

Estrategia basada en redes neuronales para el control de inversores fotovoltaicos ante  
hundimientos de tensión de la red

Gabriela Alvarado Agudelo, Laura Sofía Mendoza Ramírez y Sebastián Felipe Rincón García

Trabajo de Grado para Optar al Título de Ingenieros Electricistas y Electrónicos

Director

Juan Manuel Rey López

Doctor en Ingeniería Electrónica

Universidad Industrial de Santander

Facultad de Ingenierías Físico-Mecánicas

Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones

Ingeniería Eléctrica e Ingeniería Electrónica

Bucaramanga

2023

### **Dedicatoria**

A mis papás, por todo su amor, apoyo y sacrificio.

*Gabriela Alvarado Agudelo.*

A Dios por darme la sabiduría y permitirme llegar a este punto de mi vida. A mi familia por guiarme y darme la fortaleza y el aliento necesarios para culminar este proceso. A mi compañero de vida y aventuras por la confianza y el apoyo incondicional. A ustedes dedico este proyecto.

*Laura Sofía Mendoza Ramírez.*

Dedico este proyecto a mi familia por el gran esfuerzo que han hecho para que yo pueda salir adelante. A mi nono Efraín García, quien ha creído en mí y en mis sueños desde el principio, y me ha apoyado en todo momento. También quiero dedicar este trabajo a mi enamorada, Angélica Quintero, quien ha sido una parte importante de mi motivación para seguir adelante. Gracias por ayudarme a mantener mi horizonte y por estar a mi lado en todo momento. Este logro no solo es mío, sino de todos ustedes. Gracias por estar siempre a mi lado y por haber creído en mí.

*Sebastián Felipe Rincón García.*

### **Agradecimientos**

A Dios, por acompañarme siempre. A mi familia, por su paciencia y por creer en mí en todo momento. A mi amor, por la confianza y el apoyo depositado. A mis amigos, especialmente Laura y Silvia, por su cariño, soporte y por hacer este camino más bello. A mis compañeros de proyecto, por todo su esfuerzo y dedicación para llegar a culminar este trabajo de grado. A mi director, por su tiempo, entrega y disposición para guiar.

*Gabriela Alvarado Agudelo.*

A Dios, por guiar mi vida y darme la oportunidad de finalizar mi carrera exitosamente, todos mis logros se los debo a él. A mis padres, Oscar Mendoza y Sandra Ramírez, por inculcarme que la determinación, el esfuerzo, la honestidad y el amor son fundamentales para alcanzar los sueños. A mi hermana, Sara Mendoza, por depositar su confianza en mí. A mi amor, Myller Oliveros, por ser mi polo a tierra, creer en mí y apoyarme incondicionalmente en todo momento. A mis primos, Natalia y Sebastián, quienes han sido como dos hermanos para mí, su cariño ha sido un gran apoyo a lo largo de este proceso. A mis amigos, especialmente a Silvia, Gabriela, Karen y Dalai, quienes hicieron este camino más alegre. A Luis Carlos y Jose por las largas horas donde compartieron conmigo su valioso conocimiento y consejos para abordar este proyecto. A mis compañeros de proyecto, Gabriela y Sebastián, por brindarme el apoyo necesario para sacar adelante el trabajo de grado. Y a mi director, Juan Manuel Rey, por su conocimiento impartido y sus orientaciones.

*Laura Sofía Mendoza Ramírez.*

Agradezco de todo corazón a mis padres por su constante apoyo y por el sacrificio que han hecho para que yo pueda estar aquí hoy. También quiero agradecer a mis hermanos, quienes siempre me han motivado a tomar buenas decisiones y a valorar a los demás. Agradezco profundamente a mi abuelo Efraín García por todos los consejos y el apoyo incondicional que me ha brindado. También quiero agradecer a mi enamorada, Angélica, quien me ha ayudado no solo a formarme como profesional sino también como persona en estos últimos cinco años. No puedo dejar de mencionar a mis compañeros de universidad, con quienes compartí esta hermosa etapa de mi vida. Agradezco también a mis profesores, quienes no solo se dedicaron a formarnos como profesionales sino también como personas íntegras. Por último, quiero agradecer a todos aquellos que olvidé nombrar pero que llevo en el corazón por contar con su apoyo, especialmente en mi formación académica. Gracias por haberme permitido vivir esta hermosa etapa llamada universidad.

*Sebastián Felipe Rincón García.*

## Contenido

	<b>Pág.</b>
Introducción .....	13
1. Objetivos.....	15
1.1 Objetivo General.....	15
1.2 Objetivos Específicos.....	15
2. Hundimientos de tensión.....	16
2.1 Tipos de hundimientos de tensión.....	20
2.1.1 <i>Hundimientos de tensión modelados en Python.</i> .....	23
2.1.1.1 Hundimiento de tensión tipo A.....	23
2.1.1.2 Hundimiento de tensión tipo B .....	23
2.1.1.3 Hundimiento de tensión tipo C .....	24
2.1.1.4 Hundimiento de tensión tipo D.....	24
3. Sistema de control.....	26
4. Estrategia Base.....	27
4.1 Algoritmo de control.....	32
4.2 Códigos de red .....	34
5. Base de datos para entrenar la red neuronal.....	37
5.1 Set de datos de entrada.....	37
5.2 Set de Datos de Salida.....	38
6. Red neuronal .....	40
6.1 Construcción de la red neuronal .....	40
7. Evaluación de resultados.....	46
7.1 Evaluación del entrenamiento del modelo.....	46

ESTRATEGIA BASADA EN REDES NEURONALES PARA EL CONTROL DE...	6
7.2 Evaluación de los parámetros de salida ( $I_{q+}$ , $I_{q-}$ , $I_{p+}$ , $I_{p-}$ ) .....	48
7.2.1 <i>Análisis estadístico</i> .....	49
7.2.2 Análisis mediante diagrama de dispersión.....	50
7.2.3 Análisis de errores.....	51
7.3 Evaluación de los cuatro objetivos de control .....	52
7.3.1 <i>Objetivo 1</i> .....	52
7.3.2 <i>Objetivo 2</i> .....	54
7.3.3 <i>Objetivo 3</i> .....	55
7.3.4 <i>Objetivo 4</i> .....	57
8. Conclusiones .....	58
8.1 Sobre el desempeño de la red neuronal.....	59
8.2 Sobre el cumplimiento del objetivo de control 1.....	59
8.3 Sobre el cumplimiento del objetivo de control 2.....	59
8.4 Sobre el cumplimiento del objetivo de control 3.....	60
8.5 Sobre el cumplimiento del objetivo de control 4.....	60
Referencias Bibliograficas .....	61
Apéndices.....	63

**Lista de Tablas**

	<b>Pág.</b>
<b>Tabla 1.</b> <i>Tipos de hundimientos de tensión.</i> .....	20
<b>Tabla 2.</b> <i>Rangos de <math>V+</math>, <math>V-</math> y <math>\varphi</math> para los hundimientos de tensión frecuentes.</i> .....	25
<b>Tabla 3.</b> <i>Coordenadas de los códigos de red europeos considerados</i> .....	36
<b>Tabla 4.</b> <i>Vectores que componen los parámetros del set de datos de entrada.</i> .....	37
<b>Tabla 5.</b> <i>Coordenadas de cada código de red.</i> .....	38
<b>Tabla 6.</b> <i>Resultados obtenidos de las métricas MAE, MSE y Accuracy del modelo.</i> .....	47
<b>Tabla 7.</b> <i>Valores de media, mediana y desviación estándar.</i> .....	49
<b>Tabla 8.</b> <i>Valores de error absoluto, error cuadrático medio y coeficiente de determinación.</i> .....	51
<b>Tabla 9.</b> <i>Datos de la corriente reactiva de secuencia positiva (<math>I_q+</math>) que no cumplen con el Objetivo 2.</i> .....	53

## Lista de Figuras

	<b>Pág.</b>
<b>Figura 1.</b> <i>Histograma de las magnitudes de los hundimientos e interrupciones.</i> .....	18
<b>Figura 2.</b> <i>Número de fases afectadas por hundimientos de tensión con al menos una tensión residual del 85%.</i> .....	18
<b>Figura 3.</b> <i>Porcentaje de voltajes residual por tipo de hundimiento de tensión.</i> .....	19
<b>Figura 4.</b> <i>Tipos de hundimientos de tensión</i> .....	21
<b>Figura 5.</b> <i>Ángulos de fase para los hundimientos de tensión tipo C.</i> .....	22
<b>Figura 6.</b> <i>Ángulos de fase para los hundimientos de tensión tipo D.</i> .....	22
<b>Figura 7.</b> <i>Rangos de <math>V +</math> y <math>V -</math> para los hundimientos tipo A, B, C y D.</i> .....	25
<b>Figura 8.</b> <i>Inversor fotovoltaico conectado a la red eléctrica</i> .....	26
<b>Figura 9.</b> <i>Bloque de control del inversor fotovoltaico</i> .....	26
<b>Figura 10.</b> <i>Diagrama de flujo que representa el algoritmo de control.</i> .....	30
<b>Figura 11.</b> <i>Requerimiento de corriente reactiva tomada del código de red español.</i> .....	35
<b>Figura 12.</b> <i>Estándar de red de cada país, mostrando la potencia reactiva que debe ser inyectada a la red durante las fallas, con respecto a la profundidad de la caída de voltaje</i> .....	35
<b>Figura 13.</b> <i>Inyección de corriente reactiva establecida por los 30 códigos de red.</i> .....	39
<b>Figura 14.</b> <i>Programación del modelo de la red neuronal</i> .....	43
<b>Figura 15.</b> <i>Programación de la compilación de la red neuronal</i> .....	44
<b>Figura 16.</b> <i>Programación del entrenamiento de la red neuronal</i> .....	44
<b>Figura 17.</b> <i>Programación que ejecuta las predicciones de la red neuronal.</i> .....	45
<b>Figura 18.</b> <i>Magnitud de la función de pérdida (loss) durante el entrenamiento.</i> .....	47
<b>Figura 19.</b> <i>Diagrama de dispersión de las corrientes del código de red de España</i> .....	50

<b>Figura 20.</b> <i>Zonas C1, C2 y C3 de la gráfica de inyección de corriente <math>I_q +</math> con respecto a <math>V +</math></i>	52
<b>Figura 21.</b> <i>Valores de <math>I_q +</math> que no cumplen el objetivo 1.</i>	54
<b>Figura 22.</b> <i>Cálculo de la corriente <math>I_p +</math> sin aplicar ningún control</i>	56
<b>Figura 23.</b> <i>Definición de coordenadas en el código</i>	63
<b>Figura 24.</b> <i>Definición del nombre del archivo que contiene la base de datos</i>	63
<b>Figura 25.</b> <i>Línea de código que identifica las salidas reales a evaluar de un código de red individual.</i>	65
<b>Figura 26.</b> <i>Línea de código que identifica las salidas obtenidas a evaluar de un código de red individual.</i>	65
<b>Figura 27.</b> <i>Línea de código que identifica las entradas correspondientes a las salidas reales y obtenidas de un código de red individual</i>	65
<b>Figura 28.</b> <i>Líneas de código para modificar el nombre de los archivos de acuerdo con el código de red que se desea analizar.</i>	66
<b>Figura 29.</b> <i>Líneas de código para cargar los archivos del código de red que se desea verificar.</i>	67

**Lista de Apéndices**

	<b>Pág.</b>
<b>Apéndice A.</b> <i>Código para obtener la base de datos .....</i>	63
<b>Apéndice B.</b> <i>Código de la red neuronal y evaluación de esta .....</i>	64
<b>Apéndice C.</b> <i>Código para la evaluación de resultados y objetivo 3.....</i>	66
<b>Apéndice D.</b> <i>Código para la evaluación del objetivo 1 .....</i>	67
<b>Apéndice E.</b> <i>Código para la evaluación del objetivo 2 .....</i>	67
<b>Apéndice F.</b> <i>Código de las componentes de secuencia .....</i>	68
<b>Apéndice G.</b> <i>Código para obtener los rangos de los hundimientos frecuentes.....</i>	68

## Resumen

**Título:** Estrategia Basada en Redes Neuronales para el Control de Inversores Fotovoltaicos Ante Hundimientos de Tensión de la Red. \*

**Autor:** Gabriela Alvarado Agudelo, Laura Sofía Mendoza Ramírez y Sebastián Felipe Rincón García. \*\*

**Palabras Clave:** Hundimientos de Tensión, LVRT, Códigos de Red, Base de Datos, Red Neuronal, Estrategia de Control.

**Descripción:** Este trabajo de grado fue desarrollado en el marco del proyecto de investigación titulado “Diseño de estrategias alternativas de operación y control para sistemas fotovoltaicos multifuncionales en redes de distribución con alta penetración de energías renovables” código 70416, adscrito al “Programa de Investigación en Tecnologías Emergentes para Microrredes Eléctricas Inteligentes con Alta Penetración de Energías Renovables”, contrato No. 80740-542-2020. En este proyecto se propone una estrategia de control de inversores fotovoltaicos utilizando la técnica de redes neuronales. Esta estrategia de control está basada en el diagrama de control planteado en el artículo “Control Strategy for Grid-Connected Three-Phase Inverters During Voltage Sags to Meet Grid Codes and to Maximize Power Delivery Capability”. La estrategia mencionada anteriormente se caracteriza por dar prioridad a la inyección de potencia reactiva, teniendo en cuenta las restricciones impuestas por los códigos de red, con el fin de proporcionar estabilidad y fiabilidad a la red eléctrica; esto empleando un algoritmo que permite maximizar las capacidades del inversor. Dicha estrategia tiene como variables de entrada  $(V^+, V^-, P_G, \varphi)$ , 4 parámetros que se obtienen a partir del muestreo de variables eléctricas que se presentan durante los hundimientos de tensión, y como variables de salida  $(I_q^+, I_q^-, I_p^+, I_p^-)$ , señales de referencia para ejecutar acciones de control en el inversor. Para el entrenamiento de la red neuronal se generó una base de datos enfocada en los tipos de hundimientos de tensión que se presentan con mayor frecuencia en la red, con el fin de considerar diversos casos de operación.

---

\* Trabajo de Grado

\*\* Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones. Ingenierías Eléctrica y Electrónica. Director: Juan Manuel Rey López. Doctor en Ingeniería Electrónica.

### Abstract

**Title:** Control Strategy Based on Neural Networks for Photovoltaic Inverters During Voltage Sags in the Grid. \*

**Author(s):** Gabriela Alvarado Agudelo, Laura Sofía Mendoza Ramírez y Sebastián Felipe Rincón García. \*\*

**Key Words:** Voltage Sags, LVRT, Grid Codes, Database, Neural Network, Control Strategy.

**Description:** This undergrade project was developed within the framework of the research project “Diseño de estrategias alternativas de operación y control para sistemas fotovoltaicos multifuncionales en redes de distribución con alta penetración de energías renovables” code 70416, under “Programa de Investigación en Tecnologías Emergentes para Microrredes Eléctricas Inteligentes con Alta Penetración de Energías Renovables”, contract No. 80740-542-2020. In this project, a control strategy for photovoltaic inverters is proposed using neural networks. This proposal is based on the control strategy proposed in the article “Control Strategy for Grid-Connected Three-Phase Inverters During Voltage Sags to Meet Grid Codes and to maximize Power Delivery Capability.” The aforementioned strategy is characterized by giving priority to reactive power injection, taking into account the restrictions imposed by the grid codes (GC), in order to provide stability and reliability to the electrical grid; this is performed, using an algorithm that allows maximizing the inverter capacities. This strategy has as input variables ( $V^+$ ,  $V^-$ ,  $P_G$ ,  $\varphi$ ) 4 parameters that are obtained from the measurement of electrical variables during voltage sags, and as output variables ( $I_q^+$ ,  $I_q^-$ ,  $I_p^+$ ,  $I_p^-$ ) the reference signals to execute control actions in the inverter. For the training of the neural network, a database was generated focused on the types of voltage sags that occur more frequently in the grid, in order to consider different operation cases.

---

\* Degree Work

\*\*Faculty of Physical-Mechanical Engineering. Department of Electrical, Electronic and Telecommunications Engineering. Eléctric and Electronic Engineering. Director: Juan Manuel Rey López. Ed.D. in Electronic Engineering.

## Introducción

Un hundimiento de tensión es una disminución brusca de la tensión RMS, entre 0.1 *p. u.* y 0.9 *p. u.*, cuya duración, según el estándar IEC 6100-4-30, puede estar entre 2 [ms] y varios minutos (IEEE std 1159, 2009). Los hundimientos son usualmente asociados a fallas en el sistema, pero también pueden ser causados por la alimentación de grandes cargas o el arranque de motores de gran potencia (IEEE std 1159, 2009) .

En general, el servicio de electricidad logra suplir la demanda del consumidor promedio. Sin embargo, en el área industrial y de tecnología avanzada, los procesos de manufactura exigen requisitos estrictos en cuestión de la calidad de la energía. Estos usuarios son especialmente sensibles a variaciones en la red eléctrica por lo que sus procesos son fácilmente interrumpidos por los hundimientos de tensión, causando enormes pérdidas económicas (IEEE P2938/D3.2, 2022) (IEEE std 1668, 2014) (Cleavelin, 1997).

Ante esta problemática, se implementan sistemas de control de inversores fotovoltaicos que ayudan a la red a soportar y restablecer rápidamente los niveles operativos anteriores a las fallas. Estos sistemas se encargan de leer los parámetros que provienen del censado de las variables eléctricas en la red durante la presencia del hundimiento. Luego de procesar las entradas, el sistema envía señales de referencia a los inversores por medio de sus salidas. Esto con el fin de definir la operación del inversor que soporte la caída de tensión en la red, sin desconectarse, previniendo apagones que afecten la calidad de la energía (Bollen & Hassan, 2011).

Varios operadores del sistema de transmisión de distintos países han rediseñado sus códigos de red para asegurar la conexión a la red de los inversores durante las fallas, por ejemplo: Gran Bretaña, Dinamarca, España, Alemania y los Países Bajos (Rolán, Bogarra, & Bakkar, 2022).

Por otra parte, las estrategias de control empleadas en la actualidad se encuentran direccionadas al cumplimiento de un sólo código de red a la vez. Por tanto, el reto principal del presente proyecto es la diversificación de un sistema de control teniendo en cuenta la integración de varios códigos de red.

## **1. Objetivos**

### **1.1 Objetivo General**

Diseñar una estrategia basada en redes neuronales para el control de inversores fotovoltaicos ante hundimientos de tensión considerando el cumplimiento de códigos de red.

### **1.2 Objetivos Específicos**

- Modelar una estrategia base seleccionada para el control de inversores fotovoltaicos ante hundimientos de tensión de la red.
- Generar una base de datos de escenarios a partir de la simulación de diferentes tipos de hundimientos de tensión usando el código implementado.
- Entrenar una red neuronal a partir de la base de datos obtenida.
- Evaluar la operación de la red neuronal a través de la proposición de métricas de precisión.

## 2. Hundimientos de tensión

Existen diversos tipos de fallas que pueden afectar un sistema de potencia. Entre estas, los hundimientos de tensión son de las perturbaciones más predominantes y que causan mayor impacto en los equipos instalados en el sistema eléctrico, esto debido a que producen efectos como paradas de procesos, disparo de protecciones, funcionamiento defectuoso de equipos, entre otras (Instituto Colombiano de Normas Técnicas y Certificación [ICONTEC], 2008). Un hundimiento de tensión se define como la reducción en magnitud del voltaje RMS por debajo de un umbral específico, que tiene una duración de varios ciclos hasta varios segundos. Durante este tipo de falla la onda sinusoidal experimenta un desfase, lo que conlleva a una breve desviación de la frecuencia de la línea, provocando un mal funcionamiento o interrupción en los equipos (IEEE std 1668, 2014).

Aquellos hundimientos que impactan severamente a la red son resultado de fallas eléctricas que se presentan en el sistema de potencia. Estas fallas ocurren en mayor medida en los sistemas de distribución, debido a que la cantidad de equipos y conductores que se conectan a estas redes es superior en comparación con los sistemas de transmisión. Además, los códigos de red y estándares relacionados a la operación de los sistemas de distribución suelen ser más laxos. Así mismo, las torres que soportan los conductores aéreos del sistema de transmisión son más propensas a soportar eventos climáticos bruscos, en comparación con los conductores aéreos del sistema de distribución. De igual manera, las líneas que conforman este último están más expuestas de forma directa a la vegetación, vehículos, residuos y animales. Por esto, generalmente las fallas de fase-fase son producto de contactos forestales, descargas de nieve y conductores de galope (IEEE std 1668, 2014).

De acuerdo con dos estudios, *The Distribution Power Quality (DPQ)* y *The Distribution Power Quality II (DPQII)* (IEEE std 1668, 2014), en la mayoría de los casos, las causas de los

hundimientos de tensión se encuentran relacionadas con fenómenos ambientales. Sin embargo, también se deben a los mantenimientos de los equipos realizados por parte de las empresas de servicios públicos, la poda de árboles y el acceso de animales y vehículos.

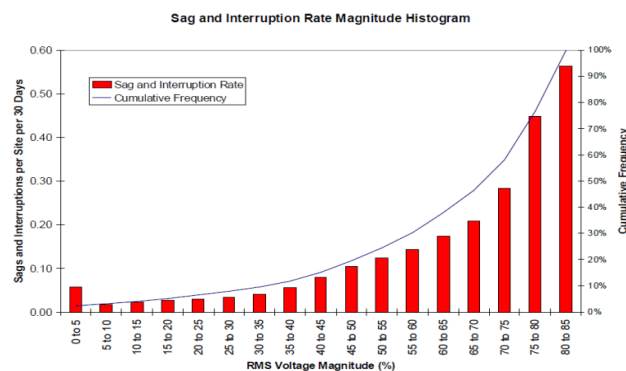
Aparte de una mayor frecuencia de fallas en el sistema de distribución, los tiempos de retransmisión son más lentos, de manera que, las caídas de tensión tienden a ser más largas. También es bastante común que el sistema de distribución se reconecte en un intento por superar la condición de falla, y, si esta permanece, se generen hundimientos de tensión adicionales (IEEE std 1668, 2014).

Para caracterizar tales hundimientos es preciso conocer en qué instante del ciclo de la onda ocurre la caída de tensión y los cambios en el ángulo de fase durante la falla. Estos se clasifican en hundimientos balanceados y desbalanceados. Un hundimiento de tensión balanceado se presenta cuando las tres fases se ven afectadas de forma equitativa, manteniendo su desfase de  $120^\circ$  entre sí. Por el contrario, los hundimientos de tensión desbalanceados presentan diferentes magnitudes de tensión en sus fases, al igual que distintos ángulos de desfase. Cabe destacar que la mayor parte de los hundimientos de tensión que se presentan en la red eléctrica son desbalanceados (IEEE std 1668, 2014).

Durante los años 2001 y 2002, se llevó a cabo el estudio DPQII, en donde se analizaron los datos obtenidos de 500 puntos de monitoreo. Con base en estos datos, se construyó el histograma que se muestra en la Figura 1, el cual representa el comportamiento de ciertas variables eléctricas durante un periodo de agregación de un minuto. En el eje vertical del histograma se indica el porcentaje de frecuencia acumulada, mientras el eje vertical izquierdo representa la tasa de caídas de tensión e interrupciones por 30 días; por otro lado, el eje horizontal denota el porcentaje de tensión residual RMS (IEEE std 1668, 2014)

**Figura 1.**

*Histograma de las magnitudes de los hundimientos e interrupciones.*




*Nota.* Tomado de *IEEE Trial-Use Recommended Practice for voltage sag and short interruption Ride – Through Testing for end use electrical equipment rates less than 1000V* (p. 28), por IEEE Std 1668 – 2014, IEEE Industry Applications Society.

Ahora bien, la Figura 2 ilustra porcentualmente el número de fases afectadas en las caídas de tensión registradas.

**Figura 2.**

*Número de fases afectadas por hundimientos de tensión con al menos una tensión residual del 85%.*

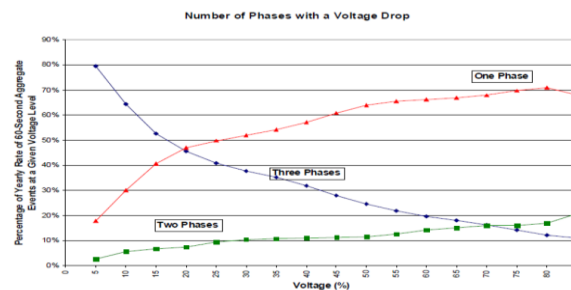


*Nota.* Tomado de *IEEE Trial-Use Recommended Practice for voltage sag and short interruption Ride – Through Testing for end use electrical equipment rates less than 1000V* (p. 29), por IEEE Std 1668 – 2014, IEEE Industry Applications Society.

Finalmente, en la Figura 3 se muestran tres gráficas que representan la cantidad de fases afectadas por los hundimientos de tensión, para diferentes magnitudes. En el eje horizontal se observa el porcentaje de tensión residual, y en el eje vertical se puede ver la tasa de caída de tensión correspondiente para cada punto de la gráfica.

### Figura 3.

*Porcentaje de voltajes residual por tipo de hundimiento de tensión.*



*Nota.* Tomado de *IEEE Trial-Use Recommended Practice for voltage sag and short interruption Ride – Through Testing for end use electrical equipment rates less than 1000V* (p. 30), por IEEE Std 1668 – 2014, IEEE Industry Applications Society.

Por ejemplo, para los datos que registran un 50% de tensión residual (eje horizontal), los porcentajes anuales de hundimientos monofásico, bifásicos y trifásicos son de 63%, 11% y 25% respectivamente.

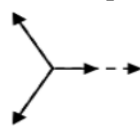
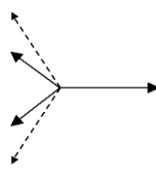
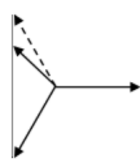
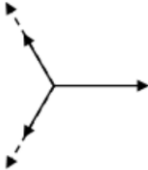
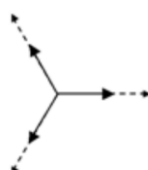
De la Figura 3 se concluye que la ocurrencia de caídas de tensión monofásicas es más frecuente y domina en un rango de tensión residual del 19% al 85%. En contraste, los hundimientos trifásicos parecen ser menos comunes, pero son más profundos en magnitud, y dominan en un rango de voltaje residual de aproximadamente 5% hasta 19%. Finalmente, los hundimientos bifásicos son los menos comunes y no dominan sobre ningún rango residual de voltaje (IEEE std 1668, 2014).

## 2.1 Tipos de hundimientos de tensión

En referencia a los distintos hundimientos de tensión que se presentan en la red eléctrica, la guía IEEE std 1668 – 2014 (2014) clasifica esta falla en tres tipos. Tal como se presenta en la Tabla 1.

**Tabla 1.**

*Tipos de hundimientos de tensión.*

Descripción de tipo	Ejemplo del método del vector de prueba	Descripción de los vectores	Comentarios
Tipo I Recomendado		$V_a = X$ $V_b = -\frac{1}{2}E - \frac{1}{2}jE\sqrt{3}$ $V_c = -\frac{1}{2}E + \frac{1}{2}jE\sqrt{3}$	Esta falla es más relevante para equipos monofásicos o trifásicos con neutro.
Tipo II Recomendado (IEC Tipo 3c)		$V_a = E$ $V_b = -\frac{1}{2}E - \frac{1}{2}jV\sqrt{3}$ $V_c = -\frac{1}{2}E + \frac{1}{2}jV\sqrt{3}$	El estudio (CIGRE C4.110, 2010) indicó que este tipo de hundimiento de tensión representa desde el 81% al 91% de los eventos del Tipo II en MT y AT.
Tipo II. A1 Permitido (IEC Tipo 3b)		$V_a = E$ $V_b = -\frac{1}{2}E - \frac{1}{2}jE\sqrt{3}$ $V_c = -\frac{1}{2}E + \frac{1}{2}j(2X - E)\sqrt{3}$	El estudio (CIGRE C4.110, 2010) indicó que este tipo de hundimiento de tensión representa del 9% al 18% de los eventos del Tipo II en MT y AT.
Tipo II. A2 Permitido (IEC Tipo 3d)		$V_a = E$ $V_b = -\frac{1}{2}X - \frac{1}{2}jX\sqrt{3}$ $V_c = -\frac{1}{2}X + \frac{1}{2}jX\sqrt{3}$	Este tipo de hundimiento de tensión puede ocurrir cuando dos fases son puestas a tierra al mismo tiempo.
Tipo III Recomendado		$V_a = V$ $V_b = -\frac{1}{2}V - \frac{1}{2}jV\sqrt{3}$ $V_c = -\frac{1}{2}V + \frac{1}{2}jV\sqrt{3}$	Este es un tipo común de hundimiento de tensión que ocurre entre el 11% y el 20% de los eventos registrados por los estudios (EPRI, 2003) y (CIGRE C4.110, 2010).

*Nota.* Adaptado de “IEEE Trial-Use Recommended Practice for voltage sag and short interruption Ride – Through Testing for end use electrical equipment rates less than 1000V” IEEE std 1668; 2014.


De acuerdo con la información anterior, los hundimientos se catalogan en:

- Tipo 1: son hundimientos monofásicos, donde se presenta una caída de tensión en una de las fases y no tiene desfase.
- Tipo 2: son hundimientos bifásicos en los cuales dos de sus fases caen en magnitud y se desfasan entre sí.
- Tipo 3: son hundimientos trifásicos donde se ve una caída en la magnitud de las tres fases, sin desfase.

Por otra parte, (Bollen, 1997) señala que ante este tipo de fallas el voltaje no solo cae en magnitud, sino que también salta en ángulo de fase; posteriormente clasifica los hundimientos de tensión en cuatro tipos (A, B, C y D). En la Figura 4 se muestra el diagrama fasorial que representa cada tipo de hundimiento.

#### Figura 4.

*Tipos de hundimientos de tensión.*



*Nota.* Tomado de *Characterization of voltage sags experienced by three-phase adjustable speed drives* (p. 3), por H. J. Bollen, 1997, IEEE Transactions on Power Delivery.


- Tipo A: todos los voltajes caen en la misma cantidad de magnitud.
- Tipo B: solo una fase cae en magnitud de voltaje.

- Tipo C: dos fases caen en magnitud y cambian su ángulo de fase.
- Tipo D: nuevamente caen las magnitudes de tensión de dos fases y su ángulo de fase cambia, el voltaje de la tercera fase solo cae en magnitud

La variación de los ángulos de desfase que presentan los hundimientos tipo C y D se ilustran en las Figuras 5 y 6, respectivamente.

### Figura 5.

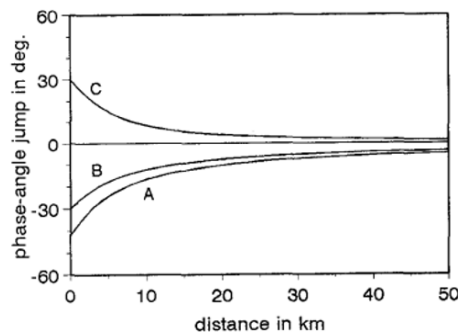
*Ángulos de fase para los hundimientos de tensión tipo C.*



*Nota.* Tomado de *Characterization of voltage sags experienced by three-phase adjustable speed drives* (p. 6), por H. J. Bollen, 1997, IEEE Transactions on Power Delivery.

### Figura 6.

*Ángulos de fase para los hundimientos de tensión tipo D.*



*Nota.* Tomado de *Characterization of voltage sags experienced by three-phase adjustable speed drives* (p. 6), por H. J. Bollen, 1997, IEEE Transactions on Power Delivery.

### ***2.1.1 Hundimientos de tensión modelados en Python.***

Teniendo en cuenta las clasificaciones y los porcentajes de tensión residual comunes que caracterizan a los hundimientos de tensión frecuentes mencionados anteriormente, este proyecto se enfoca en cuatro tipos de hundimientos (Tipo A, Tipo B, Tipo C, Tipo D) ilustrados en la Figura 4. Se utilizó Python para modelar cada tipo de hundimiento de tensión en su dominio fasorial, con el objetivo de obtener las componentes de secuencia de tensión y el ángulo de desfase entre ellas (ver apéndice F). Posteriormente se analizaron los resultados y se identificaron los rangos de  $V^+$ ,  $V^-$  y  $\varphi$  en donde se presentan los hundimientos más comunes en la red (ver apéndice G).

A continuación, se describen las características empleadas para modelar cada uno de los tipos de hundimientos, así como los rangos obtenidos en cada caso.

**2.1.1.1 Hundimiento de tensión tipo A.** En este tipo de hundimiento las tres fases se ven afectadas de forma equivalente, de manera que la magnitud de tensión residual de cada una de las fases varía del 5% al 19%, mientras sus ángulos de desfase se mantienen intactos. Como se puede observar en la Figura 4, este tipo de hundimiento es balanceado. Por esta razón, la tensión de secuencia positiva toma el mismo valor del porcentaje de tensión residual y no hay tensión de secuencia negativa, lo que implica que el desfase entre las secuencias es cero.

**2.1.1.2 Hundimiento de tensión tipo B.** Para este caso solo se ve afectada en magnitud una de las tres fases, mientras los ángulos de desfase siguen siendo los mismos. Además, la magnitud de tensión de la fase modificada varía en un voltaje residual del 19% al 85%.

Para este rango de magnitudes se obtuvo que la tensión de secuencia positiva toma un valor mínimo y máximo de 0,73 p. u. y 0,928 p. u., respectivamente. Por otra parte, el valor mínimo de

la tensión de secuencia negativa es de  $0,072 p.u.$ , mientras su valor máximo es de  $0,27 p.u.$ . El desfase se mantiene constante en  $180^\circ$  entre las componentes de secuencia.

**2.1.1.3 Hundimiento de tensión tipo C.** Para el caso de los hundimientos tipo C, dos fases caen en magnitud al mismo tiempo que varían su ángulo de fase. Las magnitudes varían del 30% al 85% de tensión residual, mientras que sus ángulos se desfasan sin mantener equivalencia. En una de las fases el ángulo varía de  $0^\circ$  a  $60^\circ$ , y en la otra de  $0^\circ$  a  $-60^\circ$ , con respecto a la condición de pre-falla.

Para dichos parámetros se obtuvo una tensión de secuencia positiva mínima de  $0,4 p.u.$  y máxima de  $0,9 p.u.$ . En cuanto a la tensión de secuencia negativa se obtiene un valor mínimo de  $0,1 p.u.$  y máximo de  $0,6 p.u.$ . Por último, el desfase entre las componentes de secuencia varía de  $-20,3^\circ$  a  $20,3^\circ$ .

**2.1.1.4 Hundimiento de tensión tipo D.** Estos hundimientos presentan caídas de tensión en las 3 fases manteniendo cierta simetría, mientras dos de estas se desfasan. Para este caso, las magnitudes de tensión residual varían del 5% al 19%. Una de las fases varía su ángulo de  $0^\circ$  a  $30^\circ$  mientras que otra de  $0^\circ$  a  $-30^\circ$ .

Ante estas características se obtuvo una tensión de secuencia positiva mínima de  $0,046 p.u.$  y máxima de  $0,19 p.u.$ . Por otra parte, la tensión de secuencia negativa toma un valor mínimo de 0 y un valor máximo de  $0,093 p.u.$ . Finalmente, el desfase entre las componentes de secuencia se mueve en un rango de  $-178,4^\circ$  y  $180^\circ$ .

La Tabla 2 señala los valores mínimos y máximos de  $V^+$ ,  $V^-$  y  $\varphi$  resultantes, para los hundimientos A, B, C y D, y la Figura 7 ilustra los rangos de  $V^+$  y  $V^-$  donde se presentan cada tipo de hundimiento.


**Tabla 2.**

Rangos de  $V^+$ ,  $V^-$  y  $\varphi$  para los hundimientos de tensión frecuentes.

Tipo de Hundimiento	Tensión de secuencia positiva ( $V^+$ )		Tensión de secuencia negativa ( $V^-$ )		Ángulo de desfase entre las secuencias ( $\varphi$ )	
	Mínimo	Máximo	Mínimo	Máximo	Mínimo	Máximo
A	0,05	0,19	0	0	0	0
B	0,73	0,928	0,072	0,27	180°	180°
C	0,4	0,9	0,1	0,6	-20,3°	20,3°
D	0,046	0,19	0	0,093	-178,4°	180°

**Figura 7.**

Rangos de  $V^+$  y  $V^-$  para los hundimientos tipo A, B, C y D



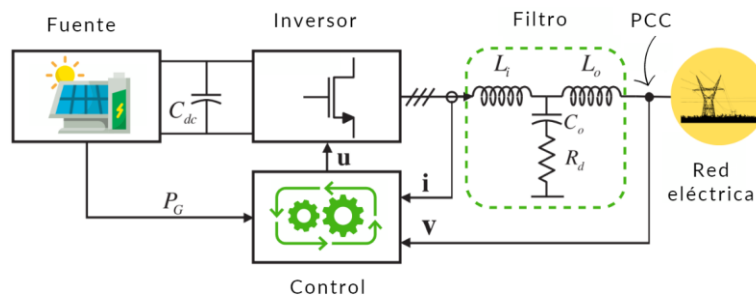
Los rangos de los hundimientos tipo A, B, C y D de la Figura 7 se representan con los colores azul, rojo, verde y amarillo, respectivamente. Cabe aclarar que en estos intervalos existe una mayor densidad de datos, dado que allí se encuentran los hundimientos de tensión más frecuentes.

### 3. Sistema de control

La figura 8 presenta el diagrama general de un inversor fotovoltaico conectado a la red eléctrica.

#### Figura 8.

*Inversor fotovoltaico conectado a la red eléctrica*

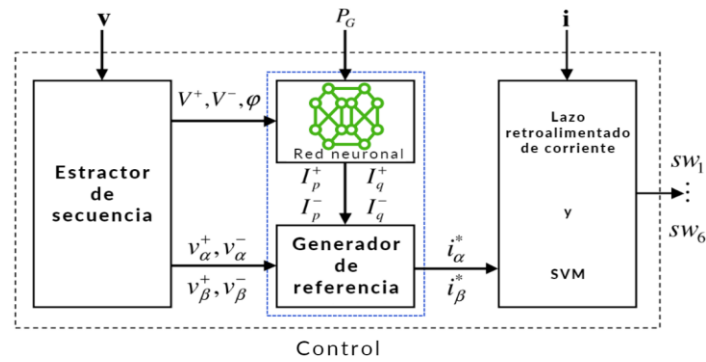


*Nota.* Adaptado de *Control Strategy for Grid-Connected Three-Phase Inverters During Voltage Sags to Meet Grid Codes and to Maximize Power Delivery Capability* (p. 3), por M. A. Garnica, J. L. García de Vicuña, J. Miret, M. Castilla & R. Guzmán, 2018, IEEE Transactions on Power Electronics.

Tal como se presenta en la figura 9, el bloque de control de este inversor está constituido por tres etapas: La etapa de generación de corrientes de referencia, el lazo retroalimentado de corriente y la modulación por espacio vectorial.

#### Figura 9.

*Bloque de control del inversor fotovoltaico.*



*Nota.* Adaptado de *Control Strategy for Grid-Connected Three-Phase Inverters During Voltage Sags to Meet Grid Codes and to Maximize Power Delivery Capability* (p. 3), por M. A. Garnica, J. L. García de Vicuña, J. Miret, M. Castilla & R. Guzmán, 2018, IEEE Transactions on Power Electronics.

Este proyecto de grado se enfoca en la etapa de generación de corrientes de referencia, específicamente en la generación de los parámetros  $I_p^+, I_p^-, I_q^+, I_q^-$ , por medio de una red neuronal fundamentada en la estrategia base que se presenta a continuación.

#### 4. Estrategia Base

La estrategia empleada para el diseño del sistema de control de inversores fotovoltaicos en el presente proyecto consiste en el método propuesto en el artículo *Control Strategy for Grid-Connected Three-Phase Inverters During Voltage Sags to Meet Grid Codes and to Maximize Power Delivery Capability* (Garnica López, García de Vicuña, Miret, Castilla, & Guzmán, 2018). Esta estrategia se caracteriza por priorizar la inyección de potencia reactiva de acuerdo con lo estipulado en los códigos de red. Se usa un algoritmo que logra maximizar las capacidades del convertidor, el cuál fue sometido a pruebas experimentales durante distintas caídas de tensión, con el fin de soportar la red ante la presencia de hundimientos de tensión.

Los códigos de red son creados y modificados por cada país o región con el objetivo de asegurar estabilidad y fiabilidad en la red eléctrica, su cumplimiento es obligatorio y por esta razón fueron considerados durante el desarrollo del algoritmo de control. Dichos códigos exigen algunas consideraciones para lograr que los sistemas de generación distribuida se comporten lo más parecido a las plantas generadoras convencionales, esto en el caso de presentarse un hundimiento de tensión:

- 1- No desconectarse de la red.
- 2- Apoyar en la recuperación de la tensión por medio de la inyección de corriente reactiva.
- 3- Reanudar la inyección de potencia activa luego de despejar la falla.

A su vez, estos proporcionan la curva que relaciona el porcentaje de corriente reactiva de secuencia positiva que se debe inyectar en función del voltaje en el punto de acople común (Garnica López et al., 2018).

El artículo indica que, para fallas trifásicas, la capacidad de LVRT es especificada en los códigos de red, pero en caso de fallas asimétricas esta capacidad es definida por cada operador de red. Por ende, el método de componentes simétricas proporciona una herramienta práctica para analizar y entender el funcionamiento de un sistema durante condiciones de desbalance, teniendo en cuenta que las fallas asimétricas tienen un porcentaje de ocurrencia del 97% - 98%.

La estrategia de control propuesta por Garnica López et al. (2018). cuenta con la ventaja de poder ser aplicada a cualquier sistema de potencia con generación distribuida. Además, le da prioridad a la inyección de potencia reactiva y realiza la inyección de corriente reactiva sin oscilaciones de potencia activa. De igual forma, el algoritmo de control cumple 4 objetivos al mismo tiempo, que garantizan el uso óptimo de las capacidades de potencia del inversor. A continuación, se formulan los objetivos de forma jerárquica:

- 1- Cumplir con los códigos de red.
- 2- Limitar la amplitud de la corriente al valor máximo permitido por el inversor.
- 3- Desarrollar un control de potencia activa.
- 4- Eliminar las oscilaciones de potencia activa.

En el último quindenio se han propuesto diferentes estrategias de control para mejorar el rendimiento del inversor durante las fallas en la red y garantizar el funcionamiento de las cargas, la mayoría de estas se basan en componentes simétricas dado que su uso permite lograr diferentes objetivos de control (Garnica López et al., 2018).

Sin embargo, dichas estrategias suelen presentar desventajas tales como:

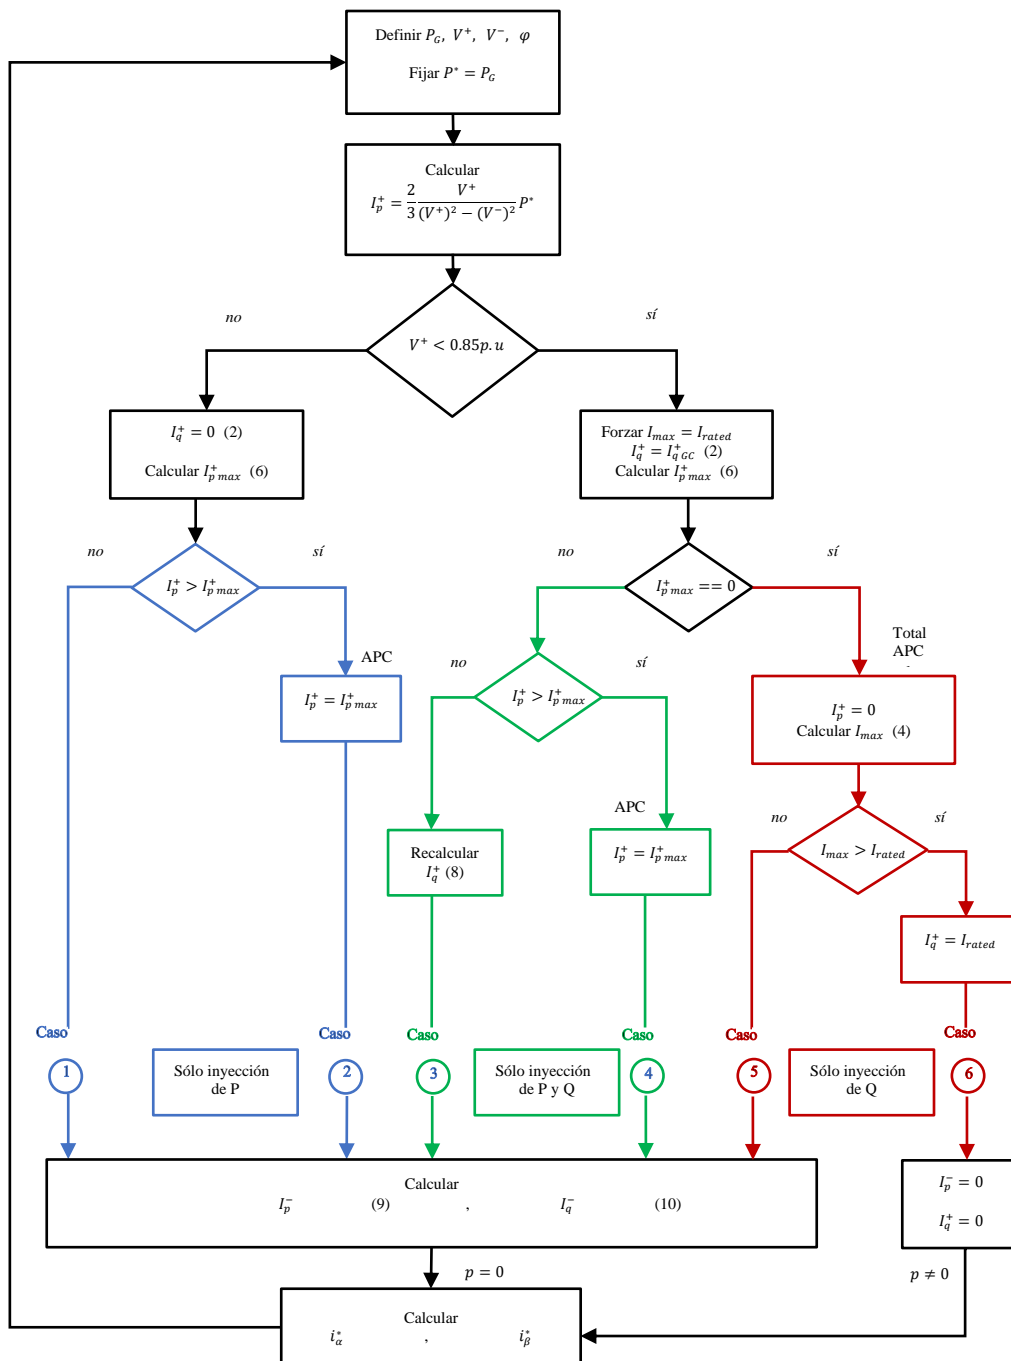
- No se logran cumplir todos los objetivos de control al mismo tiempo
- El porcentaje de distorsión armónica incrementa
- Bajo múltiples fallas la corriente de referencia del controlador puede llegar a exceder la capacidad de corriente del inversor
- Se presentan oscilaciones no deseadas en la potencia entregada
- No se tienen en cuenta algunos de los parámetros de los códigos de red

En el momento en que se presentan los hundimientos de tensión es posible describir los voltajes de fase instantáneos en el punto de acople común como la adición de sus componentes de secuencia positiva y negativa. Con base en estos valores, el sistema de potencia con generación distribuida debe alimentar a la red con cierta corriente reactiva, dado que esta inyección permite una recuperación rápida del voltaje después de la falla. Este soporte mejora la estabilidad del sistema de potencia e incrementa la calidad y confiabilidad de la red eléctrica. Los parámetros de la curva de inyección de corriente reactiva varían dependiendo de las regulaciones de cada país.

En la Figura 10 se presenta un diagrama de flujo que representa el algoritmo de control con el cual se determinan los valores de las componentes de secuencia de las corrientes que permiten cumplir con los objetivos de control (Garnica López et al., 2018).

**Figura 10.**

*Diagrama de flujo que representa el algoritmo de control.*



*Nota.* Adaptado de *Control Strategy for Grid-Connected Three-Phase Inverters During Voltage Sags to Meet Grid Codes and to Maximize Power Delivery Capability* (p. 3), por M. A. Garnica, J. L. García de Vicuña, J. Miret, M. Castilla & R. Guzmán, 2018, IEEE Transactions on Power Electronics.

Donde:

La corriente  $I_p^+$  calculada con la ecuación (1) permite la inyección de potencia activa a la red tanto en condiciones de operación normal, como en condiciones de falla.

$$I_p^+ = \frac{2}{3} \frac{V^+}{(V^+)^2 - (V^-)^2} P^* \quad (1)$$

La máxima corriente que soporta el inversor se representa como  $I_{rated}$ .

La inyección de corriente reactiva  $I_{qGC}^+$  establecida por el código de red se define en la ecuación (2).

$$I_{qGC}^+ = \begin{cases} y_1 \text{ p.u.}, & \text{si } 0.00 \leq V^+ \leq x_1 \text{ p.u.} \\ -k_1 V^+ + k_2 \text{ p.u.}, & \text{si } x_1 < V^+ < x_2 \text{ p.u.} \\ y_2 \text{ p.u.}, & \text{si } x_2 \leq V^+ \leq 1.10 \text{ p.u.} \end{cases} \quad (2)$$

En la ecuación (2), los valores  $k_1$ ,  $k_2$ ,  $x_1$ ,  $y_1$ ,  $x_2$  y  $y_2$  se obtienen de la curva que indica la inyección de corriente reactiva en función del voltaje en el punto de acople común.

El ángulo que permite obtener la amplitud máxima de la corriente es aquel con el valor mínimo de la función coseno, mostrado en (3). Teniendo en cuenta esto, la corriente de máxima amplitud puede ser calculada con (4).

$$x = \min \left\{ \cos(\varphi), \cos\left(\varphi - \frac{2\pi}{3}\right), \cos\left(\varphi + \frac{2\pi}{3}\right) \right\} \quad (3)$$

$$I_{max} = \sqrt{\frac{(V^+)^2 - 2V^+V^-x + (V^-)^2}{(V^+)^2}} \left( (I_p^+)^2 + (I_q^+)^2 \right) \quad (4)$$

Para proteger el inversor y evitar sobre corrientes se debe limitar  $I_{max}$  respecto a  $I_{rated}$ , como se indica en (5). Por otra parte,  $I_{max}$  limita únicamente a  $I_p^+$  debido a que  $I_q^+$  está dado por el código de red. De esta forma (4) se resuelve para  $I_{p max}^+$  en (6).

$$I_{max} \leq I_{rated} \quad (5)$$

$$I_{p max}^+ = \sqrt{\frac{(V^+)^2(I_{rated})^2}{(V^+)^2 - 2V^+V^-x + (V^-)^2} - (I_q^+GC)^2} \quad (6)$$

La prioridad durante un hundimiento de tensión es mantener la operación, para esto  $I_p^+$  debe ser limitada a su amplitud máxima.

$$I_p^+ \leq I_{p max}^+ \quad (7)$$

En el caso 3, al presentarse un hundimiento de tensión considerable,  $I_p^+$  es menor a  $I_{p max}^+$  generando dificultades para mantener la tensión, por ende, se debe recalculer  $I_q^+$  usando la ecuación (8). Esto permite aumentar la tensión e inyectar la máxima corriente activa posible al sistema. Teniendo en cuenta que  $I_{max} = I_{rated}$ .

$$I_q^+ = \sqrt{\frac{(V^+)^2(I_{rated})^2}{(V^+)^2 - 2V^+V^-x + (V^-)^2} - (I_p^+)^2} \quad (8)$$

Finalmente, las componentes negativas de la corriente activan y reactiva son las variables asociadas a la mitigación de la potencia oscilatoria, y se pueden escribir de la siguiente manera

$$I_p^- = \frac{V^-}{V^+} I_p^+ \quad (9)$$

$$I_q^- = \frac{V^-}{V^+} I_q^+ \quad (10)$$

#### 4.1 Algoritmo de control

En el algoritmo de control propuesto en la Figura 10 se obtienen 6 casos diferentes que dependen de las características del hundimiento de tensión y de la cantidad de potencia activa generada. Las entradas del algoritmo son: la potencia activa generada ( $P_G$ ), las amplitudes de las tensiones de secuencia positiva y negativa medidas ( $V^+, V^-$ ), y el ángulo de secuencia ( $\varphi$ ). En un

principio, se establece la potencia activa de referencia como  $P^* = P_G$  para calcular  $I_p^+$  con la ecuación (1) y así asegurar que se inyectará la máxima cantidad de potencia activa (Objetivo 3).

Si no existe hundimiento de tensión, tal como ocurre en los casos 1 y 2 ilustrados en azul, en el lado izquierdo de la Figura 10, se utiliza la ecuación (6) para asegurar que  $I_{max}$  no exceda el valor máximo permitido por el inversor (Objetivo 2). Únicamente si  $I_p^+ > I_{pmax}^+$ , se realiza una restricción de potencia activa al ajustar  $I_p^+ = I_{pmax}^+$ . Nótese que en este caso prima el objetivo 2 sobre el objetivo 3, revelando la interacción entre estos dos objetivos de control en el algoritmo. Por otra parte, el objetivo de evitar oscilaciones de potencia activa (Objetivo 4) se garantiza con la ecuación (9). En los primeros dos casos no hay requerimientos para la inyección de corriente reactiva ( $I_{qGC}^+ = I_q^+ = I_q^- = 0$ ), por consiguiente, el inversor solo entrega potencia activa. En los próximos 4 casos del algoritmo de control, cuando existe el hundimiento de tensión, aparecen los requerimientos para la inyección de corriente reactiva, y el inversor debe inyectar su máxima corriente.

En caso de hundimiento, se obtiene el valor de  $I_q^+$  del código de red en cuestión (Objetivo 1). Para luego proceder a calcular el valor correspondiente de  $I_{pmax}^+$  con la ecuación (6), para los casos 3 y 4, expuestos de color verde en la parte central de la Figura 10. Particularmente en el caso 3, cuando la corriente  $I_p^+$  no excede el límite de la corriente  $I_{pmax}^+$ ,  $I_q^+$  debe ser recalculada de acuerdo con la ecuación (8), de manera que el valor  $I_q^+$  de la ecuación (2) no se empleará más, revelando el efecto de los objetivos 2 y 3 sobre el objetivo 1.

Para los casos 5 y 6, mostrados en color rojo en la parte derecha de la Figura 10, el inversor solo inyecta corriente reactiva por medio de  $I_q^+$  e  $I_q^-$  o solo por medio de  $I_q^+$ ; de manera que se realiza una reducción total de la potencia activa ( $I_{pmax}^+ = I_p^+ = I_p^- = 0$ ) por parte del controlador

para evitar exceder  $I_{rated}$ . Específicamente, en el caso 6 todas las componentes actuales se actualizan a través del algoritmo, por ejemplo,  $I_q^- = 0$  para satisfacer el objetivo 2.


Como era de esperarse,  $I_q^+ = I_{qGC}^+$  excepto cuando  $I_p^+$  es menor a  $I_{pmax}^+$  durante condición de falla; en ese caso  $I_q^+$  debe ser recalculada con la ecuación (8) y así alcanzar la máxima capacidad de corriente del inversor ( $I_{rated}$ ). Así mismo, cuando el hundimiento de tensión es muy severo y  $V^+$  cae por debajo de 0.5 p. u., el inversor debe entregar potencia reactiva a la red entre un 90% y un 100% de su capacidad, de acuerdo con el código de red. Además, si  $V^-$  incrementa sobre cierto valor, una reducción total de la potencia activa será obligatoria. Las ecuaciones (9) y (10) demuestran que  $I_p^-$  e  $I_q^-$  son proporcionales al factor de desequilibrio de tensión y son función de  $I_p^+$  e  $I_q^+$ , respectivamente (Garnica López et al., 2018).

## 4.2 Códigos de red

La inyección de corriente reactiva de secuencia positiva en función de la tensión de secuencia positiva es un aspecto importante del sistema de control. En este sistema, la cantidad de corriente reactiva que se inyecta a la red está determinada por cada código de red, como se puede ver en la ecuación (2). Un ejemplo de esto se puede observar en la Figura 11, que muestra los límites de  $I_q^+$  que se establecen en el código de red de España.

**Figura 11.**

*Requerimiento de corriente reactiva tomada del código de red español.*

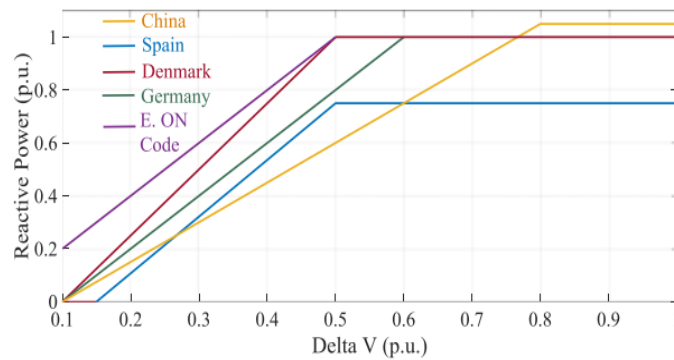


*Nota.* Tomado de *Control Strategy for Grid-Connected Three-Phase Inverters During Voltage Sags to Meet Grid Codes and to Maximize Power Delivery Capability* (p. 3), por M. A. Garnica, J. L. García de Vicuña, J. Miret, M. Castilla & R. Guzmán, 2018, IEEE Transactions on Power Electronics.

En este caso  $(x_1, y_1)$  corresponde a la coordenada  $(0.5, 0.9)$  y  $(x_2, y_2)$  corresponde a la coordenada  $(0.85, 0)$ . Mientras  $k_1$  y  $k_2$  corresponden al valor de la pendiente y del término independiente de la recta comprendida por dichas coordenadas, respectivamente. En la Figura 12 se indica la curva establecida para distintos códigos de red implementados en varios países.

**Figura 12.**

*Estándar de red de cada país, mostrando la potencia reactiva que debe ser inyectada a la red durante las fallas, con respecto a la profundidad de la caída de voltaje.*



*Nota.* Tomado de *Control Strategy for Three-Phase Grid-Connected PV Inverters Enabling Current Limitation Under Unbalanced Faults* (p. 7), por E. Afshari, G. R. Moradi, R. Rahimi, B. Farhangi, Y. Yang, F. Blaabjerg, S. Farhangi, 2017, IEEE Transactions on Industrial Electronics.

En las Figuras 9 y 10 se observa que cada código de red emplea diferentes valores en las coordenadas  $(x_1, y_1)$  y  $(x_2, y_2)$ , lo que hace que la curva que define la inyección de corriente reactiva sea diferente para cada uno. Por esta razón, en este proyecto de grado se consideran diferentes códigos de red de Europa, incluyendo España, Alemania, Dinamarca y E.ON, cuyas coordenadas se presentan en la tabla 3.

**Tabla 3.**

*Coordenadas de los códigos de red europeos considerados.*

Código de red	$(x_1, y_1)$	$(x_2, y_2)$
España	(0.5, 0.9)	(0.85, 0)
Alemania	(0.4, 1)	(0.9, 0)
Dinamarca	(0.5, 1)	(0.9, 0)
E.ON	(0.5, 1)	(0.9, 0.2)

## 5. Base de datos para entrenar la red neuronal

La base de datos sigue la estrategia de control ilustrada en la Figura 10, de modo que sus elementos se organizan en múltiples grupos de 8 parámetros, cada uno de los cuales se divide en 4 parámetros de entrada ( $P_G, V^+, V^-, \varphi$ ) y 4 parámetros de salida ( $I_p^+, I_q^+, I_p^-, I_q^-$ ).

### 5.1 Set de datos de entrada

Para el set de datos de entrada, los parámetros  $V^+, V^-$  y  $P_G$  se representan mediante un vector cuyos valores varían en un rango de 0 a 1 *p. u.*, mientras que  $\varphi$  varía en un rango de  $-180^\circ$  a  $180^\circ$ . Esta estrategia se implementa para abordar todos los posibles escenarios de hundimientos de tensión. No obstante, cabe mencionar que los pasos de variación son más rigurosos para los rangos establecidos en la tabla 2 y la Figura 7. Por lo tanto, cada parámetro se construye a partir de la concatenación de varios vectores con diferentes pasos de variación. La tabla 4 proporciona información detallada sobre los vectores que conforman cada parámetro, así como el número de pasos que cada uno contiene.

**Tabla 4.**

*Vectores que componen los parámetros del set de datos de entrada.*

Parámetro	Vector	Valor de inicio	Valor final	Valor del paso	Número de pasos
$V^+$	$V_1^+$	0,046	0,19	0,0072	21
	$V_2^+$	0,19	0,4	0,0525	5
	$V_3^+$	0,4	0,928	0,0264	20
	$V_4^+$	0,928	1	0,018	4
$V^-$	$V_1^-$	0	0,6	0,03	20
	$V_2^-$	0,6	1	0,04	10
$\varphi$	$\varphi_1$	$-180$	$-20,3$	15,97	10
	$\varphi_2$	$-20,3$	20,3	2,03	21
	$\varphi_3$	20,3	180	15,97	10
$P_G$	$P_G$	0	1	0,1	10

## 5.2 Set de Datos de Salida

Los autores de este proyecto proponen la creación de 26 códigos adicionales, esto con el objetivo explorar escenarios distintos, y disminuir el sesgo de la red neuronal a la hora de realizar el entrenamiento. Estos códigos se obtienen mediante la combinación de las coordenadas  $(x_1, y_1)$  y  $(x_2, y_2)$  de los códigos de red existentes, agregando tres nuevas coordenadas  $(0.6, 1)$ ,  $(0.4, 0.9)$  y  $(0.8, 0)$ . De esta manera, se pueden generar códigos de red con diferentes características y grados de exigencia, lo que puede ser beneficioso para adaptarse a situaciones específicas en la red eléctrica. Especialmente al definir la inyección de corriente reactiva de secuencia positiva.

Por lo tanto, se consideran un total de 30 códigos de red, incluyendo los códigos europeos. La tabla 5 indica las coordenadas que conforman las rectas de inyección de corriente reactiva en cada código. Y en la Figura 13 se presenta las curvas correspondientes a estos.

**Tabla 5.**

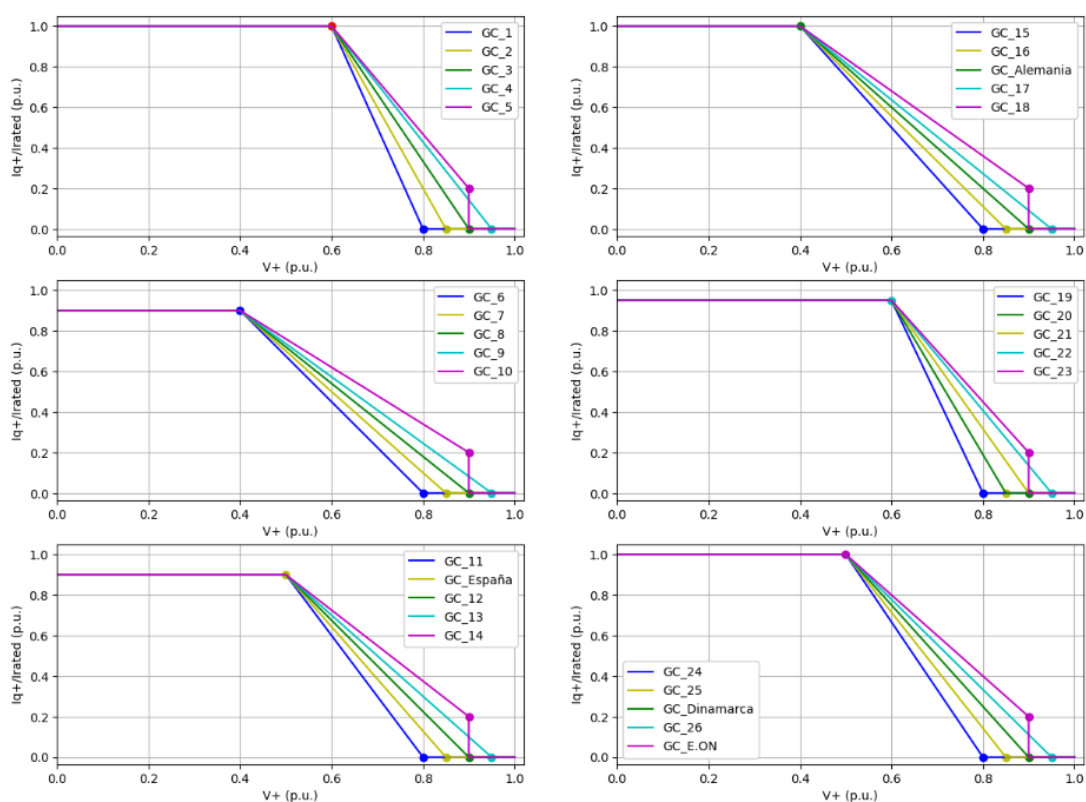
*Coordenadas de cada código de red.*

	<b>Código de red</b>	<b>(x1,y1)</b>	<b>(x2,y2)</b>
1	España	(0.5, 0.9)	(0.85,0)
2	Alemania	(0.4, 1)	(0.9,0)
3	Dinamarca	(0.5, 1)	(0.9,0)
4	E.ON	(0.5, 1)	(0.9,0.2)
5	GC_1	(0.6,1)	(0.8,0)
6	GC_2	(0.6,1)	(0.85,0)
7	GC_3	(0.6,1)	(0.9,0)
8	GC_4	(0.6,1)	(0.95,0)
9	GC_5	(0.6,1)	(0.9,0.2)
10	GC_6	(0.4,0.9)	(0.8,0)
11	GC_7	(0.4,0.9)	(0.85,0)
12	GC_8	(0.4,0.9)	(0.9,0)
13	GC_9	(0.4,0.9)	(0.95,0)
14	GC_10	(0.4,0.9)	(0.9,0.2)
15	GC_11	(0.5,0.9)	(0.8,0)
16	GC_12	(0.5,0.9)	(0.9,0)
17	GC_13	(0.5,0.9)	(0.95,0)
18	GC_14	(0.5,0.9)	(0.9,0.2)
19	GC_15	(0.4,1)	(0.8,0)
20	GC_16	(0.4,1)	(0.85,0)
21	GC_17	(0.4,1)	(0.95,0)
22	GC_18	(0.4,1)	(0.9,0.2)

	Código de red	(x1,y1)	(x2,y2)
23	GC_19	(0.6,0.95)	(0.8,0)
24	GC_20	(0.6,0.95)	(0.85,0)
25	GC_21	(0.6,0.95)	(0.9,0)
26	GC_22	(0.6,0.95)	(0.95,0)
27	GC_23	(0.6,0.95)	(0.9,0.2)
28	GC_24	(0.5,1)	(0.8,0)
29	GC_25	(0.5,1)	(0.85,0)
30	GC_26	(0.5,1)	(0.95,0)

**Figura 13.**

*Inyección de corriente reactiva establecida por los 30 códigos de red.*



Los datos de salida se generan ejecutando el diagrama de control de la Figura 10 con cada posible combinación de los parámetros de entrada. Con este fin, se ha programado un algoritmo en el lenguaje de programación Python que representa el diagrama de flujo.

Debido a que la inyección de corriente varía según el código de red implementado, se obtiene una base de datos individual para cada código de red considerado. Para obtener los datos

de salida de un código de red en particular, basta con modificar las coordenadas que definen la inyección de  $I_q^+$  y así generar la base de datos del código de red deseado. Cada una de las bases contiene todas las combinaciones posibles de los parámetros de entrada y sus respectivos datos de salida. (Ver apéndice A)

## 6. Red neuronal

Una red neuronal es un sistema de procesamiento de información inspirado en la estructura y funcionamiento del cerebro humano. Está compuesto por una red de neuronas interconectadas que reciben, procesan y transmiten información. Las redes neuronales tienen una amplia variedad de aplicaciones, incluyendo el reconocimiento de patrones, la toma de decisiones y el aprendizaje automático. En el marco de este proyecto de investigación, se implementaron las redes neuronales para explorar la posibilidad de considerar varios códigos de red usando la estrategia de control propuesta por (Garnica López et al., 2018).

Para continuar con el desarrollo de la red neuronal, se requiere una base de datos para cada uno de los 30 códigos de red anteriormente mencionados. Una vez obtenidas estas bases de datos individuales se procede a construir y entrenar la red neuronal. En un principio se entrenó la red utilizando una sola base de datos y posteriormente se agregaron las demás gradualmente, hasta completar el entrenamiento con todas ellas de forma simultánea.

### 6.1 Construcción de la red neuronal

Para la construcción del código de la red neuronal se inició cargando las 30 bases de datos que contenían, cada una, 615.000 combinaciones diferentes. Posteriormente, estas bases de datos se concatenaron en una matriz única que consta de 18'450.000 filas. Con la matriz completa que

incluye los 30 códigos de red se llevó a cabo la separación de las columnas de los datos de entrada y de salida para poder aplicar la normalización de datos por separado.

La normalización es una técnica que se utiliza con frecuencia en la preparación de datos antes de aplicar algún modelo de Machine Learning (en este caso, redes neuronales). El objetivo de la normalización consiste en cambiar los valores de las columnas numéricas del set de datos a una escala común, sin distorsionar las diferencias en los rangos de los valores o perder información (Microsoft, 2021). Para el entrenamiento de la red neuronal es fundamental que los datos de entrada se encuentren en un rango comparable para que la red pueda aprender de manera efectiva. Si los datos se encuentran en diferentes escalas, algunos parámetros pueden tener más peso que otros, lo que conlleva un mal rendimiento de la red. La técnica de normalización empleada en este proyecto es el Standard Scaler, el cuál transforma los datos para que tengan una media de cero y una desviación estándar de uno, lo que significa que los datos están centrados en cero y escalados para tener una varianza unitaria. Este proceso se realiza de manera independiente en cada parámetro calculando las estadísticas relevantes en las muestras del conjunto de datos (Scikit-learn developers, 2007 - 2023)

Después de normalizar los datos, el siguiente paso es dividir la base de datos en tres conjuntos: entrenamiento, validación y prueba. El conjunto de entrenamiento contiene el 70% de los datos, mientras que los conjuntos de validación y prueba contienen el 15% cada uno.

Ahora bien, para construir el modelo de la red neuronal se ha utilizado la API secuencial de Keras en TensorFlow. Esta elección se debe a que esta API es la más intuitiva y fácil de entender para los desarrolladores, ya que permite configurar las capas de forma secuencial, lo que resulta en un modelo de red neuronal sencillo de crear y con una curva de aprendizaje más rápida (D'Agostino, 2022).

Para llevar a cabo el modelo de la red neuronal, se optó por utilizar capas densas, dado que este tipo de capas es ampliamente utilizado para procesar grandes cantidades de datos y extraer características relevantes. Luego, se procedió a ajustar el número de capas y el número de neuronas en cada capa, realizando una serie de pruebas iterativas. Durante este proceso, se probaron diferentes combinaciones de capas y neuronas, y se evaluó el rendimiento de cada modelo en función de la precisión y eficiencia para resolver el problema en cuestión. Asimismo, se experimentó con diversas funciones de activación, para seleccionar aquella que permitiera un mejor ajuste del modelo. El objetivo final de este proceso fue obtener un modelo de red neuronal que se ajustara adecuadamente al caso de estudio, ofreciendo resultados precisos y confiables.

En concreto, el modelo de la red neuronal está compuesto por un total de 12 capas, como se observa en la Figura 14. Las primeras siete capas están configuradas con la función de activación “ReLU” y las siguientes cuatro con la función de activación “Linear”. Cada una de estas capas está compuesta por mil neuronas. En la última capa, no se especifica una función de activación y se espera una salida de 4 parámetros.

Las funciones de activación son fundamentales en una red neuronal ya que permiten modelar relaciones no lineales entre las entradas y salidas. Estas se dividen en dos tipos: lineales y no lineales. ReLU (Rectified Linear Unit) es una función no lineal ampliamente utilizada en redes neuronales, que produce una salida igual a cero cuando la entrada es negativa y la entrada misma cuando es positiva. Su facilidad de implementación y eficiencia computacional la hacen muy popular, además de resolver el problema de desvanecimiento del gradiente al mantener un gradiente constante en la propagación hacia atrás en la red neuronal (Géron, 2019). Por otro lado, la función Linear, también conocida como función identidad, produce una salida proporcional a su entrada y se utiliza comúnmente en las capas de salida de las redes neuronales para problemas de regresión, permitiendo producir cualquier valor real como salida (Géron, 2019).

La combinación de ambas funciones de activación permite que la red neuronal tenga la capacidad de modelar relaciones no lineales y realizar una regresión precisa en la tarea de predicción.

### Figura 14.

#### *Programación del modelo de la red neuronal*

```
# Modelo Fully Connected
model = tf.keras.Sequential([

    tf.keras.layers.Dense(1000, activation='relu', input_shape=(10,)),
    tf.keras.layers.Dense(1000, activation='relu'),
    tf.keras.layers.Dense(1000, activation='relu'),
    tf.keras.layers.Dense(1000, activation='relu'),
    tf.keras.layers.Dense(1000, activation='relu'),
    tf.keras.layers.Dense(1000, activation='relu'),
    tf.keras.layers.Dense(1000, activation='relu'),
    tf.keras.layers.Dense(1000, activation='linear'),
    tf.keras.layers.Dense(1000, activation='linear'),
    tf.keras.layers.Dense(1000, activation='linear'),
    tf.keras.layers.Dense(1000, activation='linear'),
    tf.keras.layers.Dense(4)

])
```

Después de definir el modelo, se procede a compilarlo como se muestra en la Figura 15. Durante la compilación se especifican los parámetros clave como el optimizador, la función de pérdida y las métricas para evaluar el modelo. En este caso, el modelo utiliza la función de pérdida de “Error Absoluto Medio” (MAE) para medir la diferencia entre las predicciones del modelo y los valores reales. El optimizador seleccionado es Adam con una tasa de aprendizaje de  $1e-6$ . Además, se especifican varias métricas, como “Error Absoluto Medio” (MAE), “Precisión” (Accuracy) y “Error Cuadrático Medio” (MSE), para evaluar el rendimiento del modelo.

**Figura 15.***Programación de la compilación de la red neuronal*

```
model.compile(loss = 'mae',
              optimizer = tf.keras.optimizers.Adam(1e-6),
              metrics = ['mae', 'accuracy', 'mse'])
```

Luego de compilar el modelo, se define una función llamada “scheduler” que se utiliza como un callback en el proceso de entrenamiento. En la Figura 16 se aprecia que la función toma dos argumentos “epoch” y “lr”, que representan el número de épocas de entrenamiento y la tasa de aprendizaje actual del modelo, respectivamente. Dentro de la función, se define una serie de condiciones basadas en el número de épocas de entrenamiento. En particular, si la época actual es menor que 10, se devuelve una tasa de aprendizaje de 1e-3. Si la época actual está entre 10 y 20 se devuelve una tasa de aprendizaje de 1e-4, y así sucesivamente.

Durante el proceso de entrenamiento del modelo, se utiliza el callback “tf.keras.callbacks.LearningRateScheduler” y se proporciona la función “scheduler” como argumento. Esto significa que, en cada época de entrenamiento, el callback ajustará la tasa de aprendizaje del modelo según las condiciones definidas en la función “scheduler”.

**Figura 16.***Programación del entrenamiento de la red neuronal*

```
def scheduler(epoch, lr):
    if epoch < (10):
        return 1e-3
    elif epoch < (20):
        return 1e-4
    elif epoch < (30):
        return 1e-5
    else:
        return 1e-6

print('Comenzando entrenamiento!')
historial=model.fit(entradasE, salidasE, epochs = 40, batch_size = 14760, validation_data = (entradasV, salidasV), shuffle = True, verbose = True,
                  callbacks=[tf.keras.callbacks.LearningRateScheduler(scheduler)])
print('Entrenamiento terminado!!!')
```

Es importante destacar que un epoch es una iteración completa del conjunto de datos de entrenamiento a través del modelo. Cada epoch actualiza los pesos del modelo una vez utilizando todos los datos de entrenamiento. Si el modelo no está aprendiendo lo suficientemente rápido, se pueden agregar más épocas al entrenamiento para mejorar la precisión. Por otra parte, el batch size es el número de ejemplos de entrenamiento que se utilizan en una sola iteración de entrenamiento para actualizar los pesos del modelo. Utilizar un tamaño de batch más grande puede acelerar el entrenamiento, ya que el modelo procesa más ejemplos a la vez. Sin embargo, el tamaño del batch debe ser lo suficientemente pequeño para que el modelo pueda caber en la memoria de la GPU o CPU. Por último, el learning rate es una tasa de aprendizaje que controla la cantidad de ajuste de los pesos del modelo en función del error de predicción. Un learning rate más grande puede hacer que el modelo aprenda más rápido, pero también puede hacer que el modelo oscile o no converja. Un learning rate más pequeño puede hacer que el modelo aprenda más lentamente, pero también puede hacer que el modelo converja más suavemente y alcance una precisión mayor (Géron, 2019).

Una vez que la red neuronal ha sido entrenada con el conjunto de datos previamente definidos para el entrenamiento, se procede a evaluar el desempeño de la red. En este punto, se realiza la predicción del modelo utilizando los datos de prueba, lo cual nos permite evaluar su capacidad para generalizar datos no vistos previamente. En la Figura 17 se presenta el fragmento de código que ejecuta las predicciones del modelo.

### **Figura 17.**

*Programación que ejecuta las predicciones de la red neuronal.*

```
#Hacer predicciones con los datos de testeo normalizados
print('Prueba de testeo')
resultados_norm = NNFinal.predict(entradasT)
print(resultados_norm)
print('fin test')
```

Finalmente, se requiere la desnormalización de los resultados obtenidos por parte de la red neuronal utilizando la función “inverse\_transform()” para obtener las predicciones originales en su escala original. Este paso es necesario para comparar y evaluar de manera precisa las predicciones del modelo con los valores reales. La función “inverse\_transform()” es comúnmente utilizada en técnicas de procesamiento y posprocesamiento de datos en el ámbito de la ciencia de datos y el aprendizaje automático. (Ver apéndice B).

## **7. Evaluación de resultados.**

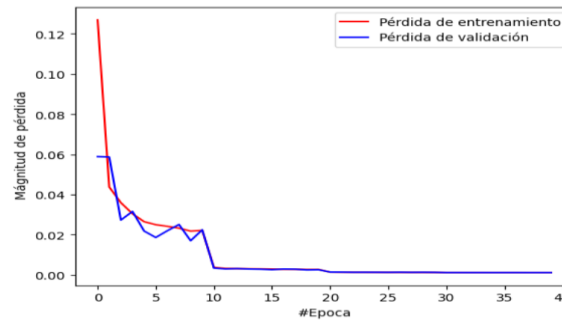
En esta sección se presentará la evaluación del modelo de la red neuronal mediante el uso de diversas métricas de precisión.

### **7.1 Evaluación del entrenamiento del modelo.**

La función de pérdida (Loss) es una medida utilizada durante el entrenamiento del modelo para evaluar la distancia entre las predicciones del modelo y las verdaderas etiquetas de los datos. En este caso, el valor de esta función está asociado al error absoluto medio (MAE). Cuando el valor de Loss es bajo, indica que el modelo está haciendo predicciones precisas y se está acercando a las verdaderas etiquetas de los datos. Por otro lado, un valor de Loss alto indica que el modelo está haciendo predicciones inexactas y que se está alejando de las verdaderas etiquetas de los datos (Géron, 2019). La Figura 18 muestra que el valor del Loss disminuye a lo largo del entrenamiento tanto en los datos del entrenamiento como en los datos de validación (ver apéndice B). Además, ambos valores convergen hacia el mismo valor de 0.0011, lo que sugiere que el modelo está generalizando adecuadamente y no está ni sobreajustando ni subajustando los datos.

**Figura 18.**

*Magnitud de la función de pérdida (loss) durante el entrenamiento.*



En la tabla 6 se presentan los resultados obtenidos de MAE, MSE y Accuracy del modelo.

**Tabla 6.**

*Resultados obtenidos de las métricas MAE, MSE y Accuracy del modelo.*

Métricas		
MAE	MSE	Accuracy
0.0011	2.1878e-4	0.9994

El MAE representa la media de la magnitud de los errores en las predicciones del modelo. Es decir, indica cuánto se desvía en promedio la predicción del modelo de la verdadera etiqueta. El MAE es una métrica de regresión y se mide en las mismas unidades que la variable objetivo (Géron, 2019). El MSE se calcula de forma similar al MAE, pero eleva los errores al cuadrado antes de calcular el promedio. Esto significa que los errores grandes son penalizados más fuertemente que los errores pequeños. El MSE también es una métrica de regresión y se mide en unidades cuadradas de la variable objetivo (Géron, 2019). Las ecuaciones 11 y 12 representan la expresión matemática que definen las métricas MAE y MSE respectivamente.

$$MAE(X, h) = \frac{1}{m} \sum_{i=1}^m |h(x^{(i)}) - y^{(i)}| \quad (11)$$

$$MSE(X, h) = \frac{1}{m} \sum_{i=1}^m (h(x^{(i)}) - y^{(i)})^2 \quad (12)$$

Donde:

$m \rightarrow$  Número total de muestras

$h(x^{(i)}) \rightarrow$  Valor real de la muestra  $i$

$y^{(i)} \rightarrow$  Valor predicho para la muestra  $i$

$X \rightarrow$  matriz que contiene los datos que permiten obtener a  $h(x^{(i)})$

$h \rightarrow$  función de predicción del sistema

Por otro lado, el Accuracy es una métrica de clasificación que mide la proporción de muestras clasificadas correctamente por el modelo. Es decir, mide la proporción de predicciones correctas sobre el total de las predicciones realizadas (ecuación 13) (Géron, 2019).

$$Accuracy = \frac{\# \text{ Predicciones correctas}}{\# \text{ Predicciones totales}} \quad (13)$$

En este caso, el modelo presenta un valor bajo de pérdida (Loss), MAE y MSE, así como un alto nivel de precisión (Accuracy), lo que indica que el modelo está haciendo predicciones acertadas en la gran mayoría de los casos y con gran precisión. (Ver apéndice B).

## 7.2 Evaluación de los parámetros de salida (Iq+, Iq-, Ip+, Ip-)

En esta sección, se realiza una comparación individual de cada uno de los parámetros de las salidas de la red neuronal con los valores reales de la base de datos. El objetivo es identificar posibles discrepancias entre los valores previstos y los valores reales. Es importante destacar que esta evaluación se enfoca exclusivamente en los datos correspondientes al código de red de España, dado que los resultados son muy similares en los 30 códigos de red implementados. (Ver apéndice C)

### 7.2.1 Análisis estadístico

En primer lugar, se lleva a cabo un análisis estadístico que compara la media, mediana y desviación estándar entre los parámetros reales y los parámetros obtenidos. La media es una medida estadística útil para comparar un grupo de datos de la misma naturaleza, ya que, representa el valor promedio de los datos en el conjunto (Salazar P. & Del Castillo G, 2018). Si los valores promedio de ambos parámetros son similares, esto podría indicar que los conjuntos son comparables en términos de la variable que se está midiendo. Por otro lado, la mediana es una medida posicional que se ubica en el centro de un conjunto de datos ordenados (Salazar P. & Del Castillo G, 2018), es decir, no se ve afectada por valores extremos o atípicos en el conjunto de datos. Esto ofrece información sobre cómo difieren los valores obtenidos de los valores reales en términos de posición central. Por último, la desviación estándar indica la variabilidad o dispersión de un conjunto de datos (Salazar P. & Del Castillo G, 2018). Al comparar la desviación estándar entre un conjunto de datos reales y uno de datos obtenidos, se puede determinar si los datos obtenidos son similares o diferentes en términos de su propia dispersión. La Tabla 7 presenta los valores de media, mediana y desviación estándar tanto de los valores reales como de los valores obtenidos del modelo de la red neuronal.

**Tabla 7.**

*Valores de media, mediana y desviación estándar.*

Parámetro	Código de red de España					
	Media		Mediana		Desviación estándar	
	Real	Obtenida	Real	Obtenida	Real	Obtenida
Iq+	8.0259	8.0257	10	10	3.4484	3.4486
Iq-	0.5490	0.5489	0	0	1.3294	1.3292
Ip+	0.9684	0.9684	0	0	1.78384	1.78387
Ip-	0.4401	0.4402	0	0	1.104	1.104

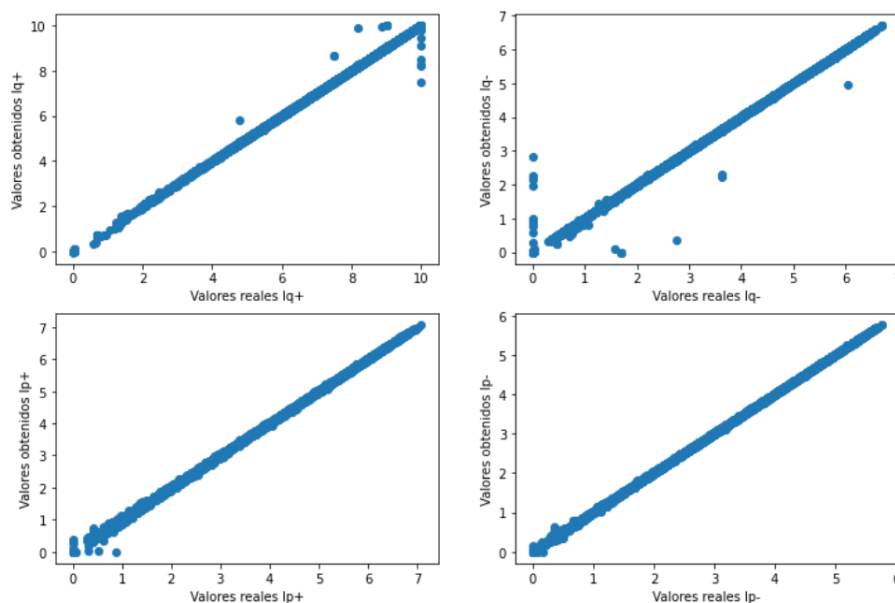
Los resultados presentados en la tabla anterior revelan que los valores de media, mediana y desviación estándar de los valores reales y los valores obtenidos están altamente cercanos. De esta proximidad se puede afirmar que el modelo de predicción está proporcionando estimaciones precisas y coherentes. La concurrencia de la media y la mediana indica que los datos tienen una distribución simétrica y no existen valores atípicos que puedan influir significativamente en la medida central. La desviación estándar similar del modelo y los datos reales sugiere que la variabilidad del modelo es equiparable a la variabilidad de los datos reales.

### 7.2.2 Análisis mediante diagrama de dispersión

A continuación, se presenta el diagrama de dispersión que compara los valores reales con los valores obtenidos de las corrientes. En la Figura 19 se puede apreciar el diagrama de dispersión correspondiente al código de red de España. (Ver apéndice C)

#### Figura 19.

*Diagrama de dispersión de las corrientes del código de red de España*



Los diagramas de dispersión son una herramienta útil para analizar la relación entre dos variables. En este caso se observa que la mayoría de los puntos en los diagramas tienden a formar una diagonal, de modo que existe una relación proporcional entre los valores reales y los resultados del modelo, esto sugiere que el modelo es preciso en la predicción y existe una alta concordancia entre los valores reales y los valores obtenidos.

### 7.2.3 Análisis de errores

La Tabla 8 indica los valores de error absoluto, error cuadrático y coeficiente de determinación, calculados para cada una de las corrientes. (Ver apéndice C)

**Tabla 8.**

*Valores de error absoluto, error cuadrático medio y coeficiente de determinación.*

Código de red de España			
Parámetro	Error absoluto	Error cuadrático medio	Coefficiente de determinación ( $R^2$ )
Iq+	0.0024	0.0003	0.999
Iq-	0.0015	0.0005	0.999
Ip+	0.0020	6.75e-5	0.999
Ip-	0.0018	1.6e-5	0.999

El error absoluto y el error cuadrático medio son medidas que permiten evaluar la discrepancia entre los valores obtenidos por el modelo y los valores reales. Si el error absoluto es cercano a cero, esto indica que las predicciones son precisas. Si el error cuadrático medio es cercano a cero, el modelo tiene un buen ajuste a los datos. Por otro lado, si el valor de  $R^2$  se acerca a 1, esto sugiere que el modelo puede explicar la variabilidad de los datos, lo que significa que la relación entre las variables es significativa (López, 2023).

### 7.3 Evaluación de los cuatro objetivos de control

#### 7.3.1 Objetivo 1


Este es el objetivo más relevante y de mayor jerarquía dentro de los cuatro objetivos de control que Garnica López et al. (2018) propone en su diagrama de control. Su función es adherirse a los requerimientos de inyección de corriente reactiva del Código de Red de España durante un hundimiento de tensión.

Para verificar el cumplimiento de este objetivo se realizó un código en Python con los siguientes pasos. Primero se importaron los datos de entradas de testeo ( $V^+$ ,  $V^-$ ,  $P_G$ ,  $\varphi$ ); salidas reales de corriente ( $I_p^+$ ,  $I_q^+$ ,  $I_p^-$ ,  $I_q^-$ ), las cuales son resultado del diagrama de flujo abordado en la Figura 10 y las salidas de corriente obtenidas de la red neuronal.

Como se observa en la Figura 20, se toman tres zonas en consideración,  $C_1$ ,  $C_2$  y  $C_3$ , las cuales están delimitadas por los valores característicos de  $V^+$  en p.u. de la gráfica de inyección de corriente reactiva del Código de Red de España (Figura 11). Luego,  $C_1$ ,  $C_2$  y  $C_3$  se encuentran en los intervalos  $0 < V^+ < 0.5$ ,  $0.5 < V^+ < 0.85$  y  $0.85 < V^+ < 1$ , respectivamente. (Ver apéndice D)

#### Figura 20.

Zonas  $C_1$ ,  $C_2$  y  $C_3$  de la gráfica de inyección de corriente  $I_q^+$  con respecto a  $V^+$



A partir de tener las zonas delimitadas en el eje  $x$ , se revisa el cumplimiento de la corriente  $I_q^+$  en el eje  $y$ , es decir, si se encuentra por encima de la curva del código de red en cada una de las zonas. En  $C_1$  sobre la recta  $y = 0.9$ , en la sección  $C_2$  los valores deben ser superiores a la ecuación  $y = -2.5714(V^+ - 0.5) + 0.9$  que corresponde a la diagonal que allí se encuentra, y en  $C_3$  superiores a la recta  $y = 0$ .

Seguidamente, se analizan los datos que no cumplen y se halla la diferencia vertical entre la  $I_q^+$  obtenida y la  $y$  del Código de Red dependiendo de la zona. Luego, se encuentra el valor máximo de esta diferencia y se guardan los valores de las  $I_q^+$  obtenidas y reales correspondientes.

Después se almacenan los valores de  $I_q^+$  obtenida que no cumplen, y su correspondiente en datos reales para poder compararlos, al igual que valores de  $V^+$  y en qué posición de los 92652 datos se encuentra. Algunos de estos datos se encuentran en la Tabla 9.

**Tabla 9.**

*Datos de la corriente reactiva de secuencia positiva ( $I_q^+$ ) que no cumplen con el Objetivo 2.*

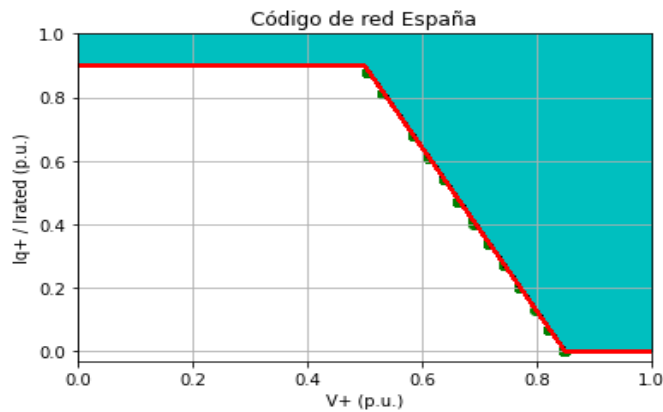
Posición	$I_q^+$		$(V^+)$
	Obtenido	Real	
99	0.41	0.41	0.6904
115	0.61	0.61	0.6112
162	0.27	0.27	0.7432
92554	0.61	0.61	0.6112

Al final, se obtiene que un 2.646% de los datos no cumplen con el código de red de España. Sin embargo, el error absoluto del valor más alejado del límite del código de red es de 0.0104. Por ende, las diferencias obtenidas entre los datos reales y los datos obtenidos pueden considerarse despreciables.

En la Figura 21 se grafican en color verde los valores de  $I_q^+$  que no cumplen, en color verde. Se evidencia que todos se encuentran suficientemente cerca de la curva del Código de Red, por lo tanto, se puede afirmar que la red neuronal cumple con el objetivo 1. (Ver apéndice D)

### Figura 21.

Valores de  $I_q^+$  que no cumplen el objetivo 1.



### 7.3.2 Objetivo 2

Este objetivo tiene que ver con limitar la corriente de fase al máximo valor en que el inversor puede funcionar sin verse afectado. En esencia, se busca limitar la corriente al valor máximo permitido,  $I_{rated}$ , teniendo en cuenta las condiciones establecidas en el diagrama de flujo presentado en la Figura 10.

Para valores de  $V^+ < 0.85$ , específicamente en los casos 3 y 4, la corriente máxima es igual a la corriente máxima tolerada por el inversor,  $I_{max} = I_{rated}$ .

Cuando  $I_{p\ max}^+$  es nula, significa que el hundimiento de tensión es considerable y se debe inyectar en su mayor parte corriente reactiva (casos 5 y 6). En este escenario la  $I_{max}$  se recalcula usando la ecuación 4, la cual es la siguiente:

$$I_{max} = \sqrt{\frac{(V^+)^2 - 2V^+V^-x + (V^-)^2}{(V^+)^2} \left( (I_p^+)^2 + (I_q^+)^2 \right)}$$

En el caso de que  $I_{max}$  sea mayor a  $I_{rated}$ , se fija  $I_{max} = I_{rated}$  para proteger la integridad del inversor. Cabe aclarar que en el caso 6, únicamente se está inyectando corriente reactiva, por lo que  $I_q^+ = I_{rated}$ , entonces  $I_q^+ = I_{max}$ .

Para valores de  $V^+ > 0.85$ , es decir, casos 1 y 2, la corriente que se inyecta es activa ya que no hay un hundimiento de tensión considerable. Aquí la corriente máxima toma el valor de la corriente que puede soportar el inversor,  $I_{max} = I_{rated}$ .

El siguiente paso consiste en se revisar cuáles valores del vector de  $I_{max}$  cumplieron con ser menores o iguales a  $I_{rated} = 10 A$ , y cuáles no lo hicieron.

Al final se tiene que ningún valor de corriente de  $I_{max}$  superó los límites de  $I_{rated}$ , entonces la tasa de éxito de este objetivo es del 100%. (Ver apéndice E)

### 7.3.3 Objetivo 3

El objetivo 3 del algoritmo de control propuesto por Garnica López et al. (2018) indica que debe existir un control de potencia activa tanto en condiciones normales de operación como en condición de falla, inyectando la máxima potencia activa siempre y cuando dicha potencia no exceda la máxima corriente que soporta el inversor ( $I_{rated}$ ).

En primer lugar, en el algoritmo de control se calcula la amplitud de la corriente activa de secuencia positiva ( $I_p^+$ ) con la ecuación 1:

$$I_p^+ = \frac{2}{3} \frac{V^+}{(V^+)^2 - (V^-)^2} P^*$$

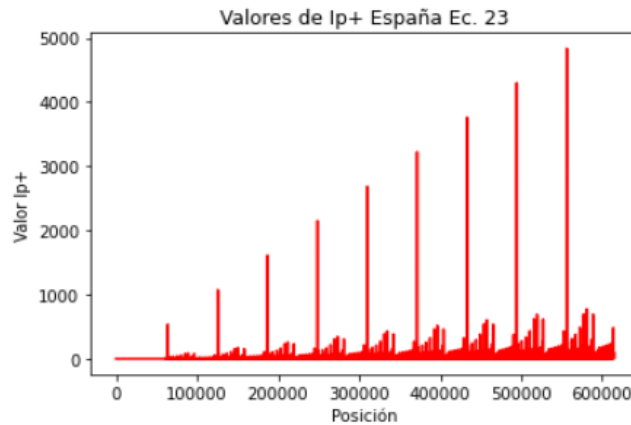
Según el artículo, esta expresión tiene la capacidad de permitir la inyección de potencia activa a la red en situaciones normales de operación, así como en momentos de falla. Por lo tanto,

controlar esta variable es esencial para lograr el tercer objetivo de control (Garnica López, García de Vicuña, Miret, Castilla, & Guzmán, 2018).

En varias ocasiones la corriente  $I_p^+$  supera el valor de  $I_{rated}$  tal como se muestra en la Figura 22 (Ver apéndice A). Razón por la cual es necesario aplicar una restricción a esta corriente.

### Figura 22.

*Cálculo de la corriente  $I_p^+$  sin aplicar ningún control*



La estrategia base limita el valor de  $I_p^+$  a su máxima amplitud posible aplicando las ecuaciones 6 y 7, correspondientes a:

$$I_{pmax}^+ = \sqrt{\frac{(V^+)^2(I_{rated})^2}{(V^+)^2 - 2V^+V^-x + (V^-)^2} - (I_q^+GC)^2}$$

$$I_p^+ \leq I_{pmax}^+$$

La red neuronal demuestra su capacidad de controlar la corriente  $I_p^+$  al comparar los datos reales con los datos obtenidos de este parámetro en la gráfica de dispersión ubicada en la parte inferior izquierda de la Figura 19, donde se evidencia una relación proporcional entre estos. Es importante destacar que el 98.02% de los valores obtenidos de  $I_p^+$  coinciden con los valores reales de este parámetro.

Además, el máximo valor que toma la corriente  $I_{pmax}^+$  a lo largo del algoritmo de control es de 7.121 A, mientras que los valores máximos de  $I_p^+$  son 7.08 A y 7.06 A para los valores reales y obtenidos, respectivamente, demostrando que la corriente  $I_p^+$  es limitada por  $I_{pmax}^+$  (Ver apéndice C). Por ende, los datos que entrega la red neuronal cumplen con el tercer objetivo de control.

#### 7.3.4 Objetivo 4

El objetivo 4 de la estrategia de control base seleccionada es minimizar las oscilaciones de potencia activa durante las caídas de tensión. El logro de este objetivo se relaciona con las corrientes de referencia del inversor, las cuales son ajustadas por medio de un esquema propuesto en el artículo “Control Strategy to Maximize the Power Capability of PV-Based Industrial Microgrids During Voltage Sags”. Este esquema expone dos expresiones matemáticas que se definen en función de las secuencias positiva y negativa de las tensiones, las potencias de referencia y cuatro parámetros de control ( $k_p^+$ ,  $k_p^-$ ,  $k_q^+$  y  $k_q^-$ ). Estos parámetros son utilizados para ajustar las corrientes de referencia del inversor y minimizar las oscilaciones de potencia activa durante las caídas de tensión (Garnica López et al., 2018).

Las dos expresiones matemáticas son las ecuaciones 14 y 15:

$$i_{\alpha}^* = \frac{2}{3} \left( \left( \frac{(k_p^+ v_{\alpha}^+ + k_p^- v_{\alpha}^-) P^*}{k_p^+ (V^+)^2 + k_p^- (V^-)^2} \right) + \left( \frac{(k_q^+ v_{\beta}^+ + k_q^- v_{\beta}^-) Q^*}{k_q^+ (V^+)^2 + k_q^- (V^-)^2} \right) \right) \quad (14)$$

$$i_{\beta}^* = \frac{2}{3} \left( \left( \frac{(k_p^+ v_{\beta}^+ + k_p^- v_{\beta}^-) P^*}{k_p^+ (V^+)^2 + k_p^- (V^-)^2} \right) + \left( \frac{(k_q^+ v_{\alpha}^+ + k_q^- v_{\alpha}^-) Q^*}{k_q^+ (V^+)^2 + k_q^- (V^-)^2} \right) \right) \quad (15)$$

Es importante destacar que los parámetros de control se seleccionan de acuerdo con este mismo artículo. Donde  $k_p^- = -k_p^+$  y  $k_q^+ = k_q^-$  para eliminar las oscilaciones de potencia activa.

Ahora bien, las potencias activa y reactiva instantáneas entregadas por un inversor trifásico VSI se definen en las ecuaciones 16 y 17.

$$p = \frac{3}{2} (v_{\alpha} i_{\alpha} + v_{\beta} i_{\beta}) \quad (16)$$

$$q = \frac{3}{2} (v_{\beta} i_{\alpha} + v_{\alpha} i_{\beta}) \quad (17)$$

Estas expresiones pueden descomponerse en las ecuaciones 18 y 19, respectivamente:

$$p = p^{+} + p^{-} + \tilde{p} \quad (18)$$

$$q = q^{+} + q^{-} + \tilde{q} \quad (19)$$

De manera que la potencia activa se puede representar en términos de las características del hundimiento de tensión ( $V^{+}$ ,  $V^{-}$  y  $\varphi$ ) y los parámetros de control ( $k_p^{+}$ ,  $k_p^{-}$ ,  $k_q^{+}$  y  $k_q^{-}$ ) en la ecuación 20:

$$p = \left( \frac{k_p^{+}(V^{+})^2 + k_p^{-}(V^{-})^2}{k_p^{+}(V^{+})^2 + k_p^{-}(V^{-})^2} P^{*} \right) + \left( \frac{(k_p^{+} + k_p^{-})(V^{+})(V^{-}) \cos(2\omega t - \varphi)}{k_p^{+}(V^{+})^2 + k_p^{-}(V^{-})^2} P^{*} \right) + \left( \frac{(k_q^{+} + k_q^{-})(V^{+})(V^{-}) \sin(2\omega t - \varphi)}{k_q^{+}(V^{+})^2 + k_q^{-}(V^{-})^2} Q^{*} \right) \quad (20)$$

Como resultado, las oscilaciones de potencia activa se eliminan cuando los parámetros de control  $k_p^{-} = -k_p^{+}$  y  $k_q^{+} = k_q^{-}$ .

La estrategia de control mitiga las oscilaciones de potencia activa. Sin embargo, el autor de la estrategia original reconocida en este proyecto de grado afirma que su método no puede funcionar con una oscilación de potencia activa nula cuando solo se inyecta corriente reactiva de secuencia positiva (como en el caso 6). Aunque su método no excede la corriente máxima, no puede evitar la oscilación de potencia activa, sino solo limitarla (Garnica López et al., 2018).

## 8. Conclusiones

En este proyecto de grado se presentó una estrategia alternativa al diagrama de flujo propuesto por Garnica López et al. (2018) usando redes neuronales para el control de inversores fotovoltaicos ante hundimientos de tensión en la red, con énfasis en aquellos que se presentan con

mayor frecuencia. La implementación de redes neuronales permitió la ejecución simultánea de múltiples códigos de red, resultando en una estrategia más flexible y adaptable a diversas situaciones.

### **8.1 Sobre el desempeño de la red neuronal.**

Pese a obtener cierto margen de error en la evaluación de los parámetros de salida  $(I_q^+, I_q^-, I_p^+, I_p^-)$ , la red neuronal demostró una operación eficiente en la evaluación de los objetivos de control del presente estudio. Por lo tanto, se validan los resultados de las métricas estadísticas MAE, MSE y Accuracy obtenidas.

### **8.2 Sobre el cumplimiento del objetivo de control 1.**

En el primer objetivo de control, la red neuronal arroja valores que cumplen con la exigencia del código de red en un 97.354%. Aunque el 2.646% restante de los resultados no cumplen con el requerimiento, estos valores no se alejan del valor mínimo solicitado, teniendo en cuenta que el mayor error absoluto en este grupo de datos es de solo 0.014 en relación con el valor mínimo. De esta manera se puede concluir que los valores arrojados por parte de la red neuronal se consideran aceptables para este objetivo de control.

### **8.3 Sobre el cumplimiento del objetivo de control 2.**

En ninguno de los casos evaluados las corrientes exceden el máximo valor de corriente que soporta el inversor, por ende, la red neuronal cumple con el segundo objetivo de control a cabalidad.

#### 8.4 Sobre el cumplimiento del objetivo de control 3.

Se valida el cumplimiento del tercer objetivo de control al verificar que la corriente  $I_p^+$  se ve restringida por la corriente  $I_{pmax}^+$ , lo que indica que existe un control que garantiza la máxima inyección de potencia activa sin sobrepasar los límites de corriente del inversor.

#### 8.5 Sobre el cumplimiento del objetivo de control 4.

La estrategia de control busca minimizar las oscilaciones de potencia activa durante los hundimientos de tensión mediante las ecuaciones 14 y 15, junto con la definición de los parámetros de control  $k_p^- = -k_p^+$  y  $k_q^+ = k_q^-$ . Aunque esta estrategia puede mitigar las oscilaciones de potencia activa, no puede eliminarlas por completo en algunas situaciones, como por ejemplo en el caso 6.

### Referencias Bibliograficas

- Afshari, E., Moradi, G. R., Rahimini, R., Farhangi, B., Yang, Y., Blaabjerg, F., & Farhangi, S. (2017). Control Strategy for Three-Phase Grid-Connected PV Inverters Enabling Current Limitation Under Unbalanced Faults. *IEEE Transactions on Industrial Electronics*, 64(11), 7. doi:10.1109/TIE.2017.2733481
- Bollen, H. J. (1997). Characterization of Voltage Sags Experienced by Three-Phase Adjustable Speed Drives. *IEEE Transactions on Power Delivery*, 12(4), 3. doi:10.1109/61.634188
- Bollen, H. J., & Hassan, F. (2011). Integration of Distributed Generation in the Power System. Wiley. doi:10.1002/9781118029039
- CIGRE C4.110. (2010). *Voltage Dip Immunity of Equipment and Installations*.
- Cleavelin, C. R. (1997). Power Quality Perspectives in the Semiconductor Industry. *EPRI*, 7(5).
- D'Agostino, A. (2022, November 22). *Towards Data Science*. Retrieved from Get started with TensorFlow 2.0 — Introduction to deep learning: <https://towardsdatascience.com/a-comprehensive-introduction-to-tensorflows-sequential-api-and-model-for-deep-learning-c5e31aee49fa>
- EPRI. (2003). Distribution System Power Quality Assessment: Phase II—Voltage Sag and Interruption Analysis. Palo Alto, CA.
- Garnica López, M. A., García de Vicuña, J. L., Miret, J., Castilla, M., & Guzmán, R. (2018). Control Strategy for Grid-Connected Three-Phase Inverters During Voltage Sags to Meet Grid Codes and to Maximize Power Delivery Capability. *IEEE Transactions on Power Electronics*, 33(11), 9360-9374. doi:10.1109/TPEL.2018.2792478

- Géron, A. (2019). Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. In A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (p. 320). Beijing, Boston, Farnham, Sebastopol, Tokyo: O'REILLY.
- IEEE P2938/D3.2. (2022). IEEE Draft Guide for Economic Loss Evaluation of Sensitive Industrial Customers Caused by Voltage Sags. *IEEE*, 71.
- IEEE std 1159. (2009). IEEE Recommended Practice for Monitoring Electric Power Quality . *IEEE*, 94. doi:10.1109/IEEESTD.2019.8796486.
- IEEE std 1668. (2014). IEEE Trial-Use Recommended Practice For Voltage Sag and Short Interruption Ride-Through Testing for End-Use Electrical Equipment Rated Less than 1000V. *IEEE Industry Applications Society*. doi:10.1109/IEEESTD.2014.6895236
- Instituto Colombiano de Normas Técnicas y Certificación. (2008). NTC 5001. *Calidad de la potencia eléctrica. Límites y metodología de evaluación en punto de conexión común*.
- López, J. F. (2023). *economipedia*. Retrieved from Coeficiente de determinación (R cuadrado): <https://economipedia.com/definiciones/r-cuadrado-coeficiente-determinacion.html>
- Microsoft. (2021, 04 11). *Microsoft*. Retrieved from Normalize Data component: <https://learn.microsoft.com/en-us/azure/machine-learning/component-reference/normalize-data>
- Rolán, A., Bogarra, S., & Bakkar, M. (2022). Integration of Distributed Energy Resources to Unbalanced Grids Under Voltage Sags With Grid Code Compliance. *IEEE Transactions on Smart Grid*, 355-366. doi:10.1109/TSG.2021.3107984
- Salazar P., C., & Del Castillo G, S. (2018). *Fundamentos básicos de estadística*. Independiente.
- Scikit-learn developers. (2007 - 2023). *Scikit Learn*. Retrieved from <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>

## Apéndices

### Apéndice A. Código para obtener la base de datos

En el siguiente enlace se encuentra el código implementado para la obtención de la base de datos

<https://colab.research.google.com/drive/1poYhzVdEisjaXzpDD-tNBPS3FMYoN029>

Respecto a esta programación, en la línea de código presentada en la Figura 23 se deben definir las coordenadas del código de red al cual se le desea obtener la base de datos.

### Figura 23.

*Definición de coordenadas en el código*

SE DEFINEN LA COORDENADAS DEL CÓDIGO QUE SE DESEA OBTENER

```
[9] x1_vec = [0.5]
    y1_vec = [0.9]
    x2_vec = [0.85]
    y2_vec = [0]
```

De igual forma, en la línea de código presentada en la Figura 24 se debe definir el nombre de la base de datos.

### Figura 24.

*Definición del nombre del archivo que contiene la base de datos*

NOMBRE DEL ARCHIVO QUE CONTIENE LA BASE DE DATOS DESEADA

```
[ ] #Se define el nombre del archivo de la siguiente manera:
    #BD_GC_1
    #Si es un código de red real:
    #BD_NombreDelPaís

    df_data.to_csv('BD_GC_26', compression='gzip', index=False)
```

En el siguiente enlace se encuentra una carpeta que contiene las 30 bases de datos:

[https://drive.google.com/drive/folders/14H1dW7gCt3134zYJ5n\\_isIRGVfmz9lPI?usp=sharing](https://drive.google.com/drive/folders/14H1dW7gCt3134zYJ5n_isIRGVfmz9lPI?usp=sharing)

### **Apéndice B.** *Código de la red neuronal y evaluación de esta*

En el siguiente enlace se puede acceder al código que implementa la red neuronal y la evaluación de sus resultados.

[https://colab.research.google.com/drive/1fhtJwUr5E8LVlJrwxE5RkE\\_DBNhZxUxW?usp=sharing](https://colab.research.google.com/drive/1fhtJwUr5E8LVlJrwxE5RkE_DBNhZxUxW?usp=sharing)

Es importante tener en cuenta que para ejecutar el código es necesario subir las 30 bases de datos al almacenamiento de la sesión.

Asimismo, si se desea hacer predicciones sin tener que volver a entrenar el modelo, en el siguiente enlace se puede descargar el archivo del modelo de la red neuronal.

[https://drive.google.com/drive/folders/1G6Xk3ty-pbVk4AhSeZ-l\\_GBFSO6psjv4](https://drive.google.com/drive/folders/1G6Xk3ty-pbVk4AhSeZ-l_GBFSO6psjv4)

Para obtener por separado los datos correspondientes a cada código de red se debe modificar el algoritmo en las zonas resaltadas de las Figuras 25, 26 y 27, de acuerdo con las coordenadas del código de red deseado (tabla 5), de la siguiente manera  $[x_1, x_2, y_1, y_2]$ .

**Figura 25.**

*Línea de código que identifica las salidas reales a evaluar de un código de red individual.*

```
# En la siguiente línea de código se utilizan las coordenadas de cada código de red
# Para obtener por separado los datos de cada código y poder evaluarlos individualmente
# Por esta razón anteriormente se agregaron las columnas correspondientes a las coordenadas
# En los datos de entrada, salidas reales y salidas obtenidas.

# Por ejemplo, en este caso la función np.where separa en una matriz diferente las filas que tienen
# los valores 0.5, 0.85, 0.9 y 0 (coordenadas x1, x2, y1 y y2 de España)
# en sus primeras cuatro columnas, respectivamente.

# Este procedimiento se realiza en las entradas, las salidas reales y las salidas obtenidas.

mascaraESPsalidascord = np.where(np.all(np.array(salidasTcord)[:,:4] == [0.5,0.85,0.9,0], axis=1))
salidasTESP = np.array(salidasTcord)[mascaraESPsalidascord]

columnasESPA = ['x1', 'x2', 'y1', 'y2', 'Iq+', 'Iq-', 'Ip+', 'Ip-']
salidasTESP = pd.DataFrame(salidasTESP, columns=columnasESPA)

salidasTESP
```

**Figura 26.**

*Línea de código que identifica las salidas obtenidas a evaluar de un código de red individual.*

```
[ ] mascaraESPresultadoscord = np.where(np.all(np.array(resultadoscord)[:,:4] == [0.5,0.85,0.9,0], axis=1))
resultadosESP = np.array(resultadoscord)[mascaraESPresultadoscord]

columnasESPA = ['x1', 'x2', 'y1', 'y2', 'Iq+', 'Iq-', 'Ip+', 'Ip-']
resultadosESP = pd.DataFrame(resultadosESP, columns=columnasESPA)

resultadosESP
```

**Figura 27.**

*Línea de código que identifica las entradas correspondientes a las salidas reales y obtenidas de un código de red individual.*

```
[ ] mascaraESPentradasT = np.where(np.all(np.array(entradasT1)[:,:4] == [0.5,0.85,0.9,0], axis=1))
entradasTESP = np.array(entradasT1)[mascaraESPentradasT]

columnasESPAET = ['x1', 'x2', 'y1', 'y2', 'cos_min_phi_grados', 'Ip_pos_max', 'Imax', 'V+pu', 'V-pu', 'V+', 'V-', 'Desfase', 'P referencia']
entradasTESP = pd.DataFrame(entradasTESP, columns=columnasESPAET)

entradasTESP
```

De igual forma, se debe modificar el nombre de los archivos en las líneas de código presentadas en la Figura 28, referentes al código de red que se desea analizar.

**Figura 28.**

*Líneas de código para modificar el nombre de los archivos de acuerdo con el código de red que se desea analizar.*

```
# Se exporta a excel los archivos de valores reales, valores obtenidos y entradas
# de cada combinación predicha para luego evaluar los resultados.
# En este caso se exportan los resultados del código de red de españa.
# Si se desean los resultados de otro código de red se debe cambiar las coordenadas
# En la función np.where mencionada anteriormente y cambiar el nombre de los archivos en las
# Sigüientes líneas de código.

salidasTESP.to_excel('BD_España_Resultados_Reales.xlsx', index=False)
resultadosESP.to_excel('BD_España_Resultados_Obtenidos.xlsx', index=False)
ENTRADAScosminphi1.to_excel('BD_España_Entradas_Testeo.xlsx', index=False)
```

En el siguiente enlace se encuentra una carpeta que contiene los archivos con los resultados obtenidos, los resultados reales y las entradas correspondientes, para cada código de red individual implementado en este proyecto.

<https://drive.google.com/drive/folders/1EjhNq31Z3Mh7xdsuIXxaeqEWYU--xggB?usp=sharing>

**Apéndice C. Código para la evaluación de resultados y objetivo 3**

En el siguiente enlace se encuentra el código donde se realiza la evaluación de los resultados de los parámetros para cada código de red individual, al igual que la evaluación del tercer objetivo de control.

[https://colab.research.google.com/drive/1JZEf1EOjP3P4Pa\\_G-E8\\_dqCj0ZR8g5sL?usp=sharing](https://colab.research.google.com/drive/1JZEf1EOjP3P4Pa_G-E8_dqCj0ZR8g5sL?usp=sharing)

Para observar los resultados de cada código de red se deben subir los archivos correspondientes en el almacenamiento de la sesión, en este caso, los archivos que se mencionaron al final del apéndice B. En las líneas de código indicadas en la Figura 29 se debe ajustar el nombre de los archivos de acuerdo con el código que se dese analizar.

**Figura 29.**

*Líneas de código para cargar los archivos del código de red que se desea verificar.*

```
Ro = pd.read_csv('BD_GC26_Resultados_Obtendidos') #Resultados Obtenidos
Rr = pd.read_csv('BD_GC26_Resultados_Reales') #Resultados Reales
datain = pd.read_csv('BD_GC26_Entradas_Testeo')
```

En el siguiente enlace se pueden observar los diagramas de dispersión de todos los códigos de red.

[https://drive.google.com/drive/folders/1W4XDei6T3man-e\\_bQ9NRXLdm8V\\_dCrFo](https://drive.google.com/drive/folders/1W4XDei6T3man-e_bQ9NRXLdm8V_dCrFo)

**Apéndice D. Código para la evaluación del objetivo 1**

En el siguiente enlace se presenta el código empleado para la evaluación del primer objetivo de control.

[https://colab.research.google.com/drive/1kV2TT\\_QrhHL8b5DKe\\_MerI28BbvienP-?usp=sharing](https://colab.research.google.com/drive/1kV2TT_QrhHL8b5DKe_MerI28BbvienP-?usp=sharing)

**Apéndice E. Código para la evaluación del objetivo 2**

En el siguiente enlace se presenta el código desarrollado para el segundo objetivo de control.

<https://colab.research.google.com/drive/1NkJ9PniyBWKluNyTXxTtkibNukR1-PVf?usp=sharing>

Cabe aclarar que en los códigos que se encuentran en los apéndices D y E se deben subir los archivos correspondientes al código de red que se desea verificar, dichos archivos son los mencionados en el apéndice B. De igual forma, se debe llamar el archivo correspondiente en las líneas de código presentadas en la Figura 27.

**Apéndice F.** *Código de las componentes de secuencia*

En el enlace que se presenta a continuación, se encuentra el código que permite obtener las componentes de secuencia de la tensión y el desfase para cualquier tipo de hundimiento, en función de la magnitud y el ángulo de las fases del sistema trifásico.

<https://colab.research.google.com/drive/1GrhsMnZ8yoNpAi57XTgE2lSK07XAbAq6?usp=sharing>

**Apéndice G.** *Código para obtener los rangos de los hundimientos frecuentes*

En el siguiente enlace se exponen los códigos con los cálculos realizados para obtener los rangos de las componentes  $V^+$ ,  $V^-$  y  $\varphi$ , para los hundimientos que se presentan con mayor frecuencia (Tipo A, Tipo B, Tipo C y Tipo D)

[https://drive.google.com/drive/folders/10a\\_hp4B\\_Dy5rTvoQj-3gDU0HRi2EFkta?usp=sharing](https://drive.google.com/drive/folders/10a_hp4B_Dy5rTvoQj-3gDU0HRi2EFkta?usp=sharing)