



# UNIVERSIDAD TÉCNICA DE COTOPAXI

## DIRECCIÓN DE POSGRADO

### MAESTRÍA EN ELECTRICIDAD

#### MODALIDAD: INFORME DE INVESTIGACIÓN

**Título:**

**Entrenamiento de una red neuronal artificial para el control de voltaje y reducción de pérdidas en la red de subtransmisión de 69kV de la EERSA**

Trabajo de titulación previo a la obtención del título de Magister en Electricidad  
mención Sistemas Eléctricos de Potencia

**Autor:**

Ing. Chiguano Velasco Alvaro Napoleón

**Tutor:**

Ing. MSc. Castillo Fiallos Jessica Nataly

LATACUNGA – ECUADOR

2023

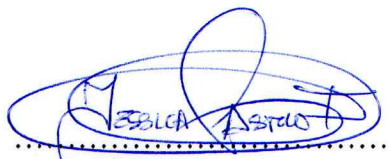
## **AVAL DEL TUTOR**

En mi calidad de Tutor del Trabajo de Titulación “Entrenamiento de una RNA para el control de voltaje y reducción de pérdidas en la red de subtransmisión de 69kV de la EERSA” presentado por Chiguano Velasco Alvaro Napoleón, para optar por el título de magíster en Electricidad mención sistemas eléctricos de potencia

### **CERTIFICO**

Que dicho trabajo de investigación ha sido revisado en todas sus partes y se considera que reúne los requisitos y méritos suficientes para ser sometido a la presentación para la valoración por parte del Tribunal de Lectores que se designe y su exposición y defensa pública.

Latacunga, febrero, 20, 2022



MSc. Castillo Fiallos Jessica Nataly  
CC.: 0604590216


## AVAL DEL TRIBUNAL

El trabajo de Titulación: Entrenamiento de una RNA para el control de voltaje y reducción de pérdidas en la red de subtransmisión de 69kV de la EERSA ha sido revisado, aprobado y autorizado su impresión y empastado, previo a la obtención del título de Magíster en Electricidad mención sistemas eléctricos de potencia; el presente trabajo reúne los requisitos de fondo y forma para que el estudiante pueda presentarse a la exposición y defensa.


Latacunga, febrero, 20, 2023



.....  
MsC. Porras Reyes Jefferson Alberto  
0704400449  
Presidente del tribunal



.....  
MsC. Toaza Iza Jimmy Xavier  
1717621062  
Lector 2



.....  
MsC. Hinojosa Guanoluisa Luis Eduardo  
0502365810  
Lector 3

## **AGRADECIMIENTO**

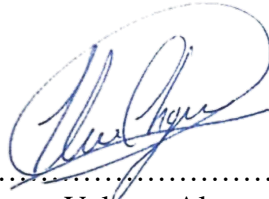
A mi familia y a mis colegas de la EERSA que han sido mi apoyo para la culminación de esta nueva meta en mi vida.

Alvaro Napoleón Chiguano Velasco

## RESPONSABILIDAD DE AUTORÍA

Quien suscribe, declara que asume la autoría de los contenidos y los resultados obtenidos en el presente trabajo de titulación.

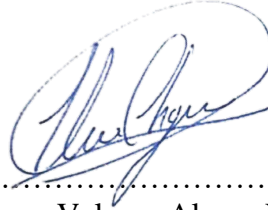
Latacunga, febrero, 20, 2023



.....  
Ing. Chiguano Velasco Alvaro Napoleón  
CC.: 1723905954

## RENUNCIA DE DERECHOS

Quien suscribe, cede los derechos de autoría intelectual total y/o parcial del presente trabajo de titulación a la Universidad Técnica de Cotopaxi.



Latacunga, febrero, 20, 2023

.....  
Ing. Chiguano Velasco Alvaro Napoleón  
CC.: 1723905954

## **AVAL DEL PRESIDENTE DEL TRIBUNAL**

Quien suscribe, declara que el presente Trabajo de Titulación: Entrenamiento de una RNA para el control de voltaje y reducción de pérdidas en la red de subtransmisión de 69kV de la EERSA contiene las correcciones a las observaciones realizadas por los lectores en sesión científica del tribunal.

Latacunga, febrero, 20, 2023



.....  
MsC. Porras Reyes Jefferson Alberto  
0704400449

**UNIVERSIDAD TÉCNICA DE COTOPAXI  
DIRECCIÓN DE POSGRADO**

**MAESTRÍA EN ELECTRICIDAD  
MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA**

**Título: Entrenamiento de una RNA para el control de voltaje y reducción de pérdidas en la red de subtransmisión de 69kV de la EERSA**

**Autor:** Chiguano Velasco Alvaro Napoleón

**Tutor:** MSc. Castillo Fiallos Jessica Nataly

**RESUMEN**

En el presente trabajo se realiza el entrenamiento y evaluación de redes neuronales para el mejoramiento de los perfiles de voltaje y reducción de pérdidas mediante compensación capacitiva, aplicándolo al sistema de 69kV de la Empresa Eléctrica Riobamba S. A. El proceso de entrenamiento empieza por el desarrollo de una metodología de optimización que determinará los mejores valores de reactivos a inyectar en cada instante y en cada una de las barras, se determinará probabilísticamente los diferentes eventos de operación que pueden ocurrir en el sistema y se aplicara la metodología de optimización para generar una respuesta de salida a cada evento evaluado. Finalmente, el proceso de entrenamiento de las RNAs tomará como parámetros de entrada y salida a los eventos y respuestas previamente determinados, las redes entrenadas serán evaluado ante diferentes condiciones de operación, finalmente se presenta una propuesta de implementación del proyecto desarrollado.

**PALABRAS CLAVE:** Compensación, optimización, voltaje, pérdidas, probabilidad, eventos, perceptrón, red neuronal artificial, error.

**UNIVERSIDAD TECNICA DE COTOPAXI**  
**DIRECCION DE POSGRADO**  
**MAESTRÍA EN ELECTRICIDAD**  
**MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA**

**Title: NEURAL NETWORK TRAINING FOR VOLTAGE CONTROL AND LOSSE  
REDUCTION IN THE EERSA 69KV SUBTRANSMISION SYSTEM**


**Author: Chiguano Velasco Alvaro Napoleón**  
**Tutor: MSc. Castillo Fiallos Jessica Nataly**

**ABSTRACT**

In the present work, the training and evaluation of neural networks is carried out for the improvement of voltage profiles and loss reduction through capacitive compensation, applying it to the 69kV system of the Empresa Eléctrica Riobamba S. A. The training process begins with the development of an optimization methodology that will determine the best values of reactivos to be injected at each moment and in each of the bars, the different operating events that can occur in the system will be probabilistically determined and the optimization methodology will be applied to generate an output response to each evaluated event. Finally, the training process of the ANNs will take previously determined events and responses as input and output parameters, the trained networks will be evaluated under different operating conditions and a proposal for the implementation of the developed project is presented.

**KEYWORD:** Compensation, optimization, voltage, losses, probability, events, perceptron, artificial neural network, error.

Natasha Carolina Ruales Andrade con cédula de identidad número:1003573258 Licenciado/a en: Lingüística aplicada con mención en Enseñanza de lenguas con número de registro de la SENESCYT: 1027-2020-2204904; **CERTIFICO** haber revisado y aprobado la traducción al idioma inglés del resumen del trabajo de investigación con el título: Entrenamiento de una RNA para el control de voltaje y reducción de pérdidas en la red de subtransmisión de 69kV de la EERSA de: Chiguano Velasco Alvaro Napoleón aspirante a magister en Magíster en Electricidad mención sistemas eléctricos de potencia.

  
.....  
Natasha Carolina Ruales Andrade  
1003573258

Latacunga, febrero, 20, 2023

# ÍNDICE DE CONTENIDOS

INTRODUCCIÓN .....	1
CAPÍTULO I. FUNDAMENTACIÓN TEORICA- METODOLOGICA .....	5
1.1. Estado del arte .....	5
1.2. Fundamentación Teórica .....	8
1.2.1. Compensación capacitiva en sistemas de potencia .....	8
1.2.2. Estadística para la definición de eventos y probabilidades .....	12
1.2.3. Redes neuronales artificiales .....	16
1.3. Fundamentación metodológica .....	22
1.4. Conclusiones Capítulo I .....	24
CAPÍTULO II. PROPUESTA.....	25
2.1 Título del proyecto .....	25
2.2 Objetivo del proyecto .....	25
2.3 Descripción de la propuesta .....	25
2.4 Metodología o procedimientos empleados para el cumplimiento de los objetivos planteados.....	26
2.4.1 Modelo de optimización para ubicación y dimensionamiento de bancos de capacitores.....	26
2.4.2 Cálculo de probabilidad de eventos en el sistema de subtransmisión de 69 kV de la EERSA.....	34
2.4.3 Entrenamiento de RNA .....	37
2.5 Conclusiones Capítulo II.....	40
CAPÍTULO III. APLICACIÓN Y/O VALIDACION DE LA PROPUESTA.....	41
3.1 Análisis de los resultados .....	41
3.1.1 Modelación de la red de subtransmisión de 69 kV de la EERSA .....	41
3.1.2 Aplicación del modelo de optimización para ubicación y dimensionamiento de bancos de capacitores en la red de 69kV de la EERSA. ....	43
3.1.3 Entrenamiento de la Red Neuronal Artificial.....	47
3.2 Validación técnica -económica de los resultados.....	60
3.2.1 Requerimientos de software .....	60
3.2.2 Requerimientos de hardware .....	61

3.3 Conclusiones Capítulo III.....	64
Conclusiones generales .....	65
Recomendaciones.....	66
Referencias bibliográficas .....	67
III. ANEXOS .....	70

## INTRODUCCIÓN

**Antecedentes:** Dado el desarrollo de diversos dispositivos electrónicos implementados a distintos equipos interruptores necesarios para la operación sistemas eléctricos, se ha venido realizando importantes mejoras en cuanto a la operación de estos. Inicialmente los avances presentados se basaron en lograr la comunicación de los equipos con los diferentes HMI permitiendo de esta manera la operación remota de los equipos, posteriormente cada fabricante ha presentado distintos avances que brindan la capacidad de la configuración online de sus características de operación. Estas mejoras sumadas a las distintas técnicas de programación han sido analizadas para la creación de todo tipo de sistemas autónomos que permitan alcanzar una mejoría en cuanto a la rapidez de respuesta y estabilización de los sistemas eléctricos.

Así mismo el objetivo de contar con mayores avances y mejoras en la operación de las redes de distribución, durante el año 2019 la Empresa Eléctrica Riobamba llevo a cabo trabajos de implementación para la automatización de su red de 13.8kV. La automatización de los equipos reconectadores fue desarrollada para reducir los tiempos de respuesta ante fallas en la red. En general la programación desarrollada fue realizada en base al uso de compuertas lógicas durante lo cual se evidencio la complejidad del desarrollo de las líneas de código necesarias para la correcta operación de los equipos.

**Planteamiento del problema:** La tendencia actual dentro de los sistemas eléctricos es la implementación de las nuevas tecnologías y métodos en la búsqueda de la optimización de la operación, indicadores como, pérdidas, factor de potencia, caída de voltaje son los principales parámetros sujetos a estudio dentro de la operación de los sistemas en estado estable. En los sistemas de transmisión la compensación reactiva es uno de los métodos más efectivos para el control de los parámetros eléctricos antes indicados. Por lo cual, se han desarrollado múltiples métodos para solventar el problema de la búsqueda de las óptimas ubicaciones y capacidades de las compensaciones requeridas en un sistema estable, donde la complejidad del método usado es relativo a la complejidad del sistema analizado [1, 2, 3].

Por otro lado, las redes de distribución suelen presentar de forma esporádica desconexiones en su carga ya sea por contingencias o en menor medida por trabajos programados con

duraciones desde unos pocos minutos hasta varias horas. A nivel de subestación las suspensiones de servicio originadas en las redes de distribución se perciben como variaciones aleatorias de la carga, por lo cual, un sistema que permita el control de los parámetros de operación de los sistemas de distribución deben considerar las variaciones continuas de carga lo que se traduce en el requerimiento de un control con una capacidad de respuesta dinámica.

Las Redes Neuronales Artificiales cuentan con la capacidad dinámica de aprendizaje y reconocimiento de patrones en base a los datos de entrada y salida que le sean ingresados, además, en concordancia a los datos con los que la RNA ha sido entrenada, estos sistemas son capaces de presentar respuestas coherentes ante diferentes variaciones de los valores de entrada. Por lo tanto, la aplicación de una RNA al control de la compensación reactiva representa una gran ventaja ante la presencia de múltiples variaciones de carga posibles ya que un entrenamiento exitoso permitirá obtener resultados análogos a los obtenidos mediante los distintos métodos de dimensionamiento de la compensación los cuales requieren múltiples resoluciones de flujos de potencia.

**Formulación del problema:** Determinar los resultados del entrenamiento de una red neuronal para la corrección de voltaje y reducción de pérdidas mediante compensación capacitiva en la red de 69kV de la EERSA tomando en cuenta variaciones de carga en las subestaciones de distribución.

**Objetivo General:** Desarrollar el entrenamiento de una red neuronal para la corrección de voltaje y reducción de pérdidas mediante compensación capacitiva en la red de 69kV de la EERSA.

**Objetivos Específicos:**

- Realizar una evaluación técnica para determinar la óptima corrección de voltaje y reducción de pérdidas en la red de 69kV de la EERSA mediante compensación capacitiva.
- Obtener una población de diferentes casos de operación con variaciones de carga y las respuestas requeridas de compensación reactiva.
- Realizar el entrenamiento de una red neuronal artificial para la corrección del voltaje y reducción de pérdidas en la red de 69 kV de la EERSA mediante compensación capacitiva.

**Sistemas de tareas en relación a los objetivos específicos:**

OBJETIVOS ESPECÍFICOS	ACTIVIDADES	RESULTADOS DE LAS ACTIVIDADES	MEDIOS DE VERIFICACIÓN
Realizar una evaluación técnica para determinar la óptima corrección de voltaje y reducción de pérdidas en la red de 69kV de la EERSA mediante compensación capacitiva.	<ul style="list-style-type: none"> <li>• Analizar el sistema de operación de la red de 69kV de la EERSA a demanda máxima.</li> <li>• Establecer el modelo heurístico a ser usado para determinar la óptima compensación capacitiva.</li> <li>• Determinar la óptima ubicación, capacidad del banco de capacitores y la máxima corrección de voltaje.</li> </ul>	<ul style="list-style-type: none"> <li>• Tabla de datos de los parámetros eléctricos antes y después de la compensación.</li> <li>• Algoritmo de optimización de la compensación capacitiva.</li> </ul>	<ul style="list-style-type: none"> <li>• Tabulación de parámetros eléctricos.</li> <li>• Diagrama de flujo.</li> </ul>
Obtener una población de diferentes casos de operación con variaciones de carga y las respuestas requeridas de compensación reactiva.	<ul style="list-style-type: none"> <li>• Recolectar información de la cargas activas y reactivas en los diferentes casos de análisis.</li> <li>• Obtener los esquema de compensación capacitiva de cada uno de los casos analizados.</li> </ul>	<ul style="list-style-type: none"> <li>• Conjunto de datos de entrada y salida para el entrenamiento de la RNA.</li> </ul>	<ul style="list-style-type: none"> <li>• Tabla de resultados.</li> </ul>
Realizar el entrenamiento y análisis de una red neuronal para la corrección autónoma del voltaje en la red de 69 kV de la EERSA.	<ul style="list-style-type: none"> <li>• Entrenamiento de la RNA</li> <li>• Análisis de los resultados y grados de aportación de cada uno de los datos de entrada.</li> <li>• Validación de la RNA con datos reales.</li> </ul>	<ul style="list-style-type: none"> <li>• Diagrama de pesos y conexiones de la RNA.</li> <li>• Error cuadrático medio.</li> </ul>	<ul style="list-style-type: none"> <li>• Diagrama gráfico de la RNA.</li> <li>• Tabla de resultados.</li> </ul>

*Elaborado por o fuente: Elaboración y formulación propia*

**Justificación:** En los sistemas eléctricos de distribución el flujo de potencia reactiva a través de las líneas de transmisión produce pérdidas de energía, caídas de voltaje, bajo factor de potencia, e incremento en la cargabilidad en líneas de transmisión. El uso de reactancias capacitivas en líneas de transmisión es una de las mejores herramientas para el control de los parámetros eléctricos de un sistema mejorando la percepción del usuario final al corregir la regulación de voltaje y económicamente al poder generar reducciones notables en las pérdidas por transporte.

Actualmente en la EERSA la operación de los equipos que cuentan con acción autónoma son comandados a través de un RTU central el cual cuenta con la capacidad de procesar las señales telemedidas y proporcionar acciones de operación para cada equipo. Las RTU cuentan con la capacidad de poder ser programadas a través de varios lenguajes de programación como por ejemplo Basic, C# e inclusive Ladder y Texto estructurado, sin embargo, dadas las limitaciones presentes en la programación todo script debe ser optimizado y simplificado.

El presente trabajo de fin de Master propone generar los resultados de un estudio inicial para el control de los perfiles de voltaje en las barras más críticas de la red de subtransmisión de la EERSA considerando las posibles variaciones de carga en las subestaciones de distribución. Una RNA proporcionaría un control adaptativo para la determinación de las reactancias capacitivas óptimas que permitan la regulación de voltaje, además que dadas las características de una RNA esta puede ser representada como una función matemática facilitando de esta manera su implementación para la operación en una red de distribución [1].

# CAPÍTULO I. FUNDAMENTACIÓN TEORICA- METODOLOGICA

El uso de inteligencia artificial aplicada a sistemas eléctricos involucra el empleo de un amplio rango de conocimientos, métodos y técnicas que permitirán resolver los diferentes problemas individuales que involucran su desarrollo, a continuación, se presentan un conjunto de las revisiones bibliográficas más relevantes relacionadas con el presente trabajo.

## 1.1. Estado del arte

De acuerdo al trabajo presentado en [2], el control de voltaje mediante compensación capacitiva es posible mediante métodos estáticos tomando en cuenta dos procedimientos, la determinación de las barras que presentan menor estabilidad de voltaje mediante la obtención de las curvas QV lo que expondría las barras donde la compensación capacitiva es requerida, por otro lado, la terminación de la capacidad requerida de los bancos de capacitores se establece mediante el uso de la matriz de sensibilidad y la relación  $Capacidad_{kVAr} = \frac{1-V_{actual}}{Sensibilidad\ QV}$  obteniéndose buenos resultados ante el análisis de contingencias para sistemas de prueba IEEE de 9 y 14 barras.

Como se muestra en [3], la compensación capacitiva aplicada a sistemas de potencia permite el control de factor de potencia, reducción de pérdidas y mejoramiento de los perfiles de voltaje. La determinación de las óptimas ubicaciones y capacidades de los bancos de capacitores requeridos es obtenida mediante la aplicación del algoritmo heurístico por Colonia de Hormigas donde se minimiza la función objetivo  $FO = \sum_{k=1}^n (V_k - V_{k+1})$ . Los resultados demuestran que el método implementado permite un excelente control de tensión, sin embargo, únicamente considera el análisis para un sistema estático y no considera cambios en las cargas además de establecerse sus elevados requerimientos computacionales.

Por otro lado en [4], se plantea el objetivo de implementar bancos de capacitores tomando en cuenta la reducción de costos, de pérdidas y de variaciones de voltaje, el algoritmo implementado es la heurística de Enjambre de Partículas PSO donde la función objetivo  $FO = \sum_{k=1}^n Costo * Pérdidas * Tiempo + Costo_{instalación} * Q_C + Costo_{operación} * Q_C$  ya involucra tanto un análisis tanto económico como técnico. Los resultados presentados indican que el algoritmo implementado presenta buenas características para el control de pérdidas y

mejora de los perfiles de voltaje, sin embargo, el análisis no presenta resultados ante distintos tipos de topología ni para variaciones de carga.

Al igual que en el trabajo anteriormente mencionado, en [5] se analizan similares restricciones para la determinación tanto de la ubicación como la capacidad de compensación reactiva para reducción de pérdidas y mejorar perfiles de voltaje mediante el algoritmo de recocido simulado (Simulated Annealing) donde se remarca la robustez y rapidez de convergencia de dicho algoritmo.

En el trabajo expuesto en [6] se analiza el concepto de sensibilidad aplicado a la compensación capacitiva. Mediante el uso de una función objetivo similar a la mostrada en [4] y la determinación de los datos de sensibilidad que relaciona las pérdidas de transporte y la magnitud de la compensación en cada barra particular, se logra ubicar las mejores ubicaciones que permitan la óptima minimización de pérdidas en el sistema. Aunque la búsqueda de las mejores soluciones se enfoca en el criterio de reducción de pérdidas, este no solo se limita a mejorar este indicador ya que mediante la ayuda de la FO se evalúan criterios tanto técnicos como económicos.

A diferencia el método usado en el trabajo anterior, en [7] se implementa un algoritmo de búsqueda armónica para realizar una búsqueda discreta con el objetivo de determinar las mejores opciones de compensación mediante FACTS hasta obtener los perfiles de voltajes deseados. El algoritmo implementado se caracteriza por no requerir de datos iniciales ni de gradientes diferenciales para la búsqueda de las mejores opciones, aunque la implementación del algoritmo de búsqueda armónica presento muy buenos resultados se debe acotar que este algoritmo no garantiza la obtención de resultados óptimos globales.

Un avance importante en el análisis de la compensación capacitiva se realiza en [8], donde además de considerar la obtención de las curvas QV y la ejecución de sucesivos flujos de potencia para determinar las mejores ubicaciones y capacidades para implementar compensación, también toma en cuenta la necesidad de estudiar la compensación reactiva requerida ante contingencias N-1 donde el principal indicador a precautelar es la cargabilidad en las líneas de transmisión. Los resultados obtenidos demuestran los beneficios del uso de compensación reactiva en el control de voltaje ante distintas escalas de incremento de carga en las barras del sistema estudiado.

Para el estudio presentado en [9] se realiza un análisis del despacho óptimo de bancos de capacitores para un periodo de demanda de 24 horas diarias donde al implementar un algoritmo de programación dinámica este predispone las óptimas opciones de operación de los bancos de capacitores por cada hora del día, esto tomando en cuenta las variaciones de carga en cada barra del sistema en estudio y al mismo tiempo reduciendo las pérdidas del sistema. El trabajo presentado además de introducir el concepto de operación horaria de banco de capacitores también indica el valor estándar de cada banco capacitor a ser operado.

Por otro lado, como se muestra en el trabajo anteriormente indicado, las operaciones de conexión y desconexión pueden ser programadas para seguir una secuencia específica de pasos a ser tomados a lo largo del día, sin embargo, este tipo de aplicaciones no tomaría en cuenta las diferentes posibilidades de operación necesarios en el caso de que existan variaciones en la carga y en la topología de la red.

Un avance importante en la operación dinámica de los equipos es presentada en [10] en donde se desarrolla una red neuronal artificial con función de base radial para la operación automática de una red en una edificación la misma que puede ser alimentada tanto a través de la red eléctrica como de un banco de paneles fotovoltaicos. En donde se optimizan tanto el uso de los recursos solares como de la capacidad de almacenamiento de los bancos de baterías.

Un uso más complejo para las redes neuronales es el desarrollado en [11] en donde el control de un sistema eólico es llevado a cabo mediante el desarrollo de dos redes neuronales, la primera para emular el controlador PID y la segunda para emular la respuesta del generador de inducción. Los resultados obtenidos demuestran una gran velocidad de respuesta para el control de potencia tomando en cuenta las variaciones en la velocidad del viento.

Por otro lado, como se muestra en [12], el entrenamiento exitoso de una RNA para la reconfiguración topológica de una red de distribución es posible creando una base de datos con todas las opciones posibles de topología e incluyéndolos dentro de un proceso de entrenamiento supervisado.

En [13] las RNA en conjunto con el uso de lógica difusa son usados para la determinación de los parámetros de control de un motor de inducción donde se remarcan importantes ventajas del uso de este tipo de técnicas ya que su implementación no requiere del uso de un

modelo matemático de la máquina sincrónica además de dar excelentes resultados ante en respuestas no lineales.

Mientras tanto en [14] las RNA son utilizadas para detección y clasificación de fallas en un sistema de potencia mediante el uso de una red neuronal probabilística (RNP) y una RNA convencional, el entrenamiento toma en cuenta tanto variaciones en la carga como todas las posibles fallas que se pueden presentar en el sistema, presentándose así una propuesta altamente flexible que presenta excelentes resultados en cuanto a la supervisión de fallas se refiere.

Otro de los principales usos de las RNA es el mostrado en [15], en donde se realiza una comparación entre el pronóstico de demanda realizado mediante el uso de regresiones y el pronóstico definido por una RNA. Los resultados obtenidos concluyen que, para el pronóstico de series de tiempo erráticas, el uso de las series de tiempo presenta mejores resultados que los de una RNA. Esto evidencia la necesidad de usar variables externas para implementar una mejora en el pronóstico.


Una mejora a los resultados encontrados en el trabajo anterior son implementados en [16], donde la predicción de la demanda en la red de subtransmisión de la empresa Eléctrica Riobamba con una RNA es posible mediante el uso extenso de información recabada de los equipos de medición además del uso de datos económicos como poblacionales. Se concluye que, dependiendo de los datos de entrada, al incluir datos poco relacionados con los resultados se presenta una escasa mejora en los resultados de la predicción pudiendo ser estos incluso excluidos.

## **1.2. Fundamentación Teórica**

### **1.2.1. Compensación capacitiva en sistemas de potencia**

El problema de la compensación capacitiva puede ser planteado desde el punto de vista del análisis y optimización de una función multivariable el cual deberá cumplir con las limitaciones y los requerimientos buscados. Tal como se plantea la búsqueda de la óptima compensación capacitiva puede ser subdividida en dos sub-problemas separados: determinación de las ubicaciones a óptimas y determinar las capacidades requeridas de los bancos de capacitores.

**Determinación de las ubicaciones.** – En base al análisis de la operación de líneas de transmisión cortas mostrado en la figura 1, se puede deducir el comportamiento de los voltajes con modelos de carga de potencias constantes.



**Figura 1:** Modelo de línea de transmisión corta

Del análisis del sistema simple de una línea de transmisión corta se obtiene el valor de la potencia reactiva ( $Q$ ) consumida en la barra 2 en función de los parámetros de la línea de transmisión [17].

$$Q = \frac{1}{x} (V_1 V_2 \cos \phi - V_2^2) \quad (1)$$

Dado que:

$$\cos \phi \approx 1 \quad (2)$$

Entonces:

$$(V_1 - V_2) = \frac{x}{V_2} Q \quad (3)$$

De la ecuación anterior se puede concluir que el valor de la caída de voltaje encontrada al final de una línea es proporcional a la reactancia de la línea y al valor de la potencia reactiva requerida por la carga. Esto deriva en que el control de potencia reactiva ( $Q$ ) sería la mejor opción que permitirá la regulación de voltaje en una barra que no cuente con generación. Dado el análisis anterior cabe indicar que durante el desarrollo de tomará en cuenta la heurística de que las barras con menor voltaje serán las principales candidatas a ubicar bancos de capacitores.

Teniendo en cuenta el enfoque de compensación capacitiva para el control de voltaje, las ubicaciones especificadas para la instalación de bancos de capacitores serán determinadas mediante el sondeo de la barra con menor voltaje. Sin embargo, como se muestra en la tabla siguiente tanto en la barra Slack como PV no es posible realizar el control de voltaje médiante

compensación capacitiva dado que estas cuentan con un control propio el que por lo general ajusta su potencia reactiva generada ( $Q_{gen}$ ) para llegar a un voltaje especificado. Por lo tanto, el uso de compensación capacitiva para control de voltaje únicamente será usada en barras tipo PQ.

**Tabla 1:** Tipos de barras en un SEP

Tipo	VARIABLES DE CONTROL	VARIABLES DESCONOCIDAS
Slack	$ V , \delta, P_{carga}, Q_{carga}$	$P_{gen}, Q_{gen}$
PV	$ V , P_{carga}, Q_{carga}, P_{gen}$	$\delta, Q_{gen}$
PQ	$P_{carga}, Q_{carga}, P_{gen}, Q_{gen}$	$ V , \delta$

**Determinación de las capacidades.** – La búsqueda de las máximas capacidades a instalar en cada barra de un SEP puede ser analizado mediante una búsqueda discreta al incrementar sucesivamente la capacidad de los bancos de capacitores en las ubicaciones determinadas. Cada paso de incremento ( $\Delta C$ ) deberá ser evaluado por la función objetivo ( $FO$ ) la cual permitirá determinar si se ha llegado o no a la mejor solución.

La función objetivo a maximizar corresponde a la ecuación indicada a continuación:

$$FO = w_1 \cdot V_{min} + w_2 \cdot P + w_3 \cdot C_{Total} \quad (4)$$

Donde:

$w_1, w_2, w_3$ : Peso de cada criterio.

$V_{min}$ : Mínimo voltaje del sistema.

$P$  : Pérdidas totales del sistema por transporte.

$C_{Total}$ : Total de potencia reactiva instalada en el sistema ( $C_{Total} = \sum_1^n C_i$ ).

Esta función objetivo será optimizada mediante la aplicación del método CRITIC mostrada en [18], la cual se resume en 5 pasos:

1. **Crear la matriz de decisión:** Se crea una matriz con todos los posibles valores de  $\Delta V$ , *pérdidas* y  $\Delta C_{Total}$  obtenidos de cada uno de los posibles conjuntos de los bancos de capacitores a instalar.

**Tabla 2:** Ejemplo matriz de decisión

	$V_{min}$	<i>Pérdidas</i>	$C_{Total}$
$C_1$	$X_{11}$	$X_{12}$	$X_{13}$
$C_2$	$X_{21}$	$X_{22}$	$X_{23}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$C_i$	$X_{i1}$	$X_{i2}$	$X_{i3}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$C_m$	$X_{m1}$	$X_{m2}$	$X_{m3}$

2. **Normalizar por el rango los valores de cada uno de los criterios:** En base a los valores de la matriz de decisión estos se transforman a p.u.

**Tabla 3:** Criterio para transformación a p.u. la matriz de decisión

Beneficio	Costo
$X_{i1 pu} = \frac{X_{i1} - \min V}{\max V - \min V}$	$X_{i2 pu} = \frac{\max P - X_{i2}}{\max P - \min P}$ $X_{i3 pu} = \frac{\max \Delta C_{Total} - X_{i3}}{\max \Delta C_{Total} - \min \Delta C_{Total}}$

3. **Calcular la desviación típica de cada criterio.**

$$\sigma = \sqrt{\frac{\sum_{i=1}^m \left[ X_{i1 pu} - \left( \frac{\sum_{i=1}^m X_{i1 pu}}{m} \right) \right]^2}{m-1}} \quad (5)$$

4. **Calcular la correlación entre cada par de criterios.**

$$r_{jk} = \frac{cov(j,k)}{\sigma_j \sigma_k} \quad (6)$$

5. **Calcular el peso de cada criterio.**

$$w_j = \sigma_j \sum_{k=1}^n (1 - r_{jk}) \quad (7)$$

**1.2.2. Estadística para la definición de eventos y probabilidades**

La estadística descriptiva es la herramienta que permite la organización y presentación de un conjunto de datos con el fin de mostrar las propiedades de estos, de esta manera permitirá determinar los valores más frecuentes además de mostrar valores poco usuales o extremos. La principal herramienta de organización de datos cuantitativos es el gráfico de distribución de frecuencias o histograma.

**Distribución de frecuencias.** - Consiste en el agrupamiento de un conjunto de  $n$  datos en grupos mutuamente excluyentes que muestran la cantidad de observaciones que se encuentran en cada rango [19]. La elaboración de la distribución de frecuencias puede ser resumido en cinco pasos.

1. **Definir el número de clases ( $k$ ):** Consiste en definir la cantidad de clases o rangos necesarios que permitan percibir de forma correcta la distribución de los valores.

Para determinar la cantidad de clases o rangos es útil el criterio de  $2^k$  en el que la cantidad de clases necesarias corresponde al mínimo valor de  $k$  en el que se cumpla la desigualdad mostrada a continuación.

$$2^k \geq n \quad (8)$$

2. **Definir el intervalo de clase ( $i$ ):** El intervalo de clase define el valor del ancho de cada subgrupo de datos. El valor del intervalo ( $i$ ) debe ser el mismo para cada subgrupo y se calcula en base a los valores máximo ( $H$ ) y mínimo ( $L$ ) del total de los datos analizados.

$$i = \frac{H-L}{k} \quad (9)$$

3. **Establecer los límites de cada clase:** Los límites de cada clase define los valores entre los cuales se agrupará cada uno de los datos. La importancia de este paso radica en que permite que cada dato sea incluido en un solo subgrupo. El cálculo de los límites de cada clase se ejemplifica de mejor manera en la tabla siguiente.

**Tabla 4:** Cálculo límites de cada clase

Clase ( $k$ )	Limite superior ( $\leq$ )	Limite inferior ( $<$ )
1	$L$	$L + 1i$
2	$L + 1i$	$L + 2i$
$\vdots$	$\vdots$	$\vdots$
$k$	$H + (k - 1)i$	$H$

4. **Conteo de número de elementos de cada clase ( $F$ ):** Se realiza el conteo de la cantidad de elementos encasillados en cada clase. La cantidad de elementos dentro de cada clase se denomina frecuencia.


**Tabla 5:** Cálculo frecuencias de cada clase

Clase ( $k$ )	Limite superior ( $\leq$ )	Limite inferior ( $<$ )	Frecuencia ( $F$ )
1	$L$	$L + 1i$	$F_1$
2	$L + 1i$	$L + 2i$	$F_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$k$	$L + (k - 1)i$	$H$	$F_k$

5. **Graficar el diagrama de distribución de frecuencias:** Consiste en la graficación mediante barras de la distribución de la frecuencia de cada clase.

Usualmente la frecuencia relativa es utilizada como un indicador de la probabilidad de que un elemento sea encontrado dentro de una clase determinada y se calcula en función de la frecuencia de una clase ( $F$ ) y el valor total de los elementos analizados ( $n$ ).

$$Fr = \frac{F}{n} \quad (10)$$



**Figura 2:** Diagrama de distribución de frecuencias

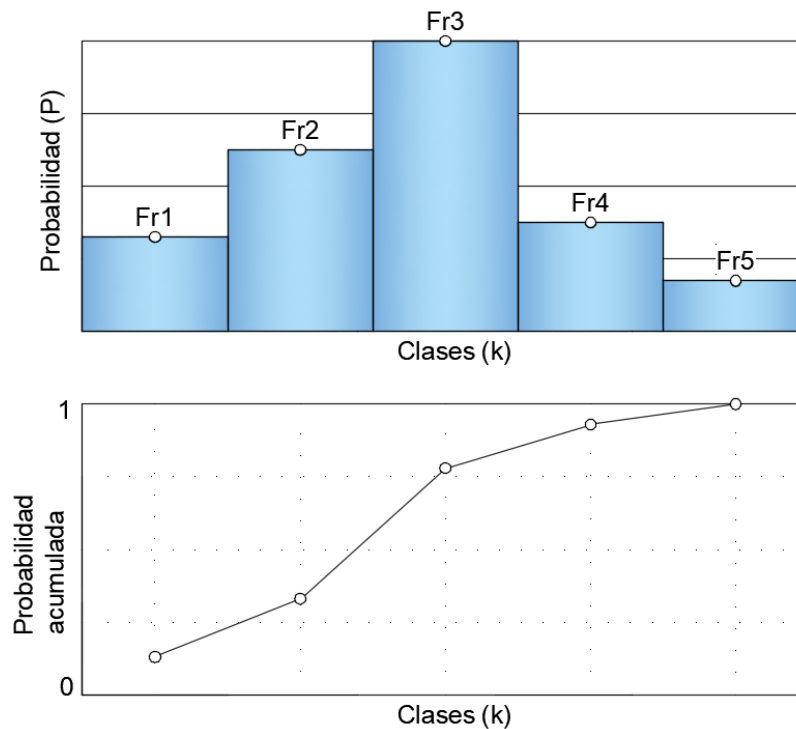
En general los valores representativos de cada clase son los correspondientes al valor medio de cada rango. De esta manera y con ayuda del diagrama de distribución de frecuencias se puede definir como los valores más probables los determinados por el valor medio de cada rango con las mayores frecuencias o probabilidades.

**Distribución de frecuencia relativa acumulativa.** – Permite calcular la probabilidad de que una observación cualquiera sea menor que un valor determinado. En menor medida también es utilizada para calcular la probabilidad de que la observación sea mayor que cierto valor o sea encontrado dentro de un rango específico[20].

**Tabla 6:** Cálculo frecuencia relativa acumulada

Clase ( $k$ )	Limite superior ( $\leq$ )	Limite inferior ( $<$ )	Frecuencia relativa ( $Fr$ )	Frecuencia acumulada
1	$L$	$L + 1i$	$Fr_1$	$Fr_1$
2	$L + 1i$	$L + 2i$	$Fr_2$	$Fr_1 + Fr_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$k$	$L + (k - 1)i$	$H$	$Fr_k$	$\sum_1^k Fr$

La siguiente imagen ejemplifica de mejor manera el cálculo de la frecuencia relativa acumulada para un diagrama de distribución de frecuencias.



**Figura 3:** Grafica probabilidad relativa acumulada


De esta manera es entiendo que mientras mayor sea la cantidad de intervalos dentro de los cuales se requiera el cálculo de probabilidad acumulada más cerca estará esta de la unidad.

En la literatura el valor de la probabilidad acumulada también suele ser expresada como nivel de confianza [20].

### 1.2.3. Redes neuronales artificiales

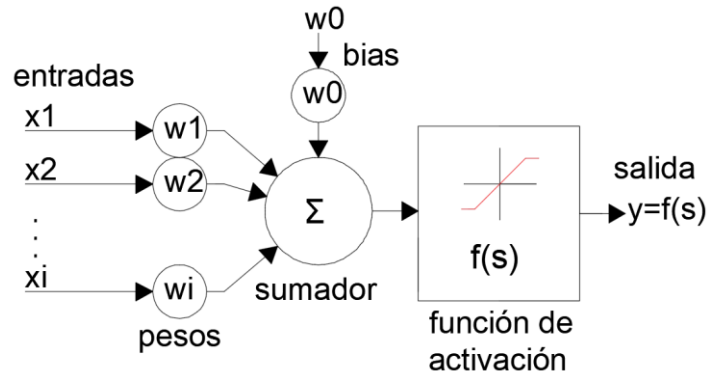
Las redes neuronales pueden ser definidas como sistemas computacionales integrados por una gran cantidad de elementos conectados entre sí, los cuales procesan la información ingresada por medio de cambios dinámicos de sus elementos [1].

En el cerebro cada neurona permite la recepción y combinación de señales a la vez de permitir el estímulo de neuronas aledañas. La neurona ofrecerá una respuesta sólo si la combinación de señales de entrada son lo suficientemente fuertes como para provocar la activación de esta. Por otro lado, las redes neuronales artificiales se componen de unidades procesadoras que combinan los valores de entrada generalmente mediante una suma aritmética, esta suma es evaluada por la función de activación y esta a su vez determinará la respuesta de la neurona [21].



**Figura 4:** Comparación de una neurona biológica vs una artificial

Una neurona artificial está dividida en tres elementos fundamentales: elemento receptor, sumador y función de activación.



**Figura 5:** Elementos de la neurona artificial

1. **Receptor:** Donde ingresan a la neurona los valores de entrada  $x_i$  y son multiplicados por sus pesos correspondientes  $w_i$ . A cada valor de entrada le corresponderá un peso específico dependiendo de su grado de importancia en la activación de la neurona.
2. **Sumador:** Donde los valores de entrada  $x_i$  y sus pesos correspondientes  $w_i$  son combinados mediante una suma algebraica proporcionando un único valor numérico ( $S$ ) que deberá ser evaluado por la función de activación.

$$S = \sum_1^n x_i \cdot w_i \quad (10)$$

3. **Función de activación:** En esta etapa los valores obtenidos del sumador ( $S$ ) serán evaluados por medio de la función de transferencia proporcionando de esta manera un valor de salida ( $y$ ). Algunas neuronas artificiales contarán únicamente con dos estados activada (1) o desactivada (0), pero otras pueden tener cualquier valor dentro de un rango específico.

Las funciones de activación más comúnmente utilizadas se muestran a continuación:

- Función escalón

$$y = \begin{cases} 0 & s \leq 0 \\ 1 & s > 0 \end{cases} \quad (11)$$

- Función lineal

$$y = \begin{cases} -1 & s \leq 0 \\ a \cdot s & -1 < s < 0 \\ 1 & s \geq 0 \end{cases} \quad (12)$$

- Función sigmoidea

$$y = \frac{1}{1+e^{-a.s}} \quad (13)$$

- Función tangente hiperbólica


$$y = \frac{e^{a.s} - e^{-a.s}}{e^{a.s} + e^{-a.s}} \quad (14)$$

## El Perceptrón

Consiste en una neurona con  $n$  entradas en donde la función de activación es una función escalón, la neurona será activada si la suma ponderada de las entradas es mayor que un umbral especificado ( $U$ ).

$$y = \begin{cases} 0 & s \leq U \\ 1 & s > U \end{cases} \quad (15)$$

Por lo general, el umbral especificado es cero y las modificaciones en la función de activación son realizadas cambiando el valor de las constantes ( $a$ ), añadiendo una entrada fija  $x_0 = +1$  y definiendo un peso específico  $w_0$ .



**Figura 6:** Variaciones en la función sigmoidea

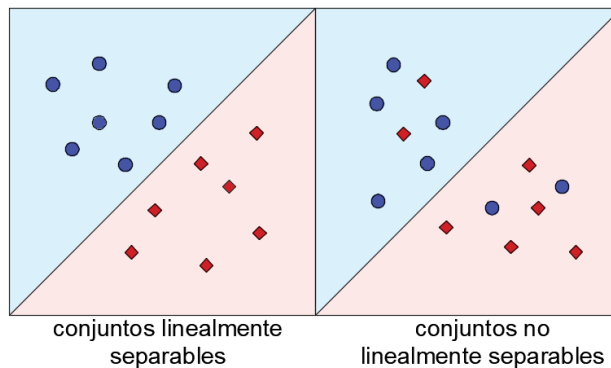
Para el entrenamiento del perceptrón se requiere dos conjuntos de datos, los valores de entrada ( $x$ ) y las respuestas deseadas ( $t$ ) denominados patrones de entrenamiento. El entrenamiento se lo realiza de forma iterativa ingresando los valores de entrada y ajustando los pesos hasta que el error entre las respuestas del perceptrón y las respuestas requeridas alcancen un mínimo establecido [22].

Una de las reglas más sencillas para el ajuste de pesos indica que su valor actualizado es proporcional ( $k$ ) al error entre la respuesta obtenida por el perceptrón ( $y$ ) y la respuesta deseada ( $t$ ).

$$w^1 = w^0 + k(t - y)x \tag{16}$$

Donde el valor  $k$  se denomina tasa de aprendizaje y es un valor menor a la unidad.

El perceptrón es un modelo de clasificación que es capaz de proporcionar respuestas adecuadas siempre y cuando los conjuntos de entrada y salida sean linealmente separables.




**Figura 7:** Límite de decisión

Para problemas no linealmente separables se recurre al uso de redes multicapa que son capaces de aprender y clasificar datos complejos.

### Redes Multicapa

Generalmente las neuronas son agrupadas en estructuras llamadas capas mientras que una agrupación de capas es llamada red. Las redes multicapa se forman con grupos de neuronas conectadas en cascada. La salida de una capa de neuronas es la entrada de la siguiente capa.



**Figura 8:** Jerarquía de sistemas neuronales

Cabe destacar que las mejoras obtenidas con el uso de redes neuronales solo se consiguen con el uso de funciones de activación no lineales. En un caso extremo, una red neuronal multicapa que utilice únicamente funciones de activación lineales podría ser reducida a un perceptrón simple [21].

A diferencia del entrenamiento del perceptrón, el entrenamiento supervisado de las redes multicapa conlleva un proceso más complejo denominado propagación hacia adelante y hacia atrás (backpropagation).

### Algoritmo de entrenamiento

Dada la necesidad de realizar el entrenamiento supervisado de sistemas neuronales de más de una capa durante los años 80 se presenta el desarrollo del algoritmo backpropagation. El algoritmo de backpropagation por lo general suele ser implementado en redes con tres capas ya que la mayoría de problemas pueden ser solventados con el uso de este tipo de redes [22].

Los sistemas neuronales de tres capas están compuestos por la capa de entrada, capa oculta o intermedia y capa de salida. Estas redes son completamente interconectadas lo que implica que las neuronas de la capa oculta tienen conexión con todas las neuronas tanto de la capa de entrada como la de salida.




Figura 9: Capas de red neuronal

El entrenamiento por backpropagation conlleva dos etapas, propagación hacia adelante y propagación hacia atrás.

1. **Propagación hacia adelante:** Esta etapa inicia con la asignación inicial de pesos ( $w$ ) del sistemas con valores iniciales de entre 0 y 1. Posteriormente se le presenta un

conjunto de valores de entrada y salida. Cada conjunto de valores de entrada es presentado a la red neuronal y esta determinará los valores correspondientes a las sumas ponderadas de cada neurona y las respuestas correspondientes de las funciones de activación.

2. **Propagación hacia atrás:** En la etapa de propagación hacia atrás se inicia con el cálculo del error ( $\delta$ ) en las neuronas de la capa de salida en función de los valores deseados ( $t$ ), los obtenidos ( $y$ ) y la derivada de la función de activación ( $f'$ ) de cada neurona evaluada en los pesos iniciales.

$$\delta_k = (t - y)f'(S_k) \quad (17)$$

Posteriormente se realiza una retropropagación para calcular el error en cada neurona de la capa oculta y de entrada.

$$\delta_j = \sum(\delta_k w_{jk}) f'(S_j) \quad (18)$$

$$\delta_i = \sum(\delta_j w_{ij}) f'(S_i) \quad (19)$$

El incremento en los pesos de cada capa se determina a través de la ecuación:

$$w^1 = w^0 + k \delta x \quad (20)$$

Donde  $x$  corresponde al valor de ingreso a la neurona y  $k$  corresponde a la tasa de aprendizaje con valores típicos de entre 0 y 1, generalmente 0.9.

El proceso de aprendizaje para el ajuste de pesos llevado a cabo para todos los conjuntos de valores de entrada y salida se denomina Época. Los procesos de aprendizaje se realizan presentando épocas de manera iterativa hasta que los errores entre los valores deseados y los obtenidos alcancen un mínimo establecido.

### **Validación de la red neuronal**

Por lo general la validación numérica de los resultados obtenidos por un sistema neuronal es realizada mediante la evaluación del error cuadrático medio presentado por la red para todos los conjuntos de datos de entrada y salida. El error cuadrático medio es calculado en base a los resultados obtenidos por la red ( $y$ ) y los valores deseados ( $t$ ).

$$E(w) = \frac{1}{2} \sum_1^n (t - y)^2 \quad (21)$$

Después del proceso de entrenamiento se debe comprobar la capacidad de la red obtenida para responder de forma adecuada ante valores distintos a los utilizados para el entrenamiento, por lo que se evalúa un nuevo conjunto de datos denominados de testeo [1].

### **1.3. Fundamentación metodológica**

Dado que el trabajo aquí presentado no se basa en demostrar una hipótesis preestablecida, este será realizado bajo un enfoque cualitativo en el cual se buscará determinar las características de los resultados obtenidos. De igual manera debido a la poca información con la que se cuenta respecto a los métodos de entrenamiento de redes neuronales aplicadas a la compensación reactiva, esta investigación es definida tipo exploratorio ya que durante todo su desarrollo permitirá evaluar si los procesos llevados a cabo para el entrenamiento de la RNA para la determinación de la óptima compensación capacitiva en la red de sub transmisión de la EERSA son apropiados.

La información concerniente a las características de la red de 69kV y al comportamiento de sus cargas será proporcionado por la Empresa Eléctrica Riobamba. Los parámetros de las líneas de transmisión y centrales de generación serán proporcionados para su directa implementación y validación mientras que el análisis del comportamiento de las cargas será llevado a cabo en base a los datos proporcionados por equipos de medición. Los escenarios más probables de operación de las cargas en cada subestación serán definidos en bases a los resultados obtenidos mediante a las herramientas estadísticas antes mencionadas.

Es importante definir que el periodo de medición de los datos utilizados para el análisis corresponderá únicamente de enero de 2021 a marzo de 2022 ya que durante el 2019 la Empresa Eléctrica Riobamba realizó una extensa labor para la repotenciación de sus redes de medio voltaje, esto mediante la reconfiguración de sus alimentadores y el reemplazo de equipos seccionadores por reconectores. Los cambios presentados en las redes de medio voltaje de 13.8kV a partir del 2019 hacen que el comportamiento de las cargas situadas en cada subestación varíe significativamente con relación a años anteriores. De igual manera se excluye del análisis las mediciones realizadas durante el 2020 ya que debido al proceso de confinamiento a causa de la pandemia de COVID-19 se presentó una disminución en la severidad y cantidad de las desconexiones presentadas en la red.

El desarrollo del algoritmo de cálculo de flujo de carga por Newton-Raphson para la red de 69kV y la implementación del algoritmo propuesto para la determinación de la óptima compensación reactiva requerida será llevado a cabo mediante el software de programación MATLAB. El uso de estos algoritmos programados en los diferentes escenarios determinados estadísticamente para cada subestación será aplicado para construir los conjuntos de datos de entrada y salidas deseadas.

Para el diseño y entrenamiento de las redes neuronales artificiales se recurrirá al uso de las herramientas de Machine Learning propias de MATLAB que definirán de manera precisa la topología y pesos de la RNA necesarios para asimilar el comportamiento del algoritmo de óptima compensación capacitiva. Paralelamente se realizará el entrenamiento de un perceptrón simple con los mismos datos de entrada y salida y cuyo desempeño será debidamente analizado y evaluado.

Por lo ya mencionado, el presente trabajo de investigación podría ser tomado como una guía o pauta metodológica para futuros trabajos aplicados al desarrollo e implementación de equipos que cuenten con la capacidad de operación autónoma dentro de redes eléctricas.

#### 1.4. Conclusiones Capítulo I

- Tal como se muestra en el apartado de compensación capacitiva, los criterios heurísticos para la ubicación de las localizaciones a instalar bancos de capacitores acompañados con la técnica estadística CRITIC para el análisis multivariable presentaría una nueva propuesta para la óptima compensación capacitiva en sistemas eléctricos, así como también la solución de diversos problemas de optimización en los que las posibles soluciones puedan ser divididas en escenarios finitos.
- La determinación de los escenarios de operación para las cargas de las subestaciones de la red de 69kV de la EERSA será abordada de forma estadística ya que los resultados del entrenamiento de los sistemas neuronales se espera que sean lo suficientemente capaces de presentar correctos resultados ante los escenarios más probables presentes en la red.
- Mientras que la simplicidad del diseño y entrenamiento del perceptrón proporcionaría la mejor solución para la implementación de sistemas neuronales en los equipos actualmente presentes en las redes eléctricas, es importante tomar en cuenta que el éxito del entrenamiento depende en gran medida de si el problema a resolver es linealmente separable. Por otro lado, las redes neuronales más profundas al incrementar su nivel de complejidad proporcionarían resultados sumamente precisos.

## **CAPÍTULO II. PROPUESTA**

### **2.1 Título del proyecto.**

Entrenamiento de redes neuronales artificial para el control de voltaje y reducción de pérdidas en redes eléctricas de subtransmisión.

### **2.2 Objetivo del proyecto.**

Desarrollar el entrenamiento de una red neuronal artificial (RNA) para la corrección de voltaje y reducción de pérdidas mediante compensación capacitiva en la red de subtransmisión de 69kV de la Empresa Eléctrica Riobamba S.A. (EERSA).

### **2.3 Descripción de la propuesta.**

En el presente trabajo primeramente se realizará el análisis de la metodología de búsqueda de la óptima compensación reactiva mediante bancos de capacitores para el mejoramiento de los perfiles de voltaje y la reducción de las pérdidas por transporte en la red de 69kV de la Empresa Eléctrica Riobamba. La función de optimización será valorada mediante el uso del método CRITIC para el análisis multivariable.

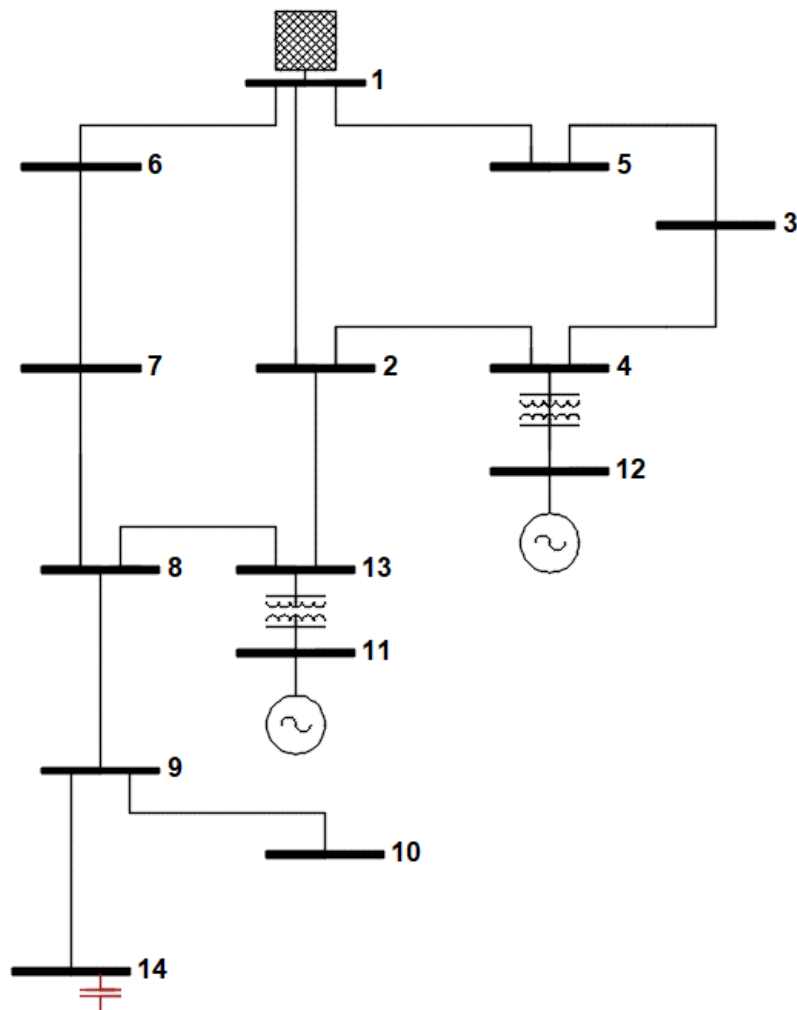
En una segunda etapa se realizará un análisis probabilístico de los múltiples modos de operación mediante el análisis de las distintas topologías de trabajo para la red de subtransmisión, así como también las posibles variaciones de carga. El método de búsqueda desarrollado para la óptima compensación capacitiva será implementado en cada uno de los modos de operación de la red de 69kV, generando de esta manera una población de entradas y respuestas que servirán de guía para el entrenamiento la RNA. Posteriormente se realizará el análisis del desempeño y las características de las RNA resultantes.

## 2.4 Metodología o procedimientos empleados para el cumplimiento de los objetivos planteados

### 2.4.1 Modelo de optimización para ubicación y dimensionamiento de bancos de capacitores


#### Determinación de la ubicación de bancos de capacitores

La propuesta metodológica para la selección de la ubicación de bancos de capacitores se basa en la determinación de las barras con menores voltajes. A manera de ejemplo en la figura 10 se presenta la red de subtransmisión de la EERSA.



**Figura 10:** Unifilar de la red de subtransmisión de la EERSA

La figura 11 muestra los perfiles de voltaje a la hora pico (19 horas) en cada barra de la red presentada.

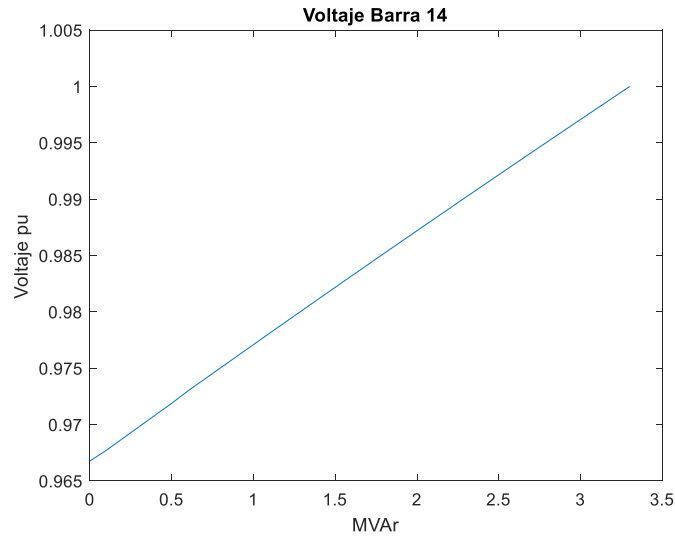


**Figura 11:** Perfil de voltajes de la red de subtransmisión de la EERSA a la hora pico.


Según el criterio previamente indicado en el cual las ubicaciones de los bancos de capacitores serán determinadas de acuerdo a la barra que presente el menor voltaje, una ubicación inicial correspondería a la barra 14. Además, es importante notar que las barras de la EERSA que presentan equipamientos de generación operan a manera de barras de carga volviendo posible el control de voltaje mediante compensación capacitiva.

Por lo dicho anteriormente, se indica que la ubicación de bancos de capacitores será únicamente tomada en barras de carga, por lo que para el caso del sistema de la figura 10 se iniciaría la ubicación de capacitores en la barra 14.

Las figuras 12 y 13 muestran las variaciones del voltaje en la barra 14 y las pérdidas del sistema de subtransmisión ante incrementos paulatinos de potencia reactiva capacitiva inyectada en la barra 14.



**Figura 12:** MVar inyectados vs voltaje en la barra 14.



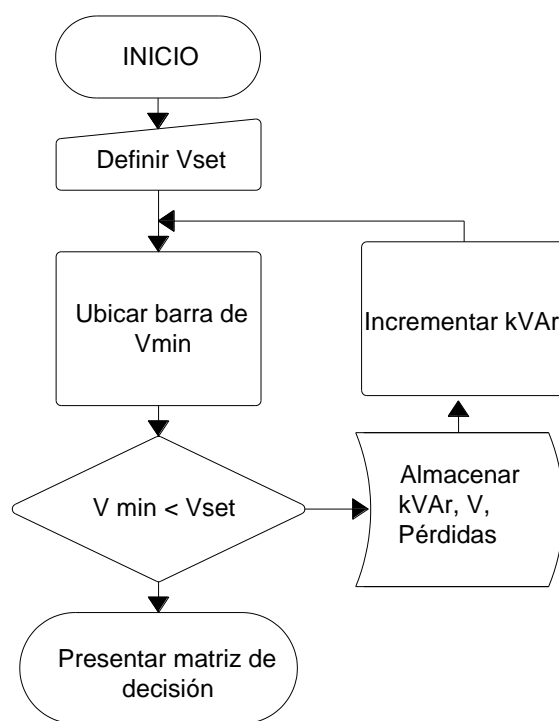
**Figura 13:** MVar inyectados en la barra 14 vs pérdidas del sistema.

Como se observa en las figuras anteriores, la relación entre la potencia reactiva capacitiva y el voltaje en la barra 14 es directamente proporcional, la relación entre la potencia reactiva inyectada y las pérdidas del sistema no es del todo clara. Si bien se observa que inicialmente la conexión de pequeños bancos de capacitores ayuda en elevación de voltajes y la reducción de pérdidas, se presenta un límite luego del cual las pérdidas del sistema se incrementan requiriéndose que se realice una evaluación entre la inyección de potencia reactiva capacitiva, sus beneficios sobre el control de voltaje y su perjuicio en el incremento de las pérdidas del sistema.

## Determinación de la capacidad de bancos de capacitores

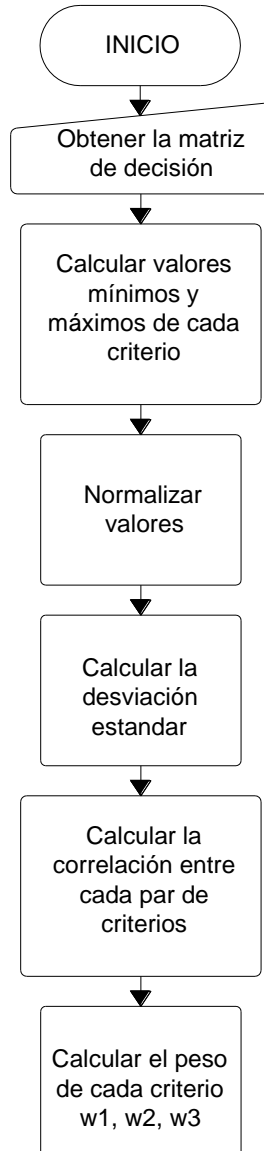
La determinación de la óptima capacidad del banco de capacitores a instalar requiere de la creación y análisis de la matriz de decisión la cual contiene información de los distintos pasos de incremento de capacitancia reactiva y las correspondientes respuestas de voltaje y pérdidas del sistema.

La figura 14 muestran el diagrama de flujo para el proceso general de creación de la matriz de decisión.



**Figura 14:** Diagrama de flujo creación matriz de decisión.

La figura 15 muestra el proceso para llevar a cabo el cálculo de los pesos requeridos para el análisis multivariable de acuerdo a lo mostrado en la ecuación 4.

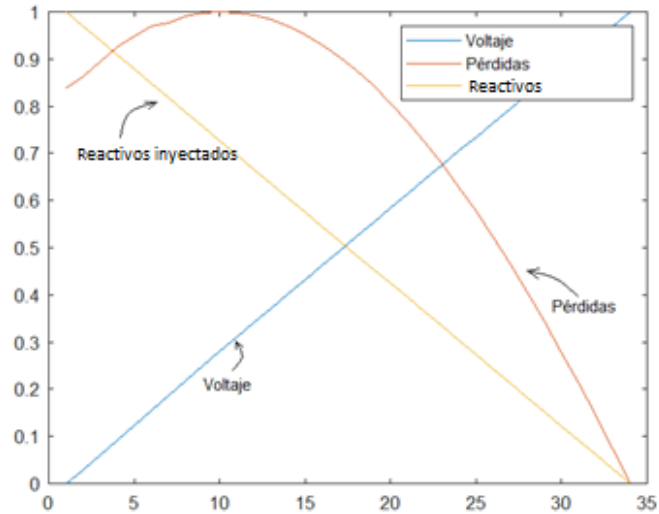


**Figura 15:** Diagrama de flujo cálculo de pesos de cada criterio.

Aunque los tamaños normalizados para bancos de capacitores corresponden a 100, 150, 250, 300, 500, 600, 750, 900, y 1200 kVAr o múltiplos de estas potencias [23]; para el presente análisis se elegirá el mínimo paso posible lo cual corresponde a 100kVAr.

El anexo 2 literal A presenta los datos de la matriz de decisión para el caso de inyección de reactivos en la barra 14 con pasos de 0.1MVar, el proceso de incremento del banco de capacitores se detiene cuando se alcanza un valor mínimo de voltaje ( $V_{set}=1pu$ ).

El anexo 2 literal B muestra los valores normalizados de la matriz de decisión, el cual corresponde al tercer paso del flujo de proceso para el cálculo de los pesos y sobre los cuales se realiza el análisis de selección del valor óptimo de inyección de reactivos.



**Figura 16:** Casos posibles vs valores normalizados.

Las tablas 7 y 8 presentan los valores determinados de manera estadística para la desviación estándar y la correlación entre los criterios de decisión analizados.

**Tabla 7:** Desviación estándar de valores analizados

Desviación estándar		
V min	Pérdidas	kVAr
0.3023	0.3054	0.3018

**Tabla 8:** Correlación entre valores analizados

Correlaciones			
	V min	Pérdidas	kVAr
V min	1	-0.8598	-0.9999
Pérdidas	-0.8598	1	0.8656
kVAr	-0.9999	0.8656	1

Finalmente se calcula los pesos de cada criterio relacionando los datos de las tablas 7 y 8 de acuerdo a lo mostrado en la ecuación 7. La tabla 9 muestra los pesos finales determinados para el caso de incremento de reactancia capacitiva en la barra 14.

**Tabla 9:** Pesos determinados para cada criterio analizado

Pesos		
W1	W2	W3
V min	Pérdidas	kVAr
1.1668	0.6091	0.6441

La relación matemática entre los valores normalizados y los pesos determinados es evaluada de acuerdo a lo mostrado en la ecuación 22.

$$FO = w_1 \cdot V_{min} + w_2 \cdot P + w_3 \cdot C_{Total} \quad (22)$$

Donde:

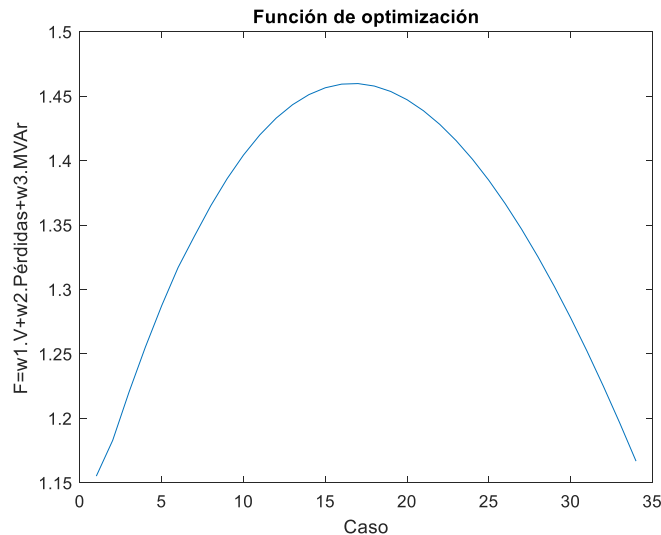
$w_1, w_2, w_3$ : Peso de cada criterio.

$V_{min}$ : Mínimo voltaje del sistema.

$P$  : Pérdidas totales del sistema por transporte.

$C_{Total}$ : Total de potencia reactiva instalada en el sistema ( $C_{Total} = \sum_1^n C_i$ ).

La figura 17 muestra gráficamente los valores puntuales de la función de optimización ante cada caso de incremento de la potencia reactiva inyectada en la barra 14.




**Figura 17:** Casos posibles vs Función de optimización.

La maximización de la función objetivo permite determinar la condición de operación que cuente con la mejor relación entre elevación de voltaje, reducción de pérdidas y menor requerimiento de potencia reactiva. Para el ejemplo evaluado se determina que la mejor condición de operación se alcanza en el caso 17 en el cual se requiere la inyección de 1.6 MVar en la barra 14. La tabla 10 permite hacer una evaluación numérica entre los valores obtenidos a condiciones normales de operación de la red de 69kV de la EERSA y la condición óptima de compensación determinada mediante el método Critic.

**Tabla 10:** Condición y operación inicial y compensada

	V min p.u	Pérdidas MW	MVar inyectados
inicial	0.9668	8.32	0
compensado	0.9832	8.29	1.6

Si bien el análisis anterior fue realizado para un instante particular de tiempo (19horas), un análisis similar puede ser realizado para cualquier instante a lo largo del día. La figura 18 muestra los resultados del análisis para la óptima compensación de reactivos en la barra 14 para un rango de estudio de 24 horas.



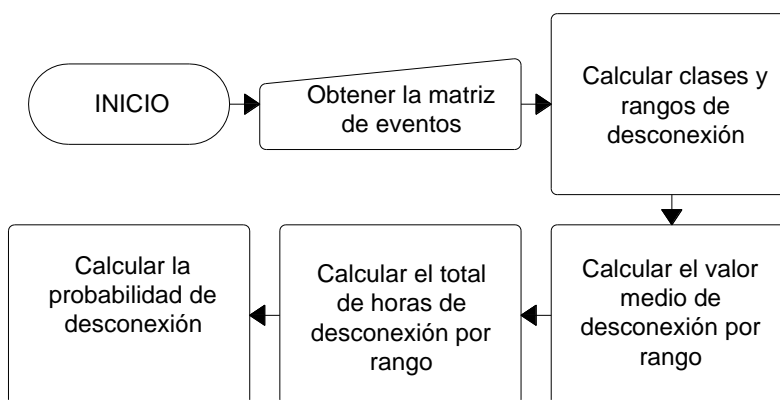
**Figura 18:** Voltajes y pérdidas iniciales vs compensados

Los resultados observados muestran que, si bien la corrección de voltaje muestra buenos resultados, no lo hace la reducción de las pérdidas. El caso analizado corresponde a la condición en la que las fuentes de generación conectadas a la red de subtransmisión de 69kV de la EERSA cuentan con un control completo de voltaje o en otras palabras se comportan como barras PV, sin embargo, los generadores ubicados en las barras 11 y 12 deberían ser tratadas como barras de carga, cuestión que se demostrará en el capítulo siguiente.

## 2.4.2 Cálculo de probabilidad de eventos en el sistema de subtransmisión de 69 kV de la EERSA

Dentro del estudio de las condiciones posibles de operación del sistema de 69kV de la EERSA principalmente se requiere un análisis probabilístico que ayudará a determinar los diferentes eventos de desconexión de carga que se puedan presentar en las distintas barras de la red. El análisis requerido puede ser realizado utilizando herramientas estadísticas que permitirán definir los valores típicos de desconexión y finalmente su probabilidad de desconexión dentro del rango de tiempo estudiado.

La figura 19 muestra el proceso que permite realizar el cálculo de los posibles porcentajes de desconexión y sus probabilidades de ocurrencia.



**Figura 19:** Diagrama de flujo cálculo de probabilidades de desconexión.

El anexo 3 muestra un conjunto de eventos de desconexión en el que constan los porcentajes de desconexión de carga en la subestación 14 y tiempo de desconexión de cada evento. El conjunto de eventos se encuentra dentro de un rango de tiempo de entre el 1/1/2020 y el 30/6/2022.

La cantidad de eventos totales presentados para la subestación 14 suman un total de 419 desconexiones, por lo cual para la elaboración de un histograma de frecuencias se requiere un conjunto de 9 clases según lo indicado por la ecuación 8. La tabla 11 muestra los resultados de los rangos y el valor medio de cada clase determinada en base a los porcentajes de desconexión de carga.

**Tabla 11:** Rango de clase (Porcentaje de desconexión SE 14)

Clase	Rango desde	Rango hasta	Porcentaje medio de desconexión
1	0.05	9.35	4.70
2	9.35	18.65	14.00
3	18.65	27.94	23.29
4	27.94	37.24	32.59
5	37.24	46.53	41.88
6	46.53	55.83	51.18
7	55.83	65.12	60.48
8	65.12	74.42	69.77
9	74.42	83.71	79.07

Con el dato de los rangos de cada clase se realiza la suma aritmética de los tiempos de desconexión de cada evento dentro del rango. La tabla 12 muestra los resultados de la cantidad total de horas desconectadas dentro del periodo de tiempo analizado.

**Tabla 12:** Total de horas desconectadas por rango de desconexión SE14

Clase	Rango desde	Rango hasta	Porcentaje medio de desconexión	Total Horas
1	0.05	9.35	4.70	26.7676
2	9.35	18.65	14.00	0.0012
3	18.65	27.94	23.29	0.0257
4	27.94	37.24	32.59	0.0597
5	37.24	46.53	41.88	0.0009
6	46.53	55.83	51.18	0.0012
7	55.83	65.12	60.48	0.0012
8	65.12	74.42	69.77	0.0018
9	74.42	83.71	79.07	0.0018

Para el rango de tiempo en análisis que corresponde al periodo entre el 1/1/2020 y el 30/6/2022 con un total de 24072 horas se calcula la probabilidad en la cual cada porcentaje

de desconexión se presente a lo largo del tiempo. La tabla 13 muestra los resultados de la probabilidad de ocurrencia de cada rango de desconexión.

**Tabla 13:** Probabilidad de desconexión por rango SE 14

Clase	Rango desde	Rango hasta	Porcentaje medio de desconexión	Total Horas	Probabilidad de desconexión
1	0.05	9.35	4.70	26.7676	<b>0.00111198</b>
2	9.35	18.65	14.00	0.0012	<b>5.0293E-08</b>
3	18.65	27.94	23.29	0.0257	<b>1.0687E-06</b>
4	27.94	37.24	32.59	0.0597	<b>2.4794E-06</b>
5	37.24	46.53	41.88	0.0009	<b>3.772E-08</b>
6	46.53	55.83	51.18	0.0012	<b>5.0293E-08</b>
7	55.83	65.12	60.48	0.0012	<b>5.0293E-08</b>
8	65.12	74.42	69.77	0.0018	<b>7.544E-08</b>
9	74.42	83.71	79.07	0.0018	<b>7.544E-08</b>

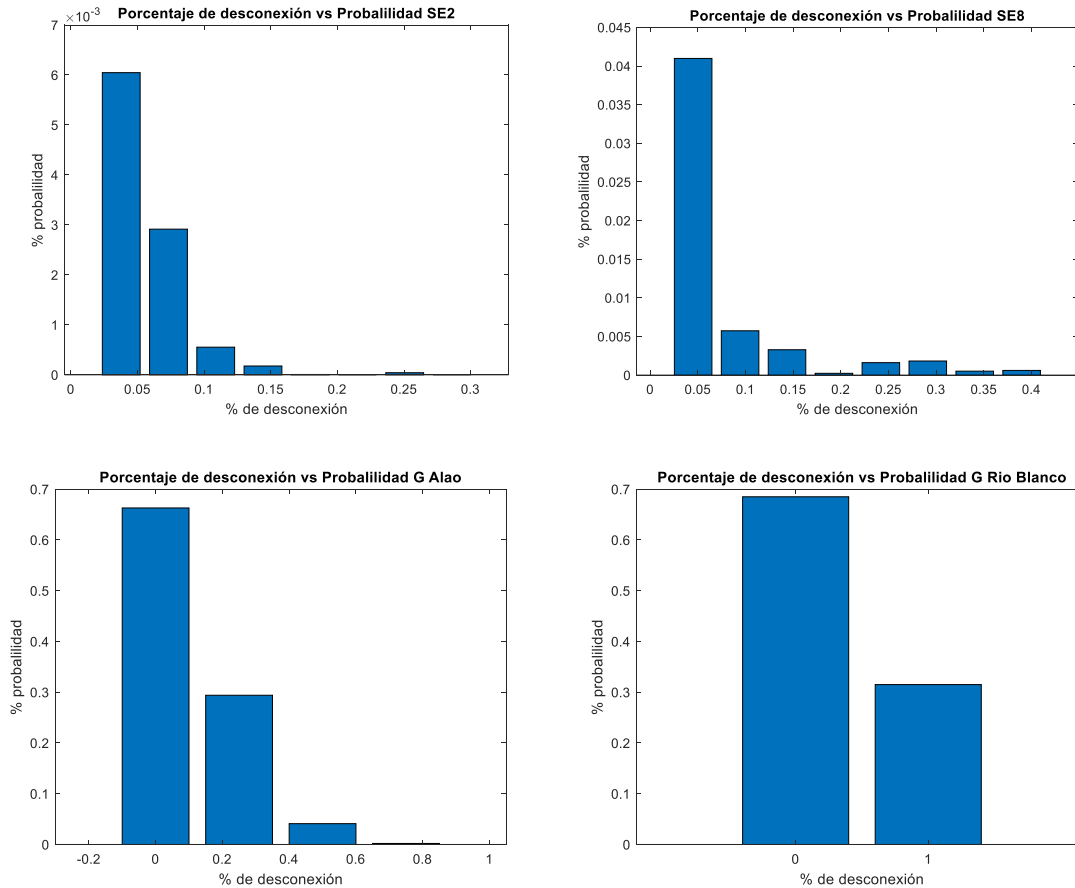
Finalmente, los datos a ser usados para la determinación de las diferentes condiciones de operación de la red corresponden a los porcentajes medios de desconexión y su probabilidad de ocurrencia. La tabla 14 muestra las probabilidades para cada porcentaje de desconexión presentado en la subestación 14.

**Tabla 14:** Porcentaje y probabilidad de desconexión SE 14

Porcentaje medio de desconexión	Probabilidad
4.70	0.00111198
14.00	5.0293E-08
23.29	1.0687E-06
32.59	2.4794E-06
41.88	3.772E-08
51.18	5.0293E-08
60.48	5.0293E-08
69.77	7.544E-08
79.07	7.544E-08

Un análisis similar deberá ser llevado a cabo para la evaluación de los eventos en cada subestación y de igual manera para determinar la probabilidad de conexión o desconexión de las líneas de transmisión y de las centrales de generación de la red de 69kV de la EERSA.

La figura 20 presenta gráficamente los resultados del cálculo de porcentajes de desconexión y sus probabilidades correspondientes tanto para una subestación urbana (SE2), rural (SE8) así como también los resultados para las centrales de generación Alao y Rio Blanco.



**Figura 20:** Porcentajes de desconexión vs probabilidad.

Los resultados presentados muestran que las subestaciones rurales presentan una mayor susceptibilidad a contingencias tanto en magnitud como en probabilidad.

### 2.4.3 Entrenamiento de RNA

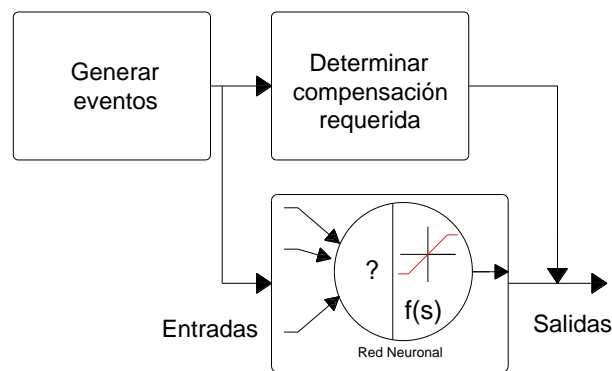
El entrenamiento supervisado de redes neuronales artificiales es un proceso en el cual se requiere de una gran cantidad de datos de entrada y salida. Los datos de entrada son aquellos que definirán las condiciones de operación del sistema dentro de los que consta la topología de la red, cargas y generación conectada a cada barra. Por otro lado, los datos de salida corresponderán a la cantidad de reactivos necesarios a ser inyectados en cada barra del sistema ante las diferentes condiciones de operación de la red.

Inicialmente los conjuntos de datos de entrada serán creados determinando eventos de manera aleatoria y su ocurrencia será determinada en base a las probabilidades previamente calculadas. La aplicación de la metodología indicada en el apartado 2.4.1 permitirá crear el

conjunto de datos de que indiquen la cantidad correspondiente de reactivos necesarios creando de esta manera el conjunto de salida que permitirá completar el proceso de entrenamiento de las redes neuronales.

Dado que cada evento debe ser definido para el conjunto de datos de entrada y estos deberán ser datos que puedan ser proporcionados por los equipos de medición que se encuentren dentro de la red; los datos de entrada a la RNA corresponderán a la potencia activa y reactiva de las cargas, la topología de la red definida por la corriente circulante por las líneas, potencia inyectada por las centrales de generación y la hora del día.

La siguiente figura proporciona un esquema general del proceso de generación de datos de entrada y salida con lo que se realizará el posterior entrenamiento de la RNA.



**Figura 21:** Creación de la población de entrada y salida para entrenamiento de la RNA.

El proceso de entrenamiento de la RNA será llevado a cabo con las herramientas proporcionadas por el software Matlab para una topología de red neuronal de tipo mono y multicapa.

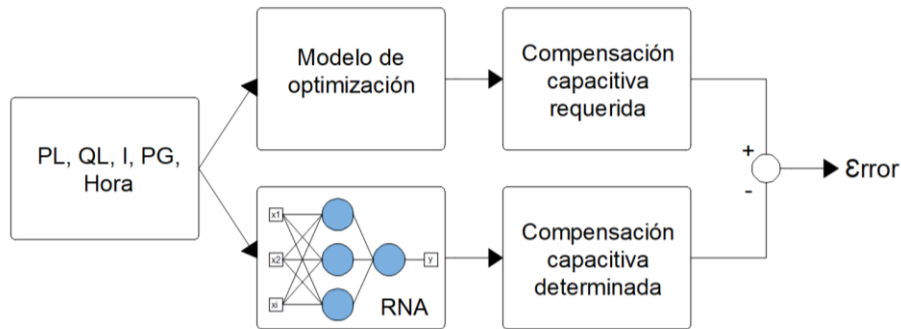
La viabilidad de cada RNA será analizada en base a los resultados de la matriz de confusión y la medida del error cuadrático medio de los resultados determinados por cada red.

Como se muestra en la figura 22, la matriz de confusión permitirá determinar el grado de exactitud con en que las RNA ordenan la activación de los bancos de capacitores cuando estos son requerido o los desactivan cuando no son requeridos. La evaluación será realizada en base a los datos requeridos por el modelo de optimización propuesto en 2.4.1 y los determinados por las RNA.

		Compensación reactiva requerida	
		No Activa	Activa
Compensación determinada	No Activa	Verdadera No Activación	Falsa No Activación
	Activa	Falsa Activación	Verdadera Activación

**Figura 22:** Matriz de confusión para los resultados de la RNA.

Por otro lado, el error cuadrático medio permitirá determinar la precisión con la que las RNA determinan el valor de compensación reactiva (VAR) a ser inyectada.



**Figura 23:** Evaluación del error en la implementación de la RNA.

La información presentada en [24] proporciona datos más relevantes acerca de las herramientas de creación, entrenamiento y evaluación de redes neuronales que serán utilizadas en el siguiente capítulo.

## **2.5 Conclusiones Capítulo II**

- La implementación del análisis estadístico permitirá determinar la correcta capacidad de reactivos a ser inyectados, la cual permitirá lograr la máxima corrección de los perfiles de voltaje sin incrementar las pérdidas por transporte en las líneas de transmisión.
- En general se puede concluir que las centrales de generación son altamente susceptibles a desconexiones ya sean estas debido a contingencias o a trabajos programados.
- La determinación de los parámetros de entrada a las redes neuronales para la operación de sistemas eléctricos en tiempo real, debe considerar únicamente los parámetros que pueden ser proporcionados por equipos de tipo telemedidos instalados en la red.

# CAPÍTULO III. APLICACIÓN Y/O VALIDACION DE LA PROPUESTA

## 3.1 Análisis de los resultados:

Describir claramente los resultados obtenidos a partir de la aplicación de los procedimientos enunciados en el Capítulo II.

### 3.1.1 Modelación de la red de subtransmisión de 69 kV de la EERSA

La red de Subtransmisión de 69kV de la EERSA está compuesta por 14 barras, la barra 1 representa la conexión al SNI, las barras 11 y 12 son barras de conexión a las centrales de generación Alao (10.2 MVA) y Rio Blanco (3MVA) respectivamente, mientras que las barras restantes corresponden a subestaciones de carga.

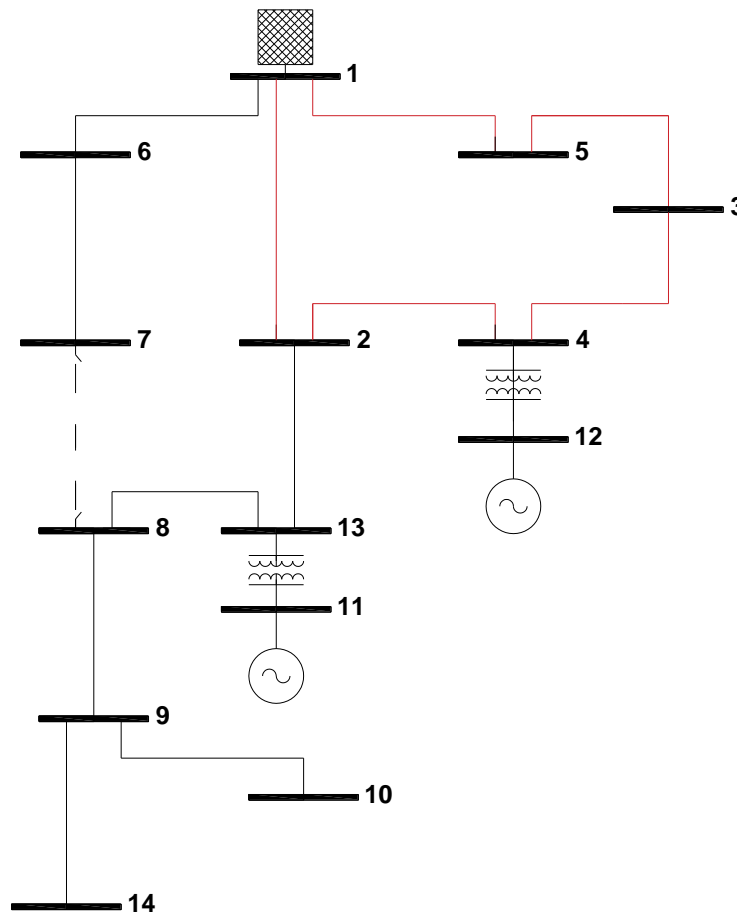

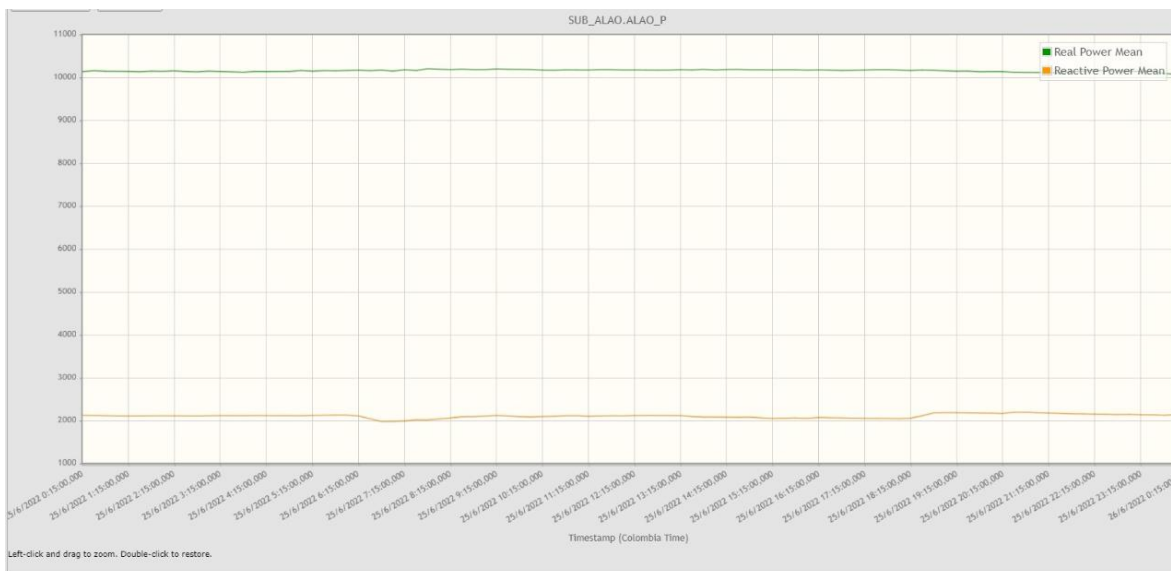


Figura 24: Red de 69kV de la EERSA.

Como se observa en la figura 24, las barras urbanas 1, 2, 3, 4 y 5 operan en esquema de anillo, mientras que, las barras 1, 2, 6, 7, 8, 9 y 13 cuentan con esquema de anillo sin embargo son operados de forma radial alternando continuamente la apertura de las líneas entre cada barra. A manera de ejemplo las figuras 25 y 26 muestran que, debido a las limitaciones de los equipos, los sistemas de control de la central Alao (Barra 11) no cuentan con la capacidad de realizar un adecuado control de voltaje comportándose está a modo de barra PQ, situación similar a la que se encuentra la central Rio Blanco (Barra 12).

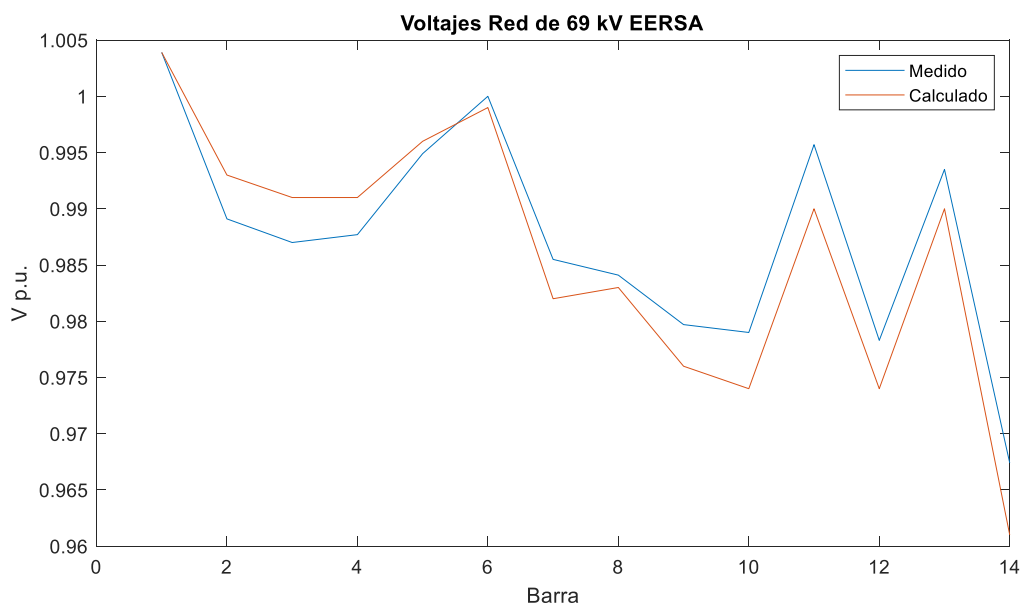


**Figura 25:** Lectura de voltaje de la barra 11 correspondiente al 26/06/2022.



**Figura 26:** Lectura de potencia activa y reactiva de la barra 11 correspondiente al 26/06/2022.

Las consideraciones en cuanto al comportamiento de la generación y los datos de las impedancias de líneas de la red de 69kV de la EERSA presentados en el anexo 1 permiten comparar los valores de voltajes proporcionados por los equipos de telemedición y los calculados según el modelo de red implementado. La figura 27 presenta una comparación de los voltajes medidos y calculados para un día aleatorio en hora pico.



**Figura 27:** Lectura de voltajes de barra medida y calculada.

Los resultados encontrados muestran que el modelo de red implementado proporciona un error máximo de 0.7 % en relación a los voltajes medidos, validando de esta manera el modelo implementado.


Por otro lado, los datos de las cargas típicas horarias proporcionadas por la EERSA mostradas en el anexo 1, servirán de base para las posteriores evaluaciones llevadas a cabo.

### **3.1.2 Aplicación del modelo de optimización para ubicación y dimensionamiento de bancos de capacitores en la red de 69kV de la EERSA.**

La implementación del método Critic a la ubicación y dimensionamiento de bancos de capacitores a la red estudiada permite encontrar una adecuada correlación entre mejoramiento de los perfiles de voltaje, reducción de las pérdidas del sistema con la mínima compensación a instalar.

### Evento 1: Caso Base – Barra 14

Los resultados obtenidos del modelo de optimización para la topología mostrada en la figura 24 con los datos de cargas típicas son mostrados en la figura 28.



**Figura 28:** Resultados barra 14 voltajes – pérdidas 24 horas. Caso base.

Los resultados obtenidos muestran que el método implementado logra un notorio mejoramiento de los perfiles de voltaje a la vez que se reduce las pérdidas por transporte del sistema.

La figura 29 muestra gráficamente los valores horarios de inyección de reactivos requeridos para las barras del sistema. Los resultados demuestran que para la condición base de estudio únicamente se requiere compensación para las barras 12 y 14 de la red de la EERSA.


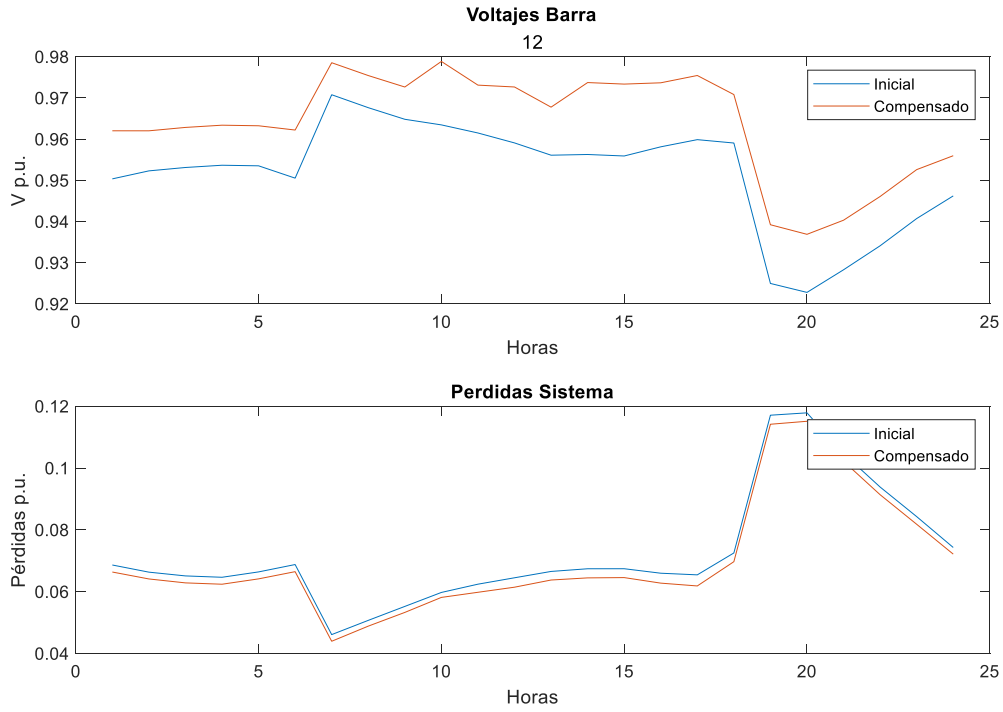


Figura 29: Resultados compensación requerida. Caso base.


### Evento 2: Desconexión de la central Rio Blanco -Barra 12

Un segundo evento analizado corresponde a la desconexión de la central Rio Blanco (Barra 12). La figura 30 muestra una aceptable corrección del perfil de voltaje mientras que la reducción de pérdidas por transporte en el sistema es mínima para este caso.

Adicionalmente, en comparación de las figuras 30 y 31 se puede observar que para el caso 2 los requerimientos de reactivos del sistema se reducen y se centralizan en la barra 12. Un rápido análisis a las condiciones de operación del caso 2 indicarían que una mayor inyección de reactivos produciría una mayor circulación de corrientes en las líneas provocando de esta manera el incremento de pérdidas en la red.



**Figura 30:** Resultados barra 12 voltajes – pérdidas 24 horas. Desconexión generador 12.



**Figura 31:** Resultados compensación requerida. Desconexión generador 12.

Los resultados mostrados demuestran que el modelo de optimización implementado adapta su respuesta de forma dinámica ante las distintas condiciones de operación presentes en la red de la EERSA. Por otro lado, cabe destacar que el modelo prioriza la inyección de reactivos en las barras con menores voltajes tal como se observa en los resultados de las evaluaciones para los casos 1 y 2.

### **3.1.3 Entrenamiento de la Red Neuronal Artificial**

El entrenamiento supervisado de toda RNA requiere del uso de un conjunto de datos de entrada y otro de salida. Para el presente caso los datos de entrada determinan las condiciones de operación de la red de la EERSA y están compuestos por un total de 46 señales entre las que se encuentran potencias activas y reactivas de las cargas, potencia suministrada por las centrales de generación, corrientes de circulación por las líneas y la hora.

La obtención de los datos o población de entrada se realiza generando eventos aleatorios de desconexión de carga, generación y cambios en la topología de la red de acuerdo a las probabilidades determinadas como se muestra en el apartado 2.4.2. Se usa un total de 500 eventos divididos en 24 períodos de una hora que brindan un total de 12000 datos que serán tomados en cuenta como población de entrada para el entrenamiento de las RNA


Los datos de salida serán determinados mediante la aplicación del modelo de optimización tal como se muestra en 3.1.2 a cada uno de los eventos de entrada, construyendo de esta manera una nueva población de 12000 datos de salida para la RNA.

Los datos de entrada ingresados para el entrenamiento de cada red neuronal corresponden a un total de 46 entre los cuales se encuentran: P1, P2, P3, P4, P5, P6, P7, P8, P9, P10, P11, P12, P13, P14, Q1, Q2, Q3, Q4, Q5, Q6, Q7, Q8, Q9, Q10, Q11, Q12, Q13, Q14, I1-2, I1-3, I1-4, I1-5, I7-8, I8-13, I8-9, I9-10, I9-14, I13-2, I2-4, I4-12, I4-3, I3-5, I13-11, PG11, PG12, HORA.

Finalmente, se analiza los resultados encontrados para las barras que operan bajo las condiciones más críticas dentro del sistema las cuales corresponden a las barras 12 y 14.

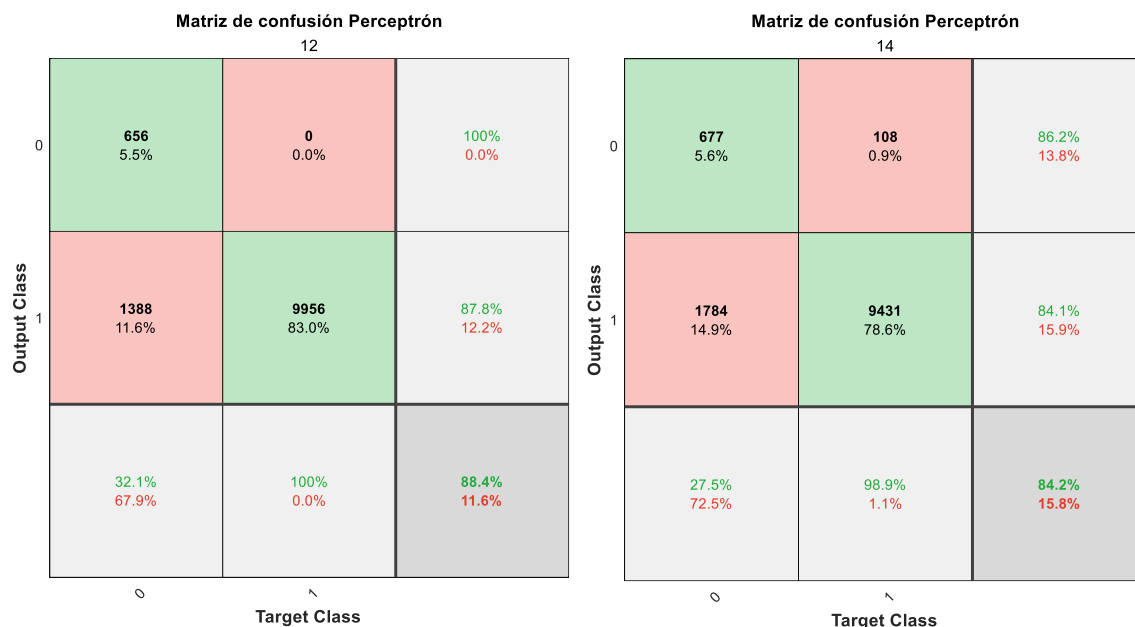
## Perceptrón

El perceptrón corresponde al esquema más básico dentro de las redes neuronales tal como se muestra en la figura 32. Dado a su simplicidad, este cuenta con ciertas limitaciones en cuanto a sus capacidades de aprendizaje por lo que los resultados encontrados con este esquema son tomados en cuenta como punto de referencia para la evaluación de redes neuronales más complejas.



**Figura 32:** Esquema del Perceptrón aplicado.

El entrenamiento se lleva a cabo para dos perceptrones individuales que determinaran la cantidad de reactivos necesarios tanto para la barra 12 y 14 respectivamente.



**Figura 33:** Matriz de confusión perceptrón barra 12 y 14.

Los resultados de la matriz de confusión (figura 33) muestran que cada perceptrón reconocen de manera satisfactoria cuando las condiciones de operación del sistema requieren la activación o desactivación de los bancos de capacitores.


La tabla 15 muestra los valores encontrados de los indicadores de la calidad del entrenamiento para cada perceptrón en donde se observa claramente que el perceptrón correspondiente a la barra 12 presenta los mejores resultados. De esta manera se determina que los resultados de la capacidad de reactivos requeridos determinada por el perceptrón para la barra 12 son más parecidos a los determinados por el modelo de optimización que los determinados por el perceptrón de la barra 14.

**Tabla 15:** Resultado de parámetros de entrenamiento del perceptrón

Perceptrón		
Barra	12	14
Error cuadrático medio $\times 10^{-4}$	0.247	10
Confusión	87.7%	84.2%


Las figuras 34 y 35 muestra gráficamente el valor promedio de cada entrada multiplicada por su peso correspondiente indicando de esta manera las señales más importantes que determinan el incremento o decremento de la cantidad de reactivos a inyectar para las barras 12 y 14 respectivamente.

Diagrama de pesos del perceptron Barra 12



**Figura 34:** Diagrama Sankey señales del perceptrón barra 12.

Diagrama de pesos del perceptron Barra 14



**Figura 35:** Diagrama Sankey señales del perceptrón barra 14.

El anexo 4 muestra los valores de los pesos para los perceptrones de las barras 12 y 14.

### Red Multicapa

Las redes neuronales multicapa se caracterizan por una mayor complejidad que les provee de una mayor capacidad de aprendizaje.

Para el análisis de la topología más adecuada para la RNA multicapa, se tomará como referencia los valores de los resultados del entrenamiento encontrados por el perceptrón, adicionalmente, se usará el criterio de búsqueda de la menor complejidad posible para la RNA. El entrenamiento para los distintos tamaños de red multicapa será llevada a cabo de acuerdo a los parámetros de entrenamiento mostrados en la tabla 16.

**Tabla 16:** Parámetros de entrenamiento de la RNA

Parámetro	Valores
Porcentaje de entrenamiento	70%
Porcentaje de validación	15%
Porcentaje de prueba	15%
Épocas	2000

Las tablas 17 y 18 muestran los resultados de los indicadores de entrenamiento para distintos tamaños de las redes para la barra 14, en estos resultados se observa que mientras incrementa el tamaño y complejidad de la red mejores son los resultados del entrenamiento.


**Tabla 17:** Resultado ECM para diferentes tamaños de RNA ( $\times 10^{-4}$ )

	Capas				
		1	2	3	4
Neuronas	1	6.3521	6.3737	6.3881	6.3540
	2	3.7920	3.4494	2.3466	1.7768
	3	1.6095	1.9508	1.4044	1.9307
	4	1.4685	0.9972	0.9678	0.6677
	5	1.3520	1.1099	0.6227	0.5495

**Tabla 18:** Resultado matriz de confusión para diferentes tamaños de RNA (%)

	Capas				
		1	2	3	4
Neuronas	1	83.8	83.6	83.6	83.6
	2	87.4	85.5	83.8	86.8
	3	91.8	86.3	79.7	82.8
	4	79.5	79.5	88.6	86.6
	5	84.2	86.6	88.8	83.6

De las tablas 17 y 18, se observa que la RNA de tres neuronas con una capa oculta como se muestra en la figura 36, presenta excelentes resultados de entrenamiento ante una complejidad relativamente reducida por lo que se usa esta topología de RNA para su análisis.



**Figura 36:** RNA de tres neuronas y una capa oculta.

Para la evaluación y comparación de los resultados encontrados, se establecen 6 condiciones de operación para la red de 69kV de la EERSA tal como se observa en la figura 37.

Los eventos 1 y 4 corresponderán a eventos de referencia para el análisis de la operación de los bancos de capacitores de las barras 12 y 14 respectivamente.

Los eventos 2 y 5 corresponden a condiciones críticas para el voltaje de las barras 12 y 14 respectivamente, los mismos que tiene una significativa probabilidad de ocurrencia, por lo que se puede afirmar que las RNA de las barras analizadas estarán entrenadas ante dichos eventos.

Los eventos 3 y 6 son favorecedores a la regulación de voltaje, sin embargo, su ocurrencia es poco probable, por lo que se puede afirmar que las RNA no estarían entrenadas ante estos.

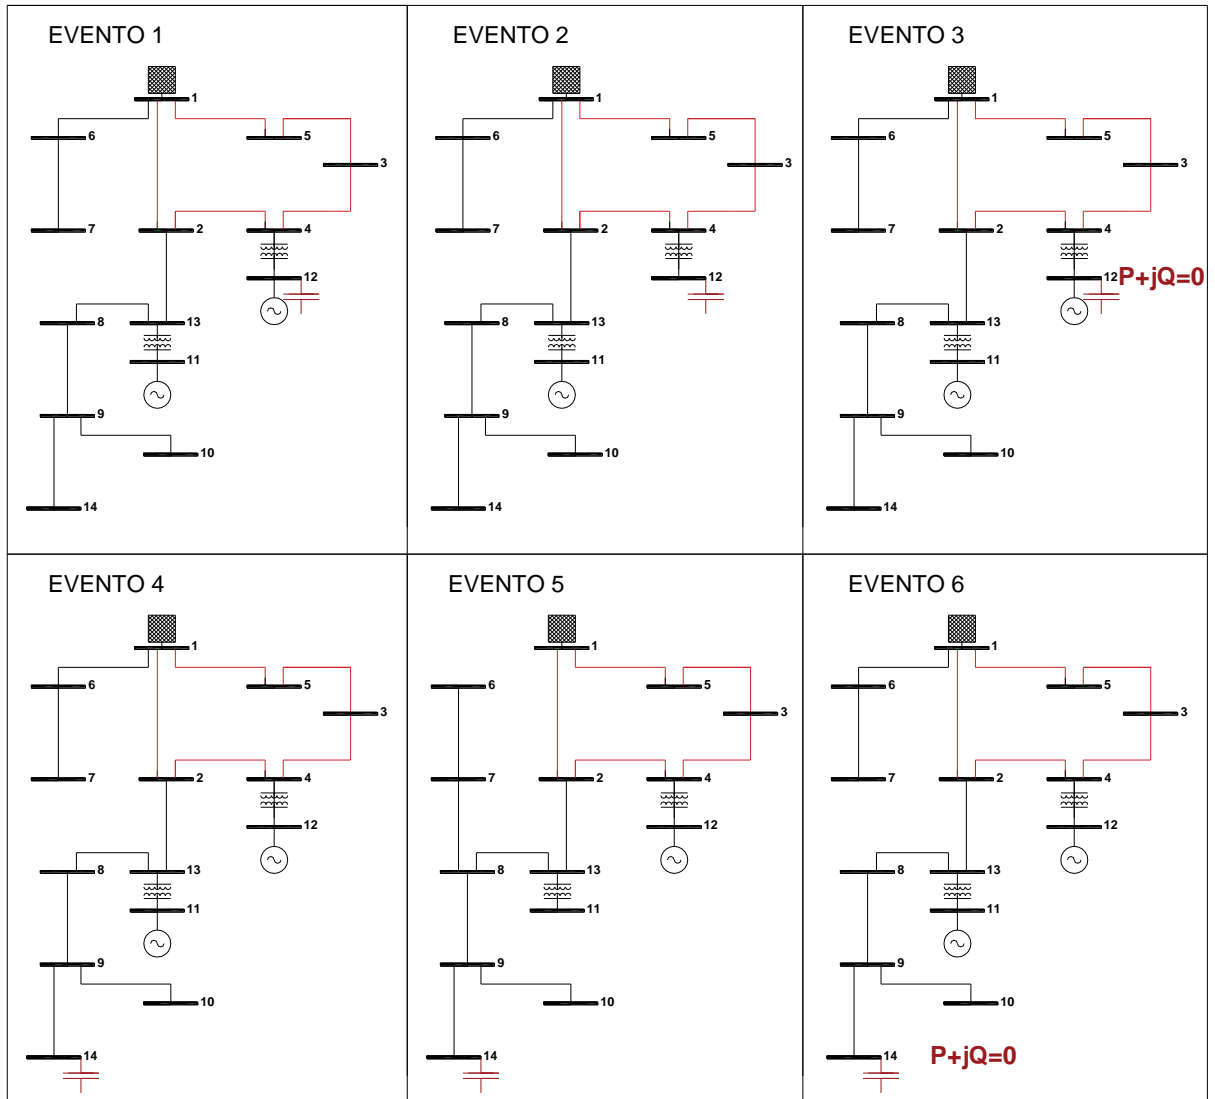
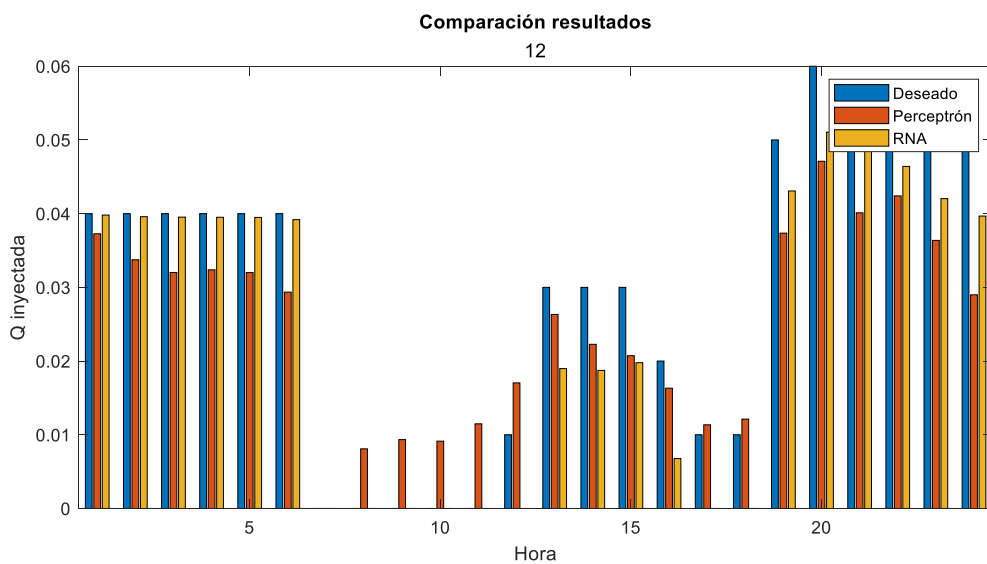


Figura 37: Escenarios de operación evaluados.


Los resultados de la aplicación de la metodología de optimización, perceptrón, y la RNA de la figura 36 son mostrados a continuación.

## Evento 1: Caso Base - Barra 12

Apertura de la línea entre las barras 7 y 8.




**Figura 38:** Resultados inyección de reactivos en la barra 12 – Evento 1.



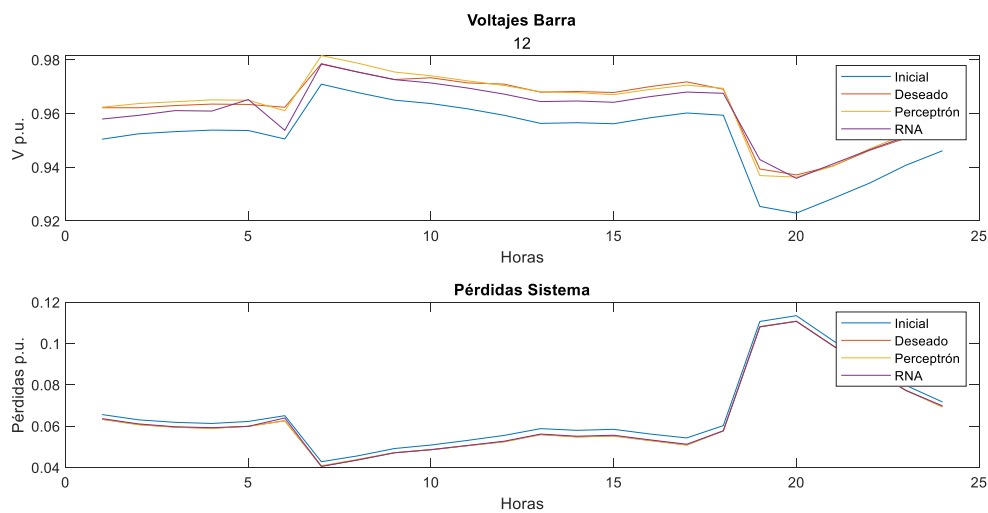
**Figura 39:** Resultados de voltajes barra 12 y pérdidas del sistema – Evento 1.

## Evento 2: Condición crítica pero probable - Barra 12

Se desconecta la generación en la barra 12 y se abre la línea entre las barras 1 y 6.



**Figura 40:** Resultados inyección de reactivos en la barra 12 – Evento 2.



**Figura 41:** Resultados de voltajes barra 12 y pérdidas del sistema – Evento 2.

### Evento 3: Condición favorable pero improbable - Barra 12

Se pierde toda carga en la barra 12 y se abre la línea entre las barras 7 y 8.




Figura 42: Resultados inyección de reactivos en la barra 12 – Evento 3.




Figura 43: Resultados de voltajes barra 12 y pérdidas del sistema – Evento 3.

## Evento 4: Caso Base - Barra 14

Apertura de la línea entre las barras 7 y 8.




Figura 44: Resultados inyección de reactivos en la barra 14 – Evento 4.

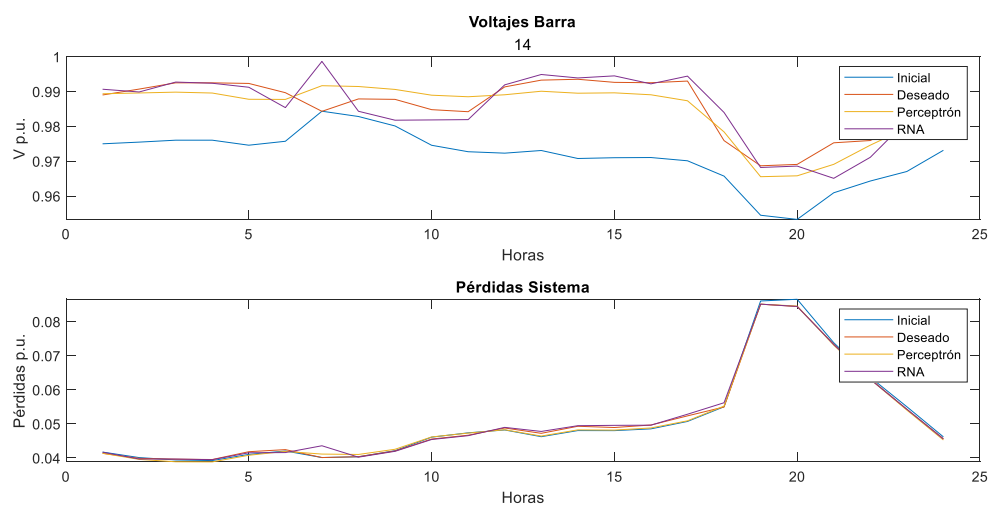


Figura 45: Resultados de voltajes barra 14 y pérdidas del sistema – Evento 4.

### Evento 5: Condición crítica pero probable - Barra 14

Se desconecta la generación en la barra 11 y se abre la línea entre las barras 1 y 6.




Figura 46: Resultados inyección de reactivos en la barra 14 – Evento 5.


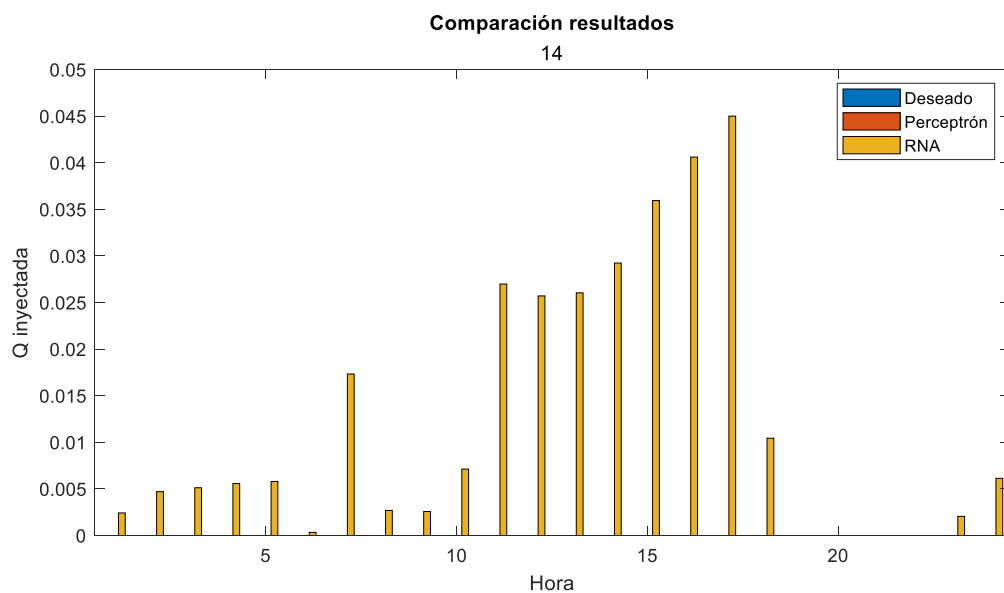



Figura 47: Resultados de voltajes barra 14 y pérdidas del sistema – Evento 5.

## Evento 6: Condición favorable pero improbable - Barra 14

Se pierde toda carga en la barra 14 y se abre la línea entre las barras 7 y 8.



**Figura 48:** Resultados inyección de reactivos en la barra 14 – Evento 6.



**Figura 49:** Resultados de voltajes barra 14 y pérdidas del sistema – Evento 6.

De los resultados de la evaluación de los seis eventos de operación de la red de la EERSA se observa que se en condiciones normales de operación los resultados determinados por el perceptrón y la RNA no difieren mucho el uno del otro. Por otro lado, se observa que en condiciones críticas de operación para la red con las cuales se haya entrenado al perceptrón y la RNA, la RNA presenta una presenta una mejor respuesta en relación a los valores determinados por la metodología de optimización.

### 3.2 Validación técnica -económica de los resultados:

El análisis de la capacidad de implementación de una inteligencia artificial para la compensación de reactivos requiere de la evaluación de los requerimientos tanto de software como de hardware.

Cabe destacar que el nivel de calidad de respuesta del sistema de compensación repercutirá directamente en los costos finales de implementación del proyecto.

#### 3.2.1 Requerimientos de software

Para el análisis de requerimientos de software es de primordial importancia determinar el tipo de RNA que se desea implementar ya que su complejidad determinará el tipo de software requerido.

A rasgos generales la representación matemática del perceptrón se muestra en la ecuación 23.

$$\begin{aligned}
 Q \text{ requerida} = & w_1 \cdot P1 + w_2 \cdot P2 + w_3 \cdot P3 + w_4 \cdot P4 + \dots + w_{15} \cdot Q1 + w_{16} \cdot Q2 + w_{17} \cdot Q3 \\
 & + w_{18} \cdot Q4 + \dots + w_{29} \cdot I1 - 2 + w_{30} \cdot I1 - 3 + w_{31} \cdot I1 - 4 + w_{32} \cdot I1 - 5 \\
 & + \dots + w_{44} \cdot PG11 + w_{45} \cdot PG12 + w_{46} \cdot \text{Hora}
 \end{aligned}
 \tag{23}$$

Tomando en cuenta la poca complejidad requerida para la formulación del perceptrón es importante notar que este puede ser programado en los equipos de comunicación y control (relés, RTUs) comúnmente presentes en cada empresa distribuidora, lo que involucra que no se requiere del empleo de ningún software adicional para su implementación.

Por otro lado, la implementación de una RNA dependiendo de qué tan profunda sea su arquitectura, esta necesitara de mayores requerimientos e incluso el uso de softwares con

mayor capacidad computacional, requiriendo de esta manera el empleo de softwares especializados en el uso de redes neuronales.

La tabla siguiente presenta una comparativa de los softwares más comunes utilizados para programación y cálculo numérico los mismos que pueden ser usados para el entrenamiento de las redes neuronales y la implementación de las mismas.

**Tabla 19:** Costo de plataformas de cálculo numérico


Python	Matlab Licencia comercial y gubernamental
Software libre	940 dólares/año

Tomando en cuenta lo dicho anteriormente es notorio que los requerimientos de software no involucrarán una considerable inversión económica sobre todo dada la existencia de softwares especializados para la implementación de redes neuronales como Python el cual es de acceso libre.

### 3.2.2 Requerimientos de hardware


Durante el presente trabajo los resultados de las RNAs muestran valores continuos de potencia reactiva requerida ( $Q$  requerida) esta información podría ser utilizada por equipos de compensación estáticos como SVCs. Una opción más económica consistiría en la discretización de las señales presentadas por las RNA, donde los valores continuos de potencia reactiva requerida pasarán a representar la conexión o desconexión de un conjunto limitado de bancos de capacitores.

La figura 50 muestra el diagrama unifilar del sistema de compensación reactiva mediante bancos de capacitores de tres niveles.




**Figura 50:** Unifilar sistema de tres bancos de capacitores.

El proceso para convertir la señal de tipo continua a una discreta requiere de la determinación de la cantidad de bancos de capacitores a implementar y los niveles en los que cada banco será activado o desactivado. Es necesario tomar en cuenta que esta discretización requerirá del uso de una banda de histéresis que brindará estabilidad y seguridad al accionamiento de cada banco tal como se muestra en la figura 51.



**Figura 51:** Señal continua de potencia reactiva requerida.

Por lo tanto, la figura 52 presenta una representación gráfica de la posible respuesta al aplicar el modelo de discretización de la señal presentada en la figura 51 para el sistema unifilar de la figura 50.



**Figura 52:** Señal discreta de potencia reactiva inyectada.

De acuerdo a los últimos procesos exitosos finalizados en el portal SERCOP hasta diciembre 31 de 2022, la tabla 20 presenta como referencia un resumen de los costos actuales de los equipos que podría ser utilizados para la implementación del proyecto.

**Tabla 20:** Costos unitarios de equipamiento requerido

Equipo	Precio unitario (USD)	Proceso
Reconectador tripolar para sistema trifásico de 27kV	18.200,00	SIE-EEQ-GD1F019-2022
Banco de capacitores trifásico de 112.5kVA, 220V	4.936,29	MCB-GADMPA-2022-0029
Banco de Capacitores trifásico de 300kVA, 13.79kV con interruptor	25.500,00	SIE-CNELGYE-077-2022
Banco de Capacitores trifásico de 900kVA, 13.79kV con interruptor	26.850,00	SIE-CNELGYE-077-2022

Final es evidente que la mayor inversión económica para la implementación de una inteligencia artificial para la compensación de reactivos corresponde a la adquisición e instalación de los equipos.

### **3.3 Conclusiones Capítulo III**

- Se observa que el modelo de optimización para compensación reactiva aplicado al sistema de 69kV de la EERSA presenta muy buenos resultados para el control de local de voltaje, sin embargo, no se aprecian mejoras considerables en cuanto a reducción de pérdidas del sistema.
- Se determina que en general mientras más compleja sea la arquitectura de la RNA implementada mejor será la respuesta de esta ante condiciones críticas de operación del sistema de la EERSA.
- Se establece que la mayor inversión económica para la implementación de una RNA para el control de voltaje y reducción de pérdidas en cualquier sistema corresponderá a la adquisición de los equipos de compensación, siendo la mejor opción el empleo de bancos de capacitores e interruptores.

## Conclusiones generales

- Se observa que el análisis estadístico aplicado a la determinación de la óptima compensación reactiva en sistemas eléctricos permite obtener buenos resultados en cuanto a corrección de voltaje y reducción de pérdidas a la vez de permitir una fácil programación y ser computacionalmente veloz al haber permitido analizar una gran cantidad de eventos de operación en la red de 69 kV de la EERSA en tiempos relativamente cortos.
- Se debe tomar en cuenta que, si bien las herramientas estadísticas permitirán establecer eventos probables de operación en las redes eléctricas, la ocurrencia de eventos poco probables pero críticos para el sistema podrían provocar operaciones no deseadas de los equipos de compensación.
- Se determinó que debido a que la corrección de voltaje y reducción de pérdidas mediante compensación capacitiva no corresponde a un componente crítico del sistema, la operación bajo un cierto margen de error es admisible, esto repercute en que de acuerdo al sistema eléctrico analizado será posible la implementación de una inteligencia artificial simple tipo perceptrón o más compleja como una RNA multicapa.

## Recomendaciones

- Se recomienda realizar una posible evaluación de la aplicación del método Critic para análisis multivariable y el análisis de su desempeño para la optimización de la ubicación de equipos de protección como seccionadores fusible y reconectores en redes de medio voltaje.
- Se invita a que para futuros trabajos se analice la posibilidad del uso de redes neuronales profundas para la automatización de la restauración del servicio en redes de medio voltaje durante fallas en la red, dado que los procesos de detección y aislamiento de fallas exigirán una mayor exactitud y precisión en el análisis de las señales.
- Debido a las capacidades de aprendizaje de las redes neuronales artificiales, se podría analizar su uso en el cálculo en tiempo real de flujos de potencia y su aplicación a la estimación de estado en redes eléctricas de pequeño y mediano tamaño con en el caso de las redes de subtransmisión de las empresas distribuidoras.

## Referencias bibliográficas

- [1] D. J. Matich, *Redes Neuronales: Conceptos Básicos y Aplicaciones*. 2001.
- [2] F. S. Ruiz tipán and C. A. Barrera Singaña, “Determinación de la compensación reactiva en paralelo en sistemas de transmisión usando resultados de sensibilidad y curvas QV,” Universidad Politécnica Salesiana, 2020.
- [3] M. L. Viracocha Chicaiza, “Óptimo Dimensionamiento Y Ubicación De Bancos De Capacitores En Redes De Distribución Usando Algoritmo De Colonia De Hormigas,” Universidad Politécnica Salesiana, 2018.
- [4] G. M. Gutiérrez Serna and A. Á. Tellez, “Óptima ubicación y dimensionamiento de banco de capacitores usando compensación VOLT-VAR en micro-redes eléctricas,” Universidad Politécnica Salesiana, 2018.
- [5] J. Rojas and A. Águila, “Óptima Compensación De La Potencia Reactiva En Redes De Distribución Eléctrica Basado En Simulated Annealing,” 2017. [Online]. Available: <https://dspace.ups.edu.ec/bitstream/123456789/14229/6/UPS-KT01373.pdf>
- [6] S. Marcial and A. Aguila, “Optimal Compensation of Reactive Power in Radial Distribution Networks Considering Design Period,” *Proc. - 2019 Int. Conf. Inf. Syst. Comput. Sci. INCISCOS 2019*, pp. 108–115, 2019, doi: 10.1109/INCISCOS49368.2019.00026.
- [7] P. A. Achig and D. Carrión, “Compensación óptima de potencia reactiva en sistemas eléctricos de transmisión mediante búsqueda armónica,” 2019.
- [8] M. Campaña, P. Masache, E. Inga, and D. Carrión, “Estabilidad de tensión y compensación electrónica en sistemas eléctricos de potencia usando herramientas de simulación,” *Ingenius*, 2022, doi: 10.17163/ings.n28.2022.07.
- [9] D. Iñiguez, J. Plazarte, and H. Arcos, “Algoritmo De Programación Dinámica Para Conexión/Desconexión Diaria De Compensación,” Escuela Politécnica Nacional, 2019. [Online]. Available: <http://bibdigital.epn.edu.ec/bitstream/15000/19923/1/CD-9377.pdf>

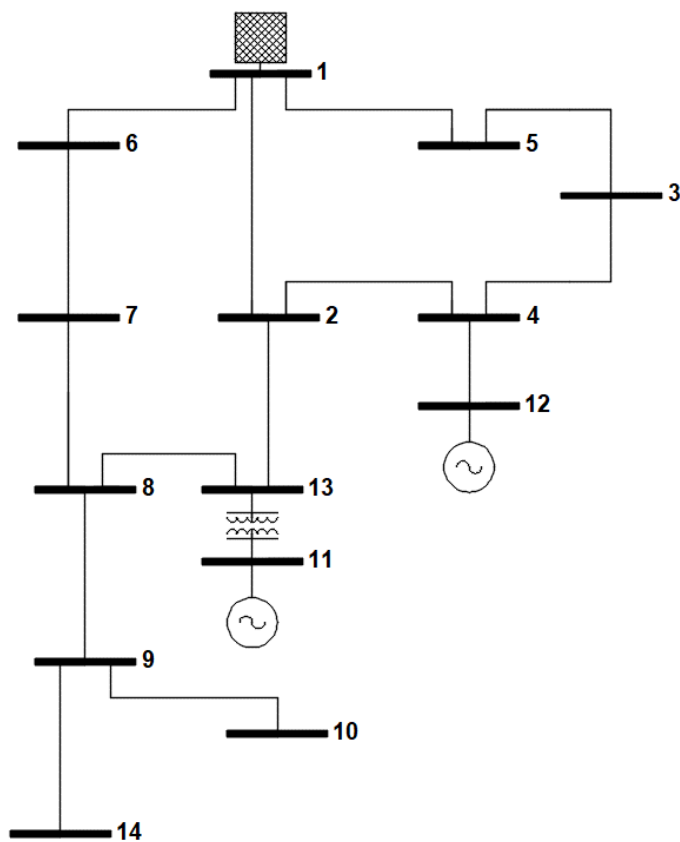
- [10] N. R. Balderramo Vélez, Y. E. Llosas Albuerne, L. Neves, and L. A. Cuenca Álava, “Diseño de Redes Eléctricas Inteligentes para una Gestión Energética,” *CICIC 2019 - Novena Conf. Iberoam. Complejidad, Inform. y Cibern. Memorias*, vol. 2, no. April, pp. 96–101, 2019.
- [11] J. Ruiz and C. Aguirre, “Diseño de un controlador óptimo usando redes neuronales dinámicas para un sistema de generación eólica,” Universidad Tecnológica de Pereira, 2020.
- [12] G. X. Carpio Suarez, P. A. Daga López, and P. D. Robles Lovato, “Aplicación de una red neuronal a un sistema eléctrico de distribución mediante el análisis de comportamiento de su carga en bajo voltaje,” Universidad Politécnica Salesiana, 2019.
- [13] C. Miguel, “Estimación de parámetros de un motor de inducción usando redes neuronales y sistemas neurodifusos,” Instituto Nacional de Astrofísica, Óptica y Electrónica, 2017.
- [14] J. Gonz, “Detección y diagnóstico de fallas en sistemas neuronal autoasociativa y una red neuronal probabilística,” Universidad autónoma de Coahuila, 2019.
- [15] S. Dorado and V. Velásquez, “Pronóstico de demanda utilizando inteligencia artificial,” Universidad ICESI, 2020.
- [16] L. D. Quisimalín Villacís and F. L. Quilumba Gudiño, “Predicción de la demanda eléctrica en barra de 69kV del sistema eléctrico de subtransmisión de la empresa eléctrica Riobamba S.A.,” Escuela politécnica nacional, 2017.
- [17] J. J. Grainger and W. D. Stevenson, “Análisis de Sistemas de Potencia.” p. 743, 1985.
- [18] V. Yepes Piqueras, “Método CRITIC de toma de decisión multicriterio,” Jan. 2022. <https://victoryepes.blogs.upv.es/2022/01/13/metodo-critic-de-toma-de-decision-multicriterio/> (accessed May 06, 2022).
- [19] D. A. Lind *et al.*, *Estadística aplicada a los negocios y la economía*, vol. XVI, no. 4. 2014.
- [20] “Uso de la función de distribución acumulada (CDF) - Minitab.”

<https://support.minitab.com/es-mx/minitab/18/help-and-how-to/probability-distributions-and-random-data/supporting-topics/basics/using-the-cumulative-distribution-function-cdf/> (accessed Jun. 19, 2022).

- [21] X. Basogain Olabe, *Redes Neuronales Artificiales y sus Aplicaciones*. [Online]. Available:  
[http://cvb.ehu.es/open\\_course\\_ware/castellano/tecnicas/redes\\_neuro/contenidos/pdf/libro-del-curso.pdf](http://cvb.ehu.es/open_course_ware/castellano/tecnicas/redes_neuro/contenidos/pdf/libro-del-curso.pdf)
- [22] M. B. Garzón, J. M. Ruiz, R. S. De Dios, and H. S. Ollero, “Fundamentos de Redes Neuronales Artificiales,” vol. 59, pp. 345–358, 2003.
- [23] LEYDEN, “Bancos de capacitores para montaje a nivel.”  
[https://www.leyden.com.ar/esp/pdf/bancos\\_nivel.pdf](https://www.leyden.com.ar/esp/pdf/bancos_nivel.pdf)
- [24] “Generar una red neuronal prealimentada - MATLAB feedforwardnet - MathWorks América Latina.”  
<https://la.mathworks.com/help/deeplearning/ref/feedforwardnet.html;jsessionid=3c114d0dc73f0e594d6568029306> (accessed Nov. 04, 2022).

### III. ANEXOS

ANEXO N°1: Diagrama unifilar red de 69kV de la Empresa Eléctrica Riobamba



Barra 1	Barra 2	$R_{pu}$	$X_{pu}$	$Y/2$	$I_{pu\ max}$
1	2	0,002471	0,004407701	0	3,657
1	6	0,0014193	0,004067624	2,57E-05	4,9542
1	5	0,0007775	0,001386828	0	3,657
6	7	0,0011016	0,007284795	0	3,5535
7	8	0,0051467	0,034035778	5,86E-05	3,5535
8	13	0,0048212	0,010719249	3,85E-05	4,5609
8	9	0,0083268	0,012787014	6,95E-05	1,8975
9	10	0,0078264	0,010844203	3,18E-05	1,8975
9	14	0,0457919	0,07878222	5,23E-05	2,1597
13	2	0,0115194	0,019818493	3,50E-05	2,1597
2	4	0,0020197	0,003372256	0	3,657
4	12	0,2055	0,1816	0	0,33258
4	3	0,0013001	0,002170687	0	3,657
3	5	0,0024196	0,00403989	0	3,657
13	11	0	0,000026529	0	1,312

**TABLA HORARIA DE POTENCIA ACTIVA (Sbase=10MVA)**

		<b>HORA</b>																								
<b>BARRA</b>		<b>01:00</b>	<b>02:00</b>	<b>03:00</b>	<b>04:00</b>	<b>05:00</b>	<b>06:00</b>	<b>07:00</b>	<b>08:00</b>	<b>09:00</b>	<b>10:00</b>	<b>11:00</b>	<b>12:00</b>	<b>13:00</b>	<b>14:00</b>	<b>15:00</b>	<b>16:00</b>	<b>17:00</b>	<b>18:00</b>	<b>19:00</b>	<b>20:00</b>	<b>21:00</b>	<b>22:00</b>	<b>23:00</b>	<b>00:00</b>	
	<b>1</b>		0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	<b>2</b>		0,53	0,51	0,51	0,51	0,53	0,66	0,64	0,72	0,81	0,83	0,84	0,85	0,81	0,78	0,8	0,79	0,81	0,82	1,03	0,99	0,92	0,83	0,69	0,58
	<b>3</b>		0,79 24	0,78 31	0,75 35	0,77 42	0,78 12	0,85 42	0,81 71	0,87 96	0,99 88	1,01 1	1,08 5	1,04 58	1,01 38	0,98 81	1,00 69	1,01 7	1,06	1,07 26	1,30 74	1,28 59	1,22 75	1,09 79	0,93 26	0,84 21
	<b>4</b>		0,37 56	0,35 41	0,35 01	0,38 3	0,37 6	0,53 9	0,45 6	0,47 3	0,49 9	0,49 6	0,52 9	0,52 4	0,50 82	0,50 28	0,50 92	0,50 29	0,48 6	0,51 8	0,73 9	0,73 3	0,70 4	0,60 6	0,49 6	0,40 64
	<b>5</b>		0,52	0,5	0,49	0,5	0,52	0,7	0,56	0,58 6	0,6	0,62 2	0,65 5	0,66 3	0,62 5	0,63 3	0,68	0,65	0,67	0,69	1	1	0,95	0,83	0,7	0,57
	<b>6</b>		0,15 6	0,15 8	0,15 5	0,15 4	0,16 4	0,20 7	0,13 3	0,12 9	0,14 7	0,15 1	0,15 6	0,14 4	0,13 7	0,14 8	0,15 8	0,15 4	0,14 1	0,14 2	0,24 8	0,25 7	0,26 4	0,20 6	0,17 8	0,16
	<b>7</b>		0,11 69	0,11 5	0,11 35	0,11 48	0,11 67	0,13 06	0,09 06	0,08 95	0,09 39	0,09 54	0,09 34	0,09 17	0,08 69	0,08 88	0,09 8	0,09 09	0,09 64	0,09 37	0,15 02	0,15 35	0,14 45	0,13 04	0,11 92	0,12 1
	<b>8</b>		0,16 43	0,16 14	0,16 17	0,16 46	0,17 3	0,20 97	0,13 13	0,11 78	0,11 76	0,11 67	0,11 14	0,11 24	0,11 09	0,11 27	0,11 55	0,11 85	0,11 78	0,12 6	0,25 56	0,25 36	0,23 34	0,20 19	0,18 5	0,17 38
	<b>9</b>		0,13 72	0,13 39	0,13 27	0,13 35	0,14 11	0,17 91	0,12 97	0,13 06	0,12 98	0,13 41	0,13 37	0,13 54	0,12 45	0,12 72	0,13 5	0,13 47	0,13 7	0,15 98	0,23 01	0,21 95	0,20 37	0,17 73	0,15 62	0,14 6
	<b>10</b>		0,09 26	0,09 08	0,08 95	0,09	0,09 17	0,10 57	0,08 2	0,07 48	0,07 36	0,07 28	0,07 4	0,07 53	0,07 69	0,07 7	0,08 04	0,08 69	0,08 81	0,09 47	0,15 01	0,14 35	0,13 19	0,12 18	0,10 82	0,09 83
	<b>11</b>		0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	<b>12</b>		0,04 84	0,04 59	0,04 49	0,02 3	0,05 4	0,08 1	0,01 1	0,00 4	0,00 8	0,01 1	0,05 8	0,06 3	0,01 88	0,02 42	0,02 78	0,02 41	0,02 1	0,02 9	0,12 8	0,13 4	0,11 3	0,09 1	0,07 1	0,05 56
	<b>13</b>		0,13 91	0,13 62	0,13 61	0,14 22	0,15	0,18 7	0,12 99	0,12 07	0,11 82	0,11 99	0,11 56	0,19 5	0,11 61	0,11 35	0,11 03	0,11 66	0,11 63	0,11 77	0,20 22	0,21 89	0,20 75	0,18 27	0,16 99	0,14 57
	<b>14</b>		0,15 3	0,15 1	0,14 9	0,14 8	0,15 5	0,16	0,12 7	0,13 1	0,14 3	0,17 2	0,18	0,18 2	0,17 97	0,19 54	0,19 19	0,19 41	0,2	0,20 63	0,22 36	0,22 01	0,2	0,19 42	0,18 82	0,16 1

**TABLA HORARIA DE POTENCIA REACTIVA (Sbase=10MVA)**

		HORA																								
BARRA		01:00	02:00	03:00	04:00	05:00	06:00	07:00	08:00	09:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00	00:00	
	<b>1</b>	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	<b>2</b>	0,155	0,149	0,148	0,157	0,148	0,151	0,135	0,147	0,189	0,197	0,207	0,214	0,2013	0,196	0,2044	0,21	0,2052	0,1875	0,183	0,178	0,177	0,171	0,159	0,157	
	<b>3</b>	0,1479	0,1525	0,1424	0,1507	0,1533	0,1445	0,1454	0,1587	0,2067	0,2197	0,2366	0,2426	0,2243	0,2151	0,2317	0,2394	0,2545	0,2342	0,2186	0,2026	0,1934	0,1852	0,1634	0,1658	
	<b>4</b>	0,1377	0,1382	0,1396	0,1361	0,1406	0,1501	0,1311	0,1489	0,1854	0,2054	0,2319	0,2328	0,2013	0,1978	0,2165	0,2091	0,1981	0,1843	0,2041	0,2039	0,1937	0,1741	1,8041	0,1496	
	<b>5</b>	0,142	0,14	0,138	0,141	0,146	0,15	0,133	0,155	0,181	0,21	0,218	0,222	0,207	0,203	0,23	0,232	0,229	0,202	0,192	0,192	0,183	0,182	0,177	0,166	0,149
	<b>6</b>	0,0199	0,0211	0,0205	0,0209	0,0202	0,0182	0,0145	0,024	0,042	0,05	0,05	0,056	0,038	0,051	0,063	0,061	0,047	0,037	0,033	0,033	0,03	0,029	0,024	0,024	0,017
	<b>7</b>	0,0166	0,0162	0,0156	0,017	0,0159	0,0141	0,0104	0,0118	0,0141	0,0193	0,017	0,0185	0,0182	0,0174	0,0223	0,0263	0,0229	0,0148	0,0165	0,0133	0,015	0,0145	0,0146	0,0146	0,0173
	<b>8</b>	0,0163	0,0155	0,0151	0,0147	0,0139	0,0121	0,0092	0,0145	0,0185	0,0234	0,0238	0,0261	0,023	0,0252	0,0257	0,0254	0,0236	0,0176	0,025	0,0217	0,0212	0,022	0,0213	0,0201	
	<b>9</b>	0,0361	0,0359	0,0364	0,0362	0,0356	0,0346	0,021	0,0261	0,0292	0,0325	0,0326	0,0367	0,0336	0,0332	0,0342	0,0324	0,0307	0,0304	0,0402	0,0362	0,0363	0,0379	0,0372	0,0379	
	<b>10</b>	0,0401	0,0409	0,0398	0,0397	0,0384	0,0381	0,0229	0,0229	0,0253	0,0274	0,0293	0,0285	0,0277	0,0277	0,0293	0,031	0,028	0,0275	0,0403	0,039	0,0384	0,0397	0,0403	0,0401	
	<b>11</b>	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
	<b>12</b>	0,00233	0,00228	0,00224	0,00219	0,00224	0,00229	0,00169	0,00171	0,00256	0,00316	0,0031	0,00312	0,00307	0,00332	0,00365	0,00359	0,00359	0,00257	0,00289	0,00251	0,00253	0,00259	0,00259	0,00519	
	<b>13</b>	0,0172	0,0171	0,0162	0,0161	0,0192	0,017	0,0119	0,0113	0,016	0,0216	0,0223	0,0226	0,0225	0,0215	0,0252	0,0289	0,0287	0,0189	0,0144	0,106	0,0117	0,0135	0,0156	0,0175	
	<b>14</b>	0,04062533	0,04143581	0,0403214	0,04022009	0,03890306	0,03859913	0,0232	0,0232	0,0244	0,0355	0,0387	0,0389	0,0386	0,0448	0,0426	0,0402	0,0407	0,0387	0,05671309	0,05488364	0,05351047	0,05243652	0,0522135	0,04153712	

**ANEXO N°2:** Matriz de decisión para incremento de reactancia capacitiva en la barra 14 a hora pico.

A)

<b>V min</b>	<b>Pérdidas</b>	<b>MVAr</b>	<b>V min</b>	<b>Pérdidas</b>	<b>MVAr</b>
0.9668	0.0832	0	0.9852	0.0832	1.8
0.9677	0.0831	0.1	0.9862	0.0834	1.9
0.9688	0.083	0.2	0.9872	0.0835	2
0.9698	0.0829	0.3	0.9882	0.0837	2.1
0.9709	0.0828	0.4	0.9892	0.0839	2.2
0.9719	0.0827	0.5	0.9902	0.0841	2.3
0.973	0.0827	0.6	0.9912	0.0843	2.4
0.974	0.0826	0.7	0.9922	0.0846	2.5
0.9751	0.0826	0.8	0.9932	0.0848	2.6
0.9761	0.0826	0.9	0.9941	0.0851	2.7
0.9771	0.0826	1	0.9951	0.0853	2.8
0.9781	0.0826	1.1	0.9961	0.0856	2.9
0.9791	0.0826	1.2	0.9971	0.0859	3
0.9802	0.0827	1.3	0.9981	0.0862	3.1
0.9812	0.0828	1.4	0.999	0.0865	3.2
0.9822	0.0829	1.5	1	0.0868	3.3
0.9832	0.083	1.6			
0.9842	0.0831	1.7			

B)

<b>V min</b>	<b>Pérdidas</b>	<b>MVAr</b>	<b>V min</b>	<b>Pérdidas</b>	<b>MVAr</b>
0	0.8391	1	0.615	0.7673	0.3939
0.0286	0.862	0.9697	0.6451	0.7244	0.3636
0.06	0.8953	0.9394	0.675	0.6784	0.3333
0.0915	0.9244	0.9091	0.7049	0.6294	0.303
0.1228	0.9493	0.8788	0.7347	0.5775	0.2727
0.1541	0.9699	0.8485	0.7645	0.5229	0.2424
0.1876	0.9779	0.8182	0.7941	0.4656	0.2121
0.2182	0.9899	0.7879	0.8237	0.4058	0.1818
0.2492	0.997	0.7576	0.8533	0.3436	0.1515
0.2801	1	0.7273	0.8828	0.2791	0.1212
0.3109	0.9987	0.697	0.9122	0.2123	0.0909
0.3417	0.9932	0.6667	0.9415	0.1435	0.0606
0.3723	0.9836	0.6364	0.9708	0.0727	0.0303
0.4029	0.9699	0.6061	1	0	0
0.4334	0.9521	0.5758			
0.4639	0.9305	0.5455			
0.4943	0.9051	0.5152			
0.5246	0.8759	0.4848			
0.5548	0.8431	0.4545			
0.585	0.8069	0.4242			

**ANEXO N°3: Porcentaje de carga de desconexión y tiempos para la subestación 14**

Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)
0.055	0.04842615	0.22388889	0.12966102	0.6625	0.12963075	1.12694444	0.12966102	1.49444444	0.00302663
0.055	0.33955811	0.22555556	0.03919492	0.6775	0.33153753	1.15638889	0.04697337	1.5	0.08556295
0.055	0.41192494	0.22805556	0.08913438	0.73333333	0.00030266	1.16666667	0.00121065	1.51666667	0.00060533
0.08638889	0.06691889	0.23	0.40783898	0.73638889	0.08459443	1.16666667	0.02106538	1.53083333	0.00060533
0.08638889	0.00741525	0.23	0.48244552	0.74861111	0.12963075	1.2	0.00060533	1.53805556	0.02106538
0.09055556	0.33153753	0.24861111	0.12966102	0.75	0.00090799	1.21666667	0.00060533	1.53972222	0.01940073
0.09138889	0.15251211	0.25944444	0.01150121	0.75722222	0.124546	1.2325	0.01331719	1.54388889	0.07400121
0.09527778	0.04812349	0.27527778	0.04636804	0.76666667	0.00060533	1.23333333	0.00302663	1.55	0.00060533
0.09527778	0.32593826	0.2875	0.04842615	0.76666667	0.00121065	1.25138889	0.00393462	1.55	0.00847458
0.09527778	0.39754843	0.2875	0.33895278	0.8	0.0434322	1.28333333	0.0028753	1.55	0.01649516
0.09861111	0.12963075	0.2875	0.41192494	0.80916667	0.08610775	1.33333333	0.01634383	1.55805556	0.04842615
0.10527778	0.12878329	0.29611111	0.262046	0.82361111	0.13625908	1.33333333	0.00060533	1.55805556	0.33955811
0.10527778	0.12963075	0.30166667	0.12963075	0.85	0.00060533	1.34111111	0.00393462	1.55805556	0.41192494
0.12138889	0.33153753	0.32111111	0.13689467	0.85527778	0.12963075	1.34833333	0.42944915	1.56666667	0.00060533
0.13555556	0.13205206	0.35472222	0.00090799	0.88277778	0.12878329	1.35	0.00272397	1.56666667	0.00090799
0.14944444	0.32381961	0.35694444	0.05326877	0.88944444	0.04636804	1.35777778	0.00423729	1.56666667	0.02106538
0.14944444	0.3969431	0.375	0.04842615	0.91666667	0.00226998	1.36666667	0.00060533	1.61666667	0.00090799
0.15	0.10360169	0.375	0.33955811	0.91666667	0.01210654	1.37916667	0.33153753	1.63333333	0.00060533
0.15444444	0.12966102	0.375	0.41192494	0.95	0.01452785	1.38305556	0.05069613	1.66055556	0.12966102
0.15555556	0.04812349	0.41861111	0.13205206	0.96666667	0.00151332	1.4	0.00060533	1.66666667	0.0033293
0.16888889	0.12966102	0.4325	0.27142857	0.98333333	0.00060533	1.40694444	0.12484867	1.66666667	0.00847458
0.17	0.08368644	0.44694444	0.15251211	0.99611111	0.00514528	1.41666667	0.01710048	1.6725	0.04645884
0.17277778	0.04812349	0.46666667	0.00756659	1.01666667	0.01210654	1.41805556	0.0839891	1.68333333	0.00181598

0.17527778	0.39633777	0.51	0.12963075	1.03416667	0.00786925	1.44055556	0.12963075	1.69861111	0.00423729
0.18333333	0.08050847	0.51444444	0.00060533	1.05861111	0.12484867	1.45	0.00090799	1.70111111	0.00393462
0.19305556	0.11092615	0.53972222	0.12484867	1.06666667	0.00847458	1.45	0.01210654	1.71666667	0.00060533
0.19944444	0.08050847	0.57527778	0.11791768	1.09166667	0.08050847	1.45305556	0.124546	1.72472222	0.04875908
0.20222222	0.12963075	0.58333333	0.00302663	1.09777778	0.14252421	1.4575	0.12963075	1.73333333	0.00226998
0.22	0.12966102	0.59833333	0.34076877	1.1	0.00060533	1.47777778	0.13810533	1.8	0.00060533
		0.65638889	0.12966102	1.11527778	0.00423729	1.48333333	0.00121065	1.8	0.01664649

Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)
1.81666667	0.00151332	2.1	0.00151332	2.63305556	0.04418886	3.15833333	0.00060533	3.73444444	0.01846247
1.83333333	0.00060533	2.13638889	0.01513317	2.65	0.00060533	3.16555556	0.33153753	3.75138889	0.01452785
1.83916667	0.00060533	2.15	0.00151332	2.65	0.00060533	3.21666667	0.01864407	3.76666667	0.00060533
1.85	0.00242131	2.15388889	0.00877724	2.68333333	0.00060533	3.22944444	0.00756659	3.78333333	0.00060533
1.86111111	0.00756659	2.16666667	0.00847458	2.68333333	0.00060533	3.23333333	0.01210654	3.83916667	0.09004237
1.86111111	0.13689467	2.16666667	0.02106538	2.68472222	0.33955811	3.24333333	0.04146489	3.85	0.00060533
1.87527778	0.04539952	2.18305556	0.02784504	2.7	0.00090799	3.24333333	0.28519976	3.85	0.00393462
1.88333333	0.00226998	2.18333333	0.00484262	2.7125	0.0371368	3.24333333	0.3253632	3.86666667	0.02587772
1.88333333	0.01634383	2.18333333	0.10360169	2.71666667	0.00877724	3.25	0.00060533	3.95	0.00060533
1.9	0.00060533	2.21666667	0.00121065	2.71666667	0.01331719	3.25	0.00060533	3.98333333	0.01150121
1.91666667	0.00121065	2.21666667	0.00060533	2.71666667	0.02285109	3.29888889	0.04697337	4.06666667	0.00060533
1.91861111	0.00393462	2.23333333	0.00090799	2.71666667	0.00090799	3.3	0.00272397	4.07	0.02678571
1.96638889	0.40178571	2.25	0.00060533	2.76666667	0.00181598	3.3	0.00771792	4.09888889	0.33153753
1.96666667	0.00393462	2.25	0.00060533	2.86666667	0.00060533	3.33333333	0.00771792	4.1	0.00302663
1.96916667	0.13689467	2.25027778	0.00060533	2.86666667	0.00060533	3.36666667	0.00060533	4.11194444	0.02330508
1.97666667	0.45066586	2.30777778	0.00060533	2.86666667	0.00151332	3.36805556	0.00696126	4.17916667	0.07733051
1.98333333	0.00181598	2.33333333	0.00363196	2.88333333	0.00786925	3.41666667	0.01452785	4.26666667	0.02406174
1.9875	0.05326877	2.34416667	0.06691889	2.88333333	0.00847458	3.4425	0.13205206	4.29805556	0.04812349

1.9875	0.40783898	2.36666667	0.00847458	2.93333333	0.00060533	3.45611111	0.00151332	4.3	0.31988499
1.9875	0.48214286	2.43083333	0.27445521	2.93333333	0.01634383	3.46944444	0.08647094	4.30888889	0.39391646
1.99305556	0.05326877	2.43333333	0.00226998	2.93333333	0.08858959	3.48277778	0.04697337	4.31583333	0.00786925
1.99861111	0.02285109	2.45	0.07400121	2.95	0.00060533	3.51666667	0.00090799	4.33083333	0.14252421
2	0.01150121	2.5	0.00060533	2.98333333	0.00090799	3.51666667	0.00060533	4.40777778	0.01788741
2.01666667	0.00302663	2.51666667	0.00090799	3	0.00302663	3.53333333	0.01634383	4.43333333	0.00151332
2.01666667	0.02224576	2.51666667	0.01210654	3.01666667	0.00060533	3.61194444	0.00847458	4.43694444	0.00060533
2.02638889	0.12260896	2.53333333	0.00847458	3.06666667	0.00060533	3.61666667	0.00181598	4.50416667	0.08647094
2.03333333	0.00847458	2.53666667	0.10904964	3.06666667	0.00181598	3.63333333	0.01210654	4.52444444	0.00242131
2.05	0.30653753	2.56666667	0.00060533	3.06666667	0.0028753	3.65	0.00060533	4.53944444	0.01210654
2.05916667	0.00030266	2.58333333	0.00060533	3.06666667	0.01649516	3.66666667	0.00060533	4.55	0.02696731
2.1	0.00060533	2.58333333	0.00272397	3.07888889	0.03332324	3.68333333	0.00090799	4.61666667	0.00090799

Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)	Porcentaje de desconexión	Tiempo (Horas)
4.79638889	0.04636804	6.58333333	0.02106538	12.18333333	0.0001816	16.75	0.00060533
5	0.14252421	6.63972222	0.04636804	12.76666667	0.00060533	16.91666667	0.00302663
5.01666667	0.00090799	6.7	0.00060533	12.85	0.00242131	16.93333333	0.00060533
5.05361111	0.00060533	6.71666667	0.01664649	13.02333333	0.04842615	17.16666667	0.00484262
5.10416667	0.0248184	6.78611111	0.00847458	13.02333333	0.33955811	17.45	0.01210654
5.11666667	0.00151332	6.8	0.00090799	13.02333333	0.41192494	17.78722222	0.00060533
5.20444444	0.00756659	6.87138889	0.41797821	13.03333333	0.01210654	18.93333333	0.00060533
5.21666667	0.00060533	6.87138889	0.49122276	13.075	0.01210654	19.53333333	0.02106538
5.25277778	0.00060533	7.4	0.01195521	13.1	0.0028753	19.73333333	0.00060533
5.29138889	0.07218523	7.52388889	0.07218523	13.2	0.00060533	19.76666667	0.00453995
5.33333333	0.00226998	7.5325	0.39418886	13.3	0.01210654	20.5880556	0.00060533
5.34888889	0.07733051	7.765	0.04842615	13.38333333	0.00453995	20.78333333	0.00060533
5.35916667	0.02799637	7.765	0.33955811	13.4952778	0.04812349	21.65444444	0.00575061

5.44833333	0.02757264	7.765	0.41192494	13.4952778	0.31837167	22.2747222	0.03332324
5.48333333	0.00060533	7.94972222	0.05326877	13.4952778	0.39331114	23.0333333	0.00121065
5.61666667	0.00060533	7.96666667	0.00030266	13.85	0.00060533	23.9333333	0.00030266
5.70611111	0.05160412	8.255	0.01271186	13.95	0.02106538	24.8	0.00877724
5.71611111	0.13371671	8.36666667	0.00090799	14.05	0.00060533	25.6180556	0.00060533
5.72416667	0.11837167	8.4	0.00060533	14.1044444	0.08647094	25.7166667	0.00181598
5.82722222	0.08647094	8.41666667	0.00060533	14.4833333	0.00030266	25.7558333	0.01210654
5.90305556	0.04842615	8.63472222	0.04878935	14.6	0.08647094	27.6422222	0.02512107
5.90305556	0.33743947	8.70722222	0.04546005	14.6333333	0.00575061	29.0333333	0.00060533
5.90305556	0.41131961	8.96583333	0.04842615	14.7833333	0.05590194	31.6761111	0.00242131
5.90916667	0.02164044	9.08333333	0.00060533	14.9166667	0.00226998	34.85	0.0590799
5.95944444	0.04697337	9.28333333	0.00181598	14.95	0.00121065	44.8166667	0.00030266
5.9775	0.05084746	9.53333333	0.00060533	15.0666667	0.00060533	45.2166667	0.00060533
5.99194444	0.13689467	10.7	0.00090799	15.0666667	0.00090799	48	0.00060533
6.10194444	0.08556295	11.0697222	0.04636804	15.5333333	0.00060533	68.9152778	0.00060533
6.155	0.0066586	11.9569444	0.00090799	15.7833333	0.01452785	82.9063889	0.00090799
6.56666667	0.00030266	12.0272222	0.04842615	16.3802778	0.00060533	83.715	0.00090799

**ANEXO 4:** Pesos para perceptón de las barras 12 y 14.

Entrada	Pesos Barra 12	Pesos Barra 14	Entrada	Pesos Barra 12	Pesos Barra 14
PSE1	0	0	QSE11	0	0
PSE2	-0.1349	-0.1737	QSE12	0.1211	0.1888
PSE3	-0.0635	-0.0936	QSE13	0.0238	0.0736
PSE4	0.1347	-0.01	QSE14	0.0153	0.0924
PSE5	0.0359	0.0545	I1-2	0.0486	0.0756
PSE6	-0.099	-0.1402	I1-3	-0.0537	-0.064
PSE7	-0.0088	-0.059	I1-4	-0.0341	-0.0092
PSE8	0.009	-0.0104	I1-5	0.0033	-0.0085
PSE9	-0.0273	0.0083	I7-8	-0.0005	0.0197
PSE10	-0.0085	0.0854	I8-13	-0.1035	-0.1338
PSE11	0	0	I8-9	0.0544	-0.1476
PSE12	0.381	0.2276	I9-10	-0.0167	-0.0815
PSE13	0.0103	0.0705	I9-14	0.049	0.4163
PSE14	-0.0513	0.4667	I13-2	-0.0099	0.0665
QSE1	0	0	I2-4	-0.0011	-0.0646
QSE2	0.033	0.1955	I4-12	-0.3236	-0.3183
QSE3	0.0483	0.1287	I4-3	0.0127	-0.0111
QSE4	-0.0045	0.1028	I3-5	0.0768	0.08
QSE5	0.0354	0.1213	I13-11	0.0321	0.3253
QSE6	-0.0418	0.0091	PG11	0.0177	-0.3206
QSE7	-0.0062	0.0049	PG12	-0.4367	0.5094
QSE8	0.0111	0.0149	Hora	-0.0099	-0.0274
QSE9	0.011	0.0635	Bias	0.0598	-0.0353
QSE10	0.009	0.0766			