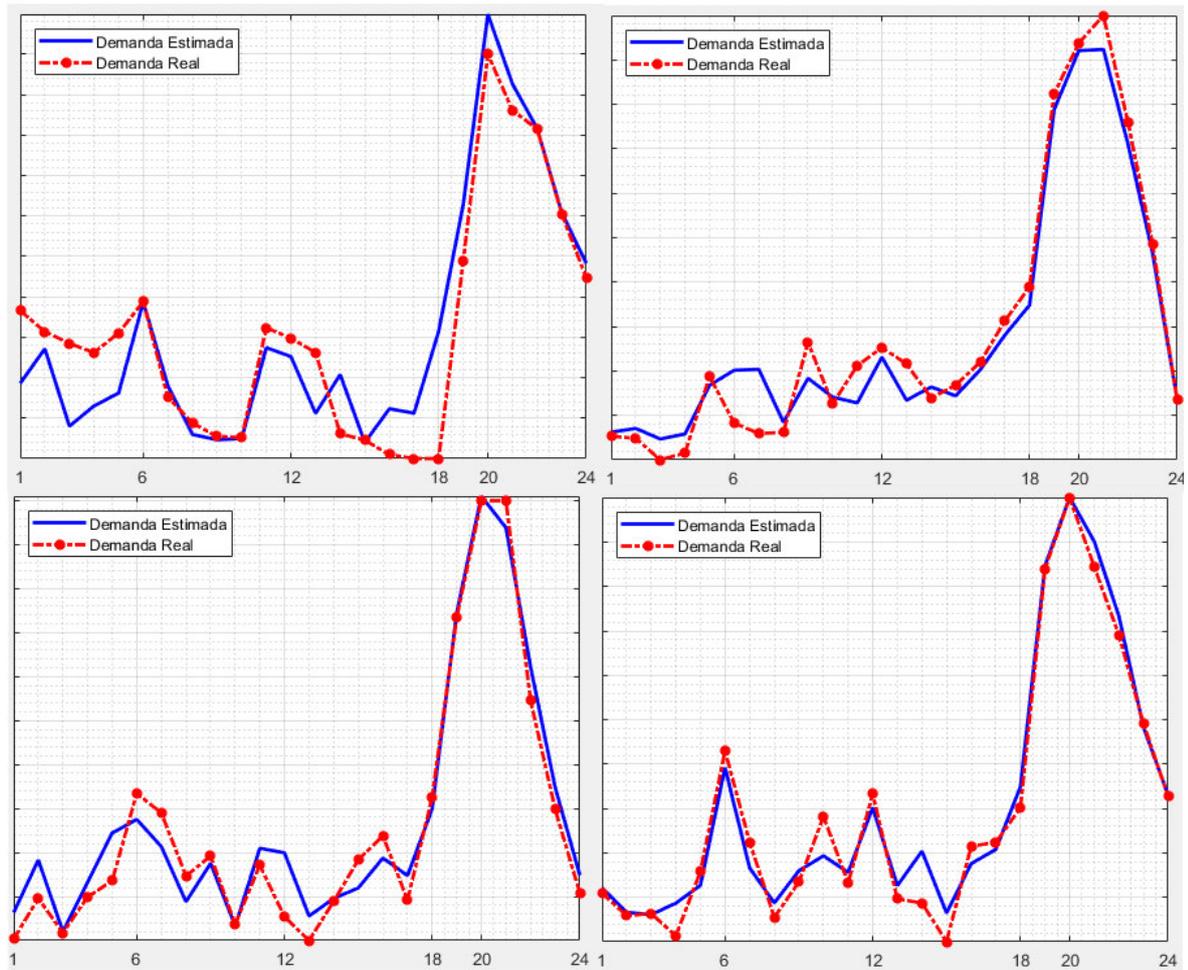


Figura 3.28 Curvas estimadas vs Curvas reales de la red neuronal 5 [Elaboración Propia].

En la Tabla 3.8 se resumen los resultados obtenidos de la validación externa del entrenamiento de las redes. Se puede remarcar que las dos clases con menor valor de coeficiente de correlación son precisamente las que mayor desviación estándar presentan. Este comportamiento indica que, en estas clases los resultados, si bien el valor promedio es aceptable, la dispersión de resultados que se puede obtener de estas redes es bastante alta, por lo tanto, sus resultados no son confiables.

**Tabla 3.8.** Coeficientes de correlación promedio de clases

Clase	Coefficiente de correlación promedio	Desviación estándar
1	0,91055	0,06408
2	0,93895	0,05706
3	0,79597	0,16706
4	0,82031	0,18847
5	0,94134	0,04063

### **3.3. Análisis de la aplicación de las redes neuronales entrenadas en un alimentador real**

El elemento escogido para la aplicación práctica de las redes neuronales es el alimentador "Circuito 2", perteneciente a la subestación Quevedo-G1 de la CNEL Santo Domingo, su número de identificación es 17QE020T12 y tiene una longitud total de 9,32 km. Este alimentador tiene un voltaje de 13,8 kV, cuenta con una carga instalada de 1,64 MVA y una capacidad de transformación de 1,69 MVA. Posee 68 transformadores monofásicos que suman una capacidad de 1,67 MVA y 1 banco de transformadores trifásico de capacidad 0,02 MVA. En la Figura 3.29 se puede observar la topología del alimentador bajo estudio y en el Anexo VIII los datos de los transformadores correspondientes al alimentador bajo estudio.

La selección del alimentador de prueba se realizó en función de dos criterios:

- La cantidad de transformadores y centros de carga presentes en el transformador: al tratarse de un estudio de validación, es conveniente trabajar con una red real reducida que se asemeje a un sistema de prueba. Donde sea posible controlar y supervisar fácilmente las variables de simulación, logrando con esto, identificar posibles fuentes de error con relativa rapidez y realizar los ajustes necesarios al modelo.
- La composición de clientes de cada transformador: los transformadores instalados en el alimentador deben poder ser utilizados con algunas de las redes neuronales disponibles. Caso contrario no se podría estimar su curva de demanda y el alimentador no contaría con la demanda en ese punto.

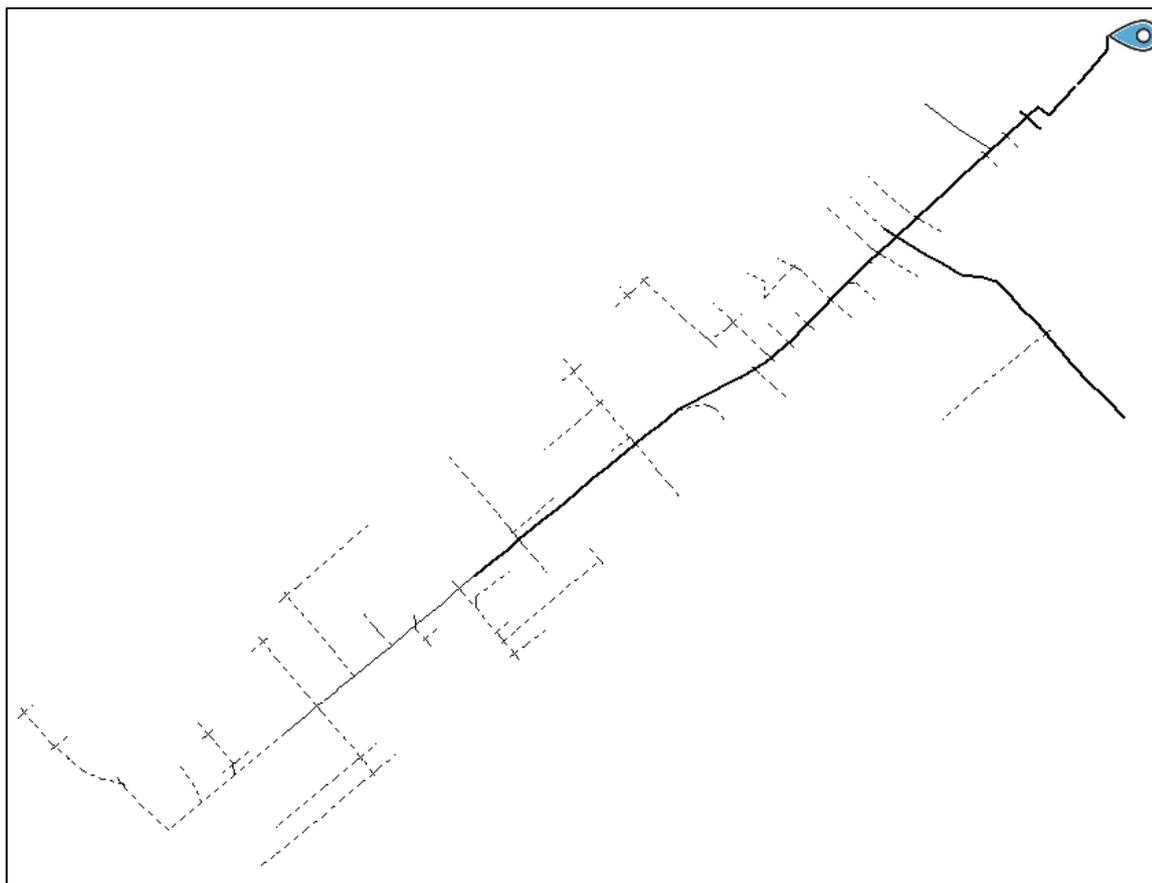


Figura 3.29 Alimentador S/E Quevedo – Circuito 2 [Elaboración Propia].

La metodología planteada para realizar la validación en el alimentador se basa en estimar, mediante las redes neuronales, las curvas de demanda horaria para todos los transformadores del alimentador Quevedo – Circuito 2. Dicha estimación se realizará en función de los datos comerciales de dichos transformadores y que pueden ser observados en el Anexo IX. Con los resultados de la estimación de la demanda horaria en todos los transformadores, se procedió a correr flujos de potencia en el alimentador, obteniendo resultados de demanda en la cabecera del alimentador. La validación se basa en comparar los resultados de los flujos, utilizando los datos logrados por la red neuronal, y mediciones reales del alimentador en el mismo punto.

En la Figura 3.30 se puede observar algunas de las curvas resultantes de la aplicación de las redes neuronales en los transformadores del alimentador 17QE020T12.

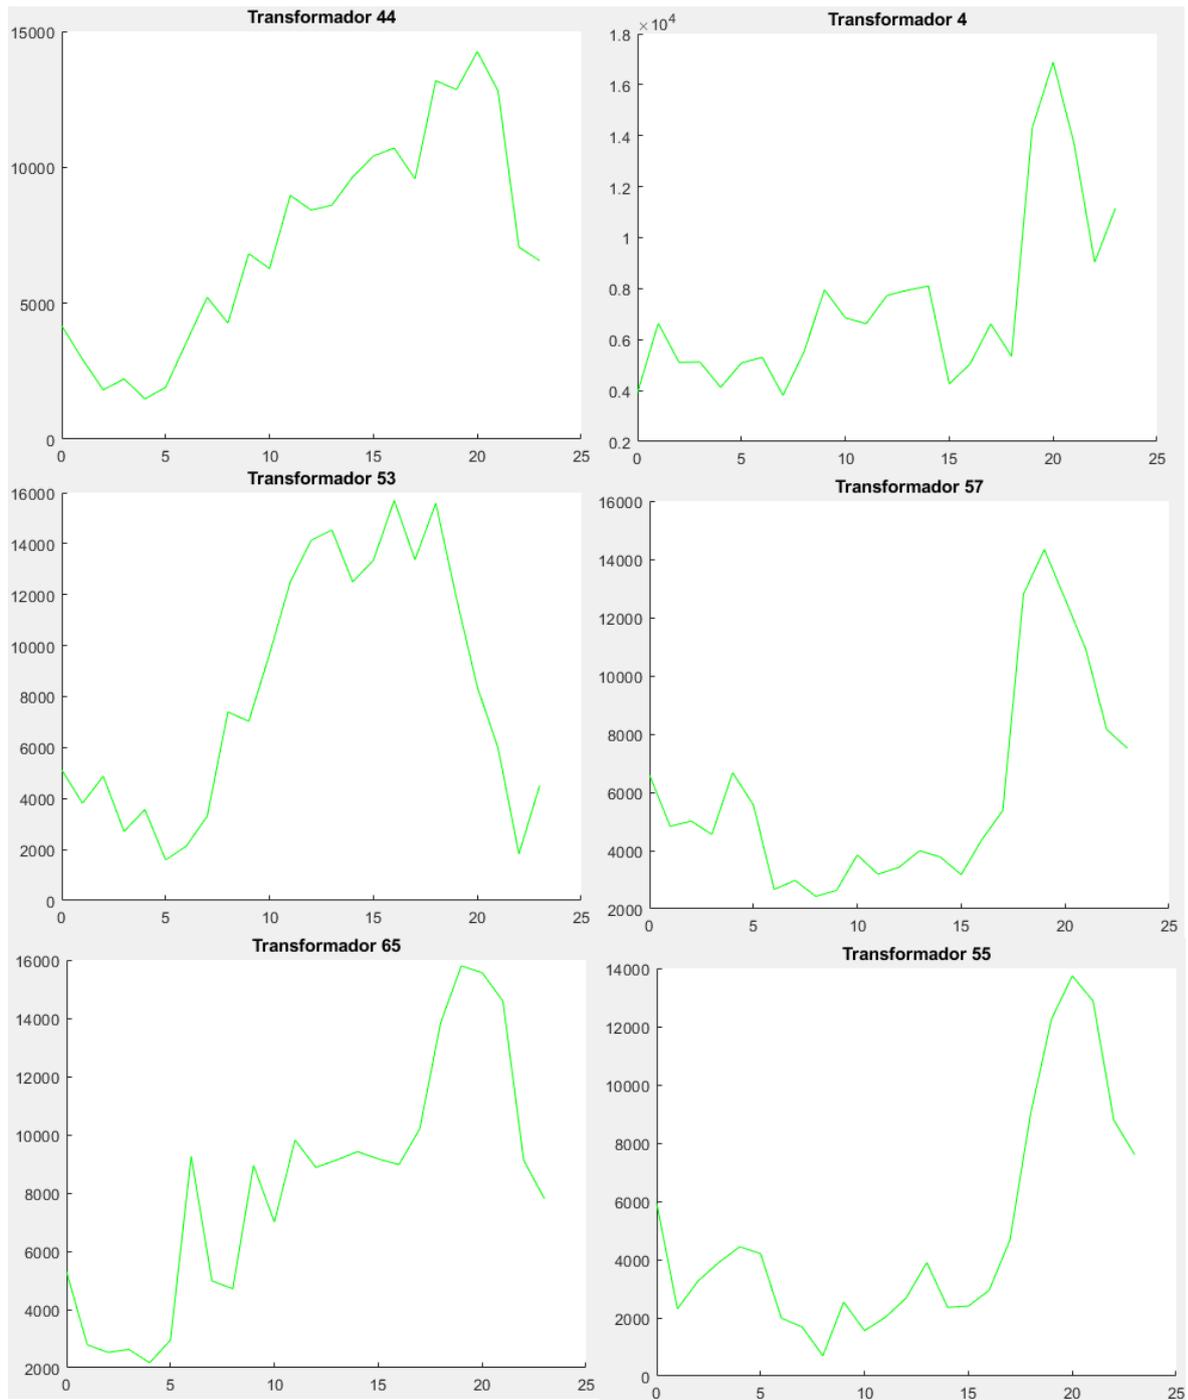


Figura 3.30 Curvas estimadas de transformadores del Alimentador Quevedo Circuito 2 [Elaboración Propia].

Cada una de las curvas estimadas corresponden a la carga instalada en los secundarios de los transformadores, incluyendo todos los elementos aguas abajo pertenecientes a la red secundaria de distribución. Significa entonces que los datos de potencia estimados, ya incluyen dentro de su valor las pérdidas técnicas y no técnicas de la red secundaria y representan la red secundaria en forma de una carga concentrada de potencia constante del tipo  $(P ; \cos\Phi)$ .

Para calcular los valores estimados de potencia en la cabecera del alimentador, se procede a simular 24 escenarios del alimentador de prueba en CYMDIST. Cada uno de los escenarios se forma con las estimaciones de potencia de todos los transformadores de distribución correspondientes a la hora respectiva.

Los datos de las curvas estimadas fueron exportados a Excel y cargados en la base de datos de Red del alimentador 17QE020T12. Este procedimiento se lo realizó a través de un archivo "Microsoft Access Database" con nombre CYMCUSTOMERLOAD.mdb, que contiene los datos de potencia de las cargas del alimentador modelados en CYMDIST, y que facilmente puede ser cambiados, como se observa en la Figura 3.31.

Emergency	CenterTapP	LoadValue1	Phase	CenterTapP	Connected	LoadValue1	LoadValue2	KWHUsage	NumberOf	LoadValue1	LoadValue2	DeviceNum	LoadValue2
0	0	2	1	0.24	13.87238817	95	136	1				MTA_L_22301	
0	0	2	1	0	13.87238817	100	0	0				MTA_L_22301	
0	0	2	1	0.42	17.58997649	95	126	1				MTA_L_71971	
0	0	2	1	0	17.58997649	100	0	0				MTA_L_71971	
0	0	2	1	0.52	6.453483706	95	66	1				MTA_L_23948	
0	0	2	1	0	6.453483706	100	0	0				MTA_L_23948	
0	0	2	2	0	6.564884897	95	0	1				MTA_L_729	
0	0	2	2	0	6.564884897	100	0	0				MTA_L_729	
0	0	2	2	0.44	9.458525510	95	112	1				MTA_L_88743	
0	0	2	2	0	9.458525510	100	0	0				MTA_L_88743	
0	0	2	3	0.75	11.1528183	95	95	1				MTA_L_11740	
0	0	2	3	0	11.1528183	100	0	0				MTA_L_11740	
0	0	2	2	0.81	7.301481713	95	89	1				MTA_L_52083	
0	0	2	2	0	7.301481713	100	0	0				MTA_L_52083	
0	0	2	2	10	0.622455132	95	213	1				MTA_L_60708	
0	0	2	2	0	0.622455132	100	0	0				MTA_L_60708	
0	0	2	1	0.56	13.28808312	95	92	1				MTA_L_25034	
0	0	2	1	0	13.28808312	100	0	0				MTA_L_25034	
0	0	2	1	0.29	20.09700058	95	257	1				MTA_L_33753	
0	0	2	1	0	20.09700058	100	0	0				MTA_L_33753	
0	0	2	1	0.54	7.528563064	95	74	1				MTA_L_22909	
0	0	2	1	0	7.528563064	100	0	0				MTA_L_22909	
0	0	2	1	0.87	7.888494122	95	168	1				MTA_L_24891	
0	0	2	1	0	7.888494122	100	0	0				MTA_L_24891	
0	0	2	1	0.48	5.367841819	95	184	1				MTA_L_63435	
0	0	2	1	0	5.367841819	100	0	0				MTA_L_63435	
0	0	2	1	0.79	3.165820426	95	0	1				MTA_L_25975	
0	0	2	1	0	3.165820426	100	0	0				MTA_L_25975	
0	0	2	1	0.32	7.044042229	95	101	1				MTA_L_10643	
0	0	2	1	0	7.044042229	100	0	0				MTA_L_10643	
0	0	2	1	0.61	9.070393892	95	106	1				MTA_L_77636	
0	0	2	1	0	9.070393892	100	0	0				MTA_L_77636	
0	0	2	3	0.26	10.5081628	95	131	1				MTA_L_19835	
0	0	2	3	0	10.5081628	100	0	0				MTA_L_19835	

Figura 3.31 Datos de potencia de transformadores en Base de datos de Access [Elaboración Propia].

La base de datos de Access actualizada se importa en CYMDIST y con ello se procedió a simular los flujos de carga para los 24 escenarios. Los resultados del flujo se toman a la salida de la S/E Quevedo, como se evidencia en la Figura 3.32, en donde se muestra los valores de potencia para la hora 24.

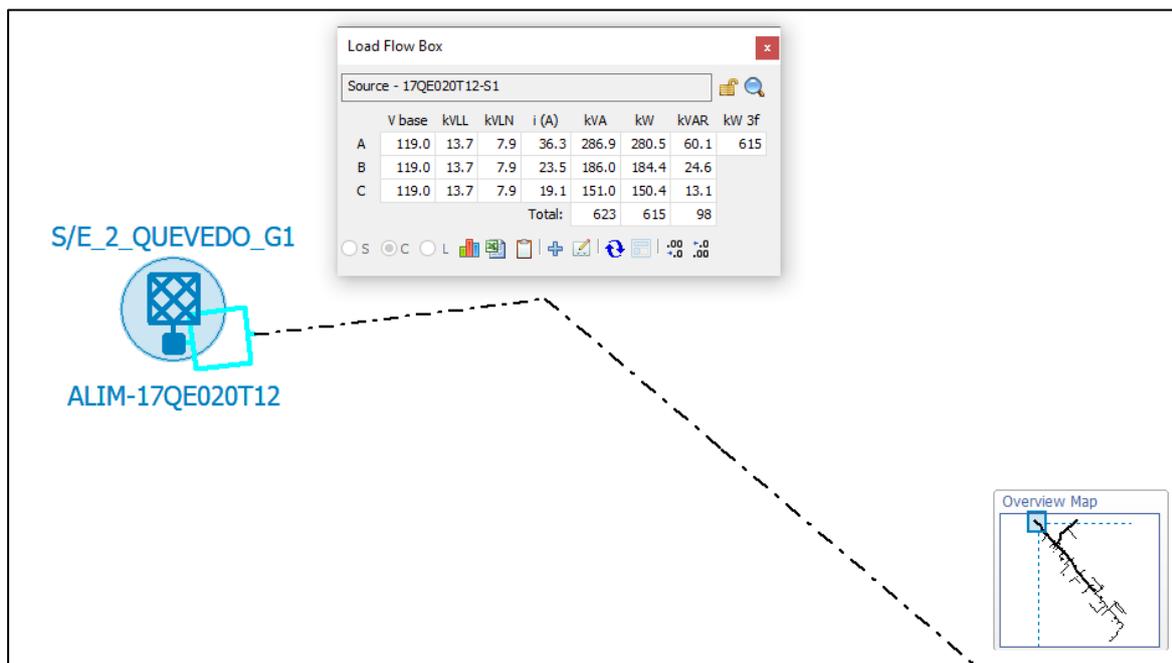


Figura 3.32 Resultados de Flujo de carga para la hora 24, simulados en CYMDIST [Elaboración Propia].

Los resultados de cada uno de los 24 escenarios fueron exportados a Excel para su análisis final. En la Figura 3.33 se muestra la comparación de resultados entre el perfil de demanda horaria de la simulación de CYMDIST y las lecturas reales en cabecera del alimentador de prueba. Se puede notar que la curva estimada sigue en gran medida la tendencia de la curva real, a pesar de que existe una diferencia importante de magnitud entre ellas, especialmente durante el pico nocturno de 20:00 a 22:00 horas.

La Figura 3.34 muestra el histograma de errores porcentuales calculados entre los datos de la curva estimada y la curva real, se puede notar que el error fluctúa entre 0,12% y 19,33%. Se nota especialmente en el horario pico nocturno una sobreestimación de la demanda, lo cual puede atribuirse a diversos factores:

- Cuando se aplica la red neuronal a cada transformador y posteriormente esos datos se llevan aguas arriba para estimar la demanda del alimentador, la red no considera la coincidencia de las demandas entre transformadores, por lo que se tiene a aumentar exponencialmente el valor de la demanda máxima del alimentador sin tomar en cuenta el concepto de simultaneidad.
- La presencia de clientes industriales cuya curva no ha sido estimada en el presente trabajo

- Al tratarse de un alimentador nuevo y alejado del centro de la urbe, existe importante presencia de hurto de energía y consumidores comerciales que están registrados como residenciales.
- Diversas aproximaciones que se realizaron durante el tratamiento de datos y entrenamiento de la red, principalmente debido al número insuficiente y a la mala calidad de los datos.

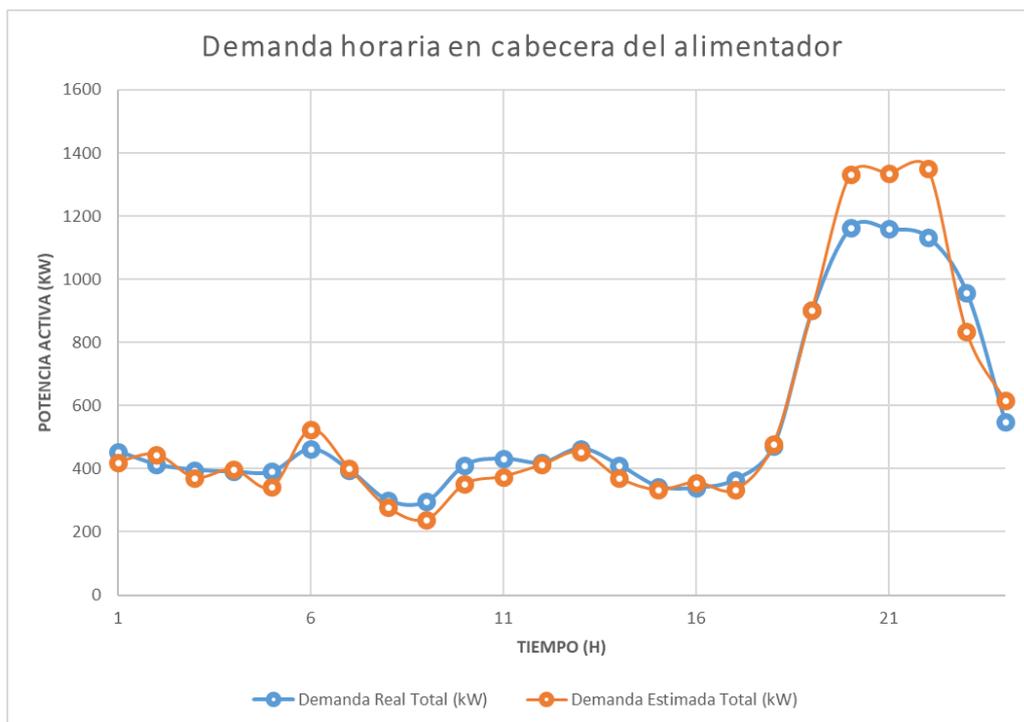


Figura 3.33 Curvas de demanda horaria en cabecera del Alimentador de prueba [Elaboración Propia].

Si bien los resultados de errores en las curvas de demanda resultan ser menores al 20%, por otro lado, el error de energía diaria resulta ser muy bajo como se puede observar en la Figura 3.35, el mismo asciende únicamente al 1,75%.

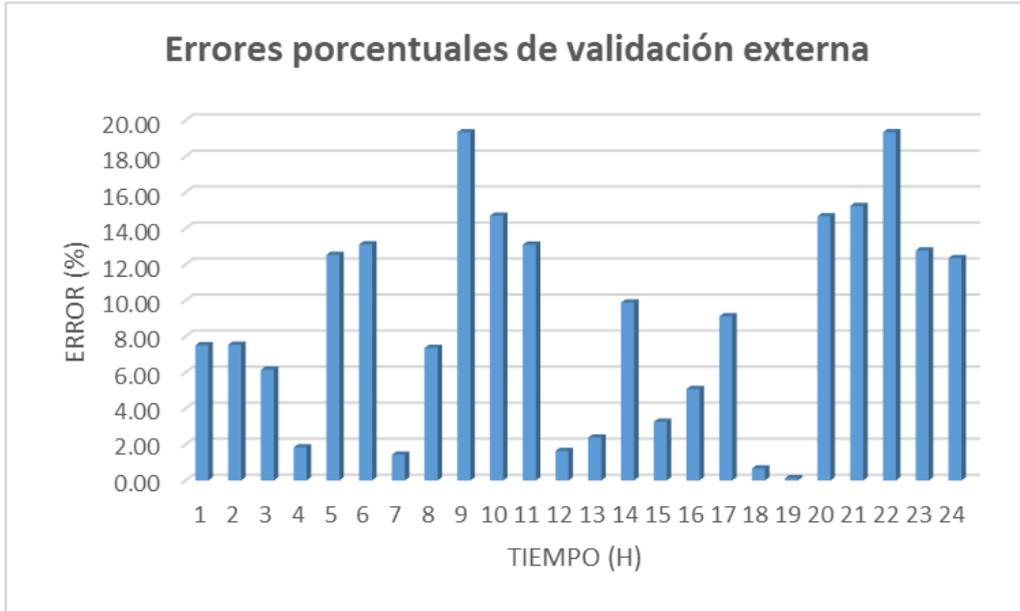


Figura 3.34 Errores de estimación de Curvas de demanda horaria en cabecera del Alimentador de prueba [Elaboración Propia].

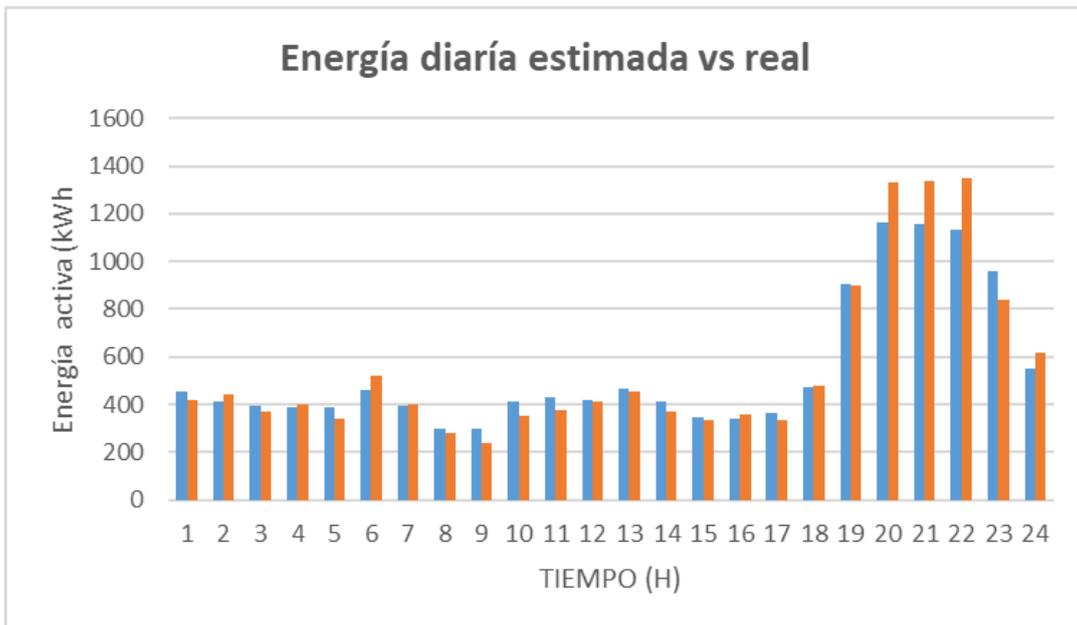


Figura 3.35 Energía real vs estimada consumida por Alimentador de prueba [Elaboración Propia].

Utilizando los datos de las curvas de demanda estimadas se calculó los factores de pérdidas correspondientes a los transformadores de distribución del alimentador de prueba con la ayuda de la Ecuación 1.21, obteniéndose los resultados de la Figura 3.36.

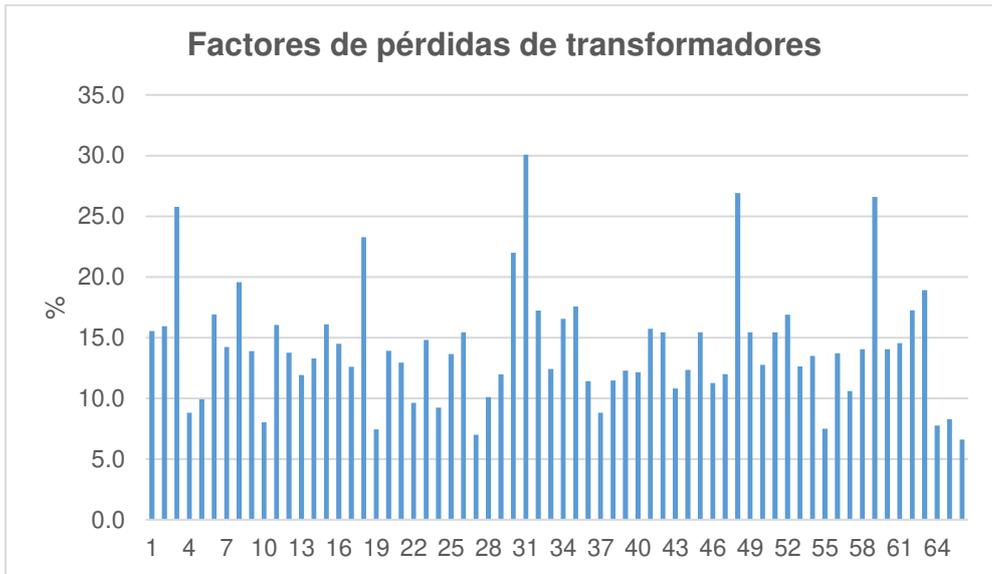


Figura 3.36 Factores de pérdidas en transformadores del alimentador de prueba [Elaboración Propia].

El cálculo del factor de pérdidas en el alimentador de prueba se lo realiza mediante la Ecuación 1.23, utilizando los datos de demanda en cabecera del alimentador, obteniéndose un valor de 0,41.

El contar con las curvas diarias de demanda de los transformadores de distribución resulta una gran ventaja para calcular las pérdidas de energía en los transformadores y las líneas del alimentador, esto debido a que se poseen los datos de demanda máxima en cada transformador. Mientras que el procedimiento convencional llevado por el personal de la CNEL Santo Domingo se basa en obtener resultados aproximados a partir de simulaciones de distribuciones de carga en CYMDIST.

## 4. CONCLUSIONES Y RECOMENDACIONES

### CONCLUSIONES

- El desarrollo de una herramienta de estimación de la demanda requiere de una base de datos actualizada y verificada de equipos, redes y clientes. De la calidad, objetividad y cantidad suficiente de información, dependerán directamente la precisión y la exactitud de la estimación. Mas concretamente, para la estimación de curvas de demanda eléctrica en transformadores de distribución realizada en el presente proyecto, los datos comerciales de tipo de cliente proporcionados por la CNEL Santo Domingo presentan muchas inconsistencias, que produjeron sesgos en el aprendizaje de las redes neuronales. Así mismo la cantidad de datos de entrenamiento resultaron insuficientes en algunas redes neuronales que se pretendía entrenar, debido a que las mediciones no fueron tomadas con el objetivo de contar con los suficientes datos para cada tipo de transformador.
- Existen tipos de curvas que pueden ser estimadas con facilidad por cualquier herramienta estadística o de inteligencia artificial, sin embargo, hay clientes como los industriales, grandes consumidores y consumidores especiales, cuyos comportamientos son muy variables y es muy difícil encontrar un patrón de comportamiento adecuado. Este es el caso también de las curvas de potencia reactiva, cuyo comportamiento es muy errático y muy complicado de predecir a nivel de los transformadores de distribución. Para este tipo de clientes y curvas resulta más efectivo la aplicación de métodos de estimación determinísticos como la adición de curvas patrón de clientes por tipo, basadas en los datos históricos de la demanda.
- La selección de las curvas de entrenamiento, validación y prueba de las redes neuronales es un proceso neurálgico de la estimación. El agrupamiento de curvas realizado previo al entrenamiento, permitió lograr mejores resultados, al trabajar con un número mayor de neuronas especializadas en la resolución de un tipo de problema en específico, sin llegar a sobre entrenarlas y que pierdan por otro lado su capacidad de generalización.

- La creación y parametrización de una red neuronal no se realiza mediante un procedimiento definido o estándar, es más bien un método heurístico de prueba y error el que determina sus ajustes estructurales y funcionales. En el presente proyecto se llevó a cabo dos etapas de validación de las redes, que permitieron ajustar los parámetros de entrenamiento de modo que se obtengan resultados de estimación satisfactorios.
- Los resultados de la validación externa son muy exitosos ya que presentan una precisión promedio del 94%, de esta manera comprueban la teoría de que las redes neuronales artificiales constituyen una herramienta muy efectiva para solucionar problemas de estimación de demanda, gracias a su capacidad de reconocer y aprender sobre patrones no lineales. Por lo tanto, se puede concluir que para obtener la curva de carga de un transformador no es necesario realizar mediciones, basta con estimarla a partir de sus datos comerciales.
- Si bien la estimación de la demanda de los transformadores pertenecientes a un alimentador de prueba, dio como resultado valores de error moderado en las estimaciones de demanda en la cabecera del alimentador, por otro lado, la energía diaria y los valores de demanda estimados a nivel de cada transformador de distribución resultaron ser muy exactos. Bajo este criterio, se puede concluir que, utilizando el método de estimación por Redes Neuronales Artificiales, los resultados se pueden utilizar en diversas aplicaciones como el diagnóstico de cargabilidad de transformadores de distribución, valoración de pérdidas de energía y demás estudios que requieran de un perfil de carga y energía a nivel de transformadores de distribución.
- La aplicación de redes neuronales para estimar curvas de transformadores en un alimentador produce una sobre estimación en los picos de demanda en la cabecera del mismo, para solucionar este inconveniente es recomendable correr una distribución de carga en CYMDIST tomando como referencia alguna medición real, para obtener resultados más cercanos a la realidad.

## RECOMENDACIONES

- La exactitud de las curvas que se obtienen como resultado de la estimación, dependen directamente de la calidad de los datos de entrenamiento que se ponga a disposición de las redes neuronales. Es por ello que se recomienda la realización de una campaña de medición dedicada para obtener la cantidad suficiente de lecturas para cada red neuronal, considerando además los adecuados criterios de aleatoriedad y muestreo para los transformadores de cada clase. La implementación de una campaña de medición a una muestra estadística de transformadores de cada tipo, garantizará que las redes entrenadas puedan aplicarse a todo el universo de transformadores de la CNEL Santo Domingo, y que la metodología desarrollada en el presente proyecto pueda implementarse exitosamente en todos sus alimentadores.
- Se recomienda a la empresa distribuidora, realizar una campaña de actualización del catastro de clientes y/o base de datos comercial, que tenga como objetivo verificar las categorías y el uso de la energía de los consumidores. La categoría residencial solo debe incluir a consumidores con uso de la energía exclusivamente doméstico o con una pequeña actividad comercial o artesanal. La recategorización de los clientes erróneamente catalogados, permitirá no solamente la correcta aplicación de la metodología de estimación planteada en el presente proyecto, sino también sincerará las tarifas pagadas por los consumidores y las estadísticas del uso de la energía.
- La metodología desarrollada en el presente proyecto de titulación tiene aplicaciones adicionales como la estimación y pronóstico de la demanda de energía y potencia en otros escenarios y puntos del sistema eléctrico. La estimación y pronóstico de la demanda mediante redes neuronales a nivel de alimentadores de media tensión y subestaciones de distribución pueden realizarse siguiendo el procedimiento propuesto y obteniendo resultados con mayor exactitud, debido a que las mediciones aguas arriba son más abundantes y de mejor calidad, y a que el comportamiento de la demanda aguas arriba tiende a ser menos errático en el tiempo.

## 5. REFERENCIAS BIBLIOGRÁFICAS

- [1] S. Chemetova, P. Santos, and M. Ventim, "Load Forecasting in Electrical Distribution Grid of Medium Voltage," Techn. Innovat. Cyber-Phys. Syst. Doct. Conf. on Comput, Electrical and Industrial Systems, Portugal, 2016, pp. 340-349.
- [2] J. Fidalgo, "Load curve estimation for distribution systems using ANN," *Proceedings of 7th World Scientific and Engineering Academy and Society, Computational Intelligence, Man-Machine Systems and Cybernetics*, El Cairo, Egipto, 2008, pp. 197–202.
- [3] X. González, A. Perea, G. Caicedo and F. Castro, "Estimación de curvas de carga en transformadores eléctricos mediante redes neuronales," *Revista Ingeniería y Competitividad*, vol. 10, Universidad del Valle, Colombia, 2008, pp. 75–86.
- [4] J. Salas, "Desarrollo con Matlab de una Red Neuronal para estimar la demanda de Energía Eléctrica," M.S. thesis, Dpto. Ing. Eléct., Universidad de Valladolid, España, 2016.
- [5] H. Hippert, C. Pedreira and R. Souza, "Neural networks for short-term load forecasting: a review and evaluation," *IEEE Trans. Power Systems*, vol. 16, no. 1, 2001, pp. 44-55.
- [6] J. Bilbao, E. Torres and J. Saenz, "Load curve estimation by means of prediction intervals," *10th Mediterranean Electrotechnical Conference. Information Technology and Electrotechnology for the Mediterranean Countries. Proceedings*, vol.3, 2000, pp. 970-972.
- [7] D. Falcao, H. Henriques, "Load estimation in radial distribution systems using neural networks and fuzzy set techniques," *2001 Power Engineering Society Summer Meeting. Conference Proceedings*, Vancouver, Canada, vol.2, 2001, pp. 1002-1006.
- [8] L. Hernández, C. Baladrón, J. Aguiar, B. Carro, A. Sánchez and J. Lloret, "Artificial neural networks for short-term load forecasting in microgrids environment," Elsevier, Universidad de Valladolid, España, 2014.
- [9] J. Álvarez, "Metodología para la estimación de curva de carga diaria para un circuito de media tensión (13.2 kV) a partir de técnicas inteligentes," M.S. thesis, Dpto. Ing Eléct. y Comp., Universidad Nacional de Colombia, Colombia, 2017.

- [10] D. Matich, "Redes Neuronales: Conceptos Básicos y Aplicaciones," M.S. thesis, Facult. Reg. Ros., Universidad Tecnológica Nacional, Argentina, 2001.
- [11] *Especificaciones Técnicas SCADA/OMS-MWM/DMS*, Ministerio de Electricidad y Energía Renovable, Proyecto SIGDE, Quito, Ecuador, 2012, pp. 3–7.
- [12] T Konjić, V Miranda, I Kapetanovic, "Fuzzy Inference Systems applied to LV Substation Load Estimation," *IEEE Trans. Power Systems*, vol. ED-20, no. 2, pp. 742–749, 2005.
- [13] M. Medina, "Estimación de Curvas de Demandas de Transformadores de Distribución," *X Seminario del Sector Eléctrico Paraguayo*, Asunción, Paraguay, vol.10, 2012.
- [14] J. Uribe, "Short-term Load Estimation for a Low-Voltage Transformer Station," M.S. thesis, EEH Power Systems Laboratory, Zurich, Switzerland, 2016.
- [15] N. Hodzic, T. Konjic and V. Miranda, "Artificial Neural Networks Applied To Short Term Load Diagram Prediction," 8th Seminar on Neural Network Applications in Electrical Engineering, Belgrade, Serbia & Montenegro, 2006, pp. 219-223.
- [16] J. Han, M. Kamber, J. Pei, "Data Mining Concepts and Techniques," Morgan Kaufmann, Waltham, Massachusetts, USA, 2006.
- [17] Z. Yanchang, "R and Data Mining: Examples and Case Studies," Elsevier, Sydney, Australia, 2015.
- [18] H. Cho, "Opto-mechatronic systems handbook," CRC Press, Boca Raton, Florida, USA, 2002.
- [19] B. Everitt, "Cluster Analysis," Wiley Series in Probability and Statistics, Londres, Reino Unido, USA, 2011.
- [20] Agencia de Regulación y Control de Electricidad, "Atlas del Sector Eléctrico Ecuatoriano," Quito, Ecuador, 2018.

- [21] A. Pacheco, "Imputación Estadística: Una aplicación al sistema nacional interconectado del Ecuador," Tesis de Maestría, EPN, Quito, Ecuador, 2008.
- [22] M. Hudson, M Hagan, H Demuth, "Neural Network Toolbox - User's Guide," MathWorks Inc, Natick, Massachusetts, USA, 2015.
- [23] N. Mahmoudi-Kohan, M Moghaddam, S Bidaki, "Evaluating Performance of WFA K-means and Modified Follow the Leader Methods for Clustering Load Curves," IEEE/PES Power Systems Conference and Exposition, Seattle, USA, 2009.
- [24] G. Chicco, R. Napoli, P. Postolache, M. Scutariu and C. Toader, "Customer Characterization Options for Improving the Tariff Offer," IEEE Tans, On Power Sys, Vol. 18, 2003.
- [25] L. Martínez, J. Reyes, C. Sánchez, "Análisis de Estratificación de clientes para la Unidad de Negocio Santo Domingo," CNEL EP, Santo Domingo, Ecuador, 2018.
- [26] L. Martínez, J. Reyes, C. Sánchez, "Estudio de pérdidas técnicas de potencia y energía para la Unidad de Negocio Santo Domingo," CNEL EP, Santo Domingo, Ecuador, 2020.
- [27] J. Brownlee, "Deep Learning with Python," CNEL EP, Melbourne, Australia, 2016.
- [28] D. Yin-Chun, A. Stephanus, "Levenberg-Marquardt Neural Network Algorithm for Degree of Arteriovenous Fistula Stenosis Classification," Department of Electrical Engineering, Southern Taiwan University of Science and Technology, Tainan, Taiwan, 2018.
- [29] S. Sapna, A. Tamilarasi, M. Pravin, "Backpropagation Learning Algorithm based on Levenberg Marquardt Algorithm," Computer Science & Information Technology Journal, Tamilnadu, India, 2012.
- [30] F. González, " Evaluación estadística del comportamiento de líneas aéreas de distribución frente a sobretensiones de origen externo - Aplicación de Redes Neuronales

en el cálculo de sobretensiones y tasa de contorneamientos", Tesis Doctoral, Universidad Politécnica de Catalunya, Departamento de Energía Eléctrica, Barcelona, España, 2001.

[31] C. Oña, " Análisis para la compensación de potencia reactiva del alimentador circuito dos perteneciente a la subestación vía Quevedo de la CNEL EP Unidad de Negocio Santo Domingo", Universidad Técnica de Cotopaxi, Proyecto de Investigación, Latacunga, Ecuador, 2016.

## **6. ANEXOS**

**ANEXO I.** Infraestructura de Alimentadores de Medio Voltaje de la CNEL Santo Domingo

**ANEXO II.** Infraestructura de Transformadores de Potencia de la CNEL Santo Domingo.

**ANEXO III.** Base comercial de Transformadores de Potencia de la CNEL Santo Domingo.

**ANEXO IV.** Gráficas de desempeño del entrenamiento de las redes neuronales.

**ANEXO V.** Gráficas de parámetros de entrenamiento de las redes neuronales.

**ANEXO VI.** Histogramas de errores de entrenamiento de las redes neuronales.

**ANEXO VII.** Gráficas de regresión de resultados de las redes neuronales.

**ANEXO VIII.** Datos eléctricos de los Transformadores del Alimentador Circuito 2 de la S/E Quevedo

**ANEXO IX.** Datos comerciales de los Transformadores del Alimentador Circuito 2 de la S/E Quevedo

**ANEXO X.** Código de la herramienta desarrollada en Matlab.