

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA

ESTIMACIÓN DEL MARGEN DE ESTABILIDAD DE VOLTAJE EN EL SISTEMA NACIONAL INTERCONECTADO S.N.I. UTILIZANDO HERRAMIENTAS DE APRENDIZAJE AUTOMÁTICO

TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE INGENIERO ELÉCTRICO

GABRIEL FRANCISCO GUAÑUNA TENORIO

DIRECTOR: Dr. Ing. JAIME CRISTÓBAL CEPEDA CAMPAÑA

CODIRECTOR: Dr. Ing. NELSON VICTORIANO GRANDA GUTIÉRREZ

Quito, agosto 2022

AVAL

Certifico que el presente trabajo fue desarrollado por Sr. Gabriel Francisco Guañuna Tenorio, bajo nuestra supervisión.



DR. ING. JAIME CRISTÓBAL CEPEDA CAMPAÑA
DIRECTOR DEL TRABAJO DE TITULACIÓN



DR. ING. NELSON VICTORIANO GRANDA GUTIÉRREZ
CODIRECTOR DEL TRABAJO DE TITULACIÓN

DECLARACIÓN DE AUTORÍA

Yo, Gabriel Francisco Guañuna Tenorio, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración dejo constancia de que la Escuela Politécnica Nacional podrá hacer uso del presente trabajo según los términos estipulados en la Ley, Reglamentos y Normas vigentes.



Gabriel Francisco Guañuna Tenorio

DEDICATORIA

A mis abuelitos María de Lourdes y Rafael, quienes me han apoyado en cada paso de mi vida para cumplir la meta de ser ingeniero eléctrico.

A mis padres Silvia y Wilson, quienes me ayudaron incondicionalmente mediante su confianza, amor y respeto.

A mi hermana Paola, quien me ha acompañado durante toda mi vida y siempre ha sido un ejemplo de dedicación y madurez.

A mis amigos quienes han estado apoyándome desde que inició esta meta.

AGRADECIMIENTO

Agradezco a mis abuelitos María de Lourdes Quilachamín y Rafael Guañuna, por brindarme el ejemplo de trabajo constante y apoyarme a pesar de todas las dificultades que hemos pasado, por demostrarme su amor incondicional y ayudarme durante toda mi vida y carrera universitaria.

Agradezco a mis padres Silvia y Wilson, por inculcar en mí valores que me han definido como persona y brindarme su amor incondicional, por confiar siempre en mí y demostrarme que todo se puede lograr a través de la determinación personal.

Gracias a mi querida Escuela Politécnica Nacional y principalmente a la Facultad de Ingeniería Eléctrica y Electrónica, por brindarme una educación de calidad de la mano de los mejores docentes del país.

Agradezco a tan prestigiosa empresa Cenace por brindarme la oportunidad de realizar mi trabajo de titulación, bajo la tutela de la Subgerencia Nacional de Investigación y Desarrollo.

A mi director Dr. Jaime Cepeda, por su interés y gran disposición de ayudarme en el desarrollo de este proyecto de titulación, también le agradezco su paciencia y ayuda en los inconvenientes que se presentaron durante la elaboración del trabajo de titulación.

A mi codirector Dr. Nelson Granda, por brindarme su apoyo incondicional, por sus consejos y gran interés para concluir el presente proyecto.

Al Dr. Diego Echeverría, por su amistad y predisposición para ayudarme a culminar mi trabajo de titulación.

Al Dr. Marlon Chamba, por guiarme durante el desarrollo de este proyecto mediante su experiencia profesional.

A Vanessa, quien ha sido la persona más especial en mi vida y ha estado en los mejores y peores momentos, siempre estaré agradecido por su apoyo incondicional y amor sincero.

Finalmente, agradezco a todos mis amigos en especial a Bryancito, David, Pancho, Santa, Leo, Cintya, Johanna y Carla quienes me apoyaron en todo momento de mi carrera.

ÍNDICE DE CONTENIDO

AVAL	I
DECLARACIÓN DE AUTORÍA.....	II
DEDICATORIA.....	III
AGRADECIMIENTO.....	IV
ÍNDICE DE CONTENIDO.....	V
RESUMEN	VII
ABSTRACT	VIII
1. INTRODUCCIÓN.....	1
1.1 OBJETIVOS	2
1.1.1. OBJETIVO GENERAL.....	2
1.1.2. OBJETIVOS ESPECÍFICOS	2
1.2 ALCANCE	3
1.3 MARCO TEÓRICO.....	4
1.3.1. ESTABILIDAD DE VOLTAJE – CONCEPTOS BÁSICOS	4
1.3.2. CLASIFICACIÓN DE LA ESTABILIDAD DE VOLTAJE	11
1.3.3. MÉTODOS DE ANÁLISIS DE ESTABILIDAD DE VOLTAJE.....	13
1.3.4. MÉTODO DE MONTECARLO APLICADO A FLUJOS DE POTENCIA PROBABILÍSTICOS.....	18
1.3.5. CURVAS DE CAPACIDAD DE GENERADORES SINCRÓNICOS	20
1.3.6. APRENDIZAJE AUTOMÁTICO	25
2. METODOLOGÍA.....	32
2.1. ETAPA 1 – MATPOWER Y POWERFACTORY	32
2.1.1. EJEMPLO DE CÁLCULO CURVAS PV – POWERFACTORY.....	33
2.1.2. EJEMPLO DE CÁLCULO CURVAS PV – MATPOWER	34
2.1.3. COMPARACIÓN DE HERRAMIENTAS COMPUTACIONALES	36
2.2. ETAPA 2 – MODELADO DE LAS CURVAS DE CAPACIDAD.....	37
2.2.1. CÁLCULO CURVAS DE CAPACIDAD EN MATLAB.....	38
2.2.2. INCLUSIÓN DE LAS CURVAS DE CAPACIDAD EN POWERFACTORY	39
2.3. ETAPA 3 – DESARROLLO PROGRAMA COMPUTACIONAL	42
2.3.1. ESTADOS OPERATIVOS Y BASE DE DATOS	42

2.3.2.	ESTRUCTURACIÓN Y PROCESAMIENTO DE DATOS	49
2.4.	ETAPA 4 - INTERPRETACIÓN DEL RESULTADOS.....	55
3.	RESULTADOS Y DISCUSIÓN	57
3.1.	CASO 1: SISTEMA IEEE 14 BARRAS.....	57
3.1.1.	RESULTADOS DEL PROCESAMIENTO DE DATOS.....	59
3.1.2.	RESULTADOS DE LA RED NEURONAL Y OPTIMIZACIÓN	64
3.1.3.	RESULTADOS DE LA MÁQUINA DE SOPORTE VECTORIAL Y OPTIMIZACIÓN.....	66
3.2.	CASO 2: SISTEMA NACIONAL INTERCONECTADO REDUCIDO.....	67
3.2.1.	RESULTADOS DEL PREPROCESAMIENTO DE DATOS	69
3.2.2.	RESULTADOS DE LA RED NEURONAL Y OPTIMIZACIÓN	73
3.2.3.	RESULTADOS DE LA MÁQUINA DE SOPORTE VECTORIAL Y OPTIMIZACIÓN.....	75
3.3.	COMPARACIÓN DE LOS REGRESORES.....	77
4.	CONCLUSIONES Y RECOMENDACIONES.....	79
4.1.	CONCLUSIONES.....	79
4.2.	RECOMENDACIONES	80
5.	REFERENCIAS BIBLIOGRÁFICAS	82

RESUMEN

La evaluación del margen de estabilidad de voltaje de un sistema de potencia puede realizarse a través de métodos convencionales como: análisis modal, flujos de potencia de continuación, curvas PV, entre otros. Sin embargo, cuando se requiere este tipo de análisis en tiempo real, resulta inconveniente aplicar todos estos métodos debido a la gran cantidad de información que se maneja durante el desarrollo de los algoritmos. En ese sentido, la generación de una base de datos confiable de todo el sistema que, considere una cantidad considerable de escenarios operativos, junto con la aplicación de algoritmos de inteligencia artificial, pueden ser la solución para evitar las complicaciones del tiempo y esfuerzo computacional.

En este trabajo, la herramienta desarrollada en Python y vinculada con PowerFactory es capaz de generar una cantidad considerable de escenarios operativos para la generación de la base de datos, teniendo en cuenta la estocasticidad de la demanda. Además, se implementan los algoritmos de redes neuronales y máquinas de soporte vectorial para la estimación del margen de estabilidad, así como el procesamiento de datos para potencializar y verificar la calidad de la información.

El presente trabajo de titulación tiene como objetivo diseñar una herramienta de evaluación de la estabilidad de voltaje capaz de funcionar en línea, mediante: la estructuración de una base de datos, tanto para el sistema IEEE 14 barras como para el Sistema Nacional Interconectado reducido, y la posterior estimación del margen de estabilidad de voltaje. Esto se realiza a través de la implementación de algoritmos de inteligencia artificial disponibles en el lenguaje de programación Python, con el propósito de optimizar los tiempos de cálculo y disminuir la carga computacional que requiere el análisis de la estabilidad de voltaje a través de métodos convencionales.

PALABRAS CLAVE: Estabilidad, curvas PV, redes neuronales, margen de estabilidad.

ABSTRACT

Voltage stability margin assessment of a power system can be done through conventional methods such as: modal analysis, continuation power flows, PV curves, among others. However, when this type of analysis is required in real time, it is inconvenient to apply all these methods due to the large amount of information that is handled during the development of the algorithms. In this sense, the generation of a reliable database of the entire system that considers a considerable number of operating scenarios, together with the application of artificial intelligence algorithms, can be the solution to avoid the complications of time and computational effort.

In this work, the tool developed in Python and linked to PowerFactory is capable of generating a considerable number of operating scenarios for the generation of the database, taking into account the stochasticity of the demand. In addition, neural network algorithms and support vector machines are implemented to estimate the stability margin, as well as data processing to enhance and verify the quality of the information.

The aim of this degree work is to design a voltage stability evaluation tool capable of working online, through: the structuring of a database, both for the IEEE 14-bar system and for the reduced National Interconnected System, and the subsequent estimation of the voltage stability margin. This is done through the implementation of artificial intelligence algorithms available in the Python programming language, with the purpose of optimizing calculation times and reducing the computational load that voltage stability analysis requires through conventional methods.

KEYWORDS: Stability, PV curves, neural networks, stability margin.

1. INTRODUCCIÓN

La creciente demanda de energía eléctrica, junto con las restricciones económicas y ambientales para la expansión de la capacidad de generación y transmisión, ha llevado a los sistemas de potencia a operar cada vez más cerca de sus límites de operación, estableciendo nuevas problemáticas relacionadas, principalmente, a la inestabilidad de voltaje. De hecho, la estabilidad de voltaje es uno de los temas primordiales tanto para los investigadores en la academia, como para las empresas encargadas de la operación y control de los Sistemas Eléctricos de Potencia (SEP) [1]. De igual forma, la inestabilidad de voltaje ha sido la causa de apagones o colapsos masivos importantes alrededor del mundo tales como: el apagón de Canadá – Estados Unidos (2003), el apagón de Suecia – Dinamarca (2003), el apagón en India (2012), el apagón en Turquía (2015) [2].

Los límites máximos de generación de potencia reactiva, los límites máximos de cargabilidad en líneas de transmisión, la confiabilidad de la red de transmisión, dispositivos de compensación de potencia reactiva y las características de la carga son los principales factores que afectan a la estabilidad de voltaje. Igualmente, el ingreso en operación de energías renovables (redes de distribución activas, las microrredes, los sistemas de energía integrados, etc.) junto con las limitaciones de los recursos de los sistemas de generación distribuida determinan restricciones que influyen sobre el margen de estabilidad de voltaje [3]. Existen diferentes enfoques para el análisis de estabilidad de voltaje como curvas P-V y Q-V, análisis modal, índices de estabilidad de voltaje (VSI) y flujos de potencia de continuación (CPF).

Los índices de estabilidad de voltaje se obtienen a través de condiciones teóricas cerca del punto de colapso de voltaje y pueden ser usados para determinar la proximidad a la inestabilidad de voltaje y efectuar acciones de control, en tiempo real. Sin embargo, algunos índices requieren como variable de entrada la topología de la red para aplicar el circuito equivalente de Thévenin, mientras que otros índices requieren mediciones sincronizadas de voltaje y corriente que pueden ser proporcionadas por unidades de medición fasorial (PMU) [4].

Por otro lado, el método de la continuación aplicado a flujos de potencia resulta conveniente cuando se aplica en sistemas eléctricos pequeños. Sin embargo, su aplicación en tiempo real a SEP grandes resulta complicada debido al esfuerzo computacional requerido por la alta cantidad de iteraciones del método. Dicho esto, se requiere explorar enfoques alternativos relacionados con modelos de aprendizaje automático (MLM), que permitan vencer esta brecha informática mediante la interacción con herramientas tecnológicas,

lenguajes de programación de alto nivel y minería de datos. El enfoque donde se utilizan mediciones sincrofasoriales y algoritmos de inteligencia artificial para el análisis de estabilidad de voltaje en tiempo real, se desarrolla con un mayor grado de complejidad en [5].

Actualmente, el Sistema Nacional Interconectado (SNI) ecuatoriano cumple con el margen de estabilidad de voltaje cuando se encuentra en condiciones normales de operación. Sin embargo, debido a la insuficiente potencia reactiva de las unidades de generación, compensación de potencia reactiva y cargabilidad de las líneas de transmisión, resulta complicado realizar un adecuado control de voltaje tanto en el corto como en el largo plazo. Consecuentemente, ante ciertas contingencias, el SNI puede no cumplir con el margen de estabilidad, lo que, en definitiva, denota la poca robustez que tiene el sistema eléctrico ecuatoriano. Con esto en mente, es de particular interés el correcto modelamiento de las curvas de capacidad de los generadores para considerar los límites operacionales durante eventos o contingencias, y así obtener resultados más cercanos a la realidad.

Además, la evaluación de la estabilidad de voltaje se debe realizar considerando áreas o regiones específicas del SEP con el propósito de determinar el déficit de reserva de potencia reactiva bajo ciertas condiciones operativas [6]. Para obtener la información necesaria, se utiliza una base de datos confiable, desarrollada mediante simulaciones de Montecarlo validadas. Estos datos son posteriormente usados por algoritmos de inteligencia artificial y minería de datos con el propósito de diseñar una herramienta para estimar el margen de estabilidad de voltaje en tiempo real, mejorando la eficiencia de su cálculo.

1.1 OBJETIVOS

1.1.1. OBJETIVO GENERAL

Estimar el margen de estabilidad de voltaje en el Sistema Nacional Interconectado ecuatoriano utilizando herramientas de aprendizaje automático y minería de datos disponibles en el lenguaje Python.

1.1.2. OBJETIVOS ESPECÍFICOS

- Investigar la información necesaria acerca de los diferentes métodos para el análisis de estabilidad de voltaje, la estructuración de un modelo de aprendizaje automático y el lenguaje de programación Python aplicado a la minería de datos.

- Determinar las curvas de capacidad de las principales unidades de generación del Sistema Nacional Interconectado (SNI) mediante un script desarrollado en Matlab para luego ser implementadas en PowerFactory de DIgSILENT.
- Desarrollar un aplicativo computacional que permita el tratamiento del conjunto de datos obtenidos de simulaciones, y el posterior entrenamiento y evaluación de los modelos de aprendizaje automático.
- Aplicar la herramienta computacional en sistemas de prueba y en el SNI con la finalidad de estimar el límite de estabilidad de voltaje en diferentes escenarios de operación.
- Seleccionar los algoritmos de aprendizaje más adecuados y que mejor se ajustan a los requerimientos del SNI mediante criterios de precisión.

1.2 ALCANCE

Se analizará la información existente en la literatura técnica acerca de las principales metodologías de evaluación de estabilidad de voltaje tales como las curvas PV y el método de continuación aplicado a flujos de potencia para observar el comportamiento de los sistemas cerca del punto de bifurcación e inclusive en la parte inestable (parte inferior de la curva). También se analizarán los requerimientos necesarios para implementar un modelo de aprendizaje automático, considerando algoritmos de aprendizaje disponibles en la literatura asociada a la inteligencia artificial y el tratamiento de datos mediante el uso del lenguaje de programación Python.

Se calcularán las curvas PV y el límite de estabilidad de voltaje utilizando las herramientas de simulación PowerFactory y MatPower para demostrar que se alcanza el punto de bifurcación en el sistema de prueba IEEE de 14 barras. Se calcularán las curvas de capacidad de las principales unidades de generación del Sistema Nacional Interconectado a través de la aplicación de un script desarrollado en Matlab con el propósito de considerar los límites operacionales de las máquinas sincrónicas. Esta información será incluida en PowerFactory para el cálculo de los flujos de potencia iterativos y la posterior determinación de las curvas PV.

Se creará una base de datos de estados operativos del Sistema Nacional Interconectado, aplicando flujos óptimos de potencia (Método de Montecarlo), mediante de una herramienta que será desarrollada a través de la vinculación entre Python y PowerFactory. Además, se implementará una herramienta computacional para entrenar y evaluar modelos de

aprendizaje automático para la estimación del margen de estabilidad de voltaje. La herramienta tendrá las siguientes funciones:

- Simular varios estados operativos aplicando el método de Montecarlo.
- Importar los datos obtenidos como resultados de las simulaciones en PowerFactory.
- Analizar la información mediante índices y gráficos estadísticos.
- Depurar la información mediante herramientas de minería de datos.
- Entrenar y evaluar el modelo a través de distintos algoritmos de aprendizaje automático tales como: redes neuronales artificiales, máquinas de soporte vectorial, árboles de decisión, entre otros.
- Estimar el margen de estabilidad de voltaje.
- Analizar el rendimiento de las técnicas de aprendizaje automático.

Por último, se utilizarán los modelos de aprendizaje automático tanto en el sistema de prueba IEEE de 14 barras como el SNI; se analizará el rendimiento de cada algoritmo de aprendizaje para elegir el que más se ajuste a los requerimientos del sistema de potencia de estudio.

1.3 MARCO TEÓRICO

A continuación, se realiza una descripción de los principales conceptos teóricos que se utilizan como fundamento para el desarrollo del presente trabajo de titulación: métodos de evaluación de estabilidad de voltaje, método de Montecarlo, flujos de potencia probabilísticos, curvas de capacidad de generadores sincrónicos, estructuración de modelos de aprendizaje automático y el uso del lenguaje de programación Python para automatización de tareas.

1.3.1. ESTABILIDAD DE VOLTAJE – CONCEPTOS BÁSICOS

De acuerdo con IEEE/CIGRE, la estabilidad de voltaje se refiere a la capacidad de un sistema de potencia para mantener voltajes cercanos al valor nominal en todas las barras del sistema después de haber estado sujeto a una perturbación [7].

Una condición necesaria para el correcto funcionamiento del sistema de potencia requiere que todos los generadores permanezcan en sincronismo, dado que estos sistemas se fundamentan en máquinas sincrónicas para la generación de energía eléctrica. Este aspecto está condicionado por la dinámica del ángulo del rotor del generador y la relación

entre potencia y ángulo. Sin embargo, existe una inestabilidad sin pérdida de sincronismo, donde un sistema se puede volver inestable cuando existe un colapso de voltaje y la preocupación recae en la estabilidad y el control de voltaje [8].

El comportamiento del sistema de potencia cuando se somete a una perturbación transitoria es de gran interés en la evaluación de la estabilidad de voltaje, dicha perturbación puede ser pequeña o grande. Una perturbación pequeña hace referencia a cambios de carga donde el sistema debe ser capaz de operar normalmente frente a estas condiciones y mantener el suministro de energía basado en la capacidad de transferencia de potencia. Mientras que una perturbación grande o severa hace referencia a numerosos fenómenos como cortocircuitos en líneas de transmisión, salida de servicio de varios generadores o cargas, desconexión entre subsistemas eléctricos, etc. [8].

La estabilidad de voltaje es la capacidad que tiene un SEP para mantener estable su perfil de voltaje en todas las barras, tanto en condiciones normales de operación como en condiciones de estrés eléctrico, luego de una perturbación. La caída de voltaje progresiva e incontrolable se produce cuando un sistema ingresa en un estado de inestabilidad que puede ser provocado por un aumento de la demanda de carga o un cambio en la condición operativa del sistema [8].

Uno de los criterios para el análisis de la estabilidad de voltaje, dada una condición operativa, es que a medida que se aumenta la inyección de potencia reactiva en una barra, también aumenta la magnitud del voltaje en dicha barra. Entonces, un sistema es inestable si para al menos una barra, la magnitud del voltaje disminuye mientras aumenta la inyección de potencia reactiva en la misma barra (sensibilidad V-Q). Además, la inestabilidad de voltaje es un fenómeno de carácter local, sin embargo, se puede generalizar y sus consecuencias pueden afectar a todo un conjunto de subsistemas. De esta manera, se explica que el colapso de voltaje es un fenómeno más complejo que la inestabilidad de voltaje porque es el resultado de varios eventos que son inestables y producen una caída significativa del perfil de voltaje en la mayor parte del sistema de potencia [8].

1.3.1.1. Características del sistema de transmisión

Las características de interés son las relaciones entre la potencia transmitida (P_R), el voltaje en la carga (V_R) y la inyección de potencia reactiva (Q_i). En ese sentido, se pueden ilustrar, de manera sencilla, las características del sistema de transmisión a través del análisis de la red radial que se observa en la Figura 1.1. Este esquema consiste en una fuente de

voltaje constante (\widehat{E}_S) que alimenta a una carga (\widehat{Z}_{LD}) a través de una impedancia serie (\widehat{Z}_{LN}) [8].




Figura 1.1. Esquema radial simple para caracterización del sistema de transmisión [8].

La expresión de la corriente (\hat{I}) se presenta en la ecuación (1.1).

$$\hat{I} = \frac{\widehat{E}_S}{\widehat{Z}_{LN} + \widehat{Z}_{LD}} \quad (1.1)$$

Donde \hat{I} y \widehat{E}_S son fasores. Los fasores \widehat{Z}_{LN} y \widehat{Z}_{LD} se presentan en las ecuaciones (1.2) y (1.3), respectivamente.

$$\widehat{Z}_{LN} = Z_{LN} \angle \theta \quad (1.2)$$

$$\widehat{Z}_{LD} = Z_{LD} \angle \phi \quad (1.3)$$

De esta manera, al sustituir y expandir las ecuaciones (1.2) y (1.3) en la ecuación (1.1), se obtiene:

$$I = \frac{E_S}{\sqrt{(Z_{LN} \cos \theta + Z_{LD} \cos \phi)^2 + (Z_{LN} \sin \theta + Z_{LD} \sin \phi)^2}} \quad (1.4)$$

Al simplificar y agrupar términos en la ecuación (1.4), se obtiene:

$$I = \frac{1}{\sqrt{F}} \frac{E_S}{Z_{LN}} \quad (1.5)$$

Donde:

$$F = 1 + \left(\frac{Z_{LD}}{Z_{LN}}\right)^2 + 2 \left(\frac{Z_{LD}}{Z_{LN}}\right) \cos(\theta - \phi) \quad (1.6)$$

El voltaje al final del corredor y la potencia suministrada a la carga se presentan en las ecuaciones (1.7) y (1.8), respectivamente.

$$V_R = \frac{1}{\sqrt{F}} \frac{Z_{LD}}{Z_{LN}} E_S \quad (1.7)$$

$$P_R = \frac{Z_{LD}}{F} \left(\frac{E_S}{Z_{LN}} \right)^2 \cos \phi \quad (1.8)$$

Las gráficas de I , V_R y P_R se muestran en la Figura 1.4. Estas gráficas están en función de Z_{LN}/Z_{LD} para el caso de $\tan \theta = 10$ y $\cos \phi = 0.95$. Los valores de I , V_R y P_R están normalizados para que los resultados del análisis apliquen para cualquier valor de Z_{LN} [8].

En la Figura 1.2. se evidencia que la demanda de la carga aumenta conforme Z_{LD} disminuye, esto provoca que P_R aumente considerablemente al principio hasta llegar a un valor máximo y finalmente disminuye. Por lo tanto, cuando $Z_{LN}/Z_{LD} = 1$, existe un valor máximo de potencia que se puede transmitir a través de la línea de transmisión desde una fuente de voltaje constante (límite operacional satisfactorio) [8].




Figura 1.2. Voltaje, corriente y potencia como función de la demanda del sistema de la Figura 1.1 [8].

Sin embargo, se pueden evidenciar dos zonas de operación correspondientes a dos valores diferentes de Z_{LD} . La zona ubicada en la parte izquierda del valor crítico, corresponde a una operación normal ($P_R = 0.8$), mientras que, la zona ubicada en la parte

derecha del valor crítico corresponde a una operación anormal dado que el control de la potencia activa mediante la variación de carga sería inestable (I mucho mayor en magnitud y V_R mucho menor en magnitud), conduciendo a una reducción progresiva del perfil de voltaje [8].

Por otro lado, existe un método convencional para ilustrar el fenómeno de la inestabilidad de voltaje que utiliza la relación entre la potencia P_R y el voltaje V_R , para diferentes valores de factor de potencia considerando una fuente de voltaje E_S constante. Las condiciones normales de operación se encuentran por encima de los puntos críticos representados mediante la línea punteada que se muestra en la Figura 1.3 [8].




Figura 1.3. Relación entre V_R y P_R del sistema radial de la Figura 1.1 para diferentes factores de potencia [8].

Las características P-V mostradas en la Figura 1.3 son la base fundamental para el análisis de sistemas de potencia grandes que constan de varias fuentes de voltaje (máquinas síncronas) y barras con diferentes cargas. De esta manera, la curva P-V que se muestra en la Figura 1.4. se obtiene a través de flujos de potencia sucesivos para diferentes niveles de carga con factor de potencia constante. Sin embargo, en la “nariz” de la curva, el Jacobiano del flujo de potencia se vuelve singular y eso se traduce en inestabilidad, de manera que operar cerca de este límite es absurdo y nada práctico [8].




Figura 1.4. Ejemplo curva PV en la barra 530 del sistema IEEE 39 barras [8].

1.3.1.2. Características del generador

Los reguladores automáticos de voltaje (AVR) de los generadores son los dispositivos de control de voltaje más importantes dentro de un sistema eléctrico de potencia. El voltaje en terminales de la máquina permanece constante bajo condiciones normales de operación, mientras que, para condiciones de bajos voltajes, la demanda de potencia reactiva de los generadores puede exceder los límites de corriente de campo o de armadura. Por consiguiente, los voltajes no pueden permanecer constantes cuando la generación de potencia reactiva está limitada [8].

En la mayoría de generadores, los operadores realizan el control de la corriente de armadura con el propósito de manipular la generación de potencia reactiva mediante alarmas emergentes en los sistemas de potencia. En algunos generadores, existen dispositivos de control automáticos de la corriente de armadura usados para limitar la generación de potencia reactiva mediante el regulador de voltaje propio de la máquina [8].

Para entender el fenómeno de la pérdida de capacidad de control de voltaje del generador, se presenta la Figura 1.5. que consiste en un sistema radial que alimenta a una carga desde una barra infinita, con generación intermedia y regulación de voltaje [8].




Figura 1.5. Sistema radial esquemático [8].

En la Figura 1.6. se puede evidenciar la característica PV (curva 1), considerando que el voltaje en la barra intermedia está controlado por el generador. Entonces, cuando el generador en la barra intermedia alcanza su límite máximo de corriente de campo, el voltaje de la barra (V_1) ya no se mantiene estable y provoca otra característica PV (curva 2). De esta manera, el punto de operación A es considerablemente más estable en la curva 1 que en la curva 2, puesto que tiene un mayor rango de margen de estabilidad [8]. Dicho esto, se puede decir que la capacidad de control de voltaje de una máquina síncrona permite un adecuado funcionamiento del sistema de potencia bajo ciertas condiciones anormales de operación.

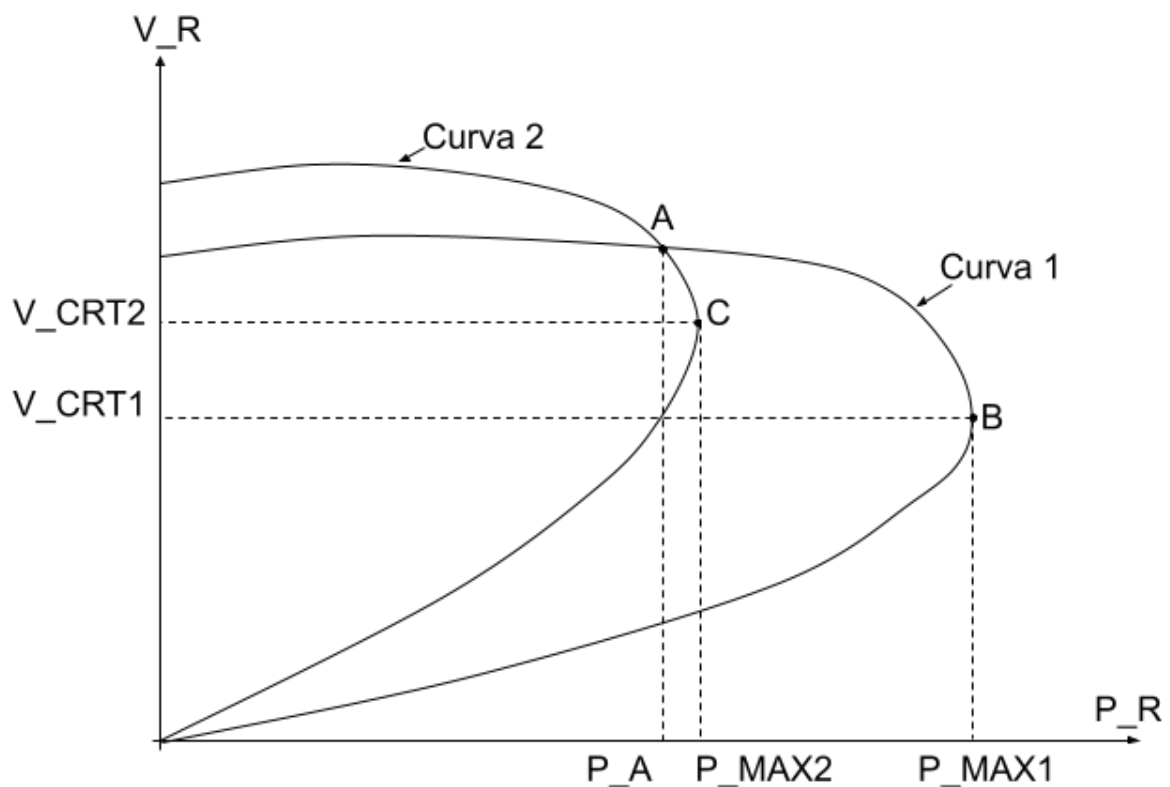


Figura 1.6. Impacto de la pérdida de regulación de voltaje en el bus intermedio [8].

1.3.1.3. Características de la carga

El funcionamiento adecuado de un sistema de potencia se refleja en el hecho de satisfacer la demanda de energía eléctrica a las cargas a través de las unidades de generación presentes en el sistema de potencia (balance generación - carga). En ese sentido, las características de la carga tienen un papel importante cuando se trata de estabilidad de voltaje. El modelado de la carga es complicado porque se compone de una gran cantidad de dispositivos diferentes como: lámparas fluorescentes, refrigeradores, calentadores, motores, hornos, etc., que resulta poco práctico representar de forma individual cada uno de ellos. Por lo tanto, la representación de la carga se realiza de manera simplificada [8].

La representación de la carga se divide en dos categorías: modelos estáticos y modelos dinámicos. Los modelos estáticos representan a las cargas mediante polinomios u otras funciones algebraicas como funciones exponenciales. La representación considera principalmente el voltaje y la frecuencia de la barra en ese instante. El componente de potencia activa y el componente de potencia reactiva se consideran por separado. Sin embargo, existen muchos casos relevantes como sistemas con gran concentración de motores, donde la dinámica de los componentes de la carga es considerada para estudios de oscilaciones entre áreas, estabilidad de voltaje, etc. [9].

1.3.2. CLASIFICACIÓN DE LA ESTABILIDAD DE VOLTAJE

La estabilidad del SEP se puede tratar como un único problema de gran importancia. Sin embargo, las diversas formas de inestabilidad que puede sufrir un sistema de potencia no pueden tratarse como una serie de dificultades sencillas debido a la complejidad y dimensión de los fenómenos de estabilidad [7], [10]. En este sentido, el análisis de estabilidad se facilita mediante la clasificación en categorías y subcategorías como se detalla en la Figura 1.7.

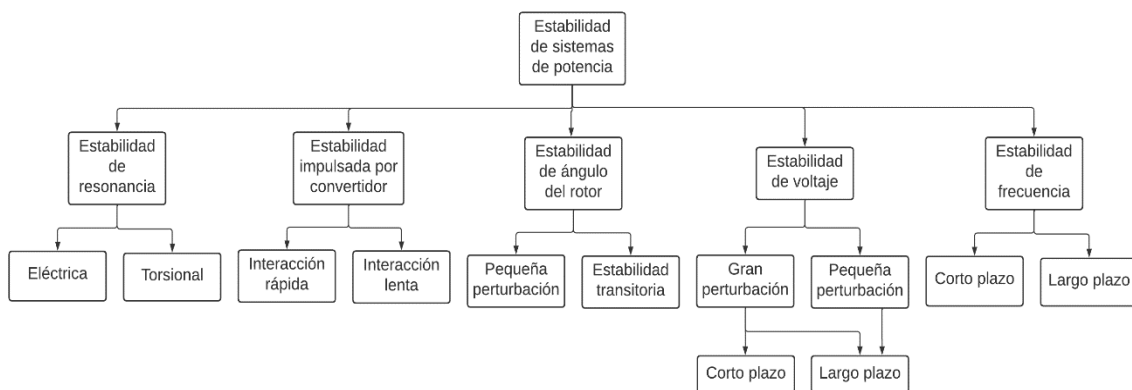


Figura 1.7. Clasificación de estabilidad de sistemas de potencia [7].

La clasificación de la estabilidad de sistemas de potencia se fundamenta en los siguientes aspectos [7], [10]:

- Naturaleza física de la inestabilidad.
- Tamaño de la perturbación (método de cálculo y predicción de estabilidad).
- Los dispositivos, procesos e intervalos de tiempo para evaluar la estabilidad.

1.3.2.1. Estabilidad de voltaje de gran y pequeña perturbación

La estabilidad de gran perturbación hace referencia a la capacidad del sistema para mantener voltajes estables después de una perturbación considerable como: cortocircuitos, contingencias en líneas de transmisión, pérdida de unidades de generación, aumento brusco de carga, entre otras. Tanto las características de la carga como las características del sistema determinan esta capacidad sobre la base de las interacciones de los controles y protecciones continuas y discretas del sistema [7].

El estudio de la estabilidad de voltaje ante grandes perturbaciones requiere determinar la respuesta no lineal del sistema de potencia durante un periodo de tiempo determinado, suficiente para identificar el desempeño de dispositivos importantes como: motores, limitadores de la corriente de campo del generador, cambiadores de taps de transformadores, etc. El periodo de estudio se puede extender desde unos pocos segundos hasta decenas de minutos [8], [11].

Por otro lado, la estabilidad de voltaje de pequeña perturbación hace referencia a la capacidad del sistema para controlar los voltajes después de pequeñas perturbaciones como incrementos sucesivos de carga. Dicha estabilidad está determinada por las características de la carga, controles continuos y discretos en un instante de tiempo determinado [11].

Las perturbaciones de estado estacionario son las que contribuyen especialmente a la inestabilidad de voltaje de pequeña perturbación. De esta manera, el análisis estático es efectivo para evaluar los márgenes de estabilidad, identificar factores que participan en la estabilidad y contrastar una amplia gama de condiciones del sistema para un gran número de escenarios post contingencia [8], [11].

1.3.2.2. Estabilidad de voltaje de corto y largo plazo

La estabilidad de voltaje de corto plazo involucra el comportamiento dinámico de las cargas de acción rápida como: motores de inducción, convertidores HVDC (High Voltage Direct

Current) y cargas controladas electrónicamente. El tiempo de estudio requerido está en el orden de los segundos y requiere la solución del sistema de ecuaciones diferenciales similar al usado para el análisis de estabilidad del ángulo del rotor. Además, la modelación dinámica de las cargas y el análisis de cortocircuitos cerca de las cargas son aspectos importantes para este tipo de estudio [11].

Mientras que, la estabilidad de voltaje de largo plazo implica equipos de acción lenta como: transformadores con cambiador de taps, limitadores de corriente del generador y cargas controladas termostáticamente. El tiempo de estudio requerido puede extenderse varios minutos y se requieren simulaciones a largo plazo para el análisis del rendimiento dinámico del sistema [11] [12].

1.3.3. MÉTODOS DE ANÁLISIS DE ESTABILIDAD DE VOLTAJE

La estabilidad de voltaje se ha convertido en el principal factor restrictivo dentro de la operación y planeamiento de los sistemas eléctricos de potencia. Por esta razón, los métodos de análisis de estabilidad de voltaje se clasifican en dos categorías: dinámicos y estáticos [13].

1.3.3.1. Métodos de análisis dinámico

Los métodos de análisis dinámico están fundamentados en la solución en el dominio del tiempo de ecuaciones diferenciales no lineales del sistema de potencia, utilizando herramientas de análisis de flujos de potencia y métodos de integración numérica. Las simulaciones en el dominio del tiempo son adecuadas porque establecen una cronología de los eventos que conducen a la inestabilidad de voltaje. Sin embargo, trabajar en el dominio del tiempo requiere un gran esfuerzo computacional y de ingeniería para establecer los resultados [14].

Asimismo, estas herramientas permiten evaluar el comportamiento del sistema en diferentes escenarios de operación, y principalmente, determinar el rendimiento y tiempo de respuesta de los elementos que componen el sistema de potencia. El análisis dinámico se aplica principalmente para el análisis de estabilidad de ángulo del rotor (estabilidad transitoria) [8], [13].

En este sentido, se presentan las ecuaciones (1.9) y (1.10), que representan las unidades de generación y los dispositivos dinámicos del sistema [8].

$$\dot{x} = f_d(x_d, V_d) \quad (1.9)$$

$$I_d = g_d(x_d, V_d) \quad (1.10)$$

Donde:

- x_d = Vector de estado de cada dispositivo
- I_d = Componentes R e I de la inyección de corriente desde el dispositivo hacia la red
- V_d = Componentes R e I del voltaje en la barra

De esta manera, las restricciones generales del sistema se componen de las ecuaciones diferenciales (1.9), las ecuaciones algebraicas (1.10) y la representación de la red, como se muestran en las ecuaciones (1.11) y (1.12).

$$\dot{x} = f(x, V) \quad (1.11)$$

$$I(x, V) = Y_N V \quad (1.12)$$

Donde:

- x = Vector de estado del sistema
- V = Vector de voltaje de barra
- I = Vector de inyección de corriente
- Y_N = Matriz de admitancias del nodo de red

Como se mencionó anteriormente, las ecuaciones (1.11) y (1.12) se pueden resolver en el dominio del tiempo, usando cualquier método de integración numérica (métodos implícitos o métodos explícitos) y métodos de análisis de flujos de potencia. El tiempo de estudio está definido en el rango de los minutos [8].

1.3.3.2. Métodos de análisis estático

Los métodos de análisis estático utilizan la información de una captura instantánea del sistema, considerando diferentes condiciones de operación y un rango de respuestas en el dominio del tiempo. En este rango de tiempos, las derivadas respecto al tiempo de las variables de estado (\dot{x}) de la ecuación (1.11) se asumen como cero. Por consiguiente, el análisis de las ecuaciones generales del sistema se reduce a un enfoque puramente algebraico, permitiendo el uso de técnicas de análisis estático [8], [14].

Los estudios de planeamiento y operación, sujetos a varias condiciones y contingencias del sistema, utilizan métodos estáticos para el análisis y la identificación de las causas de inestabilidad de voltaje [13]. En este sentido, existen diferentes técnicas de análisis de estabilidad de voltaje que se detallan en los siguientes apartados.

1.3.3.2.1. Flujos de potencia de continuación – Curvas PV

Los métodos de continuación se utilizan para trazar las curvas PV de sistemas de potencia dado un punto inicial de operación. Estos métodos también son empleados para determinar los límites de estabilidad en estado estacionario de un SEP. El límite de estabilidad está condicionado por la nariz de la curva PV que representa la máxima transferencia de potencia que el sistema puede manejar bajo condiciones preestablecidas [15].

Por otro lado, las restricciones del sistema, representadas por la ecuación (1.12), se pueden expresar linealmente mediante la ecuación (1.13). Sean ΔP , ΔQ , $\Delta \theta$ y ΔV variaciones incrementales en una barra específica de potencia activa, potencia reactiva, ángulo del voltaje y magnitud de voltaje, respectivamente [8], la ecuación (1.13) representa la sensibilidad existente a través de la matriz jacobiana.

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} J_{P\theta} & J_{PV} \\ J_{Q\theta} & J_{QV} \end{bmatrix} \begin{bmatrix} \Delta \theta \\ \Delta V \end{bmatrix} \quad (1.13)$$

En este sentido, el Jacobiano de la ecuación (1.13) se torna singular en el límite de estabilidad de voltaje. Los flujos de potencia convencionales tienen problemas de convergencia en condiciones operativas cercanas al límite de estabilidad. Sin embargo, los flujos de potencia de continuación superan este problema a través de la reformulación de las ecuaciones de flujos de potencia de tal manera que puedan permanecer correctamente condicionados para todos los posibles cambios de cargabilidad del sistema [8]. Además, la solución de estos métodos permite establecer la información necesaria para trazar tanto la zona estable como la zona inestable de la curva PV.

El principio básico del análisis de los flujos de potencia de continuación se fundamenta en un proceso iterativo de predicción y corrección como se muestra en la Figura 1.8, donde se utiliza un predictor tangente a la curva para predecir los voltajes ante un aumento adicional de carga. Por lo tanto, si la nueva carga estimada (D) sobrepasa la carga máxima de la solución exacta, se aplica un paso correctivo con voltaje fijo para encontrar la solución exacta (E) en la barra monitoreada. Entonces, el tamaño del aumento de carga debe reducirse gradualmente conforme las iteraciones del paso predictor se incrementan para

que se pueda alcanzar el límite de estabilidad y así determinar la carga máxima exacta del sistema [8], [15].

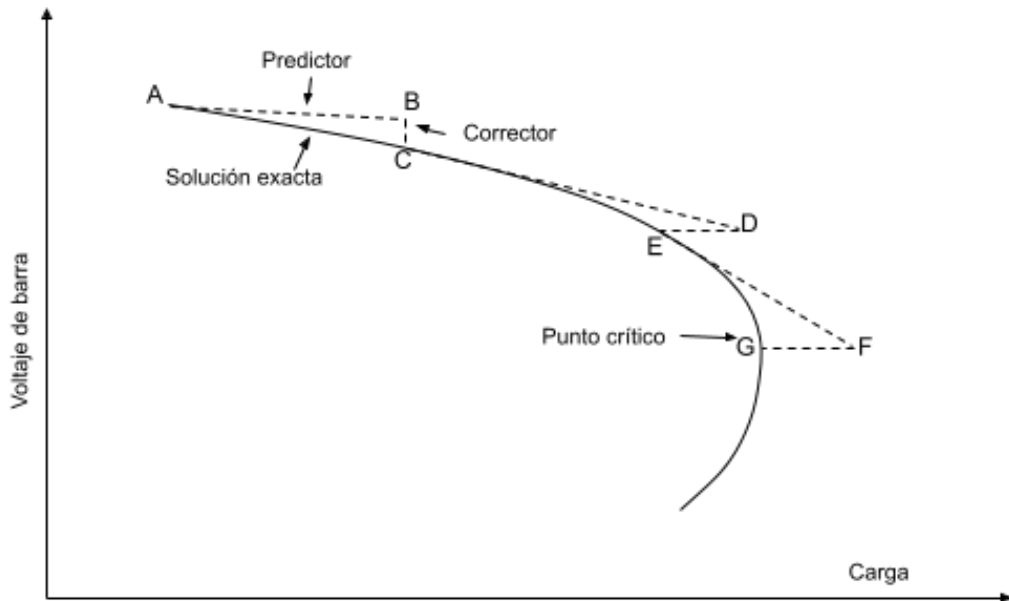


Figura 1.8. Proceso iterativo del flujo de potencia de continuación.

Las ecuaciones básicas que describen el método de continuación son similares a los análisis de flujos de potencia, con la única diferencia de la inclusión del parámetro de cargabilidad (λ) en el vector incremental de carga (K). En este sentido, las ecuaciones reformuladas del flujo de potencia, considerando el incremento de la generación como en la carga, se expresa en la ecuación (1.14) [8].

$$F(\theta, V) = \lambda K \quad (1.14)$$

Donde:

- λ = Parámetro de cargabilidad
- K = Vector que representa el incremento porcentual de la carga para cada barra
- V = Vector de magnitudes de voltaje de barra
- θ = Vector de ángulos de voltaje de barra

Las anteriores ecuaciones no lineales se pueden resolver al especificar un valor para el parámetro (λ). Cuando $\lambda = 0$ representa la condición de carga base y $\lambda = \lambda_{crítico}$ representa la carga crítica [8].

Por consiguiente, las ecuaciones reformuladas del flujo de potencia se expresan en la ecuación (1.15).

$$F(\theta, V, \lambda) = 0 \quad (1.15)$$

- **Paso predictor**

El paso predictor se aplica a través de una aproximación lineal con el propósito de estimar la siguiente solución, considerando un cambio en las variables de estado (θ, V, λ) . De esta manera, al tomar las derivadas de ambos lados de la ecuación (1.15), con las variables de estado en la solución inicial, se pueden establecer las ecuaciones lineales que se muestran en (1.16) [8].

$$[F_\theta \ F_V \ F_\lambda] \begin{bmatrix} d\theta \\ dV \\ d\lambda \end{bmatrix} = 0 \quad (1.16)$$

La inserción del parámetro λ a las ecuaciones de flujos de potencia proporciona una variable adicional al sistema de ecuaciones, y por esa razón, es necesario la formulación de una ecuación adicional para su respectiva solución. Entonces, para afrontar este problema se añade el valor de +1 ó -1 a una de las componentes del vector tangente. Además, se integra el vector fila e_k con todos los elementos igual a cero excepto por el $k^{\text{ésimo}}$ elemento correspondiente al parámetro de continuación como se muestra en la ecuación (1.17) [8].

$$\begin{bmatrix} F_\theta & F_V & F_\lambda \\ & e_k & \end{bmatrix} \begin{bmatrix} d\theta \\ dV \\ d\lambda \end{bmatrix} = \begin{bmatrix} 0 \\ \pm 1 \end{bmatrix} \quad (1.17)$$

Una vez encontrado el vector tangente, la predicción de la siguiente solución está dada por la ecuación (1.18), donde el subíndice "0" denota los valores iniciales de las variables de estado en el paso de predicción. Además, el tamaño del paso (σ) es elegido de tal manera que exista una solución del flujo de potencia con el respectivo parámetro de continuación. En el caso de que la solución no converja con el tamaño del paso elegido, se reduce este valor y el paso correctivo se repite hasta que se obtenga una solución exitosa.

$$\begin{bmatrix} \theta \\ V \\ \lambda \end{bmatrix} = \begin{bmatrix} \theta_0 \\ V_0 \\ \lambda_0 \end{bmatrix} + \sigma \begin{bmatrix} d\theta \\ dV \\ d\lambda \end{bmatrix} \quad (1.18)$$

- **Paso corrector**

En el paso corrector, la ecuación (1.15) se complementa a través de una ecuación que especifica la variable de estado seleccionada como parámetro de continuación, como se muestra en la ecuación (1.19) [8].

$$\begin{bmatrix} F(\theta, V, \lambda) \\ x_k - \eta \end{bmatrix} = [0] \quad (1.19)$$

En la ecuación anterior, x_k es la variable de estado seleccionada como parámetro de continuación mientras que η es igual al valor predicho de x_k . Cabe recalcar que el método de flujos de potencia Newton-Raphson puede ser utilizado para resolver este conjunto de ecuaciones [8]. De esta manera, la integración de x_k permite que el Jacobiano no sea singular en el punto crítico de operación y obtener la información necesaria para graficar la zona inestable de la curva PV.

La componente tangente de λ ($d\lambda$) es positiva en la parte superior de la curva, es cero en el punto crítico y es negativo en la parte inferior de la curva PV [8].

- **Selección del parámetro de continuación**

En el paso correctivo, es de suma importancia escoger adecuadamente el parámetro de continuación con el propósito de filtrar aquellas soluciones que divergen. El uso del parámetro de carga λ como parámetro de continuación puede producir una divergencia de la solución si la estimación excede la máxima carga establecida en el punto crítico de operación. Por otro lado, si la magnitud del voltaje se utiliza como parámetro de continuación puede producir una divergencia de la solución si se utiliza pasos considerables en el cambio del voltaje. Una buena práctica para evitar divergencias es utilizar el parámetro de continuación como la variable de estado con mayor grado de variación cerca de la solución dada [8].

1.3.4. MÉTODO DE MONTECARLO APLICADO A FLUJOS DE POTENCIA PROBABILÍSTICOS

La planificación y la operación de sistema de potencia, durante rutinas diarias, se fundamentan en los resultados del análisis y evaluación de flujos de potencia determinísticos. Dichos flujos de potencia utilizan valores específicos de potencia activa y reactiva de las unidades de generación y de las cargas para calcular el estado del sistema. Sin embargo, los criterios deterministas no responden ni reflejan la naturaleza probabilística o estocástica del comportamiento del sistema, de la demanda de los clientes o de las fallas

de los componentes. Además, con la integración de generación distribuida, resulta complicado que el enfoque determinístico permita analizar correctamente los sistemas de potencia modernos [16].

Entonces, para afrontar estos problemas, se pueden utilizar diferentes enfoques matemáticos para el análisis de la incertidumbre como el enfoque probabilístico, conjuntos difusos y análisis de intervalos. En el presente trabajo se emplea el enfoque probabilístico porque tiene una sólida base matemática y ha sido ampliamente utilizado en SEP para analizar la planificación a corto y largo plazo, estabilidad de voltaje, estabilidad transitoria, entre otras. Este enfoque se puede resolver numéricamente a través del método de Montecarlo o analíticamente mediante el método de convolución [17].

El método de Montecarlo es una herramienta de simulación que permite resolver flujos de potencia probabilísticos a través de sucesivos flujos de potencia determinísticos. Este procedimiento demanda un importante esfuerzo computacional debido a la cantidad de flujos de potencia que se deben realizar. El método de Montecarlo se fundamenta en dos características principales que son: la generación de números aleatorios (funciones de densidad de probabilidad para establecer las entradas) y el tipo de muestreo aleatorio (muestreo aleatorio simple, estratificado, entre otros). Un número elevado de simulaciones permite mejorar la fiabilidad de los resultados [18], [19].

En la Figura 1.9 se puede observar la clasificación de los métodos de resolución de flujos probabilísticos.

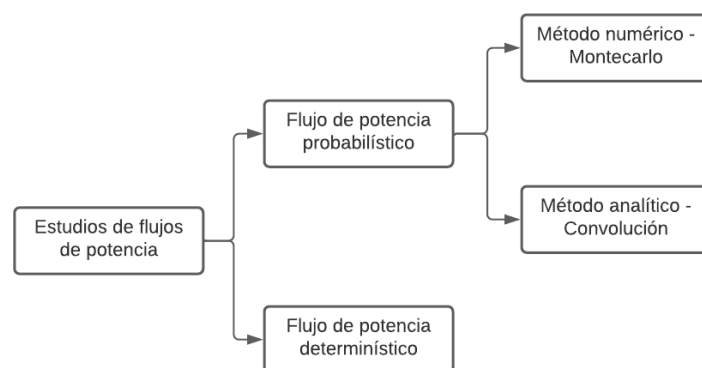


Figura 1.9. Enfoques para análisis de flujos de potencia probabilísticos [17].

Por otro lado, este método se puede utilizar en conjunto con la programación del despacho de potencia activa y reactiva de cada central de tal manera que se minimice el costo de operación y las restricciones cumplan con los límites establecidos. La capacidad de las máquinas sincrónicas y dispositivos de compensación, límites de seguridad y límites de estabilidad son las restricciones que generalmente se consideran al momento de plantar la

solución de flujos óptimos de potencia (OPF). Este problema se resuelve como parte del análisis del “Unit-commitment”, y consiste en la programación de despacho óptimo de unidades de generación en un tiempo determinado, sujeto a ciertas restricciones específicas [20], [21].

En este sentido, se presenta la ecuación (1.20) que representa la formulación matemática del problema de OPF.

$$\begin{aligned} & \text{Minimizar: } f(u, x) \\ & \text{Sujeto a: } g(u, x) = 0 \\ & \quad \quad \quad h(u, x) \leq 0 \end{aligned} \tag{1.20}$$

Donde u es el conjunto de variables de control del sistema; x es el conjunto de variables de estado; $f(u, x)$ es una función escalar que representa la función objetivo del sistema (costo total de generación, transferencia de potencia a través de un corredor de transmisión, costo total de compensación, entre otros), $g(u, x)$ es una función vectorial que contiene las ecuaciones de flujo de potencia y las restricciones de igualdad y $h(u, x)$ es el vector de restricciones de desigualdad. En efecto, los límites de flujos de potencia del estado basen y los límites de flujos de potencia del estado en contingencia son las restricciones convencionales del OPF. Sin embargo, existen propuestas para incluir los límites de estabilidad de voltaje, tanto en condiciones normales como en condiciones de contingencia, debido a la mayor precisión que presenta el límite al momento de evaluar la estabilidad de voltaje y sistemas de transmisión estresados [21].

1.3.5. CURVAS DE CAPACIDAD DE GENERADORES SINCRÓNICOS

Las máquinas sincrónicas son los elementos más importantes de un SEP debido a que son la fuente principal de potencia activa y reactiva. En un estudio de estabilidad de voltaje, los límites de capacidad de los generadores deben ser considerados con el propósito de simular la operación real de la máquina. En ese sentido, los fabricantes de las máquinas proveen las “curvas de capacidad” (capability curves), las cuales suelen estar determinadas a partir de los datos de placa, es decir, la información se entrega con base a su potencia máxima, expresada en MVA, con un nivel de voltaje y factor de potencia especificados [22], [23]. El funcionamiento de la máquina, dentro de su capacidad nominal, asegura una larga vida útil del elemento y alta confiabilidad de servicio. La curva de capacidad entregada por el fabricante considera también los límites térmicos de la máquina a partir del voltaje nominal y una resistencia de armadura que puede ser despreciable; mientras que el establecimiento de las zonas seguras de operación de los generadores debe considerar el estado actual de los componentes tanto eléctricos como mecánicos [22].

1.3.5.1. Límite por potencia máxima

La potencia activa máxima, considerando el esfuerzo mecánico de la máquina para mantener un equilibrio cinético, está determinada por la capacidad de la máquina motriz. Asimismo, este valor suele relacionarse con la potencia nominal del generador sincrónico, y, por tanto, con su factor de potencia nominal [24].

Este enfoque se expresa matemáticamente a través de la Ecuación (1.21) y en la Figura 1.10 se puede observar la gráfica de este límite.

$$P_{max} = S_{nominal} * f_p = P_n \quad (1.21)$$

1.3.5.2. Límite por potencia mínima

La potencia mínima está influenciada principalmente por la eficiencia y el esfuerzo mecánico de la turbina. Un claro ejemplo se demuestra en las centrales térmicas, donde la máquina opera eficientemente cuando trabaja a su potencia mínima y deficientemente cuando trabaja por debajo de la potencia mínima establecida. Cabe recalcar que los costos de operación son mayores cuando el generador trabaja por debajo del límite mínimo, dado que se requiere energía adicional para el proceso de enfriamiento del flujo de vapor [24].

En la Figura 1.10 se puede observar la gráfica de este límite.

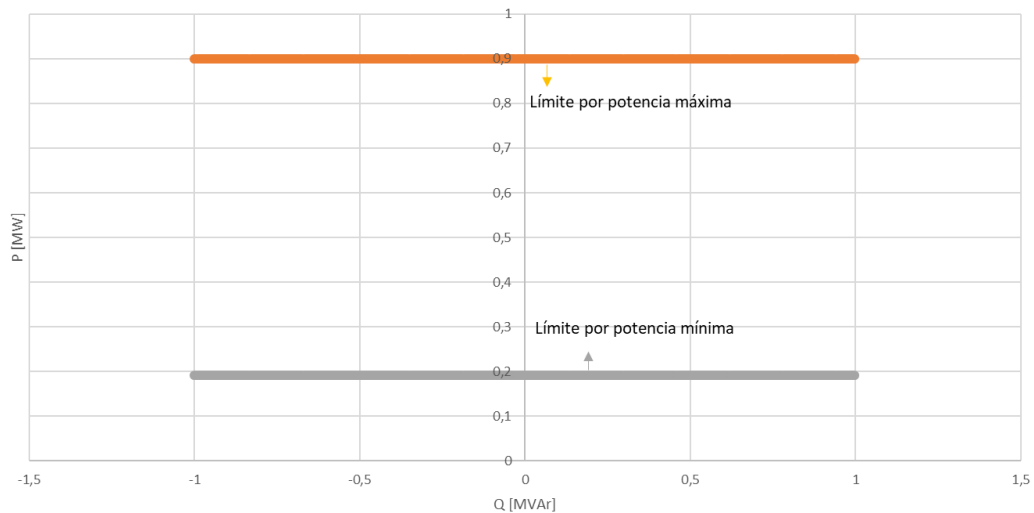


Figura 1.10. Límites de potencia máxima y mínima de un generador.

1.3.5.3. Límite por corriente de armadura

Este límite está asociado a las pérdidas debido a la resistencia del cobre del estator ($R_a I_a^2$). El control de estas pérdidas de potencia permite evitar el sobrecalentamiento de los

conductores y además establecer la corriente máxima que puede soportar el devanado de armadura [24]. El límite por corriente de armadura es una semicircunferencia con radio igual a la potencia nominal como se muestra en la Figura 1.11. La ecuación (1.22) permite graficar este límite con centro en el origen del plano P-Q, considerando (ϕ) como el ángulo del factor de potencia.

$$S = V_t I_t (\cos \phi + j \sin \phi) \quad (1.22)$$

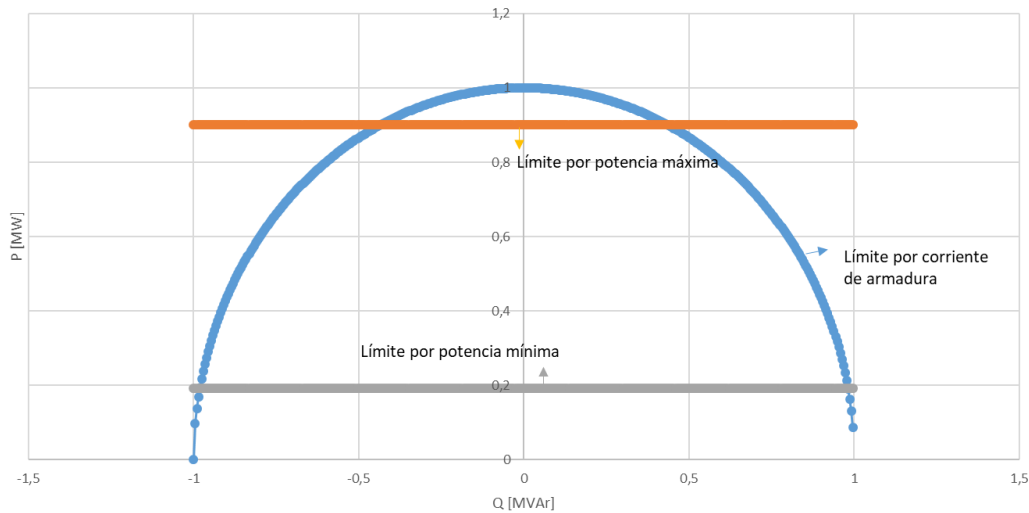


Figura 1.11. Límite por corriente de armadura.

1.3.5.4. Límite por corriente de campo

El límite por corriente de campo está asociado a las pérdidas de potencia debido a la resistencia del cobre del devanador del rotor ($R_{fd} i_{df}^2$). Entonces, para calcular la curva limitante máxima se tiene que considerar el voltaje interno máximo de la máquina, mientras que, para calcular la curva limitante mínima se tiene que considerar un porcentaje del voltaje interno máximo, generalmente 20 por ciento de este voltaje [24]. Los límites máximos y mínimo por corriente de campo se pueden calcular a partir de la expresión de transferencia de potencia reactiva presentada en la ecuación (1.23), cuando se conoce Q_{max} y Q_{min} .

$$Q = \frac{EV}{X_d} \cos(\delta - \theta) + \frac{V^2}{2} \left(\frac{1}{X_q} - \frac{1}{X_d} \right) \cos 2(\delta - \theta) - \frac{V^2}{2} \left(\frac{1}{X_q} + \frac{1}{X_d} \right) \quad (1.23)$$

Por consiguiente, en la Figura 1.12 se muestran los límites de corriente de campo máxima y mínima. Además, se puede observar que existe una intersección entre el límite por

corriente de campo máxima, el límite por corriente de armadura y el límite por potencia máxima, que está relacionada con la potencia aparente y el factor de potencia nominal.

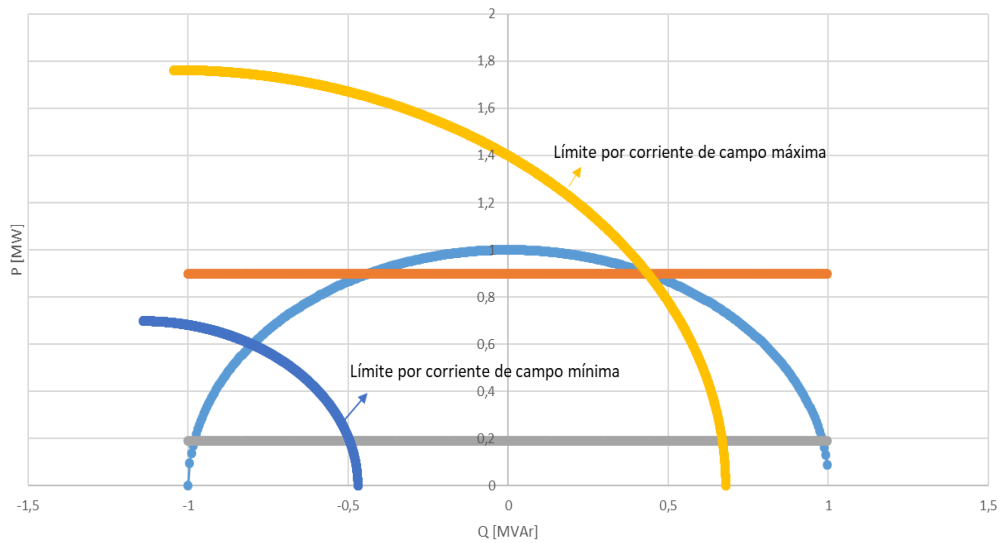


Figura 1.12. Límite mínimo y máximo por corriente de campo.

1.3.5.5. Límite por margen de estabilidad en estado estacionario

Los generadores sincrónicos poseen un rango de reserva de potencia que, cuando se encuentran operando en el punto máximo de la curva $P - \delta$, se conoce como el margen de estabilidad en estado estacionario [24]. Este efecto se puede apreciar cuando el generador se encuentra en la zona de subexcitación debido a que la curva de capacidad de transferencia de potencia tiene una menor amplitud, relacionada con bajos valores de voltaje de excitación, como se muestra en la Figura 1.13.




Figura 1.13. Margen de estabilidad en el plano P-delta [24].

Como se mencionó en apartados anteriores, garantizar apropiados márgenes de estabilidad en estado estacionario permite mantener en condiciones estacionarias de operación al sistema de potencia frente a cambios pequeños como variaciones de carga, cambios en la configuración del sistema, entre otros [24].

En la Figura 1.14 se muestra el lugar geométrico del límite de estabilidad en estado estacionario del generador sincrónico.




Figura 1.14. Límite por margen de estabilidad en estado estable.

1.3.5.6. Límite por voltaje de servicio auxiliares

Este límite se presenta en centrales de generación eléctrica donde parte de la generación de potencia activa y reactiva que entrega la máquina sincrónica es destinada a alimentar los servicios auxiliares (SSAA), además de ser una de las restricciones más severas en centrales termoeléctricas. Los equipos que componen los SSAA están calibrados para que operen dentro de un rango de voltaje, cuyas restricciones están dadas por un voltaje máximo y otro por voltaje mínimo [22].

Por estas razones, dichos servicios se consideran dentro de las zonas seguras de operación de los generadores sincrónicos. Sin embargo, para el presente trabajo de titulación, se omite la incorporación de dichos límites, debido al alcance propuesto y la suficiente información que proporciona el resto de las restricciones detalladas en los apartados anteriores.

1.3.6.1. Aprendizaje automático supervisado

El aprendizaje automático requiere un conjunto de datos de entrenamiento etiquetados para su modelación. Con la premisa de que, para cada conjunto de datos de entrenamiento, se tiene un objeto de entrada y un objeto de salida que permita al algoritmo predecir la función deseada para cualquier nuevo conjunto de datos [25]. Los algoritmos de aprendizaje supervisado se dividen en dos categorías que son: regresión y clasificación, como se muestra en la Figura 1.16.

1.3.6.2. Aprendizaje automático no supervisado

El aprendizaje automático no supervisado se basa en la recolección de un conjunto de datos que no se encuentran etiquetados. En este enfoque, se utiliza información que solo contenga entradas con el propósito de encontrar una estructura de los datos. Es decir, los algoritmos aprenden de los datos de prueba que no fueron previamente etiquetados o categorizados [25]. En el siguiente apartado, se explica uno de los algoritmos principales utilizados dentro del aprendizaje no supervisado que se conoce como análisis de componentes principales (PCA por su denominación en inglés).

1.3.6.2.1. Análisis de componentes principales (PCA)

Los algoritmos de aprendizaje no supervisado aplicados al tratamiento de información permiten adecuar la visualización, compresión y representación de los datos, mediante algoritmos de reducción de dimensionalidad. Uno de los métodos más utilizados se conoce como Análisis de Componentes Principales (PCA). Este análisis consiste en expresar los datos originales en un conjunto reducido de variables (combinaciones lineales) que no están correlacionadas estadísticamente entre sí. De forma general, este método se encarga de representar los datos iniciales en un nuevo subconjunto de características con una dimensión inferior a la original, manteniendo la mayor cantidad de información posible para explicar el modelo [27].

Una vez establecido el análisis de componentes principales, la elección del número óptimo de componentes se puede obtener mediante el método del codo y la variabilidad explicada (índice que muestra la proporción de la varianza del conjunto de datos que se encuentra a lo largo del eje de cada componente principal) [28].

En la Figura 1.17 se puede observar la curva que explica el número de componentes que se pueden elegir para reducir la dimensionalidad y obtener una variabilidad explicada por arriba del 90%.

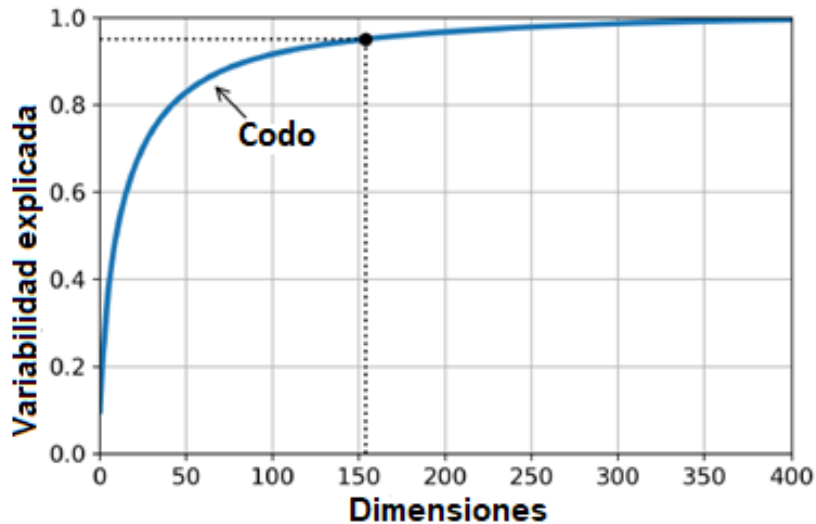


Figura 1.17. Variabilidad explicada en función del número de dimensiones [28].

1.3.6.3. Estructuración y validación de datos

El sobreajuste se conoce en el ambiente del aprendizaje automático como el resultado de probar el modelo con los mismos datos que se utilizaron en el entrenamiento. Este enfoque tendría métricas de rendimiento elevadas, pero sería inservible a la hora de predecir la función requerida. Dicho esto, la calidad y cantidad del conjunto de datos, durante el proceso de estructuración de un modelo de aprendizaje automático, es de gran importancia porque de ello depende una predicción precisa y la fiabilidad de los resultados [29]. La partición de datos de un modelo dependerá de la cantidad de información que se tenga y para ilustrar este procedimiento se muestra la Figura 1.18, donde se puede observar las dos formas de partición de datos según se requiera en la estructuración del modelo.

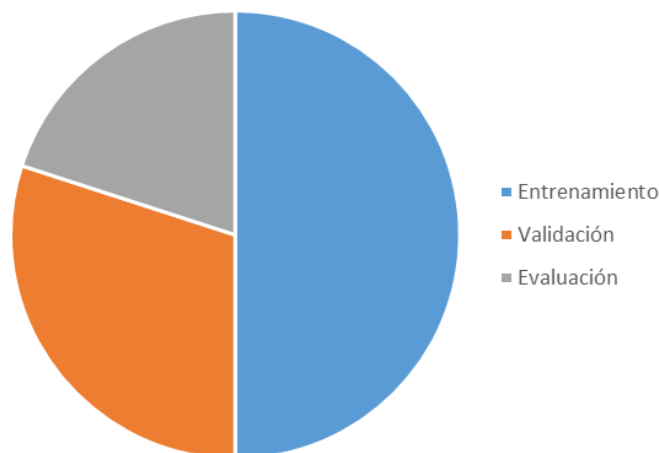


Figura 1.18. Esquema para partición del conjunto de datos

Con base en la Figura 1.18 y dependiendo de la cantidad de información que se vaya a utilizar para el modelo, se tiene la siguiente clasificación de los datos [29]:

- **Conjunto de datos para entrenamiento:** Este bloque de información ingresa al algoritmo de aprendizaje para su entrenamiento con el propósito de encontrar algún patrón o clasificación de acuerdo con los parámetros que se establezcan en el modelo.
- **Conjunto de datos para validación:** Este grupo de datos permite una validación del modelo antes de ser aplicado al conjunto de datos para prueba. La implementación de los datos de validación es importante para evitar el sobreajuste cuando el estimador trate de optimizar la predicción mediante una selección apropiada de sus hiperparámetros.
- **Conjunto de datos para prueba:** Permite evaluar finalmente la precisión de la predicción del modelo, considerando que la participación de los datos de entrenamiento y validación es nula en esta fase.

Con respecto a la validación de datos, se debe tomar en cuenta que, la división en tres conjuntos de datos, reduce drásticamente la cantidad de individuos que utiliza el modelo para su aprendizaje y, por lo tanto, los resultados pueden depender de una elección aleatoria entre el conjunto de entrenamiento y validación. Entonces para solucionar este problema, se puede aplicar un procedimiento conocido como Validación Cruzada (CV), donde el grupo de datos para validación no se toma en cuenta para realizar la evaluación final del modelo. El enfoque más básico se conoce como “k-fold” cuyo fundamento se basa en dividir consecutivamente subgrupos “k” en todo el conjunto de entrenamiento [29].

La Figura 1.19 explica de mejor manera el procedimiento adoptado por la validación cruzada.

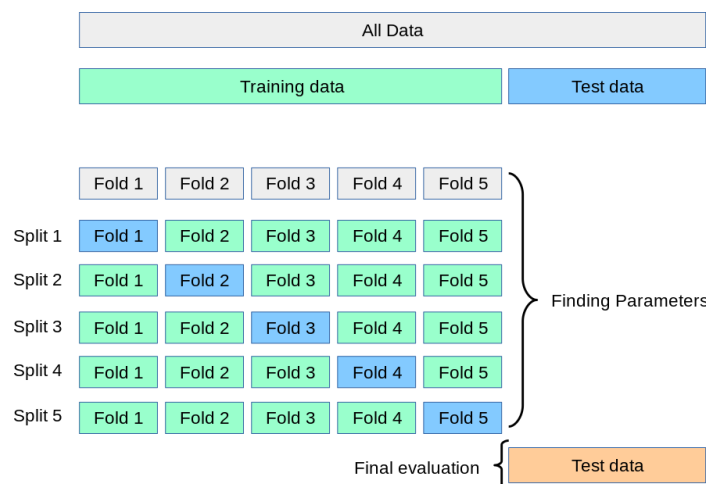


Figura 1.19. Ejemplo de la estructuración de la validación cruzada [29].

Tomando como referencia la figura anterior, para cada uno de los pliegues “k” se sigue el siguiente procedimiento:

- El modelo se entrena utilizando “k-1” de los pliegues como datos de entrenamiento.
- La validación del modelo se realiza con el restante de los datos.

De esta manera, la validación cruzada “k-fold” realiza la evaluación del modelo mediante una medida de rendimiento que se fundamenta en el promedio de los valores calculados dentro del bucle de validación. El esfuerzo computacional resulta un factor importante al momento de utilizar este enfoque por toda la cantidad de iteraciones que se realiza en el conjunto de entrenamiento, sin embargo, es la mejor opción para aprovechar la mayor cantidad de información durante la evaluación final del modelo.

1.3.6.4. Redes neuronales artificiales – ANN

Las redes neuronales artificiales se fundamentan esencialmente en la arquitectura paralela de los cerebros animales, no necesariamente humanos. Estas redes se conforman de unidades de procesamiento simples que permiten almacenar conocimiento experiencial para su posterior uso. Se caracterizan por los siguientes aspectos: el conocimiento se adquiere a través de un proceso de aprendizaje y las interconexiones entre neuronas (pesos sinápticos) permiten el almacenaje del conocimiento adquirido. Las redes neuronales se desempeñan mejor con el volumen y la velocidad de los datos, por lo que son ampliamente utilizados para escenarios de análisis en tiempo real [30], [31].

La arquitectura más simple de una red neuronal se conoce como “Perceptrón” y consta de una capa de entrada y una capa de salida y cada conexión de entrada está asociada con un peso como se muestra en la Figura 1.20 (a). Sin embargo, la estructura que generalmente se utiliza es el perceptrón multicapa y consta de una capa de entrada, una capa oculta y una capa de salida como se muestra en la Figura 1.20 (b).




Figura 1.20. Estructuras de redes neuronales artificiales: a) Perceptrón b) Perceptrón Multicapa [31].

Teniendo en cuenta la Figura 1.20 (b), las entradas (x_n) están conectadas a la neurona a través de pesos sinápticos en cada capa oculta, mientras que la suma (Σ), el sesgo (b_n) y la función de activación (θ) pertenecen al cuerpo de la red que permite obtener su posterior salida (Y_n). Por consiguiente, el número de capas y neuronas dependen de la aplicación; si se tiene un número reducido de neuronas ocultas, se crean menos subregiones y la red tiende a agrupar puntos en la misma salida, mientras que, si se tiene un gran número de neuronas, aumenta el riesgo de sobreajuste y disminuye el rendimiento generalizado. Entonces para garantizar que las particiones en cada capa oculta separen correctamente los datos, las redes neuronales se deben entrenar con los suficientes puntos de datos [31].

1.3.6.5. Máquina de soporte vectorial – SVM

Una máquina de soporte vectorial o SVM (Support Vector Machine) es un algoritmo de clasificación lineal que se utiliza en el ámbito del aprendizaje estadístico, la clasificación multiclase y las regresiones. Es un método que permite, dado un conjunto de muestras de entrenamiento, clasificar entre ejemplos positivos y negativos a través de la construcción de un hiperplano óptimo como superficie de decisión [32], [33]. Los patrones que utilizan estas máquinas para la clasificación se fundamentan en el diseño de una superficie de decisión para separar los diferentes niveles, utilizando vectores de soporte y márgenes, tal como se muestra en la Figura 1.21.




Figura 1.21. Ilustración de la separación lineal del SVM mediante el hiperplano [33].

En este sentido, SVM's son modelos robustos que funcionan correctamente con una variedad de conjuntos de datos de tal manera que permiten establecer límites de decisión simples o complejos a pesar de tener pocas características. Dicho esto, la máquina de soporte vectorial es útil para una variedad de aplicaciones en el mundo real, como la clasificación de imágenes (reconocimiento facial), la bioinformática, ciencias de la medicina, robótica, entre otras [26].

2. METODOLOGÍA

En el presente trabajo de titulación se estima el margen de estabilidad de voltaje de sistemas de potencia, a partir de la estructuración de una base de datos validada y el uso de modelos de aprendizaje automático disponibles en el lenguaje de programación Python. El procedimiento general para la estimación del margen estabilidad de voltaje se muestra en la Figura 2.1.

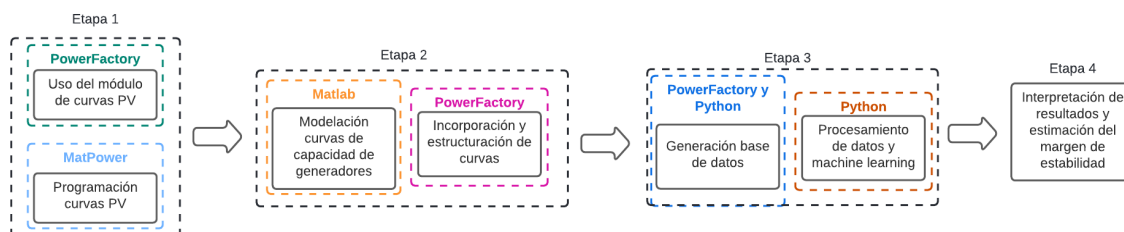


Figura 2.1. Procesos a seguir para la predicción del margen de estabilidad de voltaje.

Con base en la Figura 2.1, el proceso consta de las siguientes etapas:

Etapa 1: Se valida el módulo de curvas PV de PowerFactory mediante la información obtenida a través de Matpower.

Etapa 2: Se determinan las curvas de capacidad de los generadores mediante un script de Matlab para su posterior inclusión en PowerFactory.

Etapa 3: Utilizando los casos de estudio y modelos obtenidos en las etapas anteriores y flujos de potencia probabilísticos se genera la base de datos mediante el uso de Python y PowerFactory. Además, se desarrollan scripts de programación adicionales para la implementación de los modelos de aprendizaje automático y el tratamiento de la información.

Etapa 4: Mediante la base de datos de cada sistema de estudio en la Etapa 3 se interpretan y analizan resultados con el propósito de encontrar aquel algoritmo de aprendizaje automático que mejor se ajuste a la predicción del margen de estabilidad de voltaje.

2.1. ETAPA 1 – MATPOWER Y POWERFACTORY

El contraste de resultados entre las curvas PV de Matpower y PowerFactory permite establecer el sustento teórico-técnico para implementar la metodología del presente proyecto. Esta comparación se realiza para conocer qué tan cerca se puede llegar al codo de la curva PV mediante los algoritmos implementados en los dos programas de simulación. El sistema IEEE 14 barras se utilizará como caso de estudio.

2.1.1. EJEMPLO DE CÁLCULO CURVAS PV – POWERFACTORY

PowerFactory permite localizar el punto crítico de inestabilidad de voltaje, mediante el incremento de la demanda de potencia de las cargas seleccionadas por el usuario hasta que el cálculo del flujo de potencia no converja (límite de estabilidad). El software posee una interfaz gráfica que permite calcular y graficar fácilmente las curvas PV, tal como se muestra en la Figura 2.2.

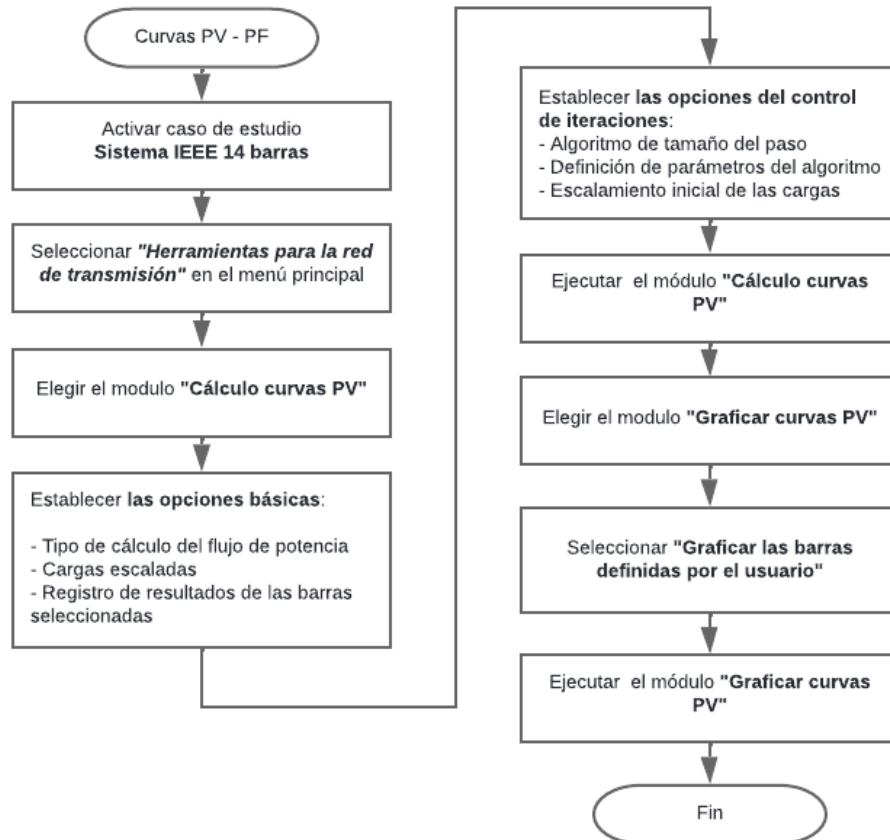


Figura 2.2. Procedimiento para calcular las curvas PV en PowerFactory.

La interfaz mencionada se encuentra disponible desde la versión de PowerFactory 2017. Si se requiere información adicional de los parámetros y funciones que posee el módulo de curvas PV, se puede revisar el manual de usuario de PowerFactory donde se tiene la información detallada para el control de las opciones básicas y de las iteraciones con el propósito de lograr un cálculo exitoso de las curvas [34].

De esta manera, se presenta la Figura 2.3 donde se muestra el resultado del cálculo de las curvas PV mediante el software PowerFactory.

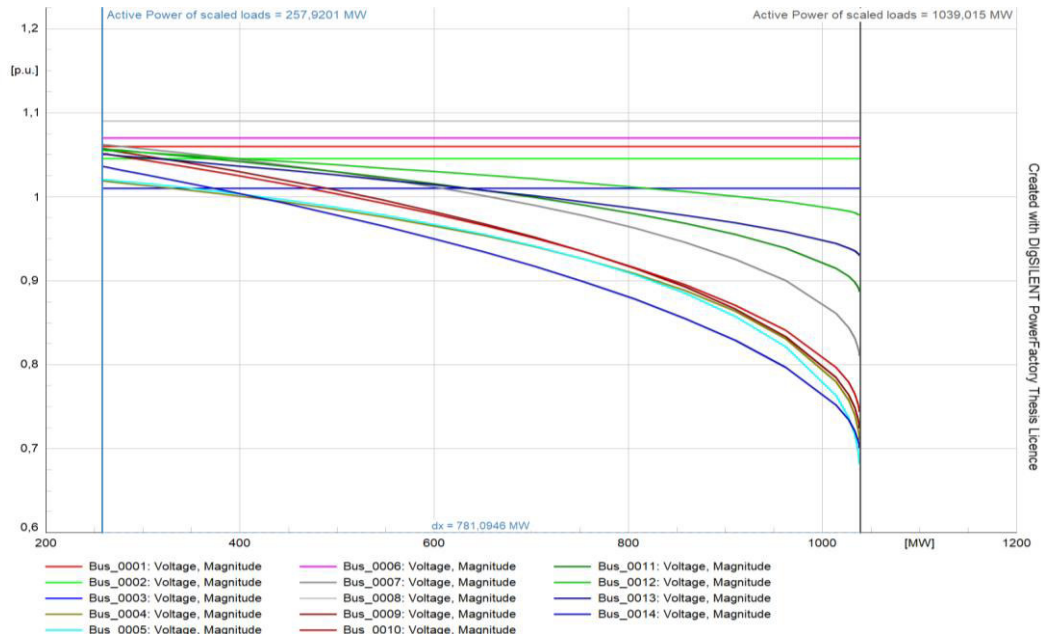


Figura 2.3. Curvas PV del sistema IEEE 14 barras en PowerFactory.

2.1.2. EJEMPLO DE CÁLCULO CURVAS PV – MATPOWER

Matpower es un paquete de simulación de Matlab que utiliza el método de continuación para trazar las curvas PV, dado un punto inicial de la curva. Este método utiliza los principios básicos de los flujos de potencia de continuación descritos en el marco teórico. Debido a que Matpower involucra el lenguaje de programación Matlab, en la Figura 2.4 se puede observar el diagrama de flujo para calcular y graficar las curvas PV del sistema IEEE 14 barras [15].

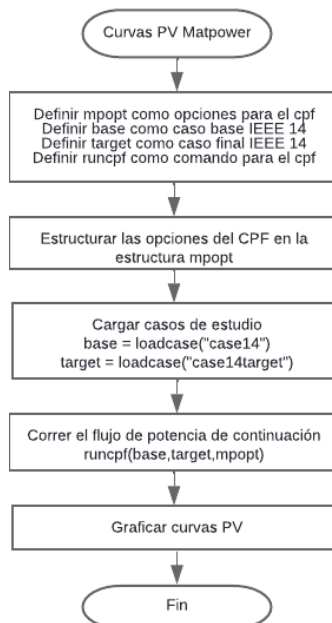


Figura 2.4. Diagrama de flujo de las curvas PV en Matpower.

Con esto en mente, Matpower ejecuta el flujo de potencia de continuación a través del comando **“runcpf”** con dos casos de estudio como sus dos primeros argumentos. El primero es el **“base”** que contiene el perfil de carga-generación base del sistema y el segundo es el **“target”** que contiene el perfil de carga-generación al que apunta el sistema. Los siguientes argumentos permiten incluir un set de opciones **“mpopt”**, una salida para guardar el nombre del archivo **“fname”** y los datos del caso resuelto **“solvedcase”**, esta estructura se puede observar en la Figura 2.5 [15].

```
%Opciones del cpf
mpopt = mption("cpf.parameterization", 3, "cpf.stop_at", 'NOSE');
mpopt = mption(mopt, "cpf.enforce_p_lims", 0, "cpf.enforce_q_lims", 0);
% Cargar casos bases y target
base = loadcase("case14");
target = loadcase("case14target");
results = runcpf(base, target, mopt);
```

Figura 2.5. Ejemplo de programación para ejecutar el cpf de Matpower.

Los casos de estudio se encuentran dentro de la base de datos del paquete de Matpower, donde su incorporación al programa se realiza a través del comando **“loadcase ()”**. Por lo tanto, los resultados del flujo de potencia de continuación se calculan con base en el parámetro λ , entonces para fines prácticos se debe realizar el cambio a potencia activa en [MW] mediante la ecuación 2.1.

$$p_{total} = (p_{load-final} - p_{load-inicial})\lambda + p_{load-inicial} \quad (2.1)$$

Donde:

- $p_{load-inicial}$: Potencia base total de las cargas en [MW].
- $p_{load-final}$: Potencia máxima total de las cargas en [MW].
- λ : Parámetro de continuación.

Todas estas funciones tienen nombres específicos, banderas de aviso, estructuras de programación y rangos de tolerancias que el software adopta durante la evaluación del flujo de potencia de continuación, por lo tanto, para obtener una información detallada de las funcionalidades de Matpower se puede revisar el manual de usuario en [15]. La estructura de opciones posee una amplia gama de parámetros que se pueden modificar según requiera el caso con el propósito de cumplir condiciones de igualdad al momento de la comparación del margen de estabilidad con el software PowerFactory.

Una vez realizado el cambio de los valores resultados a valores de potencia activa [MW], se procede a graficar las curvas PV como se muestra en la Figura 2.6.




Figura 2.6. Curvas PV del sistema IEEE 14 barras en Matpower.

2.1.3. COMPARACIÓN DE HERRAMIENTAS COMPUTACIONALES

Una vez establecidos los requerimientos importantes durante la evaluación y cálculo de las curvas PV, se presentan las características principales de cada software de simulación en la Tabla 2.1.

Tabla 2.1. Cuadro comparativo entre PowerFactory y Matpower para el cálculo de las curvas PV.

Parámetros	Power Factory	Matpower
Algoritmo de cálculo	<ul style="list-style-type: none"> • Flujo de potencia convencional iterativo. • Búsqueda binomial. • Algoritmo de paso adaptivo. 	Flujos de potencia de continuación.
Ingreso de datos del sistema	A través de una base de datos representada mediante una "grid".	Manualmente a través de matrices y archivos externos.
Graficar las curvas	La programación es interna y se realiza mediante el módulo "PV Curves Plot".	La ejecución de las curvas se comanda a través de funciones de programación.

Estructuración de opciones	Mediante selección manual dentro de la interfaz.	A través del lenguaje de programación de Matlab.
Consideración de curvas de capacidad de generadores	Se puede incluir la curva completa mediante objetos "IntQlim".	El ingreso de datos se realiza mediante matrices y solo por puntos específicos.
Tiempo de ejecución	Moderado para sistemas grandes.	Lento para sistemas grandes.
Versión	PowerFactory 2017 SP5.	Matpower 7.1.

La validación del procedimiento para cálculo de las curvas PV mediante PowerFactory se realiza usando Matpower, considerando el margen de estabilidad de voltaje como parámetro principal a analizar. Los resultados obtenidos de la Figura 2.3 y Figura 2.6 se presentan en la Tabla 2.2.

Tabla 2.2. Resultados de las curvas PV entre PowerFactory y Matpower.

Parámetros	Power Factory	Matpower
Potencia base total en [MW]	257.92	259
Potencia final total en [MW]	1039.02	1039
Margen de estabilidad en [MW]	781.23	778

El error relativo obtenido entre las mediciones correspondientes al estado inicial y al estado final del sistema es de 0.41%. Este resultado permite verificar que, efectivamente el procedimiento adoptado por PowerFactory, alcanza al límite de estabilidad y, por consiguiente, se lo usará como herramienta base para la generación de la base de datos.

2.2. ETAPA 2 – MODELADO DE LAS CURVAS DE CAPACIDAD

Como se detalló en los apartados anteriores, las curvas de capacidad permiten establecer las zonas seguras de operación de las máquinas sincrónicas. La incorporación de las curvas de capacidad de las unidades de generación permite efectuar un análisis más cercano a la realidad y representar correctamente la dinámica del sistema. En este sentido, las curvas de capacidad serán calculadas para todos los generadores que están presentes en el SNI reducido, con excepción del equivalente de Colombia. Dichas máquinas se muestran en la Tabla 2.3.

Tabla 2.3. Centrales del SNI reducido para cálculo de las curvas de capacidad.

Centrales de generación SNI	
Central Agoyán	Central Molino AB
Central Coca Coda Sinclair	Central Molino B
Central Daule Peripa	Central Pucará
Central Esmeraldas	Central San Francisco
Central Jaramijó	Central Sopladora
Central Manduriacu	Central Trinitaria
Central Mazar	Central Minas San Francisco

2.2.1. CÁLCULO CURVAS DE CAPACIDAD EN MATLAB

El enfoque descrito se aplica para los principales generadores del Sistema Nacional Interconectado reducido. El procedimiento para calcular las curvas de capacidad se efectúa a través de un script en Matlab cuyo procedimiento se muestra en el diagrama de flujo de la Figura 2.7.

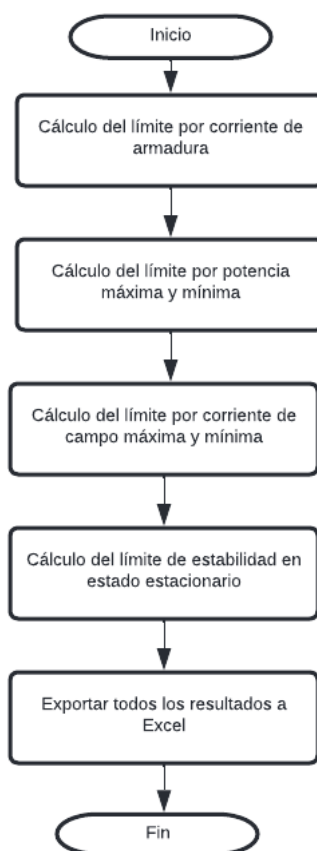


Figura 2.7. Diagrama de flujo para calcular las curvas de capacidad de generadores.

En primera instancia, se recopila la información de los parámetros principales de las máquinas. Luego, mediante programación en MATLAB, se determinan: los límites por potencia máxima y mínima con ecuación (1.21), límite por corriente de armadura con ecuación (1.22). La determinación de los límites por corriente de campo mínima y máxima requieren del uso de la función **“fsolve”** para encontrar el voltaje interno E_f de la máquina, mediante la resolución de las ecuaciones (2.2) y (2.3) que representan la potencia activa y potencia reactiva del generador, respectivamente.

$$P = \frac{E_f V_t}{x_d} \sin(\delta) + \frac{V_t^2}{2} \left(\frac{1}{x_q} - \frac{1}{x_d} \right) \sin(2\delta) \quad (2.2)$$

$$Q = \frac{E_f V_t}{x_d} \cos(\delta) + \frac{V_t^2}{2} \left(\frac{1}{x_q} - \frac{1}{x_d} \right) \cos(2\delta) - \frac{V_t^2}{2} \left(\frac{1}{x_q} + \frac{1}{x_d} \right) \quad (2.3)$$

Además, se utiliza la función **“fzero”** para calcular el ángulo de potencia de la máquina, igualando a cero la derivada de la ecuación (2.2). La implementación en Matlab requiere que se haga una suposición del valor inicial de las variables para tratar de resolver las ecuaciones involucradas, mediante la optimización de las opciones que se ingresa a la función **“fsolve”**. Mientras que, para la función **“fzero”**, simplemente se requiere un punto inicial para encontrar la raíz de la ecuación no lineal. Este procedimiento también se adopta para el cálculo del límite de margen de estabilidad en estado estable. Todas las ecuaciones de estos límites se programaron a través de identificadores de función que se conocen como “functions handles”. Dicho tipo de asociación adoptado por Matlab permite llamar a cualquier función sin importar la ubicación del programa principal y también incrementa la eficiencia de programación en el aspecto matemático.

Las funciones y sintaxis utilizadas para la implementación de las curvas de capacidad en Matlab se encuentra en [35].

2.2.2. INCLUSIÓN DE LAS CURVAS DE CAPACIDAD EN POWERFACTORY

La incorporación de las curvas de capacidad en PowerFactory se compone de dos procedimientos: el primer proceso consta en escoger los valores de potencia activa máxima y mínima ingresados previamente en el modelo de la máquina, mientras que el segundo proceso consta en ingresar los límites de potencia reactiva máxima y mínima mediante una serie de datos debidamente estructurados. Dentro del software, este segundo enfoque requiere de tres columnas de datos que son: la potencia activa (eje principal), la potencia reactiva mínima y la potencia reactiva máxima, todas en por unidad como se observa en la Figura 2.8.

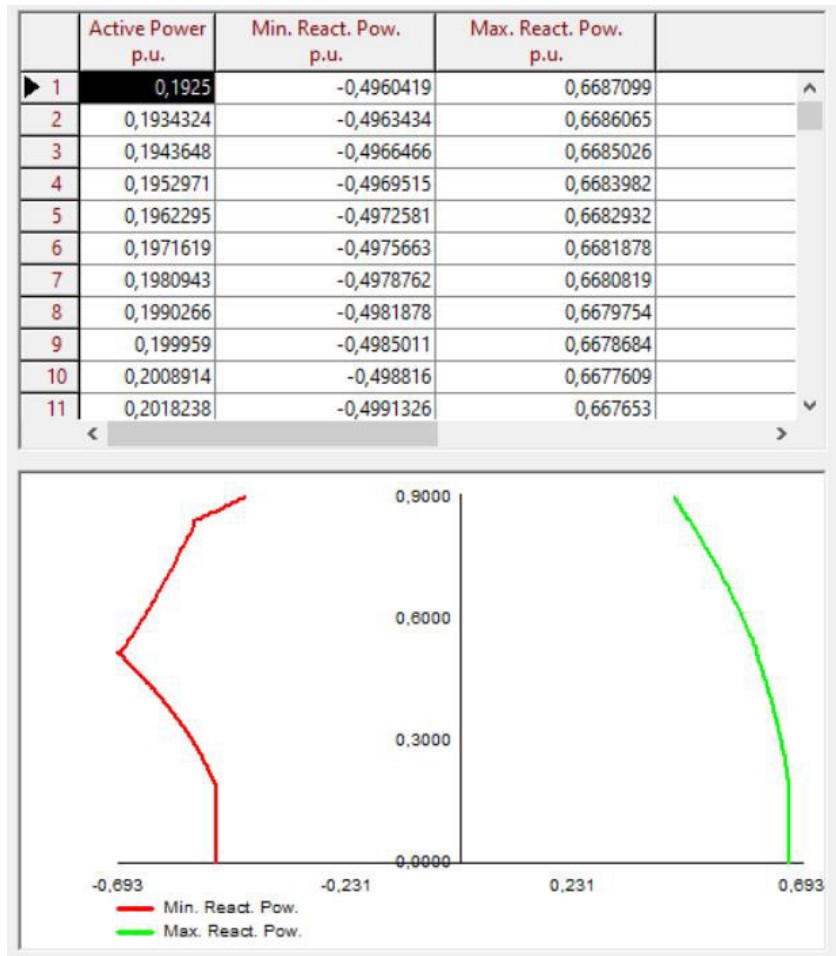


Figura 2.8. Ejemplo de límites máximos y mínimos de potencia reactiva de la central Coca Codo Sinclair.

Si bien los límites por potencia activa se establecen dentro del modelo de la máquina, en este caso simplemente sirven como referencia para crear los suficientes puntos de acuerdo con la cantidad de información que se tenga de los límites de potencia reactiva. Cabe recalcar que la cantidad de datos debe ser igual en todas las columnas y, por ende, mientras más datos existan, mayor será la precisión de los límites.

En este sentido, una vez calculados todos los límites operacionales se procede a la exportación de resultados en formato “.xlsx” mediante la función “*xlswrite ()*” [35], dicha exportación debe ajustarse de tal manera que cada punto de intersección entre los límites mínimos debe tener la misma cantidad de puntos en los límites máximos en el mismo punto de intersección. Es decir, la cantidad de puntos que se incluyan en cada curva dependerá del límite máximo por corriente de campo como se muestra en la Figura 2.9.

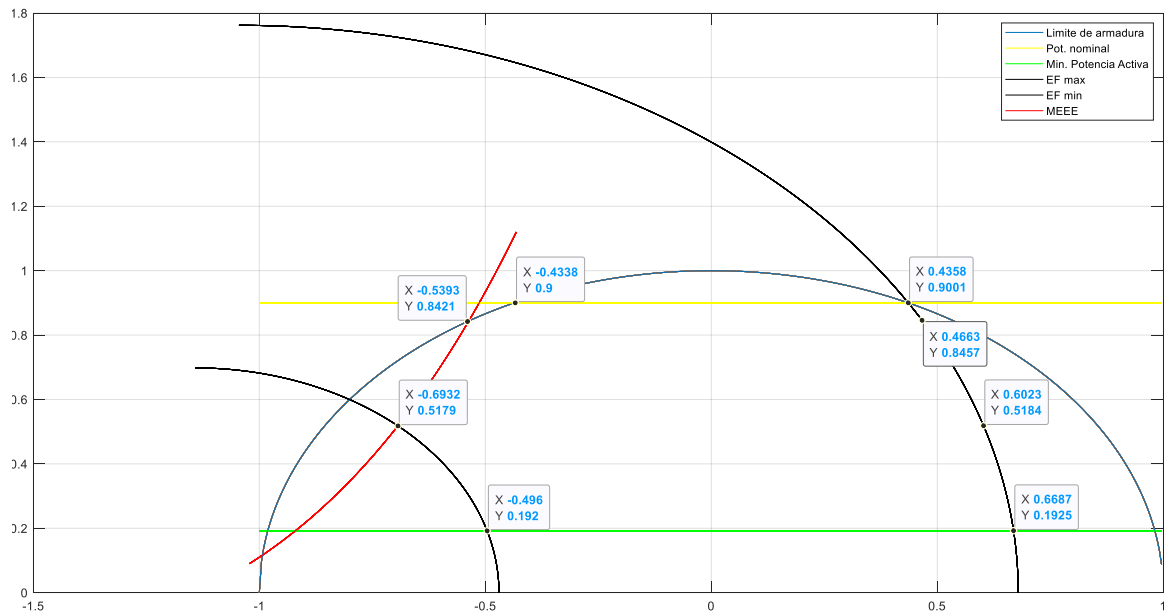


Figura 2.9. Curva de capacidad de Coca Codo Sinclair en Matlab.

Por consiguiente, dentro de la carpeta “Mvar Limit Curves” en la librería “Operational Library”, se pueden incluir una variedad de curvas de capacidad de acuerdo con los requerimientos del usuario, tal como se observa en la Figura 2.10. Cada objeto creado tiene una extensión “.IntQlim” que representa dichas curvas.

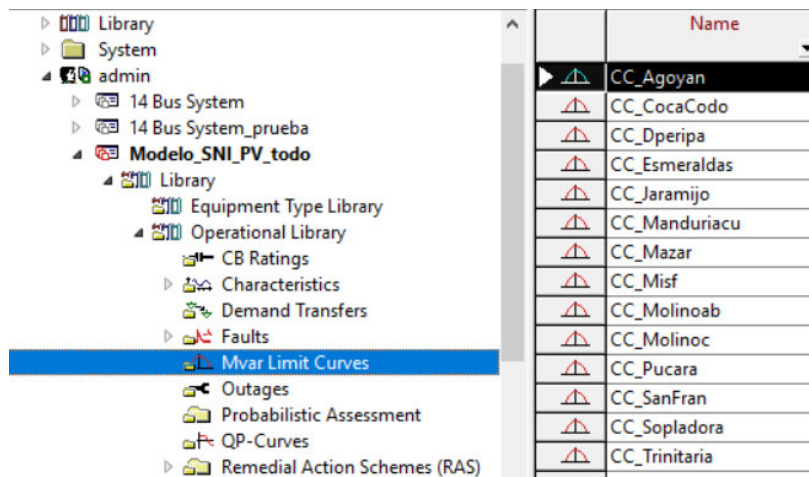


Figura 2.10. Archivos objetos de las curvas de capacidad del SNI.

Por último, para incluir las curvas en los generadores se debe ingresar dentro de la opción “Operational Limits” en la pestaña “Load Flow”, y escoger la curva correspondiente. Los límites por potencia mínima y máxima se incluyen al momento de elegir la curva porque estos valores se establecen dentro del modelo de cada máquina como se observa en la Figura 2.11.

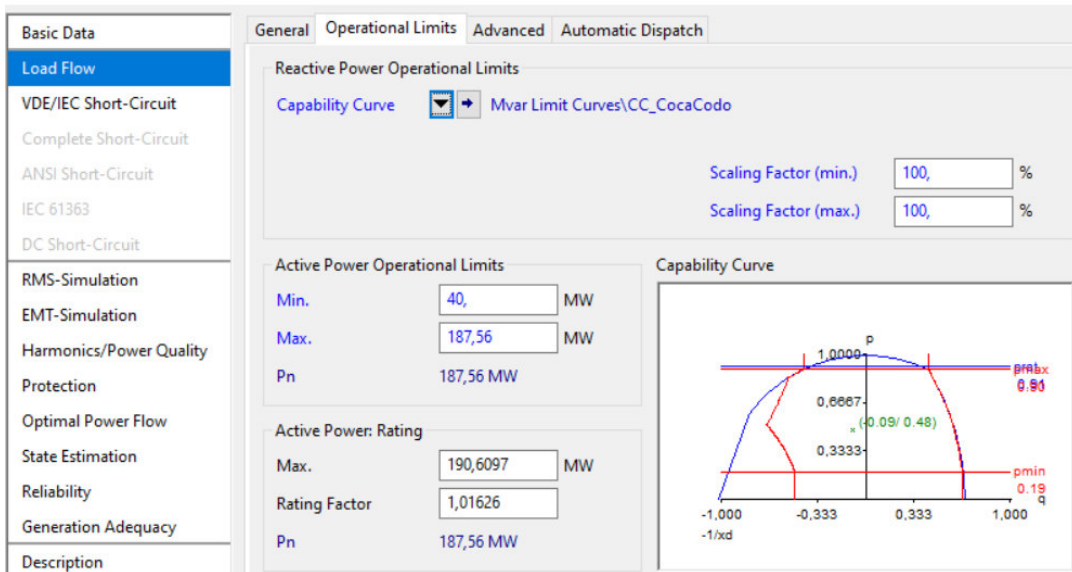


Figura 2.11. Ejemplo de la curva de capacidad completa de la central Coca Codo Sinclair.

2.3. ETAPA 3 – DESARROLLO PROGRAMA COMPUTACIONAL

El estudio técnico pretende estimar el margen de estabilidad de voltaje a partir de una base de datos validada, considerando algoritmos de aprendizaje automático. Los siguientes apartados detallan el procedimiento general que se desarrolló para la generación de la base de datos, el tratamiento de información y consideraciones para los algoritmos implementados.

2.3.1. ESTADOS OPERATIVOS Y BASE DE DATOS

La propuesta de simulación para este apartado se realiza mediante dos procesos separados. El primer proceso consiste en la generación de estados operativos estacionarios, considerando la probabilidad del comportamiento del sistema basada en flujos óptimos de potencia. El segundo proceso se encarga del cálculo del margen de estabilidad y recolección de información (base de datos).

2.3.1.1. Procedimiento para generar los casos operativos

El procedimiento para generar los casos operativos se fundamenta en la metodología de [36], donde se realiza la evaluación estocástica y gestión de riesgos de la estabilidad transitoria basada en la comunicación entre PowerFactory y Python. En este sentido, el enfoque que se adoptó para la generación de los escenarios operativos es el método de Montecarlo junto con la aplicación de flujos óptimos de potencia. Por un lado, el método de Montecarlo permite considerar la incertidumbre de la demanda, mientras que los flujos

óptimos de potencia se utilizan para obtener un despacho de las unidades de generación. Cabe recalcar que el uso de OPF frente a variaciones de carga permite solucionar el problema asociado a la congestión de las líneas de transmisión cercanas al generador oscilante cuando solamente se utiliza flujos de potencia.

En la Figura 2.12 se observa el procedimiento adoptado para la generación de estados operativos, donde los datos de entrada son: las curvas de capacidad de los generadores, los estados operativos en DlgSILENT Power Factory, los costos de generación de cada unidad y la estocasticidad de cada carga del sistema representada mediante funciones de probabilidad.

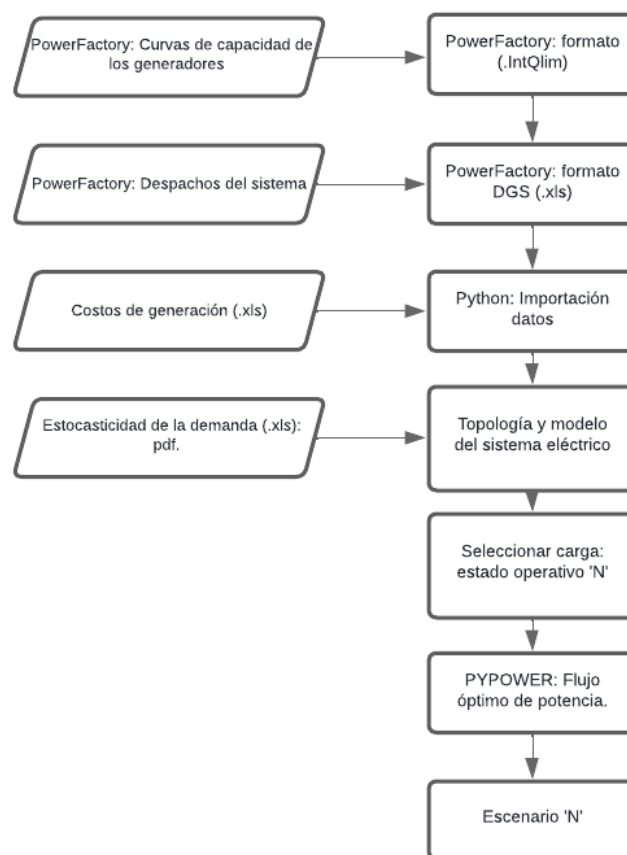


Figura 2.12. Diagrama de flujo para la generación de estados operativos [36].

Una vez que el sistema eléctrico se encuentre modelado en PowerFactory, se procede a exportar la información de la configuración de la red en formato DGS. DGS es la interfaz bidireccional estándar de PowerFactory que permite exportar resultados de cálculo para intercambiar datos con cualquier otro software en los formatos: ASCII, XML, Microsoft Excel o Microsoft Access [34]. Una de las principales ventajas de utilizar este formato es ejecutar simulaciones y análisis mediante aplicaciones externas (por ejemplo, a través de Python), considerando que también se puede realizar cambios operativos y topológicos en los sistemas de estudio.

Por consiguiente, para construir los sistemas de estudio en formato Pypower, se deben importar los formatos DGS en la interfaz de Python. De esta manera, se tiene la información completa del sistema de potencia con el fin de generar diferentes escenarios operativos (considerando datos estocásticos de la demanda) a partir de simulaciones de Montecarlo y flujos óptimos de potencia. La ejecución de este procedimiento desarrollado en Python se puede realizar directamente en PowerFactory o a través de una conexión externa que se conoce como “modo engine”, que permite controlar el programa sin la necesidad de que este abierto.

En la Figura 2.13 se muestra un ejemplo del resultado de la generación de estados operativos para el sistema IEEE 14 barras.

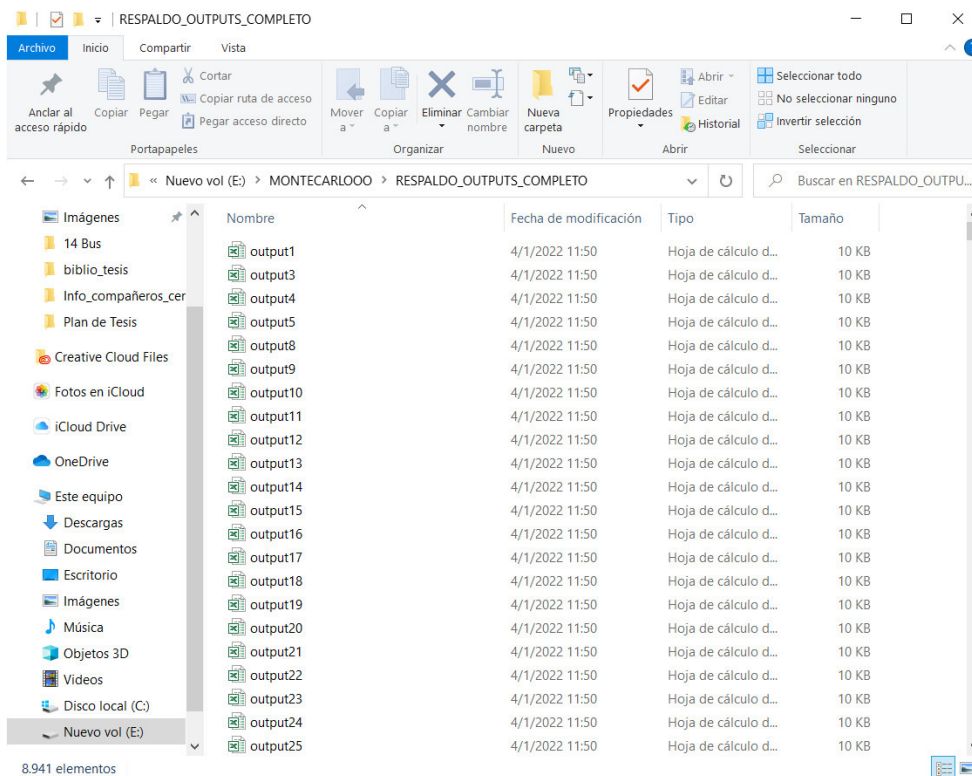


Figura 2.13. Ejemplos de estados operativos en formato DGS (.xls).

2.3.1.2. Procedimiento para establecer la base de datos

Una vez obtenidos los escenarios operativos en formato DGS, se procede a importar cada archivo a PowerFactory mediante bucles de programación. En cada iteración, el procedimiento consta en la recopilación de información del caso base cuando se ejecuta un flujo de potencia, caso pre-contingencia y el caso post-contingencia cuando se ejecuta el módulo de curvas PV. Toda esta información se guarda en variables diferentes con el propósito de evitar la superposición de datos.

El cálculo del margen de estabilidad de voltaje se realiza mediante la ecuación 2.5, como se muestra, a manera de ejemplo, en la Tabla 2.2.

$$ME = P_{final} - P_{inicial} \quad (2.5)$$

Donde:

P_{final} : Potencia activa total de las cargas en el punto de colapso en [MW].

$P_{inicial}$: Potencia activa inicial total de las cargas en [MW].

En este sentido, según el reporte de IEEE disponible en [37], el margen de cargabilidad se define como la diferencia entre la potencia activa en punto de colapso y la potencia activa inicial, por tanto, se expresa en MW y dicho criterio se adoptada para el presente trabajo de titulación. Sin embargo, si se requiere la normalización de dicho margen, para expresar en p.u. se puede hacer de las siguientes formas. Las más usadas, en su orden:

- Respecto de la potencia total en el punto de colapso (sugerido por IEEE) [37].
- Respecto de la potencia total inicial (implementado en varios softwares como se muestra en el documento acerca de las técnicas computacionales basadas en la bifurcación y los métodos de continuación para la evaluación y el control de la estabilidad de voltaje) [38].
- Respecto de una potencia base definida (poco usado).

Por consiguiente, para el caso de post-contingencia, se elige un conjunto (set) de líneas de transmisión para cada sistema de estudio, y de esta manera, mediante programación, se evalúa el criterio “n-1” al momento de ejecutar un flujo de potencia o el módulo de curvas PV. Es decir, si el flujo de potencia no converge con una línea de transmisión fuera de línea se procede a guardar ese estado operativo para su posterior registro en la base de datos, mientras que si el flujo de potencia converge se procede a ejecutar el módulo de curvas PV para guardar la información post-contingencia. Este procedimiento se repite hasta que se cubran todas las líneas de transmisión para todos los estados operativos ingresados en PowerFactory.

Por último, se guarda toda la información recopilada durante la ejecución del procedimiento en un archivo en formato “. pkl”. Estos archivos permiten el almacenamiento de resultados para que sean utilizados por otros programas de Python. El diagrama de flujo del proceso para generar la base de datos se presenta en la Figura 2.14.

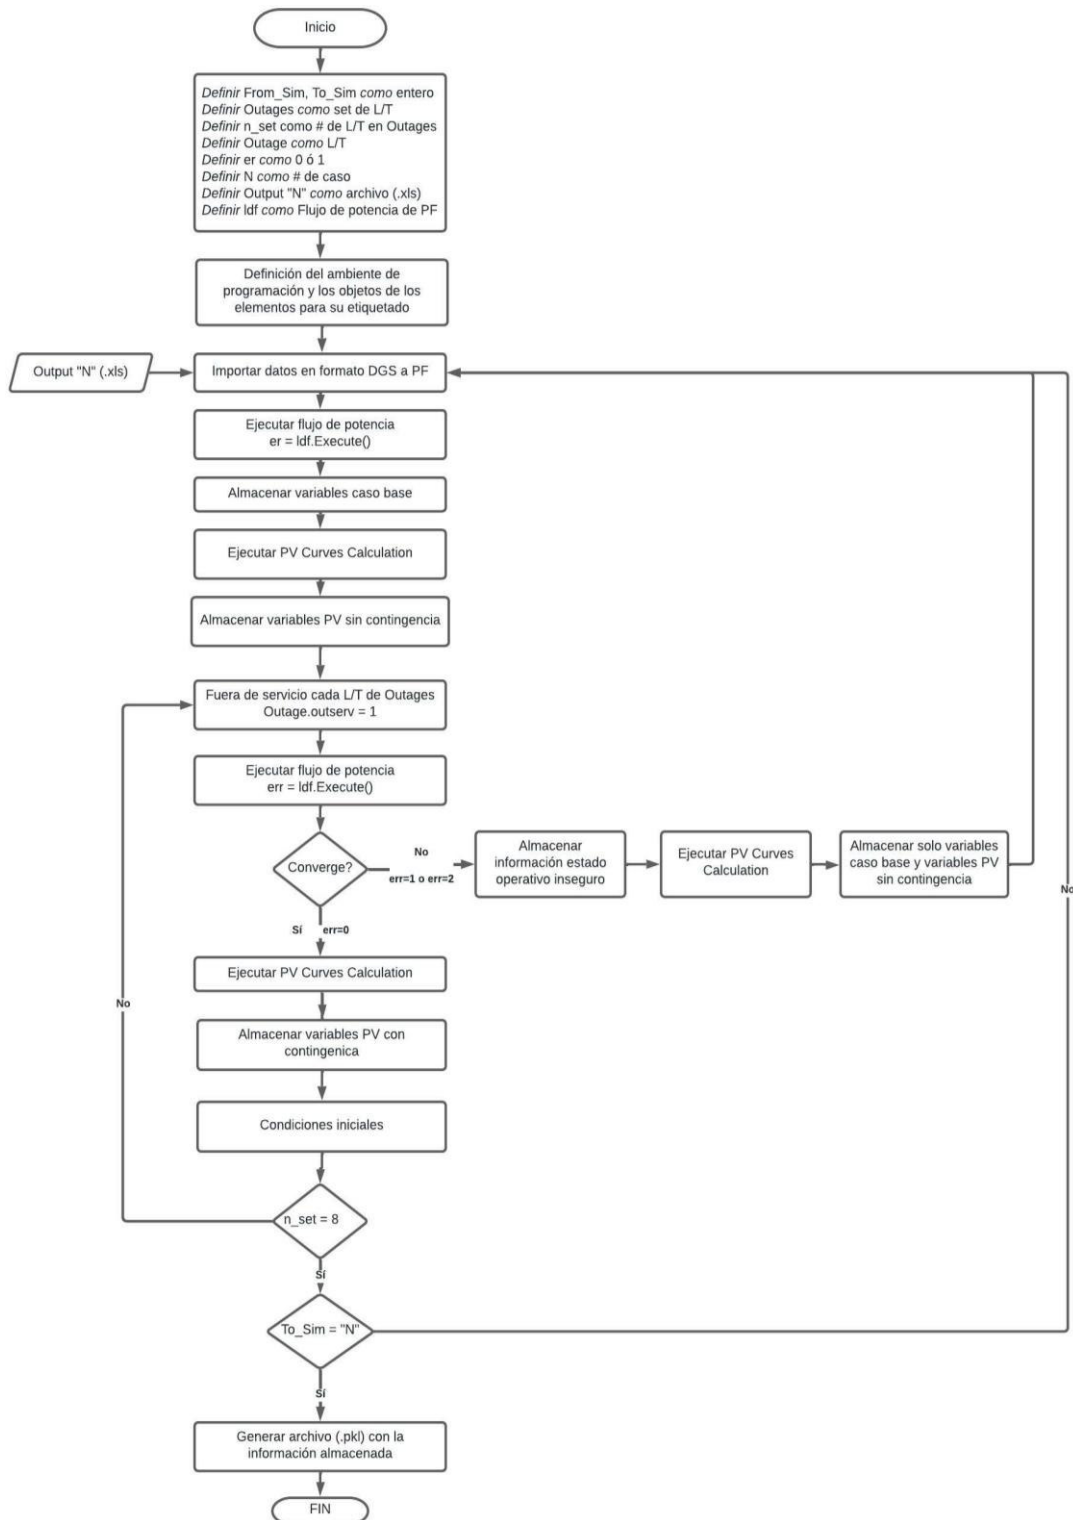


Figura 2.14. Procedimiento para la generación de la base de datos de los sistemas de potencia de estudio.

En el Anexo A se presentan los scripts relacionados a la generación de estados operativos (Probabilistic_part1) y el establecimiento de la base de datos (Probabilistic_part2), para la ejecución desde PowerFactory.

2.3.1.2.1. Selección de líneas de transmisión del sistema 14 barras IEEE

Se define un set de líneas del sistema de prueba con el propósito de controlar su salida y entrada en servicio durante el cálculo del margen de estabilidad. La selección se realizó considerando aquellas líneas de transmisión que se encuentra eléctricamente lejos de las unidades de generación; además de la experiencia de simulación y el sustento teórico/técnico que tienen todos los sistemas de prueba de PowerFactory.

En la Tabla 2.4 se muestran las líneas de transmisión que se escogieron para el sistema IEEE 14 barras.

Tabla 2.4. L/T escogidas para evaluación del margen de estabilidad.

L/T SISTEMA IEEE 14 BARRAS	
<ul style="list-style-type: none"> • L/T 0010-0011 • L/T 0012-0013 • L/T 0013-0014 • L/T 0006-0011 	<ul style="list-style-type: none"> • L/T 0006-0012 • L/T 0006-0013 • L/T 0009-0010 • L/T 0009-0014

La selección se ubica en el área de color verde que representa la zona de 33kV donde se puede observar la mayor cantidad de cargas del sistema. La Figura 2.15 muestra las L/T escogidas del sistema de prueba de acuerdo a los criterios adoptados.

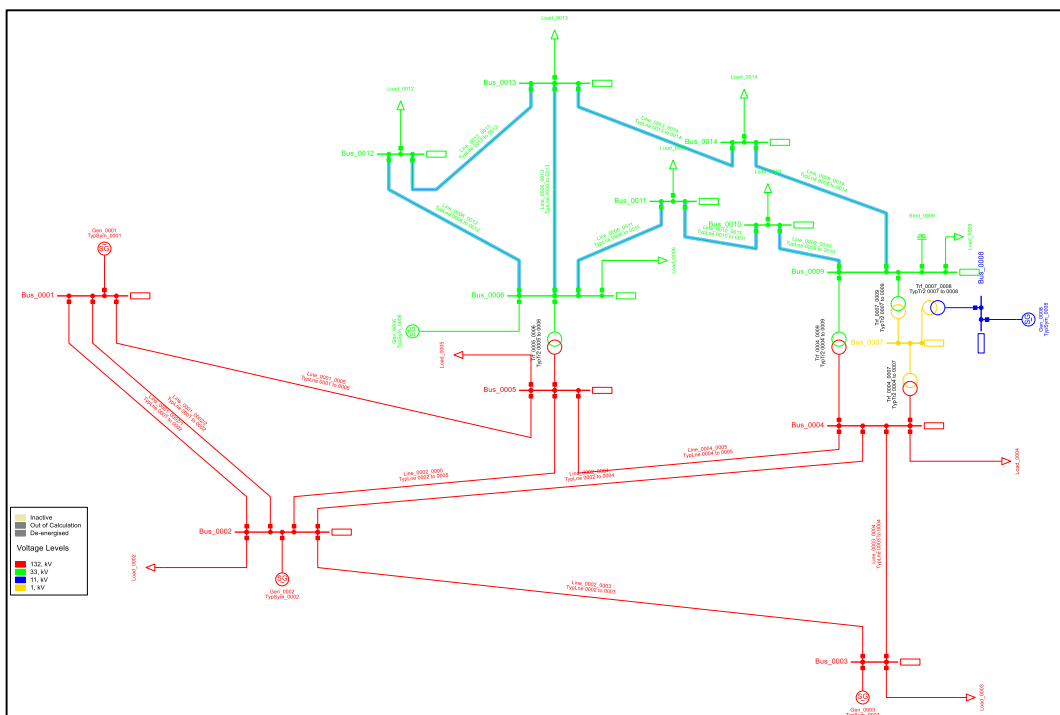


Figura 2.15. Selección de las L/T del sistema IEEE 14 barras.

2.3.1.2.2. Selección de líneas de transmisión del SNI

Se consideran, principalmente las L/T's en el área de la costa ecuatoriana como principal zona a analizar debido a los problemas de bajos voltajes que experimenta. De acuerdo al informe demostrado por CENACE en [39], donde se presenta las áreas definidas para control de voltaje en el SNI, y la experiencia operativa del sistema, se eligieron como L/T's a analizar las que se presentan en la Tabla 2.5. Además, dicha selección se establece con el propósito de comprobar el funcionamiento de la herramienta computacional, teniendo en cuenta que se puede modificar de acuerdo a estudios pre-establecidos.

Tabla 2.5. L/T escogidas para evaluación del margen de estabilidad.

L/T Sistema Nacional Interconectado	
<ul style="list-style-type: none"> • L/T CHOR_ESC_2_1 • L/T CHOR_PASC_2_1 • L/T CHOR_PASC_2_3 • L/T CHOR_TISA_5_1 	<ul style="list-style-type: none"> • L/T ESC_SOPL_230 • L/T MACH_MILA_2_2 • L/T MOLI_PASC_2_2

En la Figura 2.16 se presenta la delimitación del área de la costa en el SNI y por ende la zona donde se encuentran las líneas de transmisión escogidas para la evaluación del margen de estabilidad de voltaje.

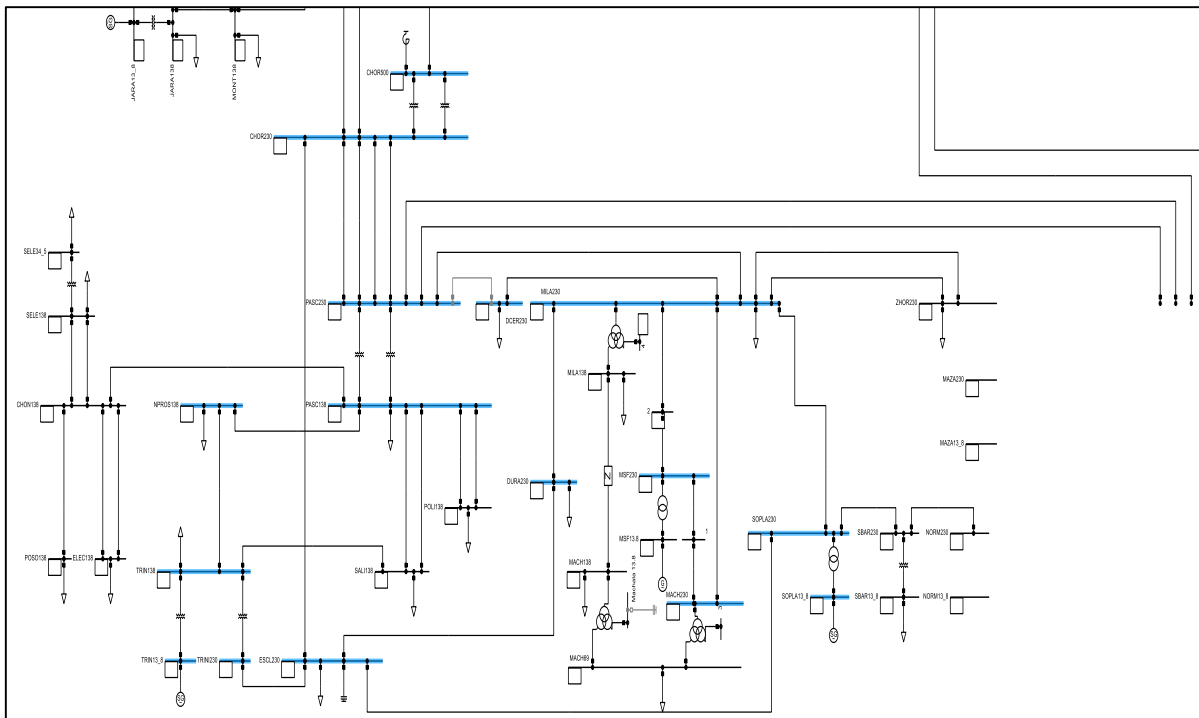


Figura 2.16. Selección de las L/T del SNI.

2.3.2. ESTRUCTURACIÓN Y PROCESAMIENTO DE DATOS

Una vez creados los archivos que contienen toda la información del caso base, caso pre-contingencia y post-contingencia, se procede a realizar un tratamiento y procesamiento de los datos para que puedan ser utilizados por las máquinas de aprendizaje automático. Todo este procedimiento se realiza en el ambiente de programación de Python, mediante el uso de las librerías que se presentan en la Tabla 2.6.

Tabla 2.6. Librerías utilizadas para machine learning.

Librería	Descripción
Numpy	Es una biblioteca utilizada para el manejo de matrices y vectores multidimensionales mediante funciones matemáticas de alto nivel.
Seaborn	Es una biblioteca de visualización que proporciona interfaces de alto nivel.
Pandas	Es una biblioteca para el análisis y manipulación de datos.
Matplotlib	Es una biblioteca para la generación y representación de gráficos.
Scikit learn	Es una biblioteca de aprendizaje automático y análisis de datos.

En la Figura 2.17 se presenta el diagrama de flujo del programa para la estructuración y procesamiento de datos.

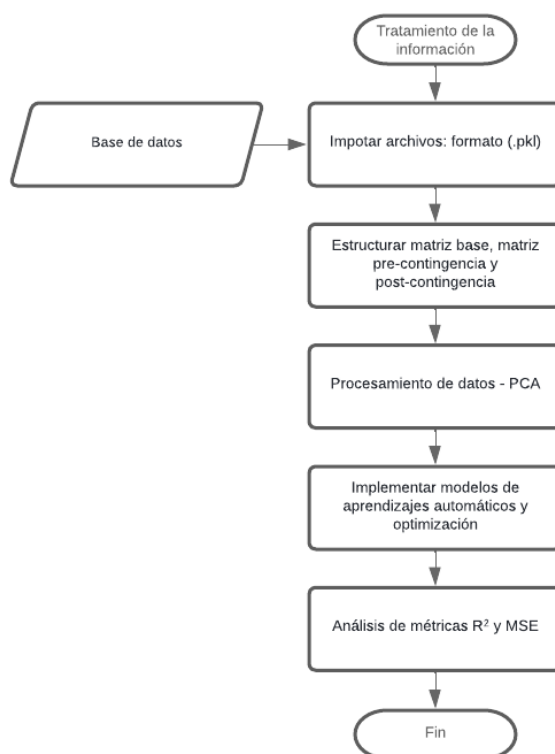


Figura 2.17. Diagrama de flujo para la implementación de los modelos establecidos.

2.3.2.1. Estructuración de matrices pre-contingencia y post-contingencia

La generación de base de datos es un proceso bastante extenso que requiere un esfuerzo computacional considerable, por esta razón se optó por dividir el conjunto de datos de tal manera que no sature de información al PowerFactory. Con esto en mente, se procede a cargar los archivos “. pkl” en el orden que fueron obtenidos con el propósito de estructurar la matriz pre-contingencia con el número de escenarios operativos establecidos (filas) y el número de variables consideradas (columnas).

Además, para el sistema IEEE 14 barras se consideran ocho líneas de transmisión y para cada una de ellas se debe extraer una matriz post-contingencia con el mismo número de filas que la matriz pre-contingencia. El mismo procedimiento se ocupa para el SNI y las siete líneas de transmisión elegidas.

El número de filas se estableció en 10 000 muestras para los dos sistemas de estudio, considerando que se aumentó la cantidad de escenarios operativos dado que algunos casos no convergieron durante la evaluación del OPF en cada iteración del algoritmo. Es decir, el número de iteraciones depende de la complejidad del sistema, experiencia durante el desarrollo de la metodología y la obtención de un conjunto de datos suficientemente representativo para aplicar correctamente las herramientas matemáticas. Mientras que, para las columnas de características, dependerán de las variables eléctricas seleccionadas y la magnitud del sistema o región que se esté analizando.

Las variables de entrada (como, por ejemplo: voltaje, corriente, potencia activa, potencia reactiva, cargabilidad) para el procesamiento de datos se constituyen dentro de la matriz pre-contingencia, mientras que las variables de salida (márgenes de estabilidad de voltaje) se seleccionan dentro de cada una de las matrices de líneas de transmisión. De esta manera, la única condición que debe cumplir el conjunto de datos para que exista coherencia, se refiere a que el número de muestras debe ser al menos 3 veces más grande que el número de características establecidas.

2.3.2.2. Procesamiento de datos

Existen variables del sistema que mantienen sus valores referencial constantes en cualquier escenario de operación, por esta razón se deben eliminar estas variables de la matriz general porque no aportan ningún aprendizaje durante el entrenamiento de la máquina de aprendizaje automático.

2.3.2.2.1. Índices estadísticos

Se utilizan métricas de análisis estadístico, disponibles en Python, con el propósito de inferir las relaciones existentes entre las variables de entrada y verificar la calidad de información obtenida durante las simulaciones tanto para el sistema de prueba como el SNI. Además, se consideran solo la magnitud de los voltajes de barra de cada sistema para obtener los principales estadísticos dado que el set de datos involucra diferentes dimensiones en características.

Los índices a obtener son los siguientes:

- Tanto la media como la mediana demuestran la existencia de valores extremos en todo el conjunto de datos. Si no existe una variación significativa entre estos índices, el conjunto de datos tiene escasos valores atípicos [40].
- La desviación estándar (std) permite explicar la variación existente de un conjunto de datos numéricos [40].
- El coeficiente de variación (cvar) utiliza la media como referencia de cálculo para demostrar la dispersión existente entre las variables involucradas. Un valor bajo de este índice demuestra que el conjunto de datos es homogéneo [40].
- El coeficiente de Kurtosis permite identificar si el conjunto de datos presenta un mayor grado de concentración (menor dispersión) o un menor grado de concentración (mayor dispersión). Los valores más pequeños (en magnitud) indican una distribución más plana y uniforme [40].
- El estadístico Skewness permite medir la falta de simetría en los datos. Valores grandes en magnitud de este índice, indican mayor simetría en la distribución de las observaciones. Un valor positivo denota que su cola se desvía hacia la derecha, mientras que un valor negativo indica que su cola se desvía hacia la izquierda. El coeficiente será cero cuando el conjunto de datos demuestre un comportamiento casi simétrico [40].

2.3.2.3. Implementación de los modelos de aprendizaje automático

Una vez establecidas las matrices pre-contingencia tanto para el sistema de prueba como para el SNI, se extrae la información respectiva del margen de estabilidad de voltaje post-contingencia para cada caso de línea de transmisión. Por consiguiente, se divide aleatoriamente en datos de entrenamiento y datos de prueba mediante la función “train_test_split”.

La Tabla 2.7 detalla los hiperparámetros adoptados para realizar este procedimiento.

Tabla 2.7. Hiperparámetros para generar los bloques de entrenamiento y prueba para los sistemas de estudio [29].

X_train, X_test, y_train, y_test = train_test_split(X, y_n, test_size=None, random_state=None)		
Hiperparámetros	Información	Dimensión o número
X	Matriz pre-contingencia después del PCA. Bloque de características.	10 000 filas 15 columnas
y_n	Matriz post-contingencia del margen de estabilidad de voltaje. Variable objetivo.	10 000 filas 1 columna
test_size	Porción que se extrae para los datos de prueba.	0.2
random_state	Controla la variabilidad aplicada a los datos antes de aplicar la división.	69

Los valores de los hiperparámetros establecidos en la Tabla 2.7 se utilizaron para los dos sistemas de estudio. Dada la consideración de ocho líneas de transmisión para el sistema IEEE 14 barras y 7 líneas de transmisión para el SNI, la matriz pre-contingencia “X” es igual para cada sistema y para cada máquina de aprendizaje que se implemente, mientras que la matriz post-contingencia “y_n” es diferente en cada caso porque se refiere al margen de estabilidad de voltaje cuando se evalúa la salida en operación de cada línea de transmisión.

2.3.2.3.1. Implementación de redes neuronales

Para este apartado se utiliza el regresor perceptron multicapa MLPRegressor disponible dentro de la clase red neuronal en la biblioteca “Scikit learn”. MLPRegressor permite entrenar el modelo de forma iterativa con el fin de actualizar los hiperparámetros iniciales en cada paso de tiempo donde se calculan las derivadas parciales de la función de pérdida (función utilizada para evaluar la desviación entre las predicciones realizadas y los valores reales).

Por lo tanto, se utiliza este modelo de red neuronal a partir de los hiperparámetros que se presentan en la Tabla 2.8.

Tabla 2.8. Hiperparámetros de la red neuronal [29].

MLPRegressor(hidden_layer_sizes=(100,),activation='relu',solver='adam',max_iter=200)		
Hiperparámetros	Información	Dimensión o número
hidden_layer_sizes	Representa el número de neuronas en la i-ésimo capa oculta.	(50,)
activation	Esta parámetro indica la función de activación de la capa oculta.	'relu'
solver	Indica el solucionador que se utiliza para la optimización del peso.	'adam'
max_iter	Número máximo de iteraciones.	1000

Los hiperparámetros anteriores no son los únicos que pueden ser modificados para implementar la red neuronal, simplemente son los más importantes a la hora de entrenar el modelo con el propósito de optimizar tiempo y resultados. Por consiguiente, se utiliza el método de validación cruzada para dividir los datos de entrenamiento y prueba mediante índices de entrenamiento y prueba. Es decir, cada pliegue “k” obtenido se utiliza para validación, mientras que los pliegues “k-1” restantes forman el conjunto de entrenamiento. El número de pliegues utilizados para la validación es de 10.

Por último, se procede a predecir el margen de estabilidad utilizando el conjunto de prueba y a su vez se calcula los índices MSE y R^2 para posteriormente analizar el modelo.

2.3.2.3.2. Implementación de máquina de soporte vectorial

El regresor que se implementa es el “SVR” el cual se encuentra dentro de la clase de máquinas de soporte vectorial en la biblioteca “Scikit learn”. Los únicos hiperparámetros que se encuentra libres en el modelo son C y epsilon, los demás tienen valores predeterminados que recomienda Python para su implementación.

Entonces, en la Tabla 2.9 se muestran los hiperparámetros que se utilizaron para estructurar la máquina de soporte vectorial

Tabla 2.9. Hiperparámetros para la máquina vectorial [29].

SVR(kernel='rbf', C=1.0, epsilon=0.1,)		
Hiperparámetros	Información	Nombre o número
kernel	Representa el tipo de núcleo que utiliza para el análisis de patrones.	'rbf'
C	Es el parámetro de regularización que necesariamente debe ser positivo.	1.0
epsilon	Indica el rango de error que se puede asumir durante la solución del modelo.	0.1

Los demás hiperparámetros se encuentran en la documentación de cada algoritmo de aprendizaje y pueden mantenerse constantes dado que son valores predeterminados que aseguran la puesta en funcionamiento de los modelos. De igual manera el cálculo de los índices de rendimiento se realiza en este modelo.

2.3.2.3.3. Optimización de los hiperparámetros

La optimización de los hiperparámetros (GridSearchCV en sus siglas en inglés) es un paso importante a la hora de encontrar los valores específicos con el cual el rendimiento del estimador es el máximo. Cabe recalcar que los hiperparámetros optimizados atraviesan una búsqueda de cuadrícula con validación cruzada.

De esta manera, en la Tabla 2.10 se encuentra los hiperparámetros ingresados en GridSearchCV para la red neuronal con el fin de encontrar los mejores valores de los coeficientes y, así optimizar los resultados y el tiempo de ejecución.

Tabla 2.10. Cuadrícula de hiperparámetros para la red neuronal [29].

GridSearchCV(estimator, param_grid*,cv=None)	
Hiperparámetros	Información
estimator	MLPRegressor
hidden_layer_sizes*	(50,50), (100,50)
activation*	'tanh', 'relu'
solver*	'sgd', 'adam'
alpha*	0.0001, 0.05
learning_rate*	'constant', 'adaptive'
cv	5

En la Tabla 2.11 se detallan los hiperparámetros ingresados en la máquina de soporte vectorial.

Tabla 2.11. Cuadrícula de hiperparámetros para la máquina de soporte vectorial [29].

GridSearchCV(estimador, param_grid*, cv=None)	
Hiperparámetros	Información
estimador	SVR
kernel*	'linear', 'rbf'
C*	1.5, 10
gamma*	1e-7, 1e-4
alpha*	0.0001, 0.05
learning_rate*	'constant','adaptive'
cv	5

Por consiguiente, se procede a estructurar la predicción optimizada a través de las funciones internas que se muestran a continuación:

- fit: Esta función permite ajustar el modelo SVM de acuerdo al conjunto de entrenamiento previamente dividido. “fit(X_train, y_train)”
- predict: Permite realizar la regresión para obtener las salidas deseadas a partir del conjunto de prueba previamente dividido. “predict(X_test)”

El tiempo de ejecución al momento de utilizar este tipo de optimizador dependerá del rango que se coloque de los hiperparámetros y la capacidad de resolución de cada modelo implementado. Los índices se calculan después de optimizar cada regresor con el propósito de verificar la maximización de su rendimiento.

2.4. ETAPA 4 - INTERPRETACIÓN DEL RESULTADOS

En esta última etapa se procede a analizar los resultados de las etapas 1, 2 y 3. La manera adecuada de medir el rendimiento de la máquina de aprendizaje es a través de índices de rendimiento tales como: el error cuadrático medio (MSE en sus siglas en inglés) y el coeficiente de determinación R^2 , disponibles en la base de datos de la biblioteca “Scikit-learn”.

La cantidad de información que se maneja en este tipo de aplicaciones requieren un análisis de datos bien estructurado debido a la complejidad de las correlaciones existentes entre las variables involucradas, por lo que, el resultado de la predicción de cada modelo

depende exclusivamente de la calidad de información que se obtenga y que tan bien se ajusta la máquina de aprendizaje al modelo de estudio.

Además, el tiempo de ejecución para la obtención de la base de datos puede resultar considerable debido a la cantidad de iteraciones que se realizan en PowerFactory y durante el manejo de información en Spyder. Sin embargo, mientras mayor sea la cantidad de escenarios operativos, mejor será la predicción del modelo debido a que puede aprender una gama extensa de situaciones no consideradas.

3. RESULTADOS Y DISCUSIÓN

En el presente capítulo se realiza una descripción detallada de los resultados obtenidos mediante la aplicación de la herramienta computacional en conjunto con la interacción entre Python y PowerFactory. El manejo y análisis de datos se realiza en el ambiente de programación de Spyder para facilitar el manejo de variables y funciones disponibles en la biblioteca “Scikit learn”. Además, para los modelos de aprendizaje automático se escoge una red neuronal y una máquina de soporte vectorial debido a que son las más utilizadas en el ámbito de machine learning y minería de datos.

La aplicación del programa computacional se realizó tanto en el sistema IEEE 14 barras como en el Sistema Nacional Interconectado reducido, con el fin de analizar el comportamiento del algoritmo adoptado en sistemas reales y la predicción del margen de estabilidad de voltaje.

Como resultado permite realizar la predicción del margen de estabilidad de voltaje de los sistemas de estudio con el propósito de disminuir el tiempo de cálculo del margen en comparación a un estudio en tiempo real mediante enfoques habituales tales como: curvas PV, flujos de potencia de continuación, análisis modales, entre otros. Además, se calcula los índices MSE y R^2 con el fin de analizar el rendimiento del modelo y su acoplamiento a las bases de datos previamente estructuradas.

3.1. CASO 1: SISTEMA IEEE 14 BARRAS

De acuerdo con lo indicado en apartados anteriores, las 8 líneas de transmisión seleccionadas que salen de servicio, generan 8 matrices post-contingencia con una columna que contienen la información de los márgenes de estabilidad, mientras que la matriz pre-contingencia contiene 106 columnas como se muestra en la Figura 3.1. Como se mencionó anteriormente, el número de filas o casos operativos se establece en 10 000 muestras para todas las matrices. Las variables de entrada que constituyen la matriz pre-contingencia para el procesamiento de datos son las siguientes:

- Magnitud y ángulo de voltaje en las barras.
- Potencia activa y reactiva de líneas de transmisión.
- Potencia activa y reactiva de generadores.
- Magnitud y ángulo de voltaje de generadores.
- Corriente y cargabilidad de las líneas de transmisión.

La variable de salida es el margen de estabilidad de voltaje que se guarda dentro de cada una de las matrices que genera la salida de cada línea de transmisión. De esta manera, la única condición que debe cumplir el conjunto de datos para que no existan problemas durante el entrenamiento del modelo, se refiere a que el número de muestras debe ser al menos 3 veces más grande que el número de características seleccionadas.

Nombre	Tipo	Tamaño
Margen_E_1	Array of float64	(10000,)
Margen_E_2	Array of float64	(10000,)
Margen_E_3	Array of float64	(10000,)
Margen_E_4	Array of float64	(10000,)
Margen_E_5	Array of float64	(10000,)
Margen_E_6	Array of float64	(10000,)
Margen_E_7	Array of float64	(10000,)
Margen_E_8	Array of float64	(10000,)
Resultado_precontingencia	DataFrame	(10000, 106)

Figura 3.1. Matriz pre-contingencia y matrices post-contingencia del sistema IEEE 14 barras.

En este sentido, la Figura 3.2 muestra un ejemplo del cálculo de las curvas PV de la barra crítica en un estado operativo, donde se puede observar que la curva de color rojo se obtiene antes de la contingencia, mientras que, la curva de color verde se obtiene después de la contingencia. Cabe recalcar que, la información de los márgenes que se observa en la Figura 3.1, se obtiene de la curva post-contingencia de color verde.




Figura 3.2. Ejemplo del cálculo de las curvas PV de la barra crítica antes y después de la salida de operación de la L/T 6-13.

De igual manera, la Figura 3.3 muestra otro ejemplo del cálculo de las curvas PV de la barra crítica en otro estado operativo, donde la curva roja y la curva verde tienen la misma representación del análisis de la Figura 3.2.




Figura 3.3. Ejemplo del cálculo de las curvas PV de la barra crítica antes y después de la salida de operación de la L/T 13-14.

3.1.1. RESULTADOS DEL PROCESAMIENTO DE DATOS

Como se mencionó anteriormente, existen variables dentro de la matriz pre-contingencia que no aportan información relevante a la hora de realizar el aprendizaje del modelo, como, por ejemplo, la magnitud y ángulo de voltaje de la barra slack, ángulo de voltaje del generador conectado a la barra slack, entre otros. Por esta razón, se realiza una depuración de las variables mencionadas, teniendo como resultado un total de 106 columnas de las 118 columnas iniciales. La aplicación de índices estadísticos y el análisis de componentes principales se presentan en los siguientes apartados.

3.1.1.1. PRINCIPALES ÍNDICES ESTADÍSTICOS

3.1.1.1.1. Caso base

Los índices estadísticos del conjunto de datos del caso base, después del Montecarlo y el flujo óptimo de potencia, se presentan en la Figura 3.4. Cabe recalcar que, para este análisis, se toma en cuenta solo la magnitud de los voltajes de cada barra debido a que el conjunto de datos posee 106 características.

Índice	mean	median	min	max	std	cvar	kurtosis	skewness
V_car_Bus_0001	1.13252	1.1491	0.855795	1.15	0.0228506	0.0201767	5.16469	-1.50939
V_car_Bus_0002	1.10845	1.11212	0.87749	1.15	0.0245204	0.0221213	5.01747	-1.31922
V_car_Bus_0003	1.05352	1.08502	0.849997	1.15	0.0818831	0.0777231	0.476913	-1.21194
V_car_Bus_0004	1.08058	1.09364	0.858517	1.14014	0.0376709	0.0348617	2.61963	-1.59742
V_car_Bus_0005	1.09015	1.09861	0.860331	1.13621	0.028893	0.0265037	5.07988	-1.89174
V_car_Bus_0006	1.13822	1.15	0.885172	1.15	0.0282806	0.0248464	15.2261	-3.47783
V_car_Bus_0007	1.10364	1.11568	0.859977	1.15	0.0398985	0.0361518	3.68845	-1.75086
V_car_Bus_0008	1.11243	1.11908	0.856437	1.15	0.0372756	0.0335082	4.02854	-1.59484
V_car_Bus_0009	1.1069	1.11902	0.856219	1.15	0.0439308	0.0396882	4.02393	-1.8044
V_car_Bus_0010	1.10596	1.11764	0.85128	1.15	0.0418765	0.0378646	4.51943	-1.9015
V_car_Bus_0011	1.11824	1.12952	0.867563	1.15	0.0345001	0.030852	7.81074	-2.50318
V_car_Bus_0012	1.12076	1.13035	0.850014	1.15	0.0327434	0.0292155	11.1057	-2.87461
V_car_Bus_0013	1.11487	1.12528	0.85	1.15	0.0351691	0.0315455	9.41528	-2.65823
V_car_Bus_0014	1.08955	1.10149	0.849999	1.15	0.0485686	0.0445766	3.70954	-1.66524

Figura 3.4. Principales estadísticos de la magnitud de los voltajes de barra en el caso base.

Los resultados de la figura anterior, permiten dar a conocer el punto inicial desde el cual parte el módulo de curvas PV en los siguientes apartados. Además, se puede observar que el valor máximo se establece en 1.15 p.u. y el valor mínimo se establece en 0.85 p.u., esto se debe a que, en la configuración del control de voltaje de todas las barras del sistema en PowerFactory, se mantiene por defecto un ΔV de $\pm 15\%$ del voltaje deseado (1 p.u.) como se observa en la Figura 3.5.

Terminal - Grid\Bus_0001.ElmTerm

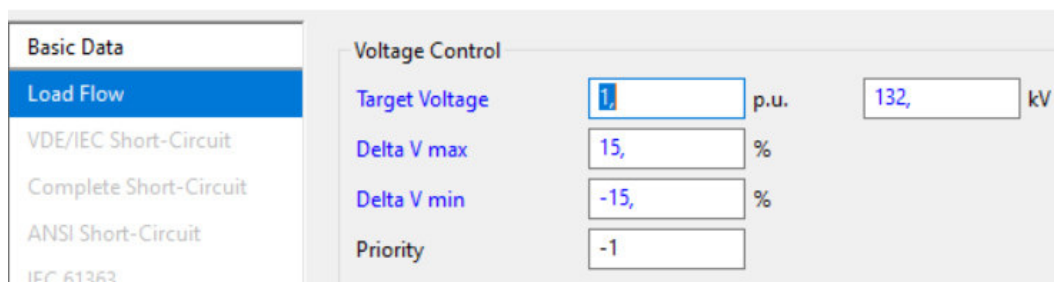


Figura 3.5. Opciones del control de voltaje de la barra 1.

3.1.1.1.2. Caso pre-contingencia

Por otro lado, en la Figura 3.6 se presentan los índices estadísticos para el análisis de la matriz pre-contingencia en la última iteración del módulo de curvas PV.

Índice	mean	median	min	max	std	cvar	kurtosis	skewness
V_car_max_Bus_0001	1.13252	1.1491	0.855795	1.15	0.0228506	0.0201767	5.16469	-1.50939
V_car_max_Bus_0002	1.01954	1.00831	0.812609	1.14863	0.0443409	0.043491	0.55696	0.679605
V_car_max_Bus_0003	0.869196	0.860494	0.625679	1.15	0.133955	0.154114	-1.24123	0.217943
V_car_max_Bus_0004	0.886656	0.891005	0.571254	1.07848	0.0611368	0.0689521	2.25354	-0.907932
V_car_max_Bus_0005	0.920481	0.927768	0.639406	1.08362	0.0563714	0.0612412	2.6195	-1.21317
V_car_max_Bus_0006	0.936416	0.92536	0.638128	1.15	0.0989374	0.105655	0.0139686	0.504311
V_car_max_Bus_0007	0.870922	0.867235	0.634487	1.13156	0.0686474	0.0788215	-0.445649	0.214136
V_car_max_Bus_0008	0.917963	0.90371	0.695286	1.15	0.0932696	0.101605	0.155604	0.768137
V_car_max_Bus_0009	0.846235	0.841924	0.539251	1.15314	0.0832566	0.0983847	-0.476643	0.119541
V_car_max_Bus_0010	0.844167	0.83776	0.550383	1.1447	0.0850219	0.100717	-0.535665	0.193356
V_car_max_Bus_0011	0.879676	0.871542	0.613568	1.13257	0.082826	0.0941551	-0.432556	0.239247
V_car_max_Bus_0012	0.885735	0.885244	0.558609	1.14441	0.105613	0.119238	-0.322123	-0.0760071
V_car_max_Bus_0013	0.869503	0.866563	0.578053	1.14266	0.101816	0.117097	-0.553071	0.0303656
V_car_max_Bus_0014	0.7941	0.777828	0.501573	1.14763	0.108455	0.136576	-0.66909	0.337286

Figura 3.6. Principales estadísticos de la magnitud de los voltajes de barra en la nariz de las curvas PV.

Con respecto a la Figura 3.6 se puede observar que el valor máximo se mantiene en 1.15 p.u., mientras que algunos valores mínimos se encuentran por debajo de 0.85 p.u. debido a que el conjunto de datos se adquiere en la nariz de las curvas PV. Además, se puede observar que la media y mediana del voltaje de la barra 1 y 2 están por arriba del 1 p.u., esto debe a que son barras con generación y las más robustas del sistema.

Entonces, de acuerdo a los índices estadísticos presentes en la Figura 3.6 se establece lo siguiente:

- La variación de la media y la mediana demuestra la existencia de valores extremos en todo el conjunto de datos.
- La desviación estándar (std) es baja debido a que no existe una dispersión significativa entre todos los datos, los valores más altos se encuentran en las barras 3, 12, 13 y 14.
- El coeficiente de variación (cvar) tiende a ser bajo al igual que la desviación estándar, lo cual demuestra que el conjunto de datos es homogéneo, los valores más altos se encuentran en las barras 3, 12, 13 y 14.
- El índice Kurtosis para el voltaje de la barra 6 es más pequeño en magnitud que el índice para el voltaje de la barra 1, lo cual denota que tiene una distribución más plana y uniforme.

- El estadístico Skewness demuestra que existe algunas variables con simetría a la izquierda (negativo) como el voltaje de las barras 1, 4, 5 y 12. Mientras que para las demás barras se establece una simetría a la derecha (positivo).

Consecuentemente, para entender de mejor manera el análisis de los índices estadísticos, se presenta la Figura 3.7 donde se muestra los valores de los voltajes de la barra 3 en el caso base y en el caso pre-contingencia en la nariz de la curva PV.




Figura 3.7. Ejemplo de histograma de: (a) Voltajes de la barra 3 en el caso base. (b) Voltajes de la barra 3 en el caso pre-contingencia en la nariz de la curva PV.

3.1.1.2. ANÁLISIS DE COMPONENTES PRINCIPALES

Una vez tratada la base de datos se aplica la reducción de las características (análisis de componentes principales) mediante el método del codo como se muestra en la Figura 3.8.




Figura 3.8. Método del codo para selección óptima de componentes principales.

Con base a la metodología propuesta, se utiliza el método del codo para seleccionar el número óptimo de componentes principales con el propósito de disminuir la pérdida de información por reducción de características. Entonces, con base en las dimensiones de la base de datos que se presenta en la Figura 3.1 se establecieron 106 variables y, mediante la metodología propuesta, se redujo a 15 componentes principales, con el propósito de obtener una variabilidad explicada aproximadamente del 97%.

3.1.1.3. CONSIDERACIONES DEL CÁLCULO DEL MARGEN DE ESTABILIDAD DE VOLTAJE

La selección de características del apartado anterior se utiliza en los dos modelos de aprendizaje automático porque constituye la matriz de pre-contingencia del sistema, la cual es responsable de establecer las variables de entrada para cada regresor. Además, como se escogió 8 líneas de transmisión para el análisis de este sistema, resulta complicado mostrar todos los gráficos sin saturar la observación; por esa razón se presenta, a manera de ejemplo, los resultados obtenidos solo cuando la L/T 10-11 se encuentra fuera de servicio.

Por lo tanto, en la Figura 3.9 se muestra un histograma que permite visualizar la distribución de los datos del margen de estabilidad de voltaje del sistema antes de ingresar a la función “train_test_split” como se detalla en la Tabla 2.7.




Figura 3.9. Datos originales del margen de estabilidad de voltaje cuando la L/T 10-11 está fuera de servicio.

Entonces, se observa que la mayor cantidad de valores tienen un sesgo hacia la izquierda por la existencia de algunos valores extremos en todo el conjunto de datos. Los márgenes de estabilidad con valor cero establecen la pauta de que, para ciertos estados operativos, la salida de la línea de transmisión en cuestión proporciona un estado inseguro para el sistema de prueba. Mientras que, los márgenes de estabilidad con valores exorbitantes, demuestran las pocas restricciones de operación que tiene el sistema de prueba en comparación con sistemas de potencia reales. Estos valores extremos aparecen debido a la variabilidad estocástica de las cargas durante el Montecarlo, el método del cálculo del margen como se muestra en la Tabla 2.2 y el rango de control de voltaje expuesto en la Figura 3.5.

Además, el propósito de aplicar la metodología en el sistema de prueba es para comprobar el funcionamiento de la herramienta computacional. Estos percances, durante la aplicación en el SNI, no se presentan debido a la robustez y el diseño del sistema.

3.1.2. RESULTADOS DE LA RED NEURONAL Y OPTIMIZACIÓN

Una vez tratado y procesado el conjunto de datos, se procede a implementar la red neuronal que se modeló en la herramienta computacional, teniendo en cuenta los hiperparámetros que se encuentran en la Tabla 2.8.

Por otro lado, se realiza la optimización de los hiperparámetros involucrados dentro de la red neuronal con el propósito de mejorar la respuesta de cada simulación. Entonces, de acuerdo a la Tabla 2.10 donde se establece un rango de opciones para el optimizador, los mejores hiperparámetros obtenidos mediante GridSearchCV se presentan en la Tabla 3.1.

Tabla 3.1. Hiperparámetros establecidos por GridSearchCV para la red neuronal.

Hiperparámetros	Información
hidden_layer_sizes	(100,50)
activation	'relu'
solver	'adam'
alpha	0.05
learning_rate	'adaptive'

Los resultados obtenidos de las dos métricas de rendimiento, antes y después de la optimización de cada índice, para cada caso de línea de transmisión fuera de servicio, se encuentran en la Tabla 3.2.

Tabla 3.2. Resultados de la red neuronal y optimización.

L_OUT \ Métrica	MSE	MSE-Optimizado	R ²	R ² -Optimizado
L/T 0010-0011	0.0869076	0.0793331	0.903963	0.919816
L/T 0012-0013	0.0897768	0.0876583	0.898385	0.917335
L/T 0013-0014	0.080408	0.0748397	0.900174	0.921621
L/T 0006-0011	0.0835245	0.0793822	0.90592	0.91464
L/T 0006-0012	0.0832008	0.0758029	0.903705	0.917196
L/T 0006-0013	0.0743623	0.0659946	0.897417	0.915314
L/T 0009-0010	0.0855541	0.0779259	0.891426	0.912342
L/T 0009-0014	0.0803362	0.0757989	0.904264	0.921231

El error medio cuadrático (MSE) de cada caso permite conocer el ajuste que tiene el modelo al conjunto de datos establecido, de esta manera y, como se evidencia en la Tabla 3.2, mientras el error se acerque a cero, mejor será el ajuste del modelo. Por otro lado, el coeficiente de determinación (R²) presenta un incremento en su valor cuando se aplica el optimizador, es decir, cuanto más cerca de 1 se situó su valor, mayor será el ajuste del modelo y, por lo tanto, mejor será la predicción del margen de estabilidad de voltaje.

En la Figura 3.10 se muestran los resultados de la predicción de la red neuronal antes y después de aplicar la optimización de hiperparámetros.

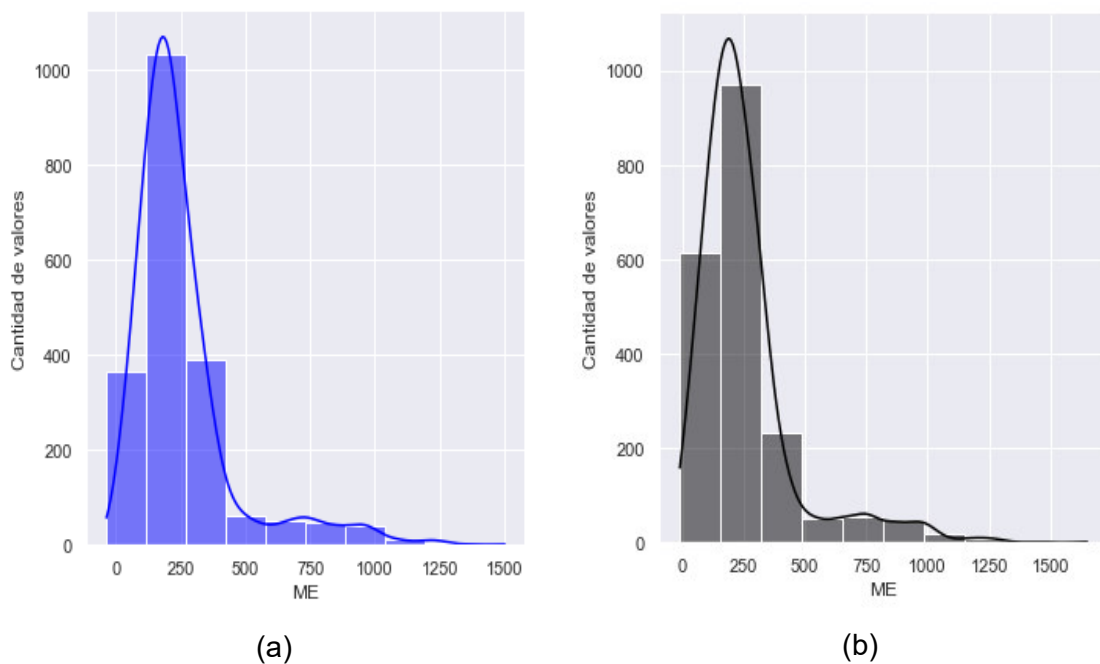


Figura 3.10. Resultados de la predicción: (a) Margen de estabilidad antes de la optimización de hiperparámetros. (b) Margen de estabilidad después de la optimización de hiperparámetros.

De acuerdo a la Figura 3.10 (a) se puede observar la misma tendencia con respecto a los datos del margen de estabilidad del sistema inicial, sin embargo, en la Figura 3.10 (b) se puede corroborar que la optimización de los hiperparámetros que ingresan en el modelo de la red neuronal, permiten mejorar el ajuste de los datos y en general la predicción del margen.

3.1.3. RESULTADOS DE LA MÁQUINA DE SOPORTE VECTORIAL Y OPTIMIZACIÓN

De igual forma, la aplicación de la máquina de soporte vectorial se realizó a través de la herramienta computacional teniendo en cuenta los hiperparámetros que se encuentran en la Tabla 2.9. Además, la optimización de estos varía de acuerdo al modelo y, por consiguiente, conforme el rango de opciones que se encuentra en la Tabla 2.11; en la Tabla 3.3 se presentan los mejores hiperparámetros encontrados mediante GridSearchCV.

Tabla 3.3. Hiperparámetros establecidos por GridSearchCV para el SVM.

Hiperparámetros	Información
kernel	'rbf'
C	10
gamma	1e-4

Los resultados obtenidos de las dos métricas de rendimiento, con la optimización de cada índice para cada caso de línea de transmisión fuera de servicio, se encuentran en la Tabla 3.4.

Tabla 3.4. Resultados del SVM y optimización.

L_OUT \ Métrica	MSE	MSE-Optimizado	R ²	R ² -Optimizado
L/T 0010-0011	0.0961789	0.150122	0.902789	0.848268
L/T 0012-0013	0.0929347	0.157559	0.912359	0.851415
L/T 0013-0014	0.0976293	0.150493	0.897754	0.842391
L/T 0006-0011	0.094906	0.145815	0.897947	0.843204
L/T 0006-0012	0.0835805	0.149462	0.9087	0.836734
L/T 0006-0013	0.0763724	0.131151	0.901997	0.831705
L/T 0009-0010	0.0951139	0.151858	0.893007	0.829176
L/T 0009-0014	0.105269	0.1586	0.890606	0.835186

De acuerdo a la Tabla 3.4, la implementación del SVM sin optimización tiene resultados bastante parecidos a la red neuronal como se presenta en la Tabla 3.2. Sin embargo, cuando el optimizador entra en funcionamiento, se demuestra que no se puede ajustar la máquina de soporte vectorial al conjunto de datos, debido a que el MSE incrementa en magnitud y el R^2 disminuye en magnitud.

En la Figura 3.11 se muestran los resultados del margen de estabilidad de voltaje antes y después de aplicar el optimizador. La perspectiva de GridSearchCV es la de mejorar la respuesta del modelo, pero si no existe tal aseveración se puede inferir que el ajuste de la máquina de soporte vectorial en la base de datos es ambiguo. Además, la complejidad del tiempo de ajuste del SVM es cuadrática con el número de muestras, lo que resulta complicado escalar un conjunto de datos extenso.




Figure 3.11. Resultados de la predicción: (a) Margen de estabilidad antes de la optimización de hiperparámetros. (b) Margen de estabilidad después de la optimización de hiperparámetros.

3.2. CASO 2: SISTEMA NACIONAL INTERCONECTADO REDUCIDO

Para el siguiente caso estudio, se toma como referencia la zona costa del SNI reducido para la aplicación de la herramienta computacional. En ese sentido, de acuerdo a los apartados anteriores, las 7 líneas de transmisión seleccionadas que salen de servicio, generan 7 matrices post-contingencia con una columna que contienen la información de los márgenes de estabilidad, mientras que la matriz pre-contingencia contiene 215 columnas como se muestra en la Figura 3.12. De igual manera, el número de filas o casos operativos se establece en 10 000 muestras para todas las matrices.

Nombre	Tipo	Tamaño
Margen_E_1	Array of float64	(10000,)
Margen_E_2	Array of float64	(10000,)
Margen_E_3	Array of float64	(10000,)
Margen_E_4	Array of float64	(10000,)
Margen_E_5	Array of float64	(10000,)
Margen_E_6	Array of float64	(10000,)
Margen_E_7	Array of float64	(10000,)
Resultado_precontingencia	DataFrame	(10000, 215)

Figura 3.12. Matriz pre-contingencia y matrices post-contingencia del SNI.

Las variables de entrada que constituyen la matriz pre-contingencia para el procesamiento de datos son las mismas que se utilizaron en el caso 1, con la diferencia que en este sistema se está analizando una zona específica. De igual forma, se debe cumplir que el número de muestras debe ser al menos 3 veces más grande que el número de características seleccionadas.

En este sentido, la Figura 3.13 muestra un ejemplo del cálculo de las curvas PV de la barra crítica en un estado operativo, donde se puede observar que la curva de color rojo se obtiene antes de la contingencia, mientras que, la curva de color verde se obtiene después de la contingencia. Cabe recalcar que, la información de los márgenes que se observa en la Figura 3.12, se obtiene de la curva post-contingencia de color verde.




Figura 3.13. Ejemplo del cálculo de las curvas PV de la barra crítica antes y después de la salida de operación de la L/T Chorillos – Tisaleo 1.

De igual manera, la Figura 3.14 muestra otro ejemplo del cálculo de las curvas PV de la barra crítica en otro estado operativo, donde la curva roja y la curva verde tienen la misma representación del análisis de la Figura 3.13.




Figura 3.14. Ejemplo del cálculo de las curvas PV de la barra crítica antes y después de la salida de operación de la L/T Sopladora - Esclusas.

3.2.1. RESULTADOS DEL PREPROCESAMIENTO DE DATOS

Dado que en la matriz pre-contingencia existen variables que no aportan información relevante, se realiza una depuración de las variables mencionadas, teniendo como resultado un total de 215 columnas de las 234 columnas iniciales. La aplicación de índices estadísticos y el análisis de componentes principales se presentan en los siguientes apartados.

3.2.1.1. PRINCIPALES ÍNDICES ESTADÍSTICOS

3.2.1.1.1. Caso base

Los índices estadísticos del conjunto de datos del caso base, después del Montecarlo y el flujo óptimo de potencia, se presentan en la Figura 3.15. Cabe recalcar que, para este análisis, se toma en cuenta solo la magnitud de los voltajes de cada barra debido a que el conjunto de datos posee 215 características.

Índice	mean	median	min	max	std	cvar	kurtosis	skewness
V_car_CHOR230	1.02568	1.02562	0.994388	1.04128	0.00421356	0.00410806	8.44305	-1.39658
V_car_ESCL230	1.03514	1.03519	0.999851	1.05071	0.0045479	0.00439351	10.6729	-1.87006
V_car_MACH230	1.03471	1.03457	1.00459	1.05308	0.00625176	0.00604204	-0.255434	-0.0751034
V_car_MILA230	1.03199	1.03209	0.996897	1.04632	0.00459187	0.00444952	7.30902	-1.37539
V_car_NPROS138	1.03116	1.03111	0.997023	1.05071	0.00498331	0.0048327	6.10775	-1.0859
V_car_CHOR500	1.03414	1.03391	1.00924	1.04849	0.00355404	0.00343673	6.42601	-0.867411
V_car_PASC230	1.02423	1.02417	0.992305	1.04006	0.00428623	0.00418481	8.55245	-1.41686
V_car_SOPLA230	1.03877	1.03955	0.98801	1.04732	0.00596703	0.00574431	37.1915	-5.87376
V_car_TRINI230	1.03299	1.03302	0.997933	1.04886	0.00457803	0.0044318	10.19	-1.79477
V_car_DCER230	1.01249	1.01266	0.974189	1.03178	0.0055266	0.00545844	3.39034	-0.806866

Figura 3.15. Principales estadísticos de la magnitud de los voltajes de barra en el caso base.

Los resultados de la figura anterior, permiten dar a conocer el punto inicial desde el cual parte el módulo de curvas PV. Además, se observa que el valor máximo se establece en 1.053 p.u. y el valor mínimo se establece en 0.98 p.u., esto se debe a que, en la configuración del control de voltaje de todas las barras del sistema en PowerFactory, se mantiene un ΔV de $\pm 5\%$ del voltaje deseado (1 p.u.) como se observa en la Figura 3.16.

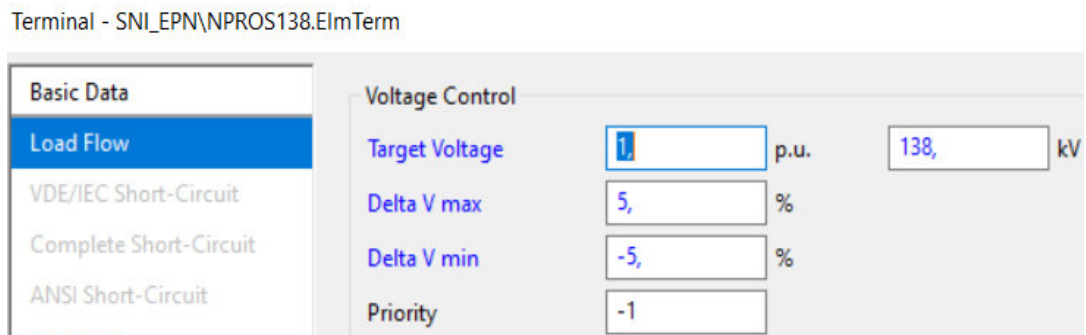


Figura 3.16. Opciones del control de voltaje de la barra Nueva Prosperina 138 kV.

3.2.1.1.2. Caso pre-contingencia

Por otro lado, en la Figura 3.17 se presentan los índices estadísticos para el análisis de la matriz pre-contingencia en la última iteración del módulo de curvas PV.

Índice	mean	median	min	max	std	cvar	kurtosis	skewness
V_car_max_CHOR230	0.882126	0.880387	0.836623	0.928751	0.00845172	0.00958108	2.87777	1.13407
V_car_max_ESCL230	0.896423	0.895197	0.850717	0.935663	0.00735027	0.00819956	3.21917	0.629658
V_car_max_MACH230	0.888429	0.889563	0.824459	0.939342	0.0153189	0.0172427	0.898285	-0.487875
V_car_max_MILA230	0.913655	0.913901	0.870172	0.942228	0.00519841	0.00568969	5.35418	-0.77305
V_car_max_NPROS138	0.850828	0.848775	0.794413	0.913542	0.0113314	0.0133181	2.16214	1.05182
V_car_max_CHOR500	0.894867	0.892807	0.858019	0.941755	0.00851566	0.00951612	3.54868	1.57077
V_car_max_PASC230	0.878689	0.876941	0.83206	0.925885	0.00857284	0.0097564	2.80957	1.09831
V_car_max_SOPLA230	0.968571	0.969299	0.916464	0.992808	0.00610115	0.00629913	31.3502	-4.87706
V_car_max_TRINI230	0.891513	0.890196	0.845021	0.932607	0.00766713	0.00860013	3.00361	0.699925
V_car_max_DCER230	0.890689	0.890871	0.849371	0.919319	0.00618344	0.00694231	2.45179	-0.460425

Figura 3.17. Principales estadísticos de la magnitud de los voltajes de barra en la nariz de las curvas PV.

De acuerdo a los índices estadísticos presentes en la Figura 3.17 se establece lo siguiente:

- La variación de la media y la mediana demuestra que no existe valores extremos.
- La desviación estándar (std) es baja debido a que no existe una dispersión significativa entre todos los datos, los valores más altos se encuentran en las barras de Machala 230 kV y Nueva Prosperina 138 kV.
- El coeficiente de variación (cvar) tiende a ser bajo al igual que la desviación estándar, lo cual demuestra que el conjunto de datos es homogéneo, los valores más altos se encuentran en las barras de Machala 230 kV y Nueva Prosperina 138 kV.
- El índice Kurtosis para el voltaje de la barra Machala 230 kV es pequeño en comparación con el índice para el voltaje de la barra Sopladora 230 kV, lo cual denota que tiene una distribución más plana y uniforme.
- El estadístico Skewness demuestra que existe algunas variables con simetría a la izquierda (negativo) como el voltaje de las barras Machala 230 kV, Milagros 230 kV, Sopladora 230 kV, Dos Cerritos 230 kV. Mientras que para las demás barras se establece una simetría a la derecha (positivo).

Consecuentemente, para entender de mejor manera el análisis de los índices estadísticos, se presenta la Figura 3.18 donde se muestra los valores de los voltajes de la barra Nueva Prosperina 138 kV en el caso base y en el caso pre-contingencia.




Figura 3.18. Ejemplo de histograma de: (a) Voltajes de la barra NP 138 kV en el caso base. (b) Voltajes de la barra NP 138 kV en el caso pre-contingencia en la nariz de la curva PV.

3.2.1.2. ANÁLISIS DE COMPONENTES PRINCIPALES

Como se mencionó, el análisis se realiza en la zona de la costa debido a problemas asociados a bajos voltajes. De igual forma, el tratamiento del conjunto de datos es un paso importante antes de ingresar a los regresores implementados en la herramienta computacional. Entonces, con base en la Figura 3.12 se eligieron 215 variables y mediante la metodología propuesta se redujo a 15 componentes principales, asegurando una variabilidad explicada aproximadamente del 95% como se puede observar en la Figura 3.19.




Figura 3.19. Método del codo para selección óptima de componentes principales.

Dicha selección de características se utiliza en los dos modelos de aprendizaje automático porque constituye la matriz de pre-contingencia del sistema, la cual es responsable de establecer las variables de entrada para cada regresor. Además, como se escogió 7 líneas de transmisión para este sistema, resulta complicado mostrar todos los gráficos; por esa razón se presenta, a manera de ejemplo, el resultado de los gráficos obtenidos solo de la L/T Chorillos – Esclusas 2-1.

Por lo tanto, en la Figura 3.20 se muestra un histograma que permite visualizar la distribución de los datos del margen de estabilidad de voltaje del sistema antes de ingresar a la función “train_test_split” como se detalla en la Tabla 2.7.




Figura 3.20. Datos originales del margen de estabilidad de voltaje cuando la L/T Chorillos – Esclusas 2-1 está fuera de servicio.

En la Figura 3.20 se puede observar una distribución normal del margen de estabilidad de voltaje debido a que no existen valores atípicos en el conjunto de datos, como se presentaron en el sistema IEEE 14 barras. Esto demuestra la robustez del SNI cuando se realiza el análisis de curvas PV junto con la aplicación del criterio “n-1”. En este sistema de estudio se implementaron las curvas de capacidad de los generadores.

3.2.2. RESULTADOS DE LA RED NEURONAL Y OPTIMIZACIÓN

Una vez establecidas las matrices que se utilizan dentro de cada modelo de aprendizaje, se aplica la red neuronal de la misma forma que en el caso de estudio anterior, teniendo en cuenta los hiperparámetros que se encuentran en la Tabla 2.8.

Además, se realiza la optimización de los hiperparámetros de cada máquina de aprendizaje con el propósito de mejorar la respuesta de cada simulación. Entonces, de acuerdo a la Tabla 2.10 donde se establece un rango de opciones para el optimizador, los mejores hiperparámetros obtenidos mediante GridSearchCV se presentan en la Tabla 3.5.

Tabla 3.5. Hiperparámetros establecidos por GridSearchCV para la red neuronal.

Hiperparámetros	Información
hidden_layer_sizes	(100,50)
activation	'tanh'
solver	'adam'
alpha	0.05
learning_rate	'adaptive'

Los resultados obtenidos de las dos métricas de rendimiento, antes y después de la optimización de cada índice, para cada caso de línea de transmisión fuera de servicio, se encuentran en la Tabla 3.6.

Tabla 3.6. Resultados de la red neuronal y optimización.

Línea fuera de servicio \ Métrica	MSE	MSE-Optimizado	R ²	R ² -Optimizado
L/T CHOR_ESC_2_1	0.0075668	0.00217553	0.341314	0.812097
L/T CHOR_PASC_2_1	0.00812494	0.0020536	0.554316	0.827191
L/T CHOR_PASC_2_3	0.00681704	0.00211346	0.404458	0.822574
L/T CHRR_TISA_5_1	0.00645749	0.00131483	0.333477	0.853639
L/T ESC_SOPL_230	0.00790889	0.0017235	0.494656	0.84759
L/T MACH_MILA_2_2	0.00744394	0.00194865	0.685832	0.875999
L/T MOLI_PASC_2_2	0.00796605	0.00174084	0.435986	0.841454

Se puede evidenciar una reducción considerable del error MSE cuando se aplica el optimizador, mientras que el coeficiente R², se acerca al valor máximo, lo cual indica que la red neuronal se ajusta adecuadamente a la base de datos establecida.

En la Figura 3.21 se muestran los resultados de la predicción de la red neuronal antes y después de aplicar la optimización de hiperparámetros.




Figura 3.21. Resultados de la predicción: (a) Margen de estabilidad antes de la optimización de hiperparámetros. (b) Margen de estabilidad después de la optimización de hiperparámetros.

En la Figura 3.21 (a) se puede observar la misma distribución del margen de estabilidad de la zona en el caso base, sin embargo, en la Figura 3.21 (b) se puede corroborar que la optimización de los hiperparámetros que, ingresan en el modelo de la red neuronal, permiten mejorar el ajuste de los datos y en general la predicción del margen.

3.2.3. RESULTADOS DE LA MÁQUINA DE SOPORTE VECTORIAL Y OPTIMIZACIÓN

Por último, se implementa la máquina de soporte vectorial, teniendo en cuenta los hiperparámetros que se encuentran en la Tabla 2.9. Además, la optimización de estos varía de acuerdo al modelo y, por consiguiente, de acuerdo con el rango de opciones que se encuentra en la Tabla 2.11, los mejores hiperparámetros encontrados por parte de GridSearchCV son los mismos que en el sistema de prueba que se encuentran en la Tabla 3.3.

Los resultados obtenidos de las dos métricas de rendimiento, con la optimización de cada índice para cada caso de línea de transmisión fuera de servicio, se encuentran en la Tabla 3.7.

Tabla 3.7. Resultados del SVM y optimización.

Línea fuera de servicio \ Métrica	MSE	MSE-Optimizado	R ²	R ² -Optimizado
L/T CHOR_ESC_2_1	0.00236481	0.00212395	0.795749	0.816552
L/T CHOR_PASC_2_1	0.00237516	0.00212589	0.800133	0.821109
L/T CHOR_PASC_2_3	0.00238173	0.00210508	0.800053	0.823278
L/T CHRR_TISA_5_1	0.00204838	0.00161284	0.771983	0.820465
L/T ESC_SOPL_230	0.00223177	0.0019083	0.802644	0.828371
L/T MACH_MILA_2_2	0.00243322	0.00211104	0.845164	0.865666
L/T MOLI_PASC_2_2	0.0023042	0.00196308	0.790146	0.821213

Se observa una reducción del MSE cuando se aplica el optimizador aunque pequeña, pero en esta ocasión el SVM se ajustó adecuadamente al conjunto de datos, en contraste con lo sucedido con el anterior sistema de prueba. Además, la métrica R² mejora cuando se aplica la optimización recalcando el adecuado rendimiento de los dos modelos de aprendizaje automático.

En la Figura 3.22 se muestran los resultados del margen de estabilidad de voltaje antes y después de aplicar el optimizador.

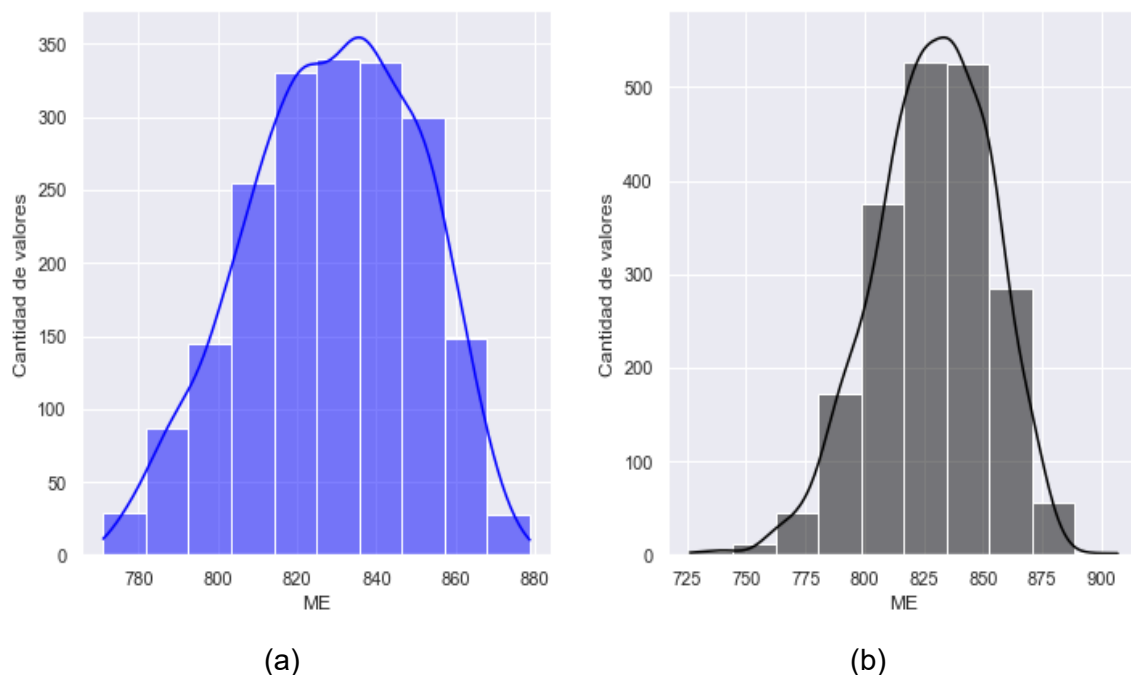


Figura 3.22. Resultados de la predicción: (a) Margen de estabilidad antes de la optimización de hiperparámetros. (b) Margen de estabilidad después de la optimización de hiperparámetros.

3.3. COMPARACIÓN DE LOS REGRESORES

Se puede observar que el comportamiento de los regresores en un conjunto de datos puede ser diferente dependiendo de la dinámica entre las variables del sistema. Para realizar una comparación entre cada modelo de aprendizaje automático, se estableció la misma cantidad de muestras y el mismo procedimiento para estructurar tanto la red neuronal como la máquina de soporte vectorial. En ese sentido, se puede evidenciar los comportamientos que se exponen en la Tabla 3.8.

Tabla 3.8. Tabla comparativa de los resultados de los regresores.

Sistema \ Máquina de aprendizaje	Red neuronal	SVM
Sistema IEEE 14 barras	<ul style="list-style-type: none"> Los resultados del MSE también se pueden expresar en porcentaje y en ese sentido, el error promedio se encuentra en 8.3%. El R^2 promedio está alrededor del 0.9. 	<ul style="list-style-type: none"> Los errores medios cuadráticos están en promedio en 9%. El R^2 promedio está alrededor del 0.9.
	<ul style="list-style-type: none"> La optimización reduce el error al 7.7% La optimización del R^2 promedio mejora al 0.92. 	<ul style="list-style-type: none"> La optimización empeora el error al 15%. La optimización del R^2 promedio empeora al 0.84.
Sistema Nacional Interconectado – Zona Costa	<ul style="list-style-type: none"> El error promedio se encuentra en 0.74%. El R^2 promedio está alrededor del 0.46. 	<ul style="list-style-type: none"> Los errores medios cuadráticos están en promedio en 0.23%. El R^2 promedio está alrededor del 0.8.
	<ul style="list-style-type: none"> La optimización reduce el error al 0.18% La optimización del R^2 promedio mejora al 0.84. 	<ul style="list-style-type: none"> La optimización reduce el error al 0.2%. La optimización del R^2 promedio mejora al 0.82.

Los resultados se analizan mediante el promedio de todos los valores obtenidos en cada caso de L/T que se encuentra fuera de servicio al momento de evaluar el margen de estabilidad.

Con base en la Tabla 3.8 se tiene como resultado final que los modelos implementados se ajustan dependiendo del conjunto de datos que se establezca, es decir, los resultados obtenidos cuando se aplica el SVM al sistema de prueba resulta no tan eficiente dado que empeora los índices de rendimiento, esto se puede justificar por los valores atípicos y el comportamiento que tiene el sistema al momento de calcular al margen de estabilidad mediante las curvas PV. Con esto en mente, analizando los casos de estudio, se concluye que el mejor algoritmo de aprendizaje es la red neuronal, ya que presenta una mejor predicción del margen de estabilidad antes y después del optimizador, así como, a pesar del rendimiento del modelo en el sistema de prueba, se demuestra que cuando se aplica a un sistema de potencia real, la obtención de la base de datos resulta más coherente y por ende mejora la calidad de la información para el aprendizaje de la red neuronal.

Por último, el establecimiento de una banda segura de operación no está dentro del alcance del presente proyecto de titulación. Sin embargo, la definición de una banda de estabilidad, mediante la aplicación de curvas PV, permite orientar adecuadamente a los operadores al momento de tomar medidas preventivas o correctivas en tiempo real del sistema de potencia. En este sentido, este rango de límites resulta subjetivo porque está relacionado a través de regulaciones de operación, informes técnicos, experiencia operativa, entre otros. En [41], se determinan los límites de alerta y alarma asociados a la estabilidad de voltaje, mediante criterios adoptados en el trabajo doctoral disponible en [42], el cual se fundamenta en el monitoreo en tiempo real del margen de estabilidad de voltaje mediante mediciones sincrofasoriales.

4. CONCLUSIONES Y RECOMENDACIONES

4.1. CONCLUSIONES

- Se efectuó la comprobación del funcionamiento del módulo de curvas PV de PowerFactory utilizando el algoritmo de flujos de potencia de continuación disponible en MatPower, que es un método confiable comúnmente utilizado para calcular el límite de estabilidad de voltaje.
- Mediante la aplicación del script de Matlab, se calcularon las curvas de capacidad de las principales unidades de generación del SNI reducido con el propósito de incluir los límites por potencia reactiva del sistema durante la generación de la base de datos de estudio.
- La interacción entre el lenguaje de programación Python y PowerFactory permite la automatización de la metodología planteada y fue de gran interés en el presente trabajo de titulación debido a que se optimizó tiempo en la generación del conjunto de datos, tanto en el sistema IEEE 14 barras como en el SNI.
- La herramienta computacional desarrollada permite generar tantos escenarios operativos como desee el usuario, tomando en cuenta la estocasticidad de la demanda a través del método de Montecarlo y a su vez el uso de flujos óptimos de potencia, con el fin de estructurar una base de datos confiable.
- Se implementó el análisis de componentes principales debido a que las matrices pre-contingencia de los sistemas de estudio poseen cientos de columnas por la cantidad de variables del sistema que se adquirió, en ese sentido, se pudo reducir las características mediante la elección óptima de componentes (Método del codo).
- El ambiente de programación Spyder es una muy versátil interfaz para gestionar a Python, ya que, además de ser de gratuito, brinda flexibilidad para la implementación del algoritmo que genera los casos operativos y también la estructuración de los modelos de aprendizaje automático, dado que permite un adecuado manejo de las variables internas del sistema, además de contar con la documentación respectiva para la programación de las redes neuronales, las máquinas de soporte vectorial y la optimización de los modelos.
- Los hiperparámetros preestablecidos que, permiten el funcionamiento de los modelos de inteligencia artificial disponibles en la biblioteca de “Scikit Learn”, son de gran importancia dado que condicionan la respuesta de las predicciones de las

máquinas, así como el tiempo de entrenamiento, validación y evaluación de los modelos.

- Al momento de estructurar el modelo de aprendizaje es de suma importancia definir el porcentaje de datos que se va a utilizar para el entrenamiento, validación y evaluación del modelo. Sin embargo, el uso de conjunto de datos de validación provoca una pérdida considerable de muestras lo cual afecta el aprendizaje de la máquina, en ese sentido, se implementó el método de validación cruzada para aprovechar la mayor cantidad de datos para la evaluación final del modelo.
- Se implementó la optimización de los hiperparámetros para el SMV mediante GridSearchCV, sin embargo, al momento de aplicar este enfoque en el conjunto de datos del sistema IEEE 14 barras, se observó que no se ajusta correctamente a los datos como se analiza en la tabla comparativa 3.8 y, por ende, la predicción del margen se ve afectada. Por otro lado, la red neuronal presenta un mejor ajuste al conjunto de datos de prueba y de estudio, antes y después de la optimización, dado que los índices de rendimiento como el MSE y R^2 , presentan valores cercanos a cero y valores cercanos a uno, respectivamente. A su vez, mediante estos indicadores, se corroboró la existencia de valores extremos en el conjunto de datos del sistema IEEE 14 barras, en contraste con el SNI donde los datos tienen una tendencia de distribución normal.
- En el presente trabajo técnico, se estimó el margen de estabilidad de voltaje tomando en cuenta todas las variables del sistema pre-contingencia y el margen de estabilidad de voltaje obtenido a través de las curvas PV, mediante algoritmos de procesamiento de datos y modelos de inteligencia artificial como redes neuronales y máquinas de soporte vectorial. La optimización de los hiperparámetros también es un aspecto importante a la hora de maximizar el rendimiento de los modelos implementados.

4.2. RECOMENDACIONES

- Se recomienda utilizar el modo engine al momento de generar los “n” casos de estudio debido a que este modo permite controlar a PowerFactory desde Python sin la necesidad de que este abierto, lo cual permite reducir el tiempo de ejecución y posibles problemas de compatibilidad con Windows al momento de trabajar con hojas de Excel.

- Se recomienda utilizar curvas de carga diaria (industriales, comerciales y residenciales) para conocer el comportamiento real de la carga en un intervalo de tiempo de 24 horas.
- Se recomienda utilizar los límites de servicios auxiliares para mejorar la respuesta de la predicción del margen de estabilidad de voltaje, así como también el SNI completo cuando se encuentre en óptimas condiciones de funcionamiento.
- Se recomienda utilizar la versión de PowerFactory 2017, la versión de Python 3.6.8 y la versión de Spyder 4.2.0 para evitar problemas de compatibilidad cuando se utilice archivos DGS.
- Se recomienda realizar una investigación amplia de los regresores en el lenguaje de programación Python con el propósito de estructurar correctamente los modelos de aprendizaje automático a través de los ejemplos prácticos disponibles en la librería de machine learning “Scikit Learn”.

5. REFERENCIAS BIBLIOGRÁFICAS

- [1] J. S. Henao, "Estudio comparativo de métodos para el cálculo del punto de carga máxima de un sistema eléctrico de potencia considerando coordenadas polares y rectangulares," Universidad Tecnológica de Pereira, 2015.
- [2] Z. Bo, O. Shaojie, Z. Jianhua, S. Hui, W. Geng, and Z. Ming, "An analysis of previous blackouts in the world: Lessons for China's power industry," *Renew. Sustain. Energy Rev.*, vol. 42, pp. 1151–1163, 2015.
- [3] M. Zhang, J. Li, Y. Li, and R. Xu, "Deep Learning for Short-Term Voltage Stability Assessment of Power Systems," *IEEE Access*, vol. 9, pp. 29711–29718, 2021.
- [4] K. D. Dharmapala, A. Rajapakse, K. Narendra, and Y. Zhang, "Machine Learning Based Real-Time Monitoring of Long-Term Voltage Stability Using Voltage Stability Indices," *IEEE Access*, vol. 8, pp. 222544–222555, 2020.
- [5] W. M. Villa-Acevedo, J. M. López-Lezama, and D. G. Colomé, "Voltage stability margin index estimation using a hybrid kernel extreme learning machine approach," *Energies*, vol. 13, no. 4, 2020.
- [6] D. E. Echeverría, V. M. Flores, W. M. Villa, and J. C. Cepeda, "Identificación de Áreas de Control de Voltaje en el Sistema Nacional Interconectado de Ecuador utilizando Minería de Datos," *Rev. Técnica "Energía"*, vol. 13, no. 1, 2017.
- [7] N. Hatziaargyriou *et al.*, "Definition and Classification of Power System Stability - Revisited & Extended," *IEEE Trans. Power Syst.*, vol. 36, no. 4, pp. 3271–3281, 2021, doi: 10.1109/TPWRS.2020.3041774.
- [8] P. Kundur, *Power System Stability And Control*. McGraw-Hill, 1994.
- [9] C. Concordia and S. Ihara, "Load Representation in Power System Stability Studies," *IEEE Trans. Power Appar. Syst.*, vol. PAS-101, no. 4, pp. 969–977, 1982.
- [10] P. Kundur, J. Paserba, and S. Vitet, "Overview on definition and classification of power system stability," *CIGRE/IEEE PES Int. Symp. Qual. Secur. Electr. Power Deliv. Syst. CIGRE/PES 2003*, pp. 1–4, 2003.
- [11] I. J. T. Force, "Definition and Classification of Power System Stability," *IEEE Trans. POWER Syst.*, vol. 19, no. 2, pp. 1387–1393, 2005.
- [12] R. Rincón, A. Pavas, and E. Mojica-Nava, "Long-term voltage stability analysis and network topology in power systems," *2016 IEEE PES Innov. Smart Grid Technol.*

Conf. Eur., 2016.

- [13] J. Patino, C. A. Ramirez, and J. Espinosa, "Modal Analysis for a Power System Benchmark with Topological Changes," *Commun. Comput. Inf. Sci.*, vol. 1052, no. November, pp. 628–639, 2019.
- [14] G. K. Morison, B. Gao, and P. Kundur, "Voltage stability analysis using static and dynamic approaches," *IEEE Trans. Power Syst.*, vol. 8, no. 3, pp. 1159–1171, 1993.
- [15] R. D. Zimmerman and C. E. Murillo-s, "Matpower manual de usuario Version 7.1," p. 248, 2020, [Online]. Available: <https://matpower.org/doc/>.
- [16] R. Billinton and L. Wenyuan, *Reliability Assessment of Electric Power System Using Monte Carlo Methods*, 1era edici. 1994.
- [17] B. Marah and A. O. Ekwue, "Probabilistic load flows," *Proc. Univ. Power Eng. Conf.*, vol. 2015-Novem, no. 1, 2015.
- [18] P. Chen, Z. Chen, and B. Bak-Jensen, "Probabilistic load flow: A review," *3rd Int. Conf. Deregul. Restruct. Power Technol. DRPT 2008*, no. April, pp. 1586–1591, 2008.
- [19] J. R. Pungil, "Flujos de Potencia Probabilísticos Considerando Centrales Fotovoltáicas Empleando el Método de Montecarlo," EPN, 2020.
- [20] W. Nakawiro, "Voltage Stability Assessment and Control of Power Systems using Computational Intelligence," University of Duisburg-Essen, 2011.
- [21] V. Radziukynas and I. Radziukyniene, "Optimization Methods Application to Optimal Power Flow in Electric Power Systems," no. January 2009, pp. 409–436, 2009.
- [22] J. Játiva, "Incorporación de Límites por Restricciones de Servicios Auxiliares en las Curvas de Capacidad de Generadores de Centrales Eléctricas," *Rev. Politécnica*, vol. 32, no. 1, pp. 33–42, 2013, [Online]. Available: http://revistapolitecnica.epn.edu.ec/ojs2/index.php/revista_politecnica2/article/view/37.
- [23] G. C. Cabrera, "Estudio de colapso de voltaje del Sistema Nacional Interconectado para el año 2014 mediante una aplicación desarrollada en Matlab," EPN, 2015.
- [24] D. O. Ramírez, "Análisis de colapso de voltaje por el método de continuación de flujos de potencia considerando zonas seguras de operación de generadores sincrónicos," EPN, 2008.

- [25] P. Flach, *Data, Machine Learning: The Art and Science of Algorithms that Make Sense of*. Cambridge University Press, 2012.
- [26] J. Bell, *Machine Learning: Hands-On for Developers and Technical Professionals*, 1era ed. Wiley, 2014.
- [27] J. Cutler and M. Dickenson, *Introduction to Machine Learning with Python*. 2020.
- [28] A. Géron, *Hands-on Machine Learning whith Scikit-Learning, Keras and Tensorfow*, 2da ed. USA: O'Reilly Media, 2019.
- [29] F. Predregosa *et al.*, "Scikit-learn: Machine Learning in Python," *J. Mach. Learn. Res.*, vol. 12, pp. 2825–2830, 2011, [Online]. Available: https://scikit-learn.org/stable/modules/cross_validation.html#cross-validation.
- [30] S. Haykin, *Neural networks and learning machines*, 3era ed., vol. 1–3. Ontario: Pearson, 2018.
- [31] M. Awas and R. Khanna, *Efficient learning machines: theories, concepts, and applications for engineers and systems designers*. Berkeley: Apress, 2015.
- [32] L. Mohan, J. Pant, P. Suyal, and A. Kumar, "Support Vector Machine Accuracy Improvement with Classification," *Proc. - 2020 12th Int. Conf. Comput. Intell. Commun. Networks, CICN 2020*, pp. 477–481, 2020, doi: 10.1109/CICN49253.2020.9242572.
- [33] N. Guenther and M. Schonlau, "Support vector machines," *Stata J.*, vol. 4, pp. 917–937, 2016.
- [34] DIgSILENT GmbH, "PowerFactory 2021 - User Manual," pp. 1–28, 2021.
- [35] I. MathWorks, "MATLAB - Ayuda y documentación.," *Mathworks.com*, 2022. https://es.mathworks.com/help/matlab/learn_matlab/help.html (accessed Feb. 15, 2022).
- [36] M. S. Chamba, W. A. Vargas, and J. Cristobal Cepeda, "Stochastic assessment and risk management of transient stability based on powerfactory and python interface," *2020 IEEE PES Transm. Distrib. Conf. Exhib. - Lat. Am. T D LA 2020*, 2020.
- [37] C. Dobson, Ian & Van Cutsem, Thierry & Vournas, Costas & Demarco, C.L. & Venkatasubramanian, M & Overbye, T & Canizares, "Voltage Stability Assessment: Concepts , Practices and Tools," *IEEE Power Eng. Soc. Power Syst. Stab. Subcomm. Spec. Publ.*, pp. 5.1-5.14, 2013.

- [38] M. A. Pai and A. Stankovic, *Computational Techniques for Voltage Stability Assessment and Control*. 2007.
- [39] G. N. de P. Operativo, "Revisión de las bandas de variación de voltaje en barras y factores de potencia en puntos de entrega del Sistema Nacional de Transmisión (SNT)," Quito, 2021.
- [40] S. Kokoska and D. Zwillinger, *Standard Probability and Statistics Tables and Formulae*. New York, 2000.
- [41] J. Cepeda, P. Verdugo, and G. Argüello, "Monitoreo de la Estabilidad de Voltaje de Corredores de Transmisión en Tiempo Real a partir de Mediciones Sincofasoriales," *Rev. EPN*, vol. 33, no. 3, 2014.
- [42] Y. Narcisse and N. Tchokonte, "Real time identification and monitoring of the voltage stability margin in electric power transmission systems using synchronized phasor measurements," p. 344, 2009.

ORDEN DE EMPASTADO