



**Análisis comparativo de técnicas basadas en máquinas de aprendizaje para predecir la estabilidad de voltaje en sistemas eléctricos de potencia.**

Romero Andrade, Bryan Alejandro y Palma Valdivieso, Santiago Jossue

Departamento de Eléctrica y Electrónica

Carrera de Ingeniería en Electromecánica

Trabajo de Titulación previo a la obtención del título de Ingeniero Electromecánico

Ing. Ortiz Villalba, Diego Edmundo. MSc PhD (c)

17 de febrero de 2022

Latacunga



**ESPE**  
UNIVERSIDAD DE LAS FUERZAS ARMADAS  
INNOVACIÓN PARA LA EXCELENCIA

**DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA**  
**CARRERA DE INGENIERÍA EN ELECTROMECAÁNICA**

### **CERTIFICACIÓN**

Certifico que el trabajo de titulación “**Análisis comparativo de técnicas basadas en máquinas de aprendizaje para predecir la estabilidad de voltaje en sistemas eléctricos de potencia**”. fue realizado por los señores **Palma Valdivieso, Santiago Jossue y Romero Andrade, Bryan Alejandro**, el mismo que ha sido revisado en su totalidad, analizado por la herramienta de verificación de similitud de contenido; por tanto, cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de las Fuerzas Armadas-ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

**Latacunga, 17 de febrero del 2022**



Firmado electrónicamente por:  
**DIEGO EDMUNDO**  
**ORTIZ VILLALBA**

---

**Ing. Ortiz Villalba, Diego Edmundo. MSc PhD (c)**

**C.C.: 1803225414**

## Reporte de verificación de contenido



ESTABILIDAD DE VOLTAJE\_COPYLEAKS.pdf

Scanned on: 16:48 February 17, 2022 UTC



Overall Similarity Score



Results Found



Total Words in Text

Identical Words	117
Words with Minor Changes	43
Paraphrased Words	603
Omitted Words	64





**ESPE**  
UNIVERSIDAD DE LAS FUERZAS ARMADAS  
INNOVACIÓN PARA LA EXCELENCIA

**DEPARTAMENTO DE CIENCIAS DE LA ELÉCTRICA Y ELECTRÓNICA**  
**CARRERA DE INGENIERÍA EN ELECTROMECAÁNICA**

**RESPONSABILIDAD DE AUTORÍA**

Nosotros, **Palma Valdivieso, Santiago Jossue y Romero Andrade, Bryan Alejandro**, con cédulas de ciudadanía 0604704197 y 1725844755 declaramos que el contenido, ideas y criterios del trabajo de titulación: **“Análisis comparativo de técnicas basadas en máquinas de aprendizaje para predecir la estabilidad de voltaje en sistemas eléctricos de potencia”**. Es de nuestra autoría y responsabilidad, cumpliendo los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

**Latacunga, 17 de febrero del 2022**

**Palma Valdivieso, Santiago Jossue**

**C.C.: 0604704197**

**Romero Andrade, Bryan Alejandro**

**C.C.:1725844755**



**ESPE**  
UNIVERSIDAD DE LAS FUERZAS ARMADAS  
INNOVACIÓN PARA LA EXCELENCIA

**DEPARTAMENTO DE CIENCIAS DE LA ELÉCTRICA Y ELECTRÓNICA  
CARRERA DE INGENIERÍA EN ELECTROMECAÁNICA**

**AUTORIZACIÓN DE PUBLICACIÓN**

Nosotros, **Palma Valdivieso, Santiago Jossue y Romero Andrade, Bryan Alejandro**, autorizamos a la Universidad de la Fuerzas Armadas ESPE publicar el trabajo de titulación: **“Análisis comparativo de técnicas basadas en máquinas de aprendizaje para predecir la estabilidad de voltaje en sistemas eléctricos de potencia”**, en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

**Latacunga, 17 de febrero del 2022**

Una firma manuscrita en tinta azul que parece leer 'Palma Valdivieso'.

---

**Palma Valdivieso, Santiago Jossue**

**C.C.: 0604704197**

Una firma manuscrita en tinta azul que parece leer 'Romero Andrade'.

---

**Romero Andrade, Bryan Alejandro**

**C.C.: 1725844755**

## Dedicatoria

Este trabajo se lo dedico:

Al ser superior que no conocemos pero que en ocasiones llamamos Dios, universo o destino. Gracias por haber puesto cada prueba y obstáculo a lo largo de este viaje conocido como vida. Pues sin ellos nunca habría llegado a este punto ni tampoco me estaría convirtiendo en el hombre de bien que deseo un día llegar a ser.

A mis abuelas y abuelo, por cada gesto de cariño, mimo y por ser la voz de aliento en cada ocasión donde estuve a punto de rendirme. Este título es enteramente suyo, gracias a su esfuerzo y dedicación, por siempre querer lo mejor para sus hijos y nietos. Ojalá la vida me permita brindarles muchas alegrías más.

A toda mi familia, padres, tíos y hermano. Pues cada uno de ustedes me ha enseñado lecciones importantes tanto positivas como negativas, pero que a la final son enseñanzas que siempre tendré presente en esta nueva etapa de mi vida.

A mis amigos universitarios, “los primos” como sabíamos llamarnos, gracias por haber hecho de la vida universitaria la mejor etapa de mi vida, sin ustedes estoy seguro de que no hubiese sido posible culminarla. Dicen que los amigos son la familia que uno elige, y ustedes sin duda son la mejor.

A mis hijos de 4 patas, gracias porque en muchas ocasiones, eran la única razón por la que sonreía en el día a pesar de que todo lo demás era un caos.

**Alejandro R.**

### **Dedicatoria**

La vida es un camino de grandes batallas, donde cada día somos los protagonistas y es nuestro deber ganar cada una ellas. El presente trabajo está dedicado a todas esas personas que confiaron y confían en mí, brindándome todo su apoyo, a mi madre que sin ella cada batalla hubiese sido una derrota, a mis tías que con su grano de arena hicieron que el camino sea firme, a mi hermana que es el motor para seguir adelante sin importar que tan difícil se torne la situación, a mi pareja que llegó en el momento adecuado y me impulsó a terminar esta meta, a mi angelito del cielo mi abuelita que con su bendición llegué a este lugar y por sobre todo a DIOS quien me brindó esta oportunidad para progresar, surgir y demostrar que con perseverancia todo es posible.

**Santiago P.**

## Agradecimiento

Le agradezco a Dios y a la vida por haberme permitido nacer y contar con todos los medios necesarios para estudiar, superarme y cada día ser una mejor versión de ser humano. A toda mi familia, por mostrarme lo que quería de la vida y lo que no, por permitirme ser independiente y ver que las cosas no siempre salen como uno quiere, pero está en uno decidir si a pesar de eso se levanta y sigue luchando o se queda conforme con lo que tiene. A mi mami Mariana, gracias a usted este logro fue posible, a cada una de las lecciones que me transmitió y a cada una de las precauciones que supo tomar desde mi niñez para asegurar mi futuro. Pasaré el resto de mi vida intentando recompensarlo. A mi abuelita Maura, gracias por cada historia y anécdota de su vida, sus historias siempre me motivaron a trabajar duro para que el día que yo tenga nietos pueda contar todas mis hazañas y vivencias. A todos mis amigos a lo largo de mi vida, a los que se fueron y a los que se quedaron, cada vivencia que he vivido junto a ustedes me impulsó para terminar mi carrera. A todos esos creadores de personajes ficticios, superhéroes, entre otros que conforman el hermoso mundo del entretenimiento, gracias porque para mí el ser ingeniero comenzó como un sueño de un niño que deseaba construir su traje de superhéroe, y aunque al crecer las prioridades cambiaron, gracias a ese sueño infantil, hoy puedo decir que estoy cumpliendo el sueño de ser ingeniero. A todos mis educadores, pero en especial a los ingenieros Diego Ortiz y Vicente Quispe, por haber transmitido su amor hacia los sistemas eléctricos, pues gracias a ustedes pude descubrir la rama de mi carrera que más me apasiona. Y adicionalmente gracias una vez más al “doc” Diego por haber sido nuestro tutor de tesis, todos los conocimientos que nos transmitió en esta etapa sin duda son invaluable para el resto de mi vida.

***Alejandro R.***

## Agradecimiento

De todo corazón agradezco:

A Dios por brindarme la vida, por bendecirme con esta familia y por sobre todo brindarme esta oportunidad.

A mami Carmita, mi primer amor y el que jamás me fallará, gracias por todo el cariño que me demuestra, por su incondicional apoyo, por esa dedicación y por ese compromiso de verme crecer.

A mi tía Ceci que en la distancia me demuestra que la familia es lo primero y el logro de uno es el logro de todos.

A mi tía Anita que con pequeños gestos me brinda su apoyo

A mi novia Kerly quien se ha convertido en una amiga, confidente, consejera y en un gran apoyo para seguir adelante.

A mis amigos de la infancia que siempre han estado pendientes.

A mis compañeros de universidad por esas largas horas de estudio, de risas y de grandes experiencias.

A todos los profesores quienes supieron brindar su conocimiento logrando formar un profesional más, en especial al Ing. Diego Ortiz quien con paciencia y compromiso logró guiarme hasta la meta final.

Y finalmente, pero muy orgulloso agradezco a la Universidad de las Fuerzas Armadas por acogerme en su seno y formar en mí una persona capaz de luchar en la vida.

**Santiago P.**

**Tabla de contenidos**

<b>Carátula.....</b>	<b>1</b>
<b>Certificación.....</b>	<b>2</b>
<b>Reporte de verificación de contenido.....</b>	<b>3</b>
<b>Responsabilidad de autoría.....</b>	<b>4</b>
<b>Autorización de publicación.....</b>	<b>5</b>
<b>Dedicatoria.....</b>	<b>6</b>
<b>Dedicatoria.....</b>	<b>7</b>
<b>Agradecimiento.....</b>	<b>8</b>
<b>Agradecimiento.....</b>	<b>9</b>
<b>Tabla de contenidos.....</b>	<b>10</b>
<b>Índice de figuras.....</b>	<b>14</b>
<b>Índice de tablas.....</b>	<b>16</b>
<b>Resumen.....</b>	<b>17</b>
<b>Abstract.....</b>	<b>18</b>
<b>Marco metodológico de la investigación.....</b>	<b>19</b>
<b>Antecedentes.....</b>	<b>19</b>
<b>Planteamiento del problema.....</b>	<b>21</b>

Importancia y justificación.....	24
Objetivos .....	25
<i>Objetivo general</i> .....	25
<i>Objetivos específicos</i> .....	25
Alcance del proyecto .....	26
Estado del arte.....	28
Estabilidad en un SEP .....	28
<i>Estabilidad por resonancia</i> .....	29
<i>Estabilidad por convertidores</i> .....	30
<i>Estabilidad en ángulo del rotor</i> .....	30
<i>Estabilidad de frecuencia</i> .....	31
<i>Estabilidad de voltaje</i> .....	31
Modelamiento del sistema .....	38
<i>Modelo en estado estacionario</i> .....	39
<i>Modelo en estado dinámico</i> .....	40
<i>Simulaciones en el Dominio del tiempo</i> .....	40
Despacho económico multinodal DC .....	41
Inteligencia Artificial .....	46
<i>Deep Learning (DL)</i> .....	47
<i>Machine Learning (ML)</i> .....	47
<i>Pre-procesamiento de los datos</i> .....	54
<i>Algoritmos de ML usados en la investigación.</i> .....	55
Trabajos previos relacionados .....	63

<b>Metodología</b> .....	<b>65</b>
<b>Desarrollo de la metodología</b> .....	<b>67</b>
<i>Modelo en estado estacionario</i> .....	<i>68</i>
<i>Problema de despacho</i> .....	<i>68</i>
<i>Proceso de agrupación de los puntos de operación</i> .....	<i>69</i>
<i>Modelamiento en estado dinámico</i> .....	<i>71</i>
<i>Modelamiento detallado</i> .....	<i>71</i>
<i>Simulaciones en el Dominio del Tiempo</i> .....	<i>72</i>
<i>Pre-procesamiento de los datos sintéticos</i> .....	<i>73</i>
<i>Implementación de los algoritmos de ML</i> .....	<i>73</i>
<i>Importancia de las características relevantes</i> .....	<i>74</i>
<b>Caso de estudio</b> .....	<b>76</b>
<b>Análisis de resultados</b> .....	<b>80</b>
<b>Etapa 1</b> .....	<b>80</b>
<i>Modelamiento en estado estacionario</i> .....	<i>80</i>
<i>Despacho económico</i> .....	<i>80</i>
<i>Proceso de agrupación de los P.O.</i> .....	<i>81</i>
<b>Etapa 2</b> .....	<b>83</b>
<i>Modelamiento en estado dinámico y modelo detallado</i> .....	<i>83</i>
<b>Etapa 3</b> .....	<b>85</b>
<i>Datos sintéticos y posibles datos relevantes</i> .....	<i>85</i>
<i>Implementación de los algoritmos de ML</i> .....	<i>85</i>
<i>Evaluación del desempeño de los algoritmos de ML</i> .....	<i>86</i>
<i>Post-validación de los resultados</i> .....	<i>89</i>

<i>Importancia de las características relevantes</i> .....	92
<b>Conclusiones y recomendaciones</b> .....	97
<b>Conclusiones</b> .....	97
<b>Recomendaciones</b> .....	99
<b>Bibliografía</b> .....	100
<b>Anexos</b> .....	105

**Índice de figuras**

<b>Figura 1.</b> <i>Estabilidad de un SEP</i> .....	<b>29</b>
<b>Figura 2</b> <i>Clasificación de la estabilidad de voltaje</i> .....	<b>34</b>
<b>Figura 3</b> <i>Arquitectura básica de un programa de modelamiento y simulación</i> .....	<b>39</b>
<b>Figura 4</b> <i>Clasificación de IA según las tareas a ejecutar</i> .....	<b>47</b>
<b>Figura 5</b> <i>Clasificación de ML según el tipo de aprendizaje</i> .....	<b>49</b>
<b>Figura 6</b> <i>Representación gráfica del funcionamiento de regresión</i> .....	<b>50</b>
<b>Figura 7</b> <i>Ejemplo básico en el aprendizaje supervisado para clasificación</i> .....	<b>51</b>
<b>Figura 8</b> <i>Ejemplo básico en el aprendizaje no supervisado</i> .....	<b>52</b>
<b>Figura 9</b> <i>Ejemplo básico en el aprendizaje semi supervisado</i> .....	<b>53</b>
<b>Figura 10</b> <i>Ejemplo básico en el aprendizaje reforzado</i> .....	<b>54</b>
<b>Figura 11</b> <i>Representación gráfica del funcionamiento de K-Means</i> .....	<b>55</b>
<b>Figura 12</b> <i>Selección de la cantidad de clusters “Regla del codo”</i> .....	<b>57</b>
<b>Figura 13</b> <i>Selección del número k de clusters usando el coeficiente de silueta</i> .....	<b>58</b>
<b>Figura 14</b> <i>Representación gráfica de SVR</i> .....	<b>59</b>
<b>Figura 15</b> <i>Representación gráfica de la estructura de un DT</i> .....	<b>60</b>
<b>Figura 16</b> <i>Representación gráfica de RF</i> .....	<b>61</b>
<b>Figura 17</b> <i>Representación gráfica del funcionamiento de B&amp;P</i> .....	<b>62</b>

<b>Figura 18</b> <i>Representación gráfica de la estructura de una ANN.....</i>	<b>63</b>
<b>Figura 19</b> <i>Diagrama de la metodología general .....</i>	<b>65</b>
<b>Figura 20</b> <i>Sistema de prueba de 24 nodos de la IEEE con introducción de ERNC .....</i>	<b>76</b>
<b>Figura 21</b> <i>Implementación de "regla de codo" para el caso de estudio .....</i>	<b>81</b>
<b>Figura 22</b> <i>Implementación del coeficiente de silueta para el caso de estudio .....</i>	<b>82</b>
<b>Figura 23</b> <i>Representación de las barras y L/T de interés.....</i>	<b>84</b>
<b>Figura 24</b> <i>Resultados de desempeño de los algoritmos en las predicciones.....</i>	<b>87</b>
<b>Figura 25</b> <i>Comparación de valores reales con las predicciones aplicando B&amp;P .....</i>	<b>88</b>
<b>Figura 26</b> <i>Resultados de predicción con una caída de voltaje de 0.1 en p.u.....</i>	<b>89</b>
<b>Figura 27</b> <i>Resultados de predicción con una caída de voltaje de 0.8 en p.u.....</i>	<b>90</b>
<b>Figura 28</b> <i>Desempeño de ANN en las predicciones con diferentes caídas de voltaje ...</i>	<b>91</b>
<b>Figura 29</b> <i>Desempeño de Random Forest en las predicciones.....</i>	<b>92</b>
<b>Figura 30</b> <i>Importancia de las características para la predicción de voltaje para RF.....</i>	<b>94</b>
<b>Figura 31</b> <i>Importancia de las características para la predicción de voltaje para ANN ...</i>	<b>95</b>

**Índice de tablas**

<b>Tabla 1</b> <i>Parámetros para los SG</i> .....	<b>77</b>
<b>Tabla 2</b> <i>Parámetros de los generadores ERNC</i> .....	<b>78</b>
<b>Tabla 3</b> <i>Número de contingencias por barra según el rango de su caída de voltaje</i> .....	<b>86</b>

## Resumen

El presente trabajo de titulación propone un análisis comparativo de máquinas basadas en Machine Learning (ML) implementadas para el estudio de estabilidad de voltaje, con el propósito de predecir su comportamiento en diferentes barras del sistema eléctrico luego de ocurrida una contingencia, evitando así el uso de simulaciones que requieren gran demanda computacional como las de dominio del tiempo (TDS). De esta forma se optimizan recursos económicos, computacionales y tiempo. Para este trabajo se utilizó un sistema de prueba modificado, el cual considera generación tradicional junto con inserción de energías renovables no convencionales (ERNC). Esta investigación parte con la implementación del modelo en estado estacionario del sistema, utilizado para resolver el problema de despacho económico. Adicionalmente, para el análisis de estabilidad de voltaje y debido a su naturaleza variante en el tiempo, mediante el uso de herramientas computacionales del área eléctrica se realiza el modelamiento en estado dinámico del sistema junto con el modelamiento detallado de ciertos elementos, de manera que se puedan realizar las TDS en las cuales se consideran eventos de cortocircuito en líneas de transmisión necesarios para la obtención de los datos sintéticos. Estos datos pasan por una etapa de pre-procesamiento, de manera que puedan ser utilizados para el entrenamiento y validación de los algoritmos de ML. Para el análisis comparativo de dichos algoritmos y sus respectivas predicciones se utiliza la métrica del error cuadrático medio (RMSE).

Palabras clave:

- **ESTABILIDAD DE VOLTAJE**
- **MACHINE LEARNING**
- **CORTOCIRCUITO**

**Abstract**

This project proposes a comparative analysis between Machine Learning (ML) techniques implemented in stability voltage studies, with the purpose of predicting the voltage behavior of any existing bus-bar in a Power System (PS) after a contingency. The goal is to avoid the need of a time domain simulation (TDS) in order to optimize computational resources and time. For this study a modified test system was used in order to consider the growing existence of non-conventional renewable energy (NCRE). This study begins with the implementation of the stationary model time series of the system in order to solve the economic dispatch problem. Moreover, due to the natural changing behavior in time of the voltage in the study of its stability, the dynamic model of the system needs to be implemented by using computational tools existing in the electrical area. In addition to this model, the detailed model of some elements of the system needs to be added. These models are mandatory for the implementation of the TDS which consider the implementation of short circuit events in order to generate the synthetic data. This data requires a pre-processing step, in a way that it can be used for training ML algorithms for predicting the voltage behavior before a fault happens. Once all the algorithms have been trained, their performance is evaluated with the Root Mean Square Error (RMSE) finding the algorithm that fits better with the voltage behavior of this project.

Key words:

- **VOLTAGE STABILITY**
- **MACHINE LEARNING**
- **SHORT CIRCUIT**

## Capítulo I

### 1. Marco metodológico de la investigación

#### 1.1. Antecedentes

En (Kotari & Nagra, 2008), manifiesta a los sistemas eléctricos de potencia (SEP), son redes interconectadas admitiendo el transporte de energía a varios usuarios distribuidos en un determinado espacio. Un SEP tiene 4 zonas de operación: la primera es conocida como estado normal, en la cual todos los valores de las variables se encuentran dentro del rango permitido por los códigos de red, la segunda es el estado de alerta en donde producto de una contingencia todas las variables del sistema cambian y algunas de ellas sobrepasan los rangos dispuestos por los códigos de red, la tercera corresponde al estado de alarma, esta se produce como producto del cambio de las variables que terminan sacando del límite estipulado a otros elementos del sistema (desconexión de otras líneas, generadores, entre otros). En este estado el apagón total tiene una alta probabilidad de producirse, es por esta razón que los códigos de red permiten que el sistema únicamente se mantenga así por 30 minutos en los cuales el operador del sistema deberá encontrar un nuevo punto de operación evitando una desconexión total (CONELEC, 2008). Finalmente, el estado de recuperación del sistema depende de las condiciones en que se encuentre el SEP después de una contingencia, pues en este estado se deben realizar operaciones como el arranque en negro, redespacho, toma progresiva de carga, entre otras acciones correctivas hasta que el SEP vuelva a las condiciones normales de funcionamiento.

La intención de los operadores de red es permanecer siempre en el estado normal del sistema y para lograrlo es necesario disponer de herramientas digitales para analizar condiciones que podrían vulnerar su funcionamiento. Para el estudio de

estabilidad del sistema se suelen utilizar las simulaciones en el dominio del tiempo (TDS), estas requieren resolver sistemas de ecuaciones algebraico-diferenciales complejos, por lo que se requiere de gran esfuerzo computacional y tiempo, para la obtención de resultados, (Wang, Elyas, & Thomas).

Es por ello que los operadores de red se encuentran en constante búsqueda de herramientas computacionales que faciliten el estudio de estabilidad del sistema en el contexto de la operación, pues una determinada contingencia podría dejar al sistema vulnerable derivando en un apagón total, y este a su vez repercutir de forma directa en pérdidas económicas, así como también impactando en la calidad de vida de sus habitantes.

Para la aplicación de herramientas de ML el recurso principal son los datos de entrada pues estos muestran el comportamiento de un determinado sistema. En un SEP la adquisición de datos es un proceso constante, pues realizar mediciones de las magnitudes más importantes en su operación son un reflejo claro del estado del mismo, sin embargo, la accesibilidad a estos datos se ven restringidos por reglas de confidencialidad y acuerdos de no divulgación limitando así la investigación. Es por esta razón que, para realizar estudios, se suele hacer uso de datos sintéticos obtenidos mediante simulaciones que representan el comportamiento del SEP ante una posible contingencia (Li, Yeo, L, & T, 2017).

En (Tilottama & Uponika, 2019), se hace referencia a la incorporación de modelos de ML para la detección de eventos críticos. El uso de este tipo de algoritmos es bien visto en redes eléctricas dado que no requiere de una gran cantidad de recursos computacionales a diferencia de las TDS citadas anteriormente. En (Liu, 2018) se resalta la importancia de la predicción de eventos, pues mediante esta aplicación se

pueden tomar acciones correctivas antes de que ocurran, evitando así daños innecesarios y posibles fallas en cascadas que deriven en un apagón completo.

En (Riad, Chen, Sánchez-Sinencio, & Li, 2020), se muestra una aplicación del uso de ML en redes de distribución, el estudio está enfocado en la regulación de voltaje combinando las ventajas de los reguladores de voltaje (VR) de conmutación.

En (Yun, Tengyu, Bing, Jing, & Zhongje, 2015), se hace referencia al uso de decision tree aplicado a la estabilidad de voltaje, este algoritmo permite encontrar las magnitudes que poseen mayor relación con el comportamiento del voltaje. En el caso de estudio se concluye que las características de mayor relevancia es el ángulo de voltaje en barras, ligado a su importancia por ser el parámetro que varía en la regulación de potencia entregada hacia las cargas. Los resultados se obtuvieron al aplicar la metodología propuesta a un sistema de prueba, dejando en claro que la aplicación de ML para un correcto análisis sobre voltaje son una gran alternativa.

## **1.2. Planteamiento del problema**

En la actualidad todos los SEP se encuentran interconectados presentando mayor complejidad al momento de analizar el estado del mismo, el uso de unidades de medición fasorial (PMU), es una alternativa que se ha tomado con la finalidad de facilitar la adquisición de datos para un posterior tratamiento y obtener soluciones inmediatas. Mantener un sistema estable requiere de un constante análisis y monitoreo, es por ello que la academia exhorta el constante estudio e innovación en cuanto a la estabilidad de variables importantes como lo son: frecuencia, ángulo del rotor y voltaje, ya que su comportamiento son indicadores relevantes del estado en el que se encuentra el sistema. Como se ha mencionado anteriormente, el objetivo principal de los operadores

de red es mantenerse dentro del estado normal para no llegar a un estado de alarma y peor aún al estado de emergencia, (Betancurth, 2021).

La importancia de indagar sobre el comportamiento del voltaje referente a su estabilidad radica en el hecho de que una variación en el voltaje del sistema produce que la capacidad de entrega de potencia activa decaiga. El estudio de estos fenómenos se suele dividir en: pequeñas perturbaciones que pueden ser de corto o largo plazo y en grandes perturbaciones que de igual manera puede tener estos plazos de ocurrencia. Estas perturbaciones se pueden presentar debido a: grandes distancias entre los generadores y la carga, niveles bajos de voltaje en los bornes de generación, maniobras de operación o mantenimiento, sobre compensación reactiva, entre otras. Dichas perturbaciones pueden tener mayor o menor incidencia dependiendo de la estructura y características únicas de cada SEP, (Betancurth, 2021).

A lo largo de los años se han presentado varias herramientas para el estudio y corrección de este tipo de fallas como lo son el uso de TDS, compensadores estáticos de potencia reactiva (SVC), uso de curvas P-V, esquemas de alivio de carga y el uso del cambiador de taps bajo carga en los transformadores de subestaciones (OLTC), sin embargo, todas estas acciones son útiles cuando la falla ya ocurre, (Constantino & Aquino, 2021).

Los modelos basados en TDS obtienen información del comportamiento del sistema mediante la representación de su modelo detallado y la generación de eventos que simulan una determinada contingencia. Esto hace que la velocidad de cálculo sea lenta, ya que se requieren solucionar sistemas complejos de ecuaciones algebraico-diferenciales por lo cual, el método no es el adecuado para la predicción rápida de las variables ante una perturbación.

Se ha presentado la problemática de que, al momento de analizar la estabilidad de voltaje en el contexto de operación de un SEP, estos fenómenos no se evidencian hasta que ya ha ocurrido el proceso de inestabilidad y en el momento que ocurren muchos de ellos terminan siendo igual o más graves que los fenómenos relacionados con la estabilidad de frecuencia o ángulo del rotor. De ahí la importancia de desarrollar nuevos modelos que relacionen el uso de herramientas modernas como son los modelos basados en ML, con el objetivo de tomar medidas correctivas ante eventos de gran impacto que pongan en peligro el correcto funcionamiento de un SEP y que deriven en un apagón, (Constantino & Aquino, 2021).

En la actualidad existen varios algoritmos usados en ML como: Decision Tree, Logistic Regression, Support Vector Machine, entre otros. Los cuales pueden ser implementados en el análisis del estado de los SEP, la diferencia entre cada uno de estos modelos es la efectividad que se obtienen en los resultados dependiendo del caso de estudio y complejidad del mismo. Para lograr un correcto funcionamiento es necesario entrenar de forma correcta dichas herramientas computacionales mediante datos reales con el fin de que se logre una representación cercana al funcionamiento del sistema, pero en muchos de los casos el acceso a estos datos es limitado o inexistente. Es por ello que para el uso de ML se suelen generar datos sintéticos bajo varias metodologías con el fin de que se obtenga una base de datos que refleje de manera cercana el funcionamiento real del sistema.

Con el afán de resolver toda la problemática presentada y hacer uso de las herramientas computacionales relacionadas a ML en el campo eléctrico, el presente trabajo propone evaluar el desempeño de varios algoritmos de ML aplicados a la predicción de estabilidad de voltaje, mediante la generación de datos sintéticos que representen el comportamiento del sistema, para un posterior entrenamiento y

evaluación de cada uno de los algoritmos para finalmente concluir con la selección del algoritmo que obtenga el mejor desempeño en la predicción de la variable de interés.

### **1.3. Importancia y justificación**

Hoy en día el recurso energético es primordial para lograr el desarrollo económico y productivo de un país. Dada su importancia es uno de los sistemas que se encuentra en constante cambio tanto en la infraestructura, tecnología y diversificación en cuanto a su matriz de generación, de ahí la inserción progresiva de ERNC. Debido a esto, el manejo del sistema por parte del operador de red cada vez es una tarea más difícil. Con el propósito de mantener un mejor control en el funcionamiento del SEP los operadores de red han implementado equipos de adquisición de datos, permitiendo almacenar una gran cantidad de información acerca del estado del mismo con el objetivo de identificar de forma oportuna un posible estado de vulnerabilidad, a fin de aplicar medidas correctivas y que el sistema no llegue a un estado de alerta y peor aún al estado de alarma en donde el apagón es inminente. Sin embargo, al tratarse de una gran cantidad de datos, su tratamiento y almacenamiento se vuelve complejo.

La alteración en la estabilidad de voltaje puede afectar de manera directa a la frecuencia y ángulo rotórico, provocando daños en la infraestructura, desconexión del sistema y pérdidas económicas considerables. Por esta razón es necesario implementar nuevas metodologías como modelos de predicción de eventos utilizando ML, las cuales con un correcto entrenamiento puedan predecir eventos post contingencia que podrían tener una gran incidencia sobre el SEP.

En este trabajo se propone desarrollar un modelo de predicción de la estabilidad de voltaje, evaluando distintos algoritmos ML, permitiendo seleccionar el que mejor se ajuste a las condiciones establecidas.

Para su entrenamiento, los datos sintéticos se obtienen de la ejecución de TDS en softwares utilizados en el sector eléctrico. Posteriormente se eligen las magnitudes que serán estudiadas (posibles características relevantes), esto permite que la máquina de ML tenga un mayor desempeño en sus resultados. La introducción de este nuevo modelo va a representar una mejora en la respuesta ante una contingencia en el sistema, pues permite optimizar los tiempos de simulación además que el esfuerzo computacional se verá reducido.

#### **1.4. Objetivos**

##### ***1.4.1. Objetivo general***

- Realizar un análisis comparativo de algoritmos aplicados en ML para el desarrollo de estudios en estabilidad de voltaje mediante el uso de herramientas computacionales aplicadas en el área eléctrica.

##### ***1.4.2. Objetivos específicos***

- Implementar un modelo de despacho económico en un sistema de prueba modificado considerando la inserción de ERNC utilizando herramientas computacionales de optimización para emular condiciones operacionales de un SEP
- Desarrollar un modelo detallado del sistema de prueba modificado en una herramienta computacional utilizada en el sector eléctrico con el propósito de desarrollar simulaciones dinámicas para la obtención de datos sintéticos.
- Seleccionar las características más relevantes que influyen en la inestabilidad de voltaje, con el propósito de tener información apropiada para

el entrenamiento de las ML utilizando algoritmos que permitan discriminar las variables menos relevantes.

- Evaluar el desempeño de los diferentes modelos de ML mediante el uso de datos sintéticos obtenidos en los procesos anteriores para poder predecir la inestabilidad de voltaje.

### **1.5. Alcance del proyecto**

El presente proyecto propone un análisis comparativo de algoritmos de ML aplicados al estudio de estabilidad de voltaje en un SEP, para lograr predecir caídas de voltaje en las barras del sistema producto de contingencias que perjudiquen su punto de operación, siendo necesario encontrar lo antes posible otro punto donde se pueda restablecer. La metodología propuesta consta de las siguientes etapas:

Selección del sistema de prueba junto con los parámetros necesarios para el modelamiento en estado estacionario. Este modelo se utiliza para resolver un problema de despacho económico para cuatro semanas del año con una resolución de 1 hora. Las horas de despacho obtenidas no consideran la regulación de voltaje en barras ni la regulación de reactivos, consideraciones necesarias para las TDS en la siguiente etapa. Para solucionar este problema se realiza un proceso de clustering el cual agrupa horas de despacho con características similares, identificando en cada grupo una hora representativa en las que se ajustan las condiciones iniciales del sistema las cuales sirven para todas las horas pertenecientes a cada grupo.

En la segunda etapa se realiza el modelamiento en estado dinámico del SEP, el cual necesita incluir los modelos detallados de algunos elementos que permitan a las TDS simular el comportamiento real del sistema ante una contingencia y así generar la data sintética.

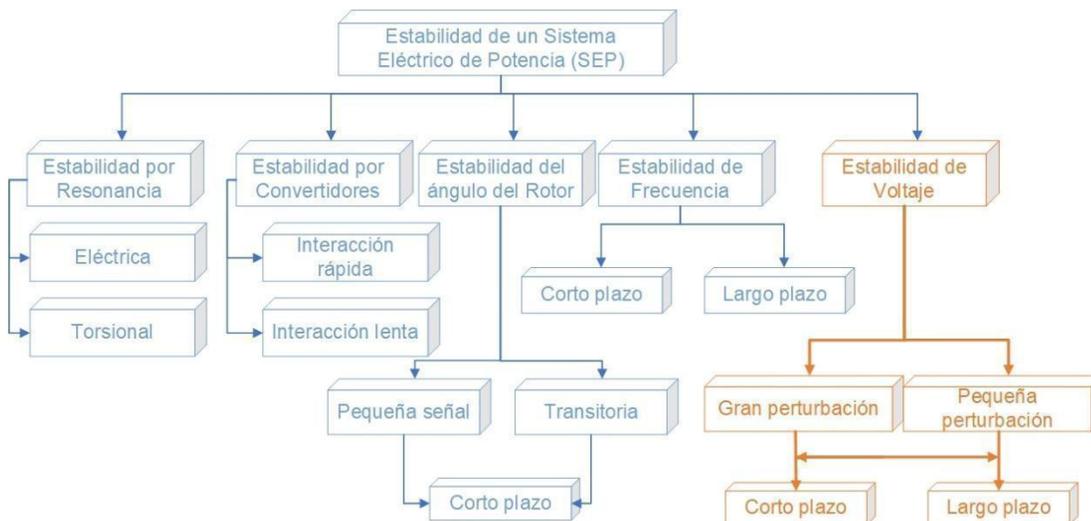
En la tercera y última etapa se realiza una preselección de las posibles características relevantes, estas son aquellas variables del sistema en las que la literatura ha demostrado que su comportamiento posee una estrecha relación con el voltaje. Dichas variables son separadas y organizadas mediante un pre procesamiento de los datos sintéticos obtenidos en la etapa anterior y son utilizados para el entrenamiento de los algoritmos de interés. Finalmente se procede al análisis comparativo de los resultados obtenidos para la predicción de voltaje usando el criterio del RMSE el cual permite elegir el algoritmo con mejor desempeño y al mismo tiempo validar si las características relevantes elegidas fueron las correctas.

## Capítulo II

### 2. Estado del arte

#### 2.1. Estabilidad en un SEP

La estabilidad de un sistema se define como la capacidad del SEP de reaccionar ante una contingencia, permitiéndole operar en condiciones normales. Debido a la dinámica variante de los SEP, la creciente implementación de ERNC, instalación de dispositivos en la red (SVC, STATCOMs), expansiones en la topología e introducción de nuevos tipos de carga han hecho que esta tarea sea mucho más compleja. Es por esto que la academia en su afán de dar solución a estos problemas, ha realizado estudios determinando la existencia de nuevos fenómenos los cuales no pueden ser clasificados dentro de los tipos de estabilidad considerados hasta hace unos años. Una nueva alternativa para el estudio de estabilidad en los SEP es propuesta en (Hatziagyriou, Milanović, & Rahmann, 2020), donde se establecen dos nuevas clasificaciones conocidas como estabilidad por resonancia y estabilidad por convertidores. Estas nuevas propuestas junto con las clasificaciones previamente estudiadas se representan en la Figura 1.

**Figura 1.***Estabilidad de un SEP*

*Nota.* En el gráfico muestra la clasificación de la estabilidad en un SEP, considerando los nuevos fenómenos de estabilidad. Obtenido de (Hatzigiariou, Milanović, & Rahmann, 2020).

A continuación, se realiza una breve definición para cada tipo de estabilidad, pero se da mayor detalle al estudio en la estabilidad de voltaje, debido a que es el tema principal en esta investigación.

### **2.1.1. Estabilidad por resonancia**

La resonancia en un sistema ocurre cuando el intercambio de energía se realiza periódicamente de manera oscilatoria. Estas oscilaciones crecen cuando no se puede disipar toda la energía en su trayectoria y se manifiesta como intensificación en las magnitudes de voltaje, corriente y torque. Cuando estas magnitudes superan los umbrales permitidos se dice que se ha producido una inestabilidad de resonancia. La estabilidad de resonancia también abarca a la resonancia subsincrónica (SSR) ya sea

que esté asociada a una resonancia electromecánica o resonancia completamente eléctrica, (Hatziaiyriou, Milanović, & Rahmann, 2020).

### **2.1.2. Estabilidad por convertidores**

Este tipo de estabilidad nace de la diferencia en el comportamiento dinámico de los generadores ERNC y los generadores sincrónicos (GS), esto se debe a que la interfaz de un generador ERNC se basa en lazos de control y algoritmos con tiempos de respuesta rápido. En este sentido la amplia escala de tiempo relacionada con los controladores de los ERNC da lugar a acoplamientos cruzados tanto con la dinámica electromecánica como con los transitorios de la red, produciéndose oscilaciones inestables del SEP en un amplio rango de frecuencias, diferenciando las interacciones lentas y rápidas. Los fenómenos de inestabilidad que muestran frecuencias relativamente bajas se clasifican como estabilidad impulsada por convertidor de interacción lenta (típicamente, menos de 10 Hz), mientras que los fenómenos con frecuencias relativamente altas se clasifican como estabilidad impulsada por convertidor de interacción rápida (típicamente, decenas a cientos de Hz, y posiblemente en kHz), (Hatziaiyriou, Milanović, & Rahmann, 2020).

### **2.1.3. Estabilidad en ángulo del rotor**

La estabilidad acerca del ángulo del rotor hace referencia a la aptitud de las máquinas con tecnología sincrónica interconectadas en un SEP, para permanecer en sincronismo en condiciones normales de funcionamiento y recuperar el sincronismo después de estar sujetas a una pequeña o gran perturbación. Una máquina mantiene el sincronismo si el par electromagnético es igual y opuesto al par mecánico entregado por el motor primario. En consecuencia, este tipo de estabilidad depende de la capacidad

de las máquinas sincrónicas para mantener o restablecer el equilibrio entre estos dos pares opuestos, (Hatziaiyriou, Milanovié, & Rahmann, 2020).

#### **2.1.4. Estabilidad de frecuencia**

La estabilidad referida a la frecuencia como la capacidad de un SEP para restablecer la frecuencia luego de una perturbación severa provocada por un desbalance entre generación y carga. Para sistemas donde la generación dominante es GS, la estabilidad de frecuencia depende en un inicio de la inercia presente en las masas rotóricas de los GS, si la variación de frecuencia no es restablecida, la regulación se lleva a cabo con el control primario, en donde los elementos de respuesta pertenecientes a los generadores logran restablecerla a sus valores nominales. Si el desbalance en la frecuencia es tan severo que no logra ser restablecida, se procede al control secundario, en donde es necesario realizar maniobras como deslastre de carga por parte de los operadores de manera que el balance entre generación y carga sea restablecido. Cuando se tiene una alta penetración de ERNC la inercia del sistema decae, debido a que este tipo de generación desplaza a los GS, provocando que las variaciones de frecuencia sean más rápidas, producto de ello desbalances de frecuencia más severos, (Hatziaiyriou, Milanovié, & Rahmann, 2020).

#### **2.1.5. Estabilidad de voltaje**

Se refiere a la capacidad de un SEP para mantener un voltaje adecuado en todos los nodos del sistema tanto para condiciones normales de funcionamiento y luego de ocurrida una perturbación. Un sistema entra en un estado de inestabilidad de voltaje cuando una perturbación, producto de un aumento en la demanda o modificaciones en la condición del sistema, provocan una caída de voltaje progresivo e incontrolable. El principal factor que causa este tipo de alteración, es la falta de capacidad en el SEP

para satisfacer la demanda y regular la inyección de reactivos, provocando una caída en la magnitud del voltaje hasta violar los valores límites obligando a los equipos de protección se activen. Como consecuencia se tiene salida de líneas o generadores que pueden causar un colapso total de voltaje. La raíz del problema suele ser la caída de voltaje que se produce cuando la potencia activa y la potencia reactiva son transmitidas por la reactancia inductiva asociada a la red, (Kundur, 2009).

#### **i. Clasificación de la estabilidad de voltaje.**

El fin de esta clasificación es facilitar el análisis de la estabilidad de voltaje para la identificación de: perturbaciones, aplicación de las herramientas que se van a utilizar en el análisis, y planteamiento de medidas que actúen eficazmente contra el problema de estabilidad identificado, (Sevilla, 2015). La clasificación de la estabilidad de voltaje se subdivide en:

#### **ii. Estabilidad de voltaje ante grandes perturbaciones.**

Se refiere a la capacidad del SEP de mantener los niveles de voltaje constante después de ocurrir grandes perturbaciones, estos pueden ser: fallas que afectan directamente al sistema de transmisión, aumentos desmesurados en la demanda, funcionamiento cercano a los límites en transmisión de potencia, generación alejada de la carga e insuficiencia en la compensación de potencia reactiva. Para determinar la estabilidad de voltaje ante grandes perturbaciones es mandatorio la respuesta no lineal del SEP para un determinado periodo de tiempo, representando el funcionamiento y comportamiento relacionado a los dispositivos tales como: cambiadores de tomas bajo carga presentes en los transformadores y limitadores de campo presentes en el generador. El estudio suele tener un periodo de interés que se extiende a partir de algunos segundos a 10 minutos, (López, 2008).

**iii. Estabilidad de voltaje ante pequeñas perturbaciones.**

Se refiere a la capacidad del sistema de mantener los niveles de voltajes constantes después de pequeños disturbios, estos pueden ser cambios incrementales relacionados con la demanda. Este concepto es utilizado en la evaluación constante de los voltajes y su reacción ante pequeños cambios que consideran las cargas del sistema. Las ecuaciones referentes al sistema requieren realizar un proceso de linealización para un correcto análisis, permitiendo así la posibilidad de evaluar la sensibilidad de los factores que influyen sobre el voltaje. A pesar de lo antes expuesto, hay que considerar el hecho de que este procedimiento no permite la explicación de efectos no lineales producidos en los controles. Por lo tanto, la manera de resolver estas complicaciones es mediante la implementación de manera combinada de técnicas lineales y no lineales para el análisis de su estabilidad, (López, 2008).

**iv. Estabilidad de voltaje a corto plazo.**

La estabilidad de corto plazo hace referencia a los cambios en el tiempo de elementos pertenecientes a la demanda del sistema (como motores). Su estudio considera un periodo de interés en el orden de varios segundos, y para su análisis se requiere encontrar soluciones para las ecuaciones diferenciales, de manera similar al análisis referente al estudio del ángulo referente a su estabilidad, (Castaño & Torres, 2009).

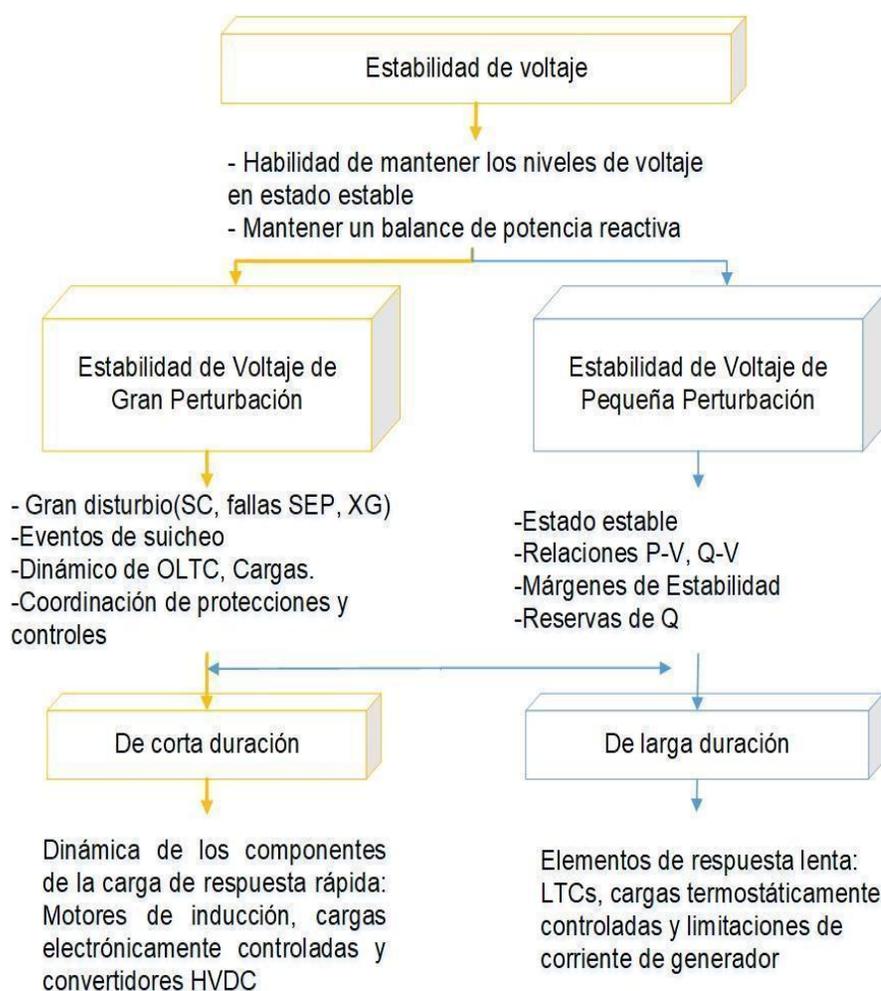
**v. Estabilidad de voltaje a largo plazo.**

Hace referencia al comportamiento de la red en el orden de los minutos, con la finalidad de poner a prueba la manera en la que responde el sistema ante un crecimiento sostenido generado a partir de variaciones en la demanda. Debido a esto, es de suma importancia realizar correctamente el modelo en estado dinámico de las

demandas (cargas) y de los demás elementos presentes en una red, como los transformadores con cambio de tomas (LTC), el control de la sobreexcitación de los generadores, la compensación shunt, etc, (Castaño & Torres, 2009). En la Figura 2, se muestra de forma gráfica la clasificación de la estabilidad de voltaje.

**Figura 2**

*Clasificación de la estabilidad de voltaje*



*Nota.* En esta gráfica se muestra, la clasificación de la estabilidad de voltaje y los elementos que pueden producir este fenómeno. Obtenido de, (Castaño & Torres, 2009).

## vi. Factores que causan inestabilidad de voltaje

Los principales factores son:

- Aumento de la carga, o exceso de la misma en el sistema.
- Grandes distancias entre generación y carga.
- Niveles de voltaje bajos presentes en bornes de generación.
- Restablecimiento de la carga vía operación de transformadores con OLTC.
- Desempeño de equipos SVC (condensadores, compensadores sincrónicos, etc.).
- Falta de inyección reactiva necesaria para las cargas.
- Balance de potencia reactiva (demanda excesiva, generación insuficiente).
- Pobre coordinación entre varios sistemas de control y protección.

Todos estos factores derivan en una nueva contingencia, conocida como colapso de voltaje el cual está íntimamente relacionado con el estudio de estabilidad de voltaje.

## vii. Causas por las que un SEP puede alcanzar un colapso de voltaje

Desde un punto de vista físico las causas fundamentales para que el sistema alcance el colapso son:

- **Potencia reactiva generada/absorbida por los generadores.**

Si los voltajes de consigna no poseen una magnitud correcta, la regulación de potencia reactiva de los generadores, puede derivar en corrientes por las líneas demasiado elevadas provocando considerables caídas en los voltajes de las barras del sistema.

- **Sistemas con grandes desequilibrios generación-demanda entre áreas (grandes transferencias de energía entre áreas).**

Al exceder los límites en la transmisión de energía a través de las líneas, se provoca un aumento en las corrientes presentes en ellas, lo que contribuye a grandes caídas de voltaje.

- **Grupos en sus límites de generación o absorción de potencia reactiva.**

Al saturar la generación de potencia reactiva referente a GS, se concluye en bajos niveles de voltaje para su consigna. Esto provoca que, para transportar la misma cantidad de energía hacia nodos presentes en la cercanía, la corriente presente en las líneas se incrementa, que provoca el mismo efecto en las caídas de voltaje presentes en dichas líneas.

- **Pérdida de uno o más elementos de la red: líneas, generadores, transformadores, etc.**

Para elementos presentes en la etapa de transmisión como lo son transformadores y líneas, es de vital importancia que no se pierda su presencia, pues de llegar a ocurrir se producen complicaciones como el aumento en los flujos por las líneas que no salieron de funcionamiento, lo que deriva en pérdidas mucho más elevadas. Y por parte de los generadores, si se llega a perder en gran parte, esta caída es asumida por los demás generadores, concluyendo en que los bloques de energía a transportar se incrementen.

### **viii. Estudios de estabilidad de voltaje**

Pese a que la estabilidad de voltaje es un fenómeno de naturaleza fundamentalmente dinámica, el grado de estabilidad de voltajes se puede medir utilizando un modelo estático, (Ríos, Torres, & Torres, 2000). Por lo tanto, este

fenómeno puede estudiarse ya sea con consideraciones estáticas o dinámicas.

Dependiendo de la naturaleza de la perturbación y de la estabilidad de voltaje del sistema/subsistema puede considerarse como un fenómeno lento y rápido, (Kotari & Nagra, 2008).

#### **ix. Métodos de estudio de la estabilidad de voltaje**

Los métodos de estudio para el análisis de la estabilidad de voltaje buscan detectar y predecir cambios en la estabilidad. Estos métodos son utilizados para representar el modo en el que operan los nodos de un SEP y los métodos de predicción tienen como objetivo de encontrar límites de operación para el voltaje (márgenes de operación) para una operación segura. Todos estos estudios se realizan mediante métodos analíticos y de monitoreo, (Candelo, Caicedo, & Castro, 2008).

- **Métodos analíticos**

Son utilizados para el estudio en detalle de las causas y efectos de la estabilidad de voltaje, así también el comportamiento de las variables y elementos que se involucran en el sistema. Los resultados obtenidos sirven para dar respuesta de manera preventiva además de correctiva referente a su estabilidad. Para ello, utilizan técnicas basadas en conceptos matemáticos las cuales requieren de herramientas computacionales para el análisis de SEP complejos. Una característica de este tipo de estudios es que se los realiza en forma estática, con métodos basados en flujos de potencia convencionales y flujos progresivos. Además, es posible realizar análisis dinámicos del estado del sistema en estado transitorio, de pequeña señal y cuasi estacionarios (Candelo, Caicedo, & Castro, 2008).

- **Métodos de monitoreo**

Son técnicas que están basadas en la obtención de datos reales permitiendo encontrar los estados de operación, zonas “críticas” de la red, el margen en los límites de estabilidad, estos métodos son utilizados como herramientas de detección y predicción, (Candelo, Caicedo, & Castro, 2008).

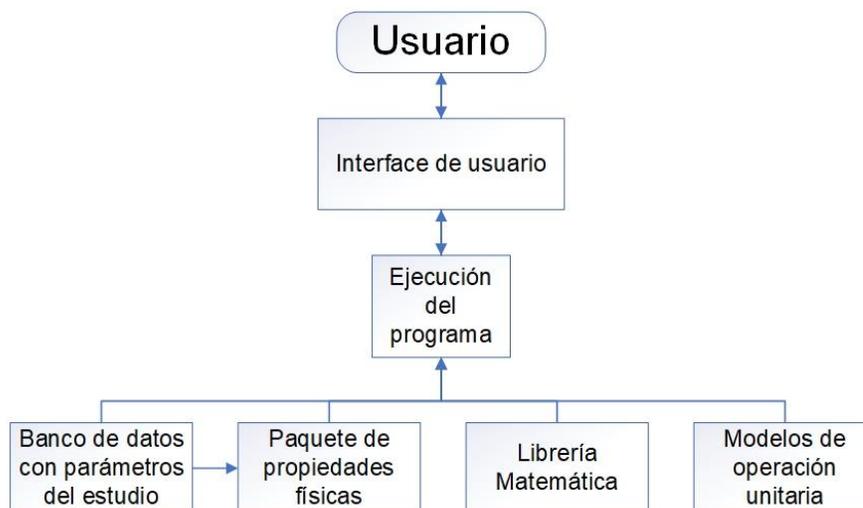
## **2.2. Modelamiento del sistema**

El modelamiento de un sistema es la representación de un determinado objeto o grupo de objetos mediante un conjunto de ecuaciones que intentan representar el comportamiento del mismo. Esta representación permite observar diferencias entre la realidad y lo mostrado por el modelo sobre el comportamiento del sistema. Si las diferencias que se obtienen son relevantes se puede justificar la implementación de un mejor modelo el cual solucione todas estas diferencias dando una mejor representación del objeto, (Cisa, 2015).

En la actualidad el desarrollo tecnológico ha permitido que la industria vaya creando programas especializados para el modelamiento exacto de sistemas complejos. En la Figura 3, se muestra la arquitectura básica de un programa de modelamiento y simulación.

**Figura 3**

*Arquitectura básica de un programa de modelamiento y simulación*



*Nota.* En la figura se muestra la arquitectura básica, que siguen los programas para la ejecución de las simulaciones Obtenido de (Cisa, 2015).

A continuación, se realiza una breve explicación de los tipos de modelos utilizados en este estudio.

### **2.2.1. Modelo en estado estacionario**

Un modelo en estado estacionario es la representación de un sistema donde los parámetros que se desean analizar no varían en el tiempo, es decir no presenta cambios a medida que el tiempo fluye, (Bulmaro, 2020).

Algunos de los problemas que se pueden analizar con simulaciones utilizando modelos en estado estacionario son:

- **Problemas de optimización.** - Se resuelven mediante el planteamiento de una función objetivo que permita encontrar la solución a un proceso específico. Para esto se añaden restricciones y grados de libertad para

que, en base a estas, el programa tome decisiones y así llegar a solucionar el problema.

- **Problemas de diseño.** - Estudia diferentes conjuntos de especificaciones, valorando los parámetros existentes.
- **Estudios de sensibilidad.** - Permite estudiar la influencia de ciertos parámetros en el funcionamiento adecuado de un sistema.
- **Problemas de síntesis.** - Con los datos de entrada y salida se desea conocer las condiciones de operación y los parámetros de los equipos.

### ***2.2.2. Modelo en estado dinámico***

En un modelo en estado dinámico las variables de un sistema se consideran en función del tiempo, de manera que son capaces de describir trayectorias temporales. Generalmente un modelo dinámico constituye una descripción matemática, por ello uno de los modelos dinámicos más utilizados en la ingeniería es la ecuación diferencial. Y para describir la dinámica de un proceso se utilizan varias ecuaciones diferenciales. En la mayoría de los casos estos modelos son aproximaciones precisas del sistema, dependiendo de las variables que se toman en cuenta y las que no al momento de su implementación. La ecuación [1] describe de forma general la representación matemática de un sistema de una entrada y una salida (sistema SISO), (Oviedo, 2003).

$$f(y, \dot{y}, \ddot{y}, \dots, y^n, u, \dot{u}, \ddot{u}, \dots, u^m) = 0 \quad [1]$$

### ***2.2.3. Simulaciones en el Dominio del tiempo***

Las simulaciones en el dominio del tiempo evalúan el comportamiento dinámico del SEP, donde ecuaciones no lineales son resueltas simultáneamente. Este método evalúa el estado del sistema antes, durante y después de haber ocurrido una falla, para

lo cual se consideran los modelos detallados de los diferentes componentes del sistema consiguiendo resultados más confiables, (Chamba, Vargas, & Cepeda, 2018).

### 2.3. Despacho económico multinodal DC

Un despacho económico es un modelo en estado estacionario pues se resuelve un problema de optimización. El objetivo de un despacho económico es encontrar, para un determinado periodo de tiempo, la potencia con la que debe aportar cada una de las unidades de generación, de modo que, todas las cargas del sistema sean satisfechas al menor costo cumpliendo con las restricciones técnicas de la red y de las unidades de generación (Anjos & Conejo, 2017).

A continuación, se definen algunos aspectos que se deben considerar para realizar un despacho económico.

- **Considerar límites técnicos para GS:** Esto se debe a que las unidades de generación convencionales no pueden operar con potencias menores a la potencia mínima o exceder la potencia máxima para los que fueron diseñados, (Anjos & Conejo, 2017). Los límites técnicos se pueden definir de la siguiente forma:

$$P_g^{min} \leq P_{gt} \leq P_g^{max} \quad [2]$$

Donde:

$P_g^{min}$  = Es el mínimo técnico de la unidad de generación.

$P_g^{max}$  = Es el máximo técnico de la unidad de generación.

$P_{gt}$  = Es la potencia generada por la unidad de generación.

- **Límites de rampa para GS:** Esto se debe a que ninguno de estos generadores puede tomar abruptamente carga, pues poseen un límite denominado “límite de aceleración” el cual también depende del tipo de central. De igual forma si una unidad de generación se encuentra apagada y se la dispone a arrancar posee un límite conocido como “límite de rampa de arranque”, (Anjos & Conejo, 2017).
- **Límites de capacidad de transmisión de las líneas:** Las líneas de transmisión, por razones físicas, cuentan con un límite al momento de transmitir una cierta cantidad de energía, relacionado a consideraciones térmicas o de estabilidad. Por lo cual una línea de transmisión no debe superar su límite de capacidad, (Anjos & Conejo, 2017).
- **Definir un horizonte de planificación:** Un horizonte de planificación representativo es un día distribuido en 24 horas. Los intervalos de tiempo se indican con el índice  $t$  (Anjos & Conejo, 2017), como se muestra en [3]:

$$t = 1, 2, \dots, N^T \quad [3]$$

Donde  $N^T$ , es el número de periodos de tiempo en el horizonte de planificación, los cuales pueden estar en una resolución de minutos u horas.

Adicionalmente en un despacho económico donde se considera generación renovable es necesario definir sus modelos, estos dependen del tipo de tecnología y recurso primario que utilicen. Los modelos considerados en este estudio son expuestos a continuación:

- **Modelo para generación eólica**

La generación eólica es aquella que utiliza la velocidad del viento como su recurso principal, la potencia de generación al utilizar este recurso se expresa matemáticamente de la siguiente forma:

- Cálculo de la potencia disponible.

$$P_W = \frac{1}{2} \left( \delta * A_{barrido} * v^3 * \left( \frac{P_{GE_{nom}}}{P_{GE_{turbina}}} \right) \right) \quad [4]$$

Cálculo del coeficiente de potencia ( $cp$ ): Se obtiene a partir de la curva potencia velocidad, relación técnica que cada fabricante especifica para sus aerogeneradores. El  $cp$  se calcula mediante la ecuación [5].

$$cp = \frac{P_{nom_{v_i}}}{0.5 * \eta_{aerogenerador} * A_{barrido} * v^3} \quad [5]$$

- Cálculo de la potencia eólica generada.

$$P_{GE} = P_W * cp \quad [6]$$

Donde:

$P_{GE}$  = Potencia de generación eólica.

$P_{nom_{v_i}}$  = Potencia nominal del aerogenerador a una cierta velocidad, curva potencia velocidad del aerogenerador.

$\eta_{aerogenerador}$  = Eficiencia del aerogenerador.

$P_W$  = Potencia eólica disponible.

$\delta$  = Densidad de aire en  $[kg/m^3]$ .

$A_{barrido}$  = Área de barrido de las palas.

$v$  = Velocidad del viento en  $[m/s]$ .

$P_{GE_{nom}}$  = Potencia nominal del aerogenerador.

$P_{GE_{turbina}}$  = Potencia de la turbina del aerogenerador.

$cp$  = Coeficiente de potencia.

- **Modelo para generación solar**

La generación solar o mejor conocida como generación fotovoltaica, es aquella que aprovecha la radiación que emite el sol hacia la tierra, la potencia eléctrica que se puede generar con este recurso se especifica a continuación.

- Cálculo del número de paneles.

$$\#Paneles = P_{GS_{nominal}}/P_{GS_{panel}} \quad [7]$$

- Área total de la planta fotovoltaica.

$$A_{total} = A_{panel} * \#Paneles \quad [8]$$

- Potencia eléctrica generada.

$$P_{GS} = \eta_{panel} * \eta_{instalación} * A_{total} * Ir \quad [9]$$

Donde:

$\#Paneles$  = Número total de paneles de la planta fotovoltaica.

$P_{GS_{nominal}}$  = Potencia nominal de diseño de la planta fotovoltaica.

$P_{GS_{panel}}$  = Potencia nominal de diseño del panel a una irradiancia de  $1000[W/m^2]$ .

$A_{total}$  = Área total de la planta fotovoltaica en  $[m^2]$ .

$A_{panel}$  = Área del panel en  $[m^2]$ .

$P_{GS}$  = Potencia de generación solar en  $[W]$ .

$\eta_{panel}$  = Eficiencia del panel.

$\eta_{instalación}$  = Eficiencia de la instalación.

$I_r$  = Irradiancia solar en  $[W/m^2]$ .

- **Modelo para generación hidráulica**

La generación hidráulica, es una tecnología con muchos años de desarrollo en países con recurso hídrico abundante, a este tipo de tecnología se la considera generación convencional renovable, pues utiliza GS, pero su recurso primario es renovable. La potencia eléctrica que se puede generar a partir de este tipo de centrales depende del tipo de central que se esté interesado en estudiar, pues existen 3: las centrales de embalse, centrales serie y las centrales de paso. En el caso de esta última la potencia eléctrica a generar depende del caudal existente, como se presenta a continuación:

- Cálculo de la potencia hidráulica.

$$P_H = \rho * g * Q * h \quad [10]$$

- Potencia total generada.

$$P_{TH} = P_H * \eta \quad [11]$$

Donde:

$P_H$  = Potencia hidráulica.

$\rho$  = Densidad del agua en  $[kg/m^3]$ .

$g$  = Aceleración de la gravedad en  $[m/s^2]$ .

$Q$  = Caudal de agua en  $[m^3/s]$ .

$h$  = Altura de caída en  $[m]$ .

$\eta$  = Eficiencia de la planta hidráulica.

#### **2.4. Inteligencia Artificial**

La inteligencia artificial (IA), se define como la habilidad presente en las máquinas para que mediante algoritmos, aprendan sobre la información presente en los datos y utilizarlo posteriormente para tomar decisiones, de manera similar a como lo haría un ser humano, con la diferencia de que los dispositivos no necesitan descansar y al mismo tiempo pueden analizar grandes volúmenes de datos a un ritmo mucho más acelerado y con un porcentaje de error considerablemente menor, (Case, 2020).

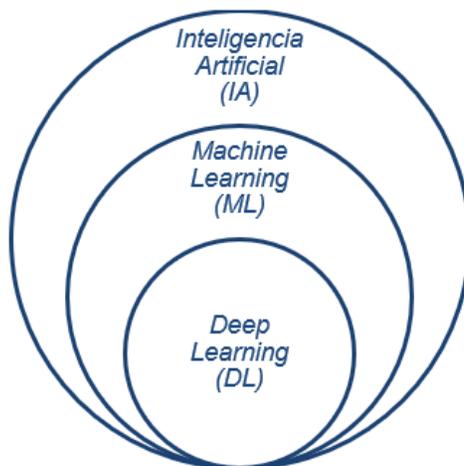
La IA actualmente es aplicada en gran cantidad de procesos y aplicaciones específicos y del día a día, a continuación, se enlistan los más importantes:

- Reconocimiento de imágenes estáticas
- Clasificación y etiquetado
- Mantenimiento predictivo
- Detección y clasificación de objetos

Como se puede ver la IA tiene varios campos de aplicación, por lo que para facilitar su estudio y tener una mejor comprensión es clasificada siguiendo la estructura mostrada en la Figura 4.

## Figura 4

*Clasificación de IA según las tareas a ejecutar*



*Nota.* En la figura se presenta la clasificación de la Inteligencia artificial.

Para profundizar el aprendizaje respecto estas técnicas, son descritas a continuación, pero se da mayor enfoque a ML ya que es la técnica empleada en esta investigación.

### **2.4.1. Deep Learning (DL)**

Se trata del subcampo de IA utilizado para solucionar problemas complejos y que normalmente implican bases de datos sumamente grandes. La mayor aplicación de este tipo de aprendizaje se da mediante el uso de redes neuronales, las mismas se organizan en capas para reconocer relaciones o patrones que son muy complejos presentes en la base de datos, (Kiril & Potenves, 2020).

### **2.4.2. Machine Learning (ML)**

“Es el campo de estudio que le da a las computadoras la habilidad de aprender sin la necesidad de ser programadas explícitamente. ML utiliza una combinación de

algoritmos que le permiten acceder a datos y usarlos para aprender de ellos”, (Jiawei & Kamber, 2007).

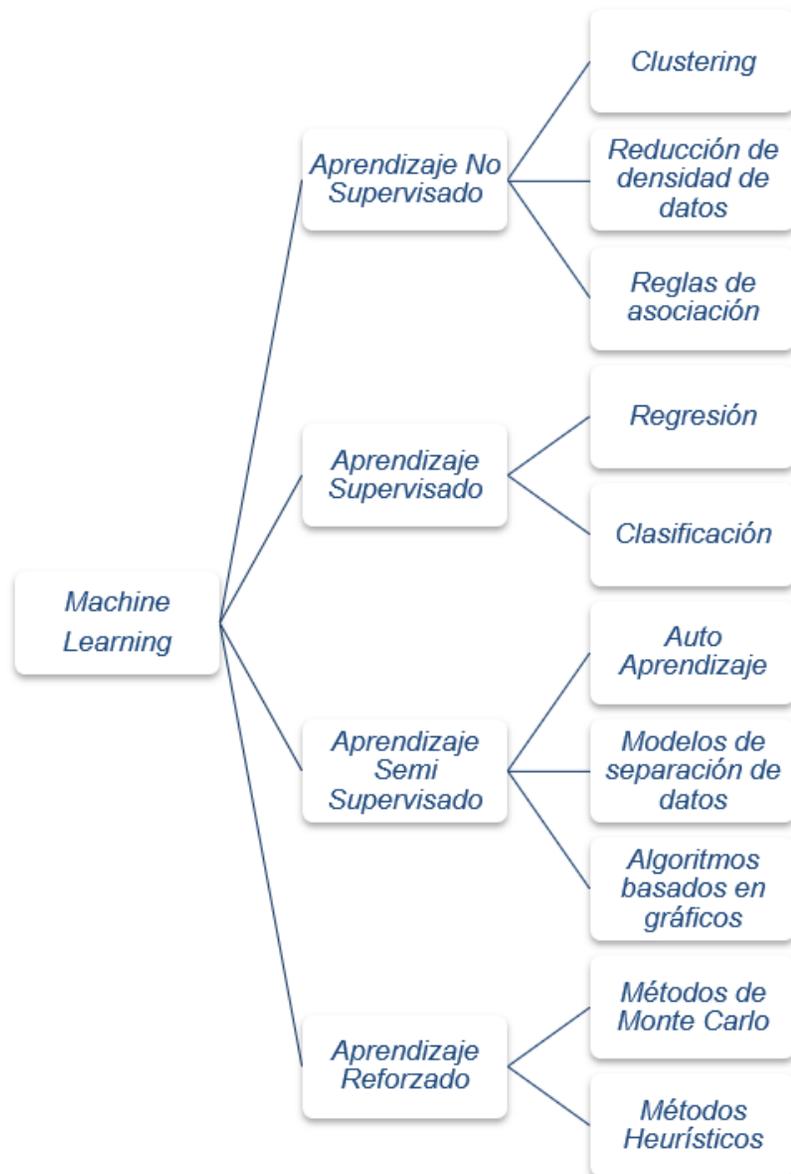
ML sirve para:

- Resolver problemas cuyas soluciones tradicionalmente requieren una extensa generación de códigos o que a su vez requieran de una gran lista de reglas y restricciones. Un algoritmo de ML puede en la mayoría de los casos, simplificar el código y muchas de las veces con un mejor desempeño que los métodos tradicionales.
- Es capaz de cambiar de ámbito, se adaptan fácilmente a nuevas bases de datos, (Kiril & Potenves, 2020).

La clasificación de ML principalmente se divide en 4 tipos de conocimientos como se muestra en la Figura 5.

**Figura 5**

*Clasificación de ML según el tipo de aprendizaje*



*Nota.* En la figura se muestra la clasificación de ML con los métodos de aprendizaje y los algoritmos que se utilizan.

### i. Aprendizaje supervisado.

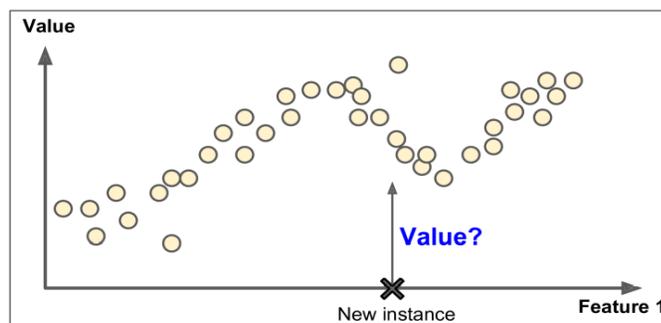
Este tipo de algoritmos elaboran modelos basados en datos de entrenamiento que son capaces de ser utilizados para clasificar o predecir un valor en específico. Este tipo de algoritmos requieren de la intervención humana para proporcionar una retroalimentación durante la validación de su entrenamiento, (Géron, 2019).

Dentro del aprendizaje supervisado existen 2 categorías principales:

- **Regresión:** Este tipo de algoritmo busca predecir un valor específico (variable dependiente), basado en un grupo de variables que son llamadas variables independientes o predictores. Para entrenar el algoritmo es necesario darle ejemplos de valores para la variable dependiente junto con sus respectivos valores para las variables independientes, de esta manera el algoritmo encuentra relaciones o patrones, almacenando este conocimiento para utilizarlo al momento de predecir un nuevo valor, (Géron, 2019).

#### Figura 6

*Representación gráfica del funcionamiento de regresión*

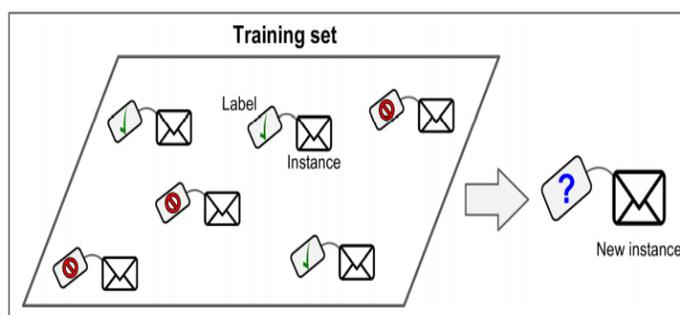


*Nota.* En la figura se muestra el principio de funcionamiento para los algoritmos basados en regresores. Obtenido de, (Géron, 2019).

- Clasificación:** Este tipo de algoritmo a diferencia de predecir un valor, tiene como objetivo predecir una categoría. La diferencia radica en que los algoritmos buscan relaciones en los valores de las variables independientes de tal manera que las variables dependientes formen grupos con características similares entre ellas, (Géron, 2019).

**Figura 7**

*Ejemplo básico en el aprendizaje supervisado para clasificación*



*Nota.* En esta figura se presenta el principio de funcionamiento de los algoritmos para clasificación. Obtenido de, (Géron, 2019).

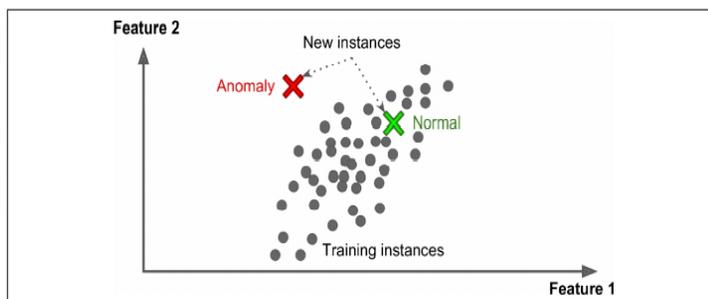
Los algoritmos más utilizados en este tipo de aprendizaje son: K-Nearest Neighbors, Linear Regression, Logistic Regression, SVMs, Decision Tree, Random Forests y Artificial Neural Networks, (Géron, 2019).

## ii. Aprendizaje no supervisado.

Este tipo de aprendizaje el algoritmo recibe los datos sin una clasificación previa, donde el objetivo es encontrar similitudes entre ellos y formar grupos en base a estas. Además, pueden ser usados para la detección de variaciones o anomalías dentro de un grupo de datos al encontrar características que salen de un determinado patrón.

**Figura 8**

*Ejemplo básico en el aprendizaje no supervisado*



*Nota.* En esta figura se presenta el principio de funcionamiento de algoritmos utilizados en aprendizaje no supervisado. Obtenido de, (Géron, 2019).

Las técnicas más usadas y estudiadas de aprendizaje no supervisado son:

- **Clustering:** Su objetivo es agrupar instancias similares en grupos. Sus aplicaciones son múltiples pudiendo ir desde segmentación de bases de datos, motores de búsqueda, entre otros.
- **Detección de anomalías:** Su objetivo es aprender qué es “normal” dentro de una base de datos y usar esa información para detectar instancias “anormales” (Ej: productos defectuosos en una línea de producción).

Los algoritmos más usados en el aprendizaje no supervisado son:

- **Clustering:** K Means, DBSCAN, Hierarchical Classification Algorithms (HCA).
- **Detección de anomalías y detección de novedades:** Subclase de SVM, Isolation Forest.

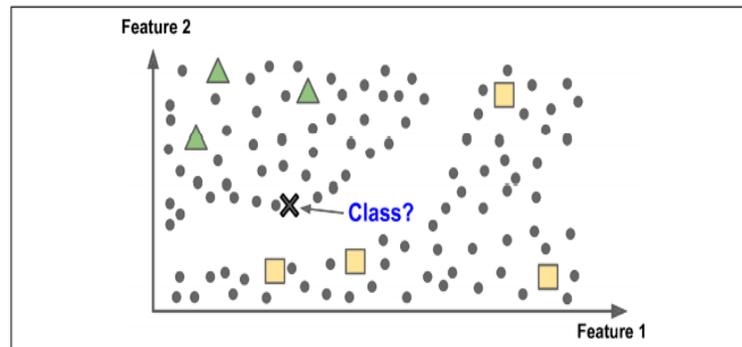
### iii. Aprendizaje semi supervisado.

Esta categoría hace referencia a los algoritmos capaces de trabajar con datos parcialmente organizados, esto quiere decir que la base de datos estará conformada

por datos que fueron correctamente agrupados e identificados y una gran parte de ellos que no han sido ni agrupados ni identificados.

### Figura 9

*Ejemplo básico en el aprendizaje semi supervisado*



*Nota.* En esta figura se muestra el principio de funcionamiento para los algoritmos con aprendizaje semi supervisado. Obtenido de, (Géron, 2019).

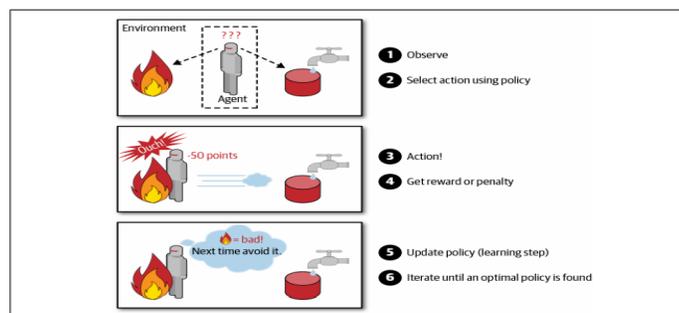
Un ejemplo es el Deep Belief Network (DBN's), este algoritmo se basa en modelos no supervisados llamados Boltzmann Machines (RBM'S), (Géron, 2019).

#### iv. Aprendizaje reforzado.

Esta categoría hace referencia a los algoritmos que aprenden de la experiencia, es decir que son premiados cuando realizan una predicción correcta y son sancionados cuando fallan mediante el uso de un subsistema llamado "agente", el cual se configura de manera interna pues posee un sistema de ganancias y penalizaciones, (Géron, 2019).

## Figura 10

### Ejemplo básico en el aprendizaje reforzado



*Nota.* Esta figura muestra un ejemplo del funcionamiento del aprendizaje reforzado. Obtenido de, (Géron, 2019).

La mayor aplicación del aprendizaje reforzado se encuentra en los métodos de Monte Carlo y Heurísticos, (Kiril & Potenves, 2020).

### 2.4.3. Pre-procesamiento de los datos

Independientemente de la aplicación que se implemente en ML el primer paso a realizar es el pre-procesamiento de los datos. Para ello existen varias etapas, aunque hay que tomar en cuenta que estas pueden variar dependiendo del algoritmo que se vaya a usar. De manera general a continuación se enlistan los pasos que pertenecen al preprocesamiento de los datos, (Kiril & Potenves, 2020).

- Organización de los datos
- Tratamiento de los datos faltantes
- Codificar categorías
- División de los datos
- Escalamiento de los datos

#### 2.4.4. Algoritmos de ML usados en la investigación.

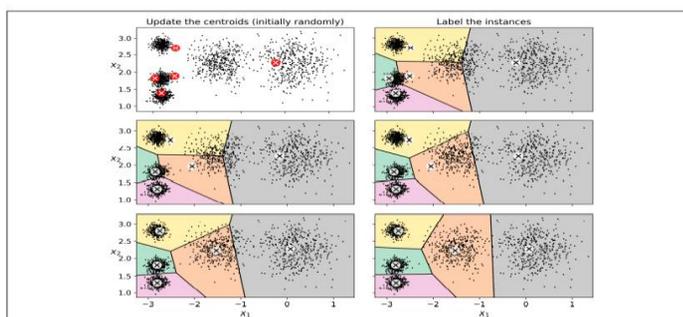
##### i. Aprendizaje no supervisado.

- **K-MEANS**

K-means busca agrupar los datos en  $n$  grupos con la asignación de centroides aleatorios mediante la dispersión de la data, tratando de formar grupos cercanos a estos puntos específicos. El principio de funcionamiento del algoritmo es elegir  $k$  instancias como centroides de manera aleatoria, luego etiqueta cada instancia y actualiza el centroide, este proceso se realiza hasta que los centroides se dejan de mover, es decir la distancia media entre las instancias de cada cluster es muy pequeña en comparación a las otras instancias cercanas. En la Figura 13, se puede observar de manera gráfica como el algoritmo va actuando en cada iteración hasta encontrar los centroides. Cabe recalcar que el número de iteraciones no es infinito y que usualmente son pocas, por ello, este algoritmo no posee buen funcionamiento cuando la dispersión gráfica de los puntos es muy amplia, (Kiril & Potenves, 2020).

#### Figura 11

*Representación gráfica del funcionamiento de K-Means*



*Nota.* En la figura se presenta el principio de funcionamiento para algoritmos de clustering. Obtenido de, (Géron, 2019).

Adicionalmente se debe tener en cuenta que el número de clusters que se vayan a formar depende de la base de datos con la que se esté trabajando, para determinar un número ideal de clusters existen dos herramientas aplicables al uso de K-Means, las cuales se muestran a continuación:

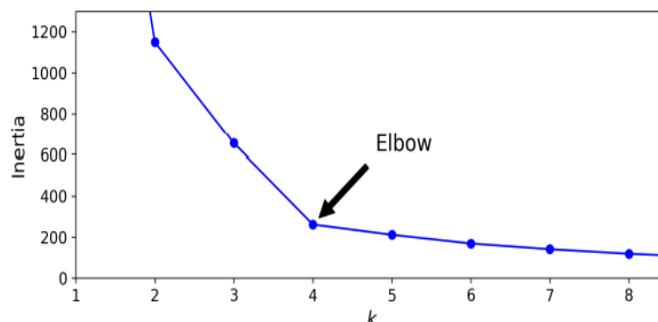
- ***La regla del codo***

Esta herramienta hace referencia a la inercia de los datos, es decir cuánto va a cambiar la precisión del algoritmo si se aumenta o disminuye la cantidad de clusters para su división, (Géron, 2019). El objetivo de esta herramienta es encontrar un punto de quiebre (conocido como codo), donde la pendiente de la inercia en función del número de clusters deje de presentar una variación significativa.

En la Figura 14, se muestra de forma gráfica la representación de la regla del codo, donde: en el eje de las abscisas se encuentran la cantidad de clusters y en el eje de las ordenadas la inercia de la base de datos. Aquí se observa que la inercia posee una pendiente pronunciada para 2 y 3 clusters, mientras que desde 4 clusters en adelante se observa un aplanamiento de la misma, es decir la variación de la inercia ya no es significativa. Por tal razón en  $k=4$  se cumple con la regla del codo, siendo este el número ideal de clusters para este ejemplo.

**Figura 12**

*Selección de la cantidad de clusters “Regla del codo”*



*Nota.* En la figura se muestra la regla del codo, donde el punto de quiebre representa el número de clústeres necesarios para la base de datos seleccionada. Obtenido de, (Géron, 2019).

- **Coefficiente de silueta**

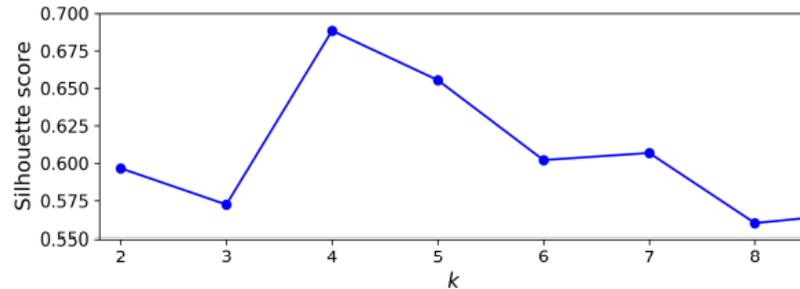
El coeficiente de silueta es una métrica utilizada en algoritmos de clustering para evaluar la calidad del agrupamiento, su objetivo es determinar el número óptimo de grupos en los que se debe segmentar la data, (Bachero, 2015). Es un método más preciso que la regla del codo, pero requiere mayores recursos computacionales.

Este coeficiente relaciona la diferencia media entre las instancias de un mismo cluster y la diferencia con el cluster más cercano. Sus valores están comprendidos entre -1 y 1 donde el número de cluster que más se acerque a 1 es el número ideal de grupos a formar, (Géron, 2019).

En la Figura 13, se muestra el coeficiente de silueta aplicado a un caso de clustering, aquí se puede observar que para este ejemplo el valor más cercano a 1 se obtiene cuando se elige 4 clusters.

**Figura 13**

*Selección del número  $k$  de clusters usando el coeficiente de silueta*



*Nota.* En la figura se muestra el diagrama de silueta utilizado en problemas de clustering. Obtenido de, (Géron, 2019).

## ii. Aprendizaje supervisado

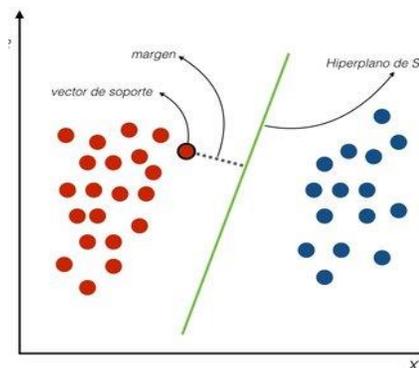
### • Support Vector Regression (SVR)

El principio de funcionamiento de este algoritmo implica encontrar el margen máximo de separación de los datos, mediante el movimiento de un hiperplano haciendo uso de vectores de soporte. Este proceso se repite hasta que el hiperplano se adapta de mejor manera a todos los datos y al mismo tiempo encuentra un balance en la complejidad del modelo y el error en la predicción, (Kiril & Potenves, 2020).

Una de las grandes ventajas de SVR es que no depende de la dimensión de los datos de entrada. Adicionalmente tiene un excelente rango de predicción, aunque no es muy recomendable en bases de datos sumamente grandes. El principal uso de SVR se recomienda en bases de datos donde no exista una relación lineal entre ellos.

**Figura 14**

*Representación gráfica de SVR*



*Nota.* En la figura se presenta el principio de funcionamiento del algoritmo de SVR. Obtenido de, (Kiril & Potenves, 2020).

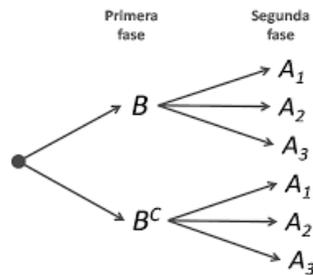
- **Decision Tree (DT)**

Es la representación de una función que evalúa cada instancia bajo un determinado criterio, este tipo de algoritmo realiza predicciones mediante la división de la data en varios bloques que cumplen determinada condición. El algoritmo usa la desviación estándar para estas divisiones, donde en cada una ellas el valor de desviación debe ir disminuyendo hasta llegar a la menor cantidad posible, (Géron, 2019).

En la Figura 15, se muestra el principio de funcionamiento de DT, aquí se puede observar cómo el algoritmo va tomando decisiones en función de las condiciones que se van formando a partir de los datos.

**Figura 15**

*Representación gráfica de la estructura de un DT*



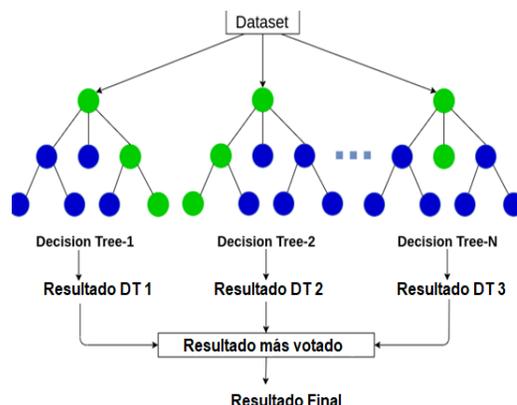
*Nota.* En la figura se presenta el principio de funcionamiento del algoritmo Decision Tree. Obtenido de, (Géron, 2019).

- **Random Forest (RF)**

Se puede decir que Random Forest es un caso particular de DT o mejor dicho es un conjunto de DT. Este método introduce extra aleatoriedad al momento de tomar decisiones en la construcción de los árboles, ya que en lugar de buscar la característica que mayor disminución tiene en la desviación, RF genera varios árboles de decisión con diferentes características y selecciona aquella que con más frecuencia se haya repetido, (Case, 2020).

Figura 16

Representación gráfica de RF



*Nota.* En la figura se presenta el principio de funcionamiento del algoritmo Random Forest. Obtenido de, (Case, 2020).

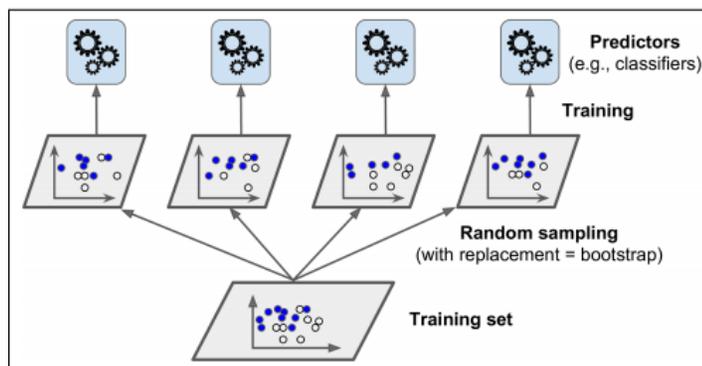
Como ventaja sobre DT se tiene que genera mejores resultados de manera general, pues DT suele ser muy casuístico apegándose mucho a los datos de entrenamiento, la extra aleatoriedad de RF soluciona este problema.

- **Bagging & Pasting (B&P)**

Este tipo de algoritmo usa múltiples árboles de decisión entrenándolos con diferentes subgrupos de datos de una misma base, consiguiendo así mayor diversificación en las predicciones. Tiene 2 formas de funcionamiento: la primera es entrenar más de una vez cada árbol con un subgrupo de datos distinto (Bagging) y la otra es entrenar todos los árboles con los subgrupos de datos solo una vez (Pasting), (Géron, 2019).

Figura 17

Representación gráfica del funcionamiento de B&P



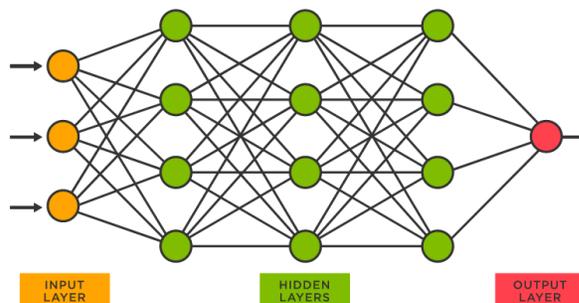
*Nota.* En la figura se presenta el principio de funcionamiento para el algoritmo B&P. Obtenido de, (Géron, 2019).

- **Redes Neuronales Artificiales (ANN)**

Las ANN tienen su nombre debido a que hacen analogía al funcionamiento del cerebro humano, específicamente al sistema nervioso, donde cada neurona posee baja capacidad de procesamiento, pero el conjunto de ellas tiene una capacidad sumamente mayor. De forma análoga las ANN se forman a partir de capas, las cuales relacionan los datos de entrada con funciones de activación, generando un sistema de ponderación de las mismas por pesos que representan su importancia. En función de estos pesos las neuronas calculan el valor de la variable dependiente y lo comparan con el valor real que se encuentra dentro de los datos de entrenamiento. De esta manera se calcula su error y se reajustan los pesos hasta que el error sea el menor posible, (Kiril & Potenves, 2020).

**Figura 18**

*Representación gráfica de la estructura de una ANN*



*Nota.* En la figura se presenta el principio de funcionamiento para ANN. Obtenido de, (Kiril & Potenves, 2020)..

## 2.5. Trabajos previos relacionados

El uso de ML en el análisis de la estabilidad de voltaje ha tenido un gran desarrollo a lo largo del tiempo, un ejemplo de esto es que desde 1997 se ha propuesto el monitoreo de la seguridad de voltaje a través de redes neuronales (Chih-Wen, Chang, & Su, 1998), en 1998 se presentó un método de predicción y monitoreo en cada nodo del sistema usando redes neuronales y lógica difusa (Belhadj, Duwaish, Shwehdi, & Farag, 1998). En el año 2007 se propuso un control de tipo preventivo y de monitoreo referido a la estabilidad de voltaje con datos medidos de la red, para obtener los límites de estabilidad. (Zhao, 2007). En (Yun, Tengyu, Bing, Jing, & Zhongje, 2015), se presenta la implementación de DT, esta metodología permite evaluar el estado de la estabilidad de voltaje en el sistema eléctrico, utilizando herramientas computacionales para las simulaciones. En (Singh, Parida, Chauhan, & Choudhary, 2021), se presenta la implementación de redes neuronales basadas en la técnica de Levenberg Marquardt (LM) para pronosticar la inestabilidad del voltaje, los datos de entrada para el

entrenamiento de este modelo son la potencia activa y reactiva de los generadores del sistema.

Adicionalmente se menciona que la aplicación de ML en el estudio de un SEP no solo se limita a voltaje, pues como se observa en (Rahmann, Ortiz, Villalba, & Álvarez, 2017), se presenta una metodología relacionada a la ubicación y detección de puntos de operación críticos respecto a la estabilidad de frecuencia. La metodología termina de ser desarrollada en (Ortiz, Rahmann, Alvarez, Canizares, & Chritoph, 2020), donde se propone que una vez los puntos críticos han sido identificados se realiza un proceso de agrupación (clustering) implementando modelos de ML, de modo que se pueda realizar una filtración de los mismos dejando solo el peor escenario posible para evaluar la estabilidad de frecuencia usando TDS.

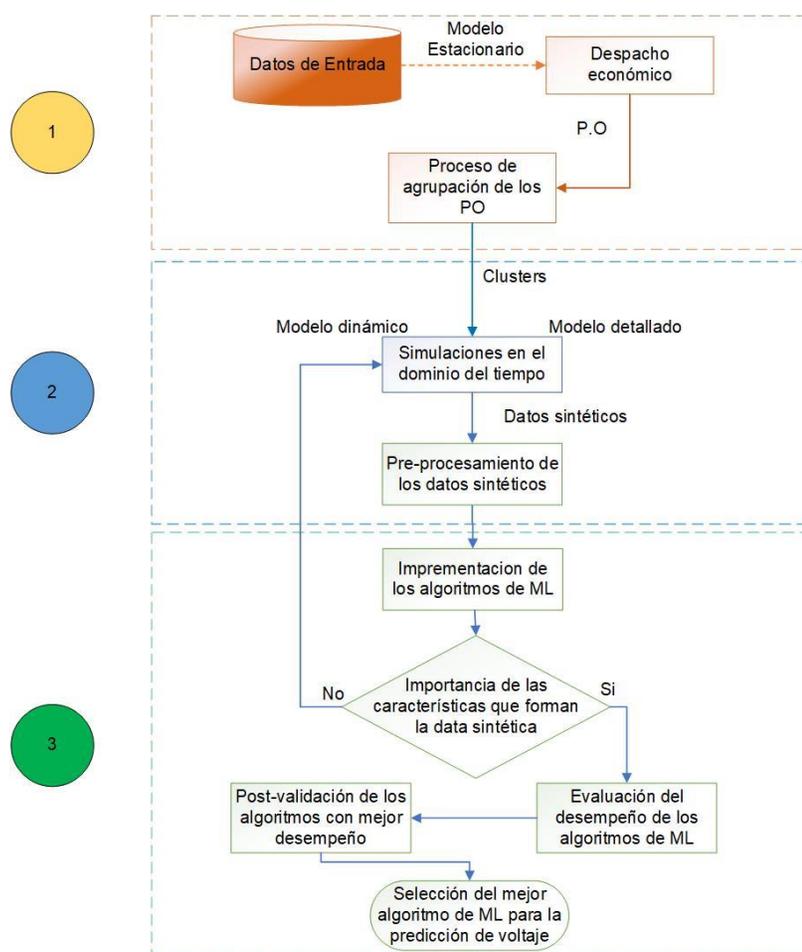
## Capítulo III

### 3. Metodología

En este capítulo se realiza una descripción de las etapas que se incluyen en este trabajo de investigación, el cual fue desarrollado en base a los antecedentes teóricos propuestos en el Capítulo II. La metodología se divide en tres etapas como se muestra en la Figura 19.

**Figura 19**

*Diagrama de la metodología general*



*Nota.* En la figura se muestra la metodología de la investigación dividida en tres etapas.

La primera etapa de esta metodología tiene como objetivo representar el modelamiento del SEP en estado estacionario, el cual es necesario para resolver el problema de despacho económico. Estas simulaciones incluyen las restricciones técnicas que posee el sistema como, por ejemplo: límites de generación (máximos y mínimos), máxima capacidad de transmisión de las líneas, entre otras. Los resultados del despacho son la potencia activa de las unidades de generación, más no se considera regulación de voltaje en las barras del sistema ni despacho de reactivos, ajustes necesarios para la definición de las condiciones iniciales del sistema que serán usadas en las TDS de la siguiente etapa debido a que se modela el despacho utilizando flujos DC. Dado que el horizonte de tiempo de la metodología es amplio, ajustar las condiciones iniciales para cada hora de despacho se convertiría en una tarea ardua. Para resolver este problema se realiza un proceso de clustering, el cual permite agrupar horas de despacho con condiciones similares donde, por cada grupo se obtiene un punto representativo conocido como centroide siendo el punto con mayor grado de similitud con el resto de elementos de cada grupo. De esta manera la hora de despacho designada como centroide en cada cluster, será la única cuyas condiciones iniciales se ajusten, pues estos ajustes (ajuste de taps, ajuste de set points en los AVR, activación de bancos de compensación reactiva, entre otros) servirán para el resto de elementos de cada grupo.

La segunda etapa de esta metodología utiliza los resultados obtenidos de la etapa anterior como parámetros de entrada de las TDS. Estas simulaciones analizan el comportamiento del sistema después de ocurrida una contingencia. La creación de eventos de falla permite determinar la evolución en el tiempo no solo del voltaje sino también de magnitudes que, tanto en la literatura como en investigaciones previas, han demostrado tener una estrecha relación con esta variable de interés (posibles

características relevantes). Para realizar estas simulaciones se hace uso de software especializado en el área eléctrica, pues estas herramientas poseen internamente el modelo dinámico de todos los elementos de un SEP. Adicionalmente, debido a la naturaleza variante que posee una excursión de voltaje, es necesario especificar el modelo detallado de ciertos elementos del sistema que permitan obtener una representación casi real del mismo. Con todos los modelos establecidos se ejecutan las TDS, permitiendo generar la data sintética.

La tercera y última etapa que se desarrolla en esta metodología hace referencia a la implementación de los algoritmos de ML para el análisis de la estabilidad de voltaje a partir de la data sintética obtenida en la etapa anterior. Como primer paso de esta etapa se realiza un pre-procesamiento de la data sintética, donde estos datos son acondicionados en base al requerimiento de cada algoritmo de interés. Una vez que se realiza este proceso, se procede a su implementación. El siguiente paso es evaluar la importancia de las posibles características relevantes mediante el uso de herramientas internas que poseen dichos algoritmos, permitiendo discriminar si son relevantes o no. Con las características relevantes ya definidas se realiza la validación de los algoritmos de ML, para lo cual se utiliza la métrica del RMSE, obteniendo así el desempeño de todos los algoritmos de interés. De esta manera se puede identificar las dos mejores alternativas para una última etapa de post-validación, logrando así obtener el mejor algoritmo para la predicción de voltaje.

### **3.1. Desarrollo de la metodología.**

A continuación, se explica en detalle la metodología descrita previamente.

### **3.1.1. Modelo en estado estacionario**

Para la generación del modelo en estado estacionario se especifican los parámetros de operación de los elementos presentes en el sistema, estos parámetros son necesarios para desarrollar e implementar el modelo de despacho.

### **3.1.2. Problema de despacho**

En esta etapa se resuelve el problema de despacho económico multinodal DC, el cual tiene como objetivo minimizar el costo del despacho para cada hora, mediante la combinación de todas las tecnologías de generación disponibles, tanto sincrónicas como ERNC, sujetas a restricciones técnicas del SEP.

La solución de este problema se logra a partir del planteamiento de la función objetivo, en ella se debe incluir todas las tecnologías de generación disponibles, además que en el caso de las tecnologías no renovables es necesario especificar su respectivo costo de generación debido a su recurso primario, y en el caso de las tecnologías renovables, el costo de vertimiento el cual aparece producto de una mala gestión en el uso de recursos primarios disponibles. De esta manera la potencia de despacho para cada generador se convierte en las variables a optimizar. Los resultados para cada tecnología tendrán como objetivo minimizar el costo total del despacho en base a los parámetros y restricciones que deberán ser definidos para cada hora de estudio, (Villamarín, Haro, Aguirre, & Ortiz, 2021). De manera general se puede decir que los parámetros necesarios para obtener el valor de la función objetivo son 4:

- **Parámetros de los GS:** Barras en las que están ubicados, costo del recurso primario, mínimos y máximos técnicos, reserva máxima y valores de rampa para toma de carga.
- **Parámetros de los generadores ERNC:** Barras en las que están ubicados, recurso primario disponible según la tecnología (sol, viento, afluyente).

- **Parámetros de las líneas de transmisión:** Barras a las cuales se conectan, flujos máximos y reactancias.

**Parámetros de las cargas:** Barras en las que se ubican y potencia activa consumida.

Adicionalmente a los parámetros de los elementos en la función objetivo se introduce la variable de holgura conocida como “energía no suministrada” (ENS). Esta variable permite que la función objetivo converja en el caso que no exista suficiente potencia de generación para cubrir la demanda.

Una vez que se han identificado y definido todos los parámetros y variables, es necesario plantear las restricciones de igualdad y desigualdad, las mismas que dependen de cada grupo de elementos en el SEP, entre ellas las ecuaciones de balance y flujos que se transmitirán por las líneas, límites de operación de las unidades de generación, entre otras. La formulación del problema de optimización se muestra en el Anexo 1.

Como datos de salida de esta etapa se obtienen:

- Costo del despacho del sistema.
- Potencia de despacho de cada generador, tanto sincrónico como renovable.
- Valor de los flujos por cada L/T.
- Valores de reserva para cada GS.
- Valores de vertimiento para cada tecnología renovable.

Adicionalmente se debe comprobar que no exista ENS, para ninguna de las horas bajo estudio.

### ***3.1.3. Proceso de agrupación de los puntos de operación***

Las horas de despacho obtenidas en la etapa anterior corresponden a los puntos de operación (P.O) del sistema. Sin embargo, en la industria estos resultados sólo

consideran el despacho de potencia activa desde el punto de vista económico y no se considera despacho de reactivos ni tampoco regulación de voltaje en las barras del sistema, (Llanos & Ortiz, 2016). Esta tarea es asignada a los operadores de red, que son los encargados de ajustar las condiciones operacionales del SEP con el objetivo de mantenerlo en estado normal de funcionamiento. El problema de regulación de reactivos y voltajes en barra se ve más complejo cuando el número de P.O. a ser analizado es grande debido que se requieren ajustar las condiciones iniciales del SEP para cada P.O. con el propósito de garantizar que las TDS reflejen el comportamiento del SEP ante una contingencia.

En esta metodología dado que los P.O se obtienen para un horizonte de tiempo representativo y que estos son la entrada para las TDS en la siguiente etapa, ajustar las condiciones iniciales para cada punto sería una tarea extenuante, pero al no realizarla, estas simulaciones tendrían un punto de partida erróneo y no reflejarán en realidad lo que va a suceder con el sistema ante una contingencia. Para resolver este problema en esta etapa se hace uso de la herramienta de ML conocida como clustering, la cual permite agrupar horas de despacho con condiciones similares. En concreto, se hace uso del algoritmo K-Means el cual además de dividir los datos en clusters permite obtener para cada uno de ellos un punto representativo denominado centroide, pues es el punto que posee mayor grado de similitud con el resto de elementos de cada clúster. De esta manera las condiciones iniciales para las TDS se ajustan sólo para una hora de despacho (centroide) ajustes que servirán para el resto de horas de cada grupo.

Como datos de salida de esta etapa se obtiene:

- P.O divididos en grupos con características similares
- Centroide de cada grupo

#### **3.1.4. Modelamiento en estado dinámico**

Una vez que se ha resuelto el problema de despacho y que el proceso de clustering ha sido implementado en los P.O, la siguiente etapa es el modelamiento del sistema en estado dinámico mediante el uso de softwares para análisis y diseño del área eléctrica.

Para la obtención de este modelo se toma como punto de partida los parámetros presentes en el modelo en estado estacionario obtenido en la etapa anterior, de manera que el software haciendo uso de sus librerías asigne a cada uno de los elementos su representación matemática, permitiendo simular los cambios de su comportamiento en función del tiempo.

#### **3.1.5. Modelamiento detallado**

Para estudios de estabilidad en un SEP, además de la implementación del modelo en estado dinámico es necesario crear el modelo detallado de ciertos elementos, con el objetivo de obtener un comportamiento casi real del sistema ante una contingencia, estos modelos junto con los P.O son las entradas para las TDS.

A continuación, se describen los elementos en los cuales se implementó el modelo detallado para esta metodología.

##### **i. Modelamiento de los GS.**

Los GS son uno de los elementos más importantes que existe en la infraestructura de un SEP, pues son aquellos que intervienen de forma directa en su comportamiento al ocurrir una contingencia. Su modelo detallado consiste en especificar todos los elementos internos que poseen e intervienen en su funcionamiento como: regulador automático de voltaje (AVR), regulador automático de velocidad (governor),

limitador de sobreexcitación (OEL), limitador de sub-excitación (UEL), estabilizador de potencia (PSS), entre otros.

## **ii. Modelamiento de centrales renovables no convencionales.**

La introducción de altos porcentajes de generadores de tipo ERNC tiene gran incidencia en el comportamiento del sistema y esto se debe a que su tecnología está fuertemente ligada a controladores dinámicos basados en electrónica de potencia, es por esto que es necesario implementar su modelo de planta.

### **3.1.6. Simulaciones en el Dominio del Tiempo**

Para la implementación de las TDS en esta metodología, primero se determinan las líneas de interés bajo el criterio de cargabilidad superior, la razón principal de aplicar este criterio es que cuando la línea está más saturada existe mayor regulación de reactivos por lo que las caídas de voltaje en barras son mayores luego de una contingencia. Para determinar la cargabilidad de las líneas se utilizan flujos de potencia para cada uno de los P.O simulados.

Una vez determinadas las líneas de interés, se modelan eventos de cortocircuito (ShC), despeje de falla y desconexión de interruptores. Estos eventos asociados con una TDS permiten observar el comportamiento del sistema al ocurrir una contingencia en un periodo determinado de tiempo.

Dado que en las TDS es posible monitorear gran cantidad de variables eléctricas, es necesario elegir un grupo de ellas conocidas como “posibles características relevantes”. Para la elección de estas variables se considera la estrecha relación que poseen con la variable de interés, expuesto en la literatura y en investigaciones previas. Estas características conforman los datos sintéticos para la implementación de los algoritmos en ML.

### **3.1.7. Pre-procesamiento de los datos sintéticos**

Los datos sintéticos obtenidos de las TDS pasan por una etapa de pre-procesamiento en la cual se debe cumplir con determinados procesos según las necesidades de cada algoritmo. Sin embargo, la división de los datos es un proceso común para todos los algoritmos, pues se necesitan 2 grupos de datos, uno para el entrenamiento y otro para la validación de cada algoritmo. En esta metodología se utiliza la regla del 80-20: esto quiere decir que la base de datos se divide en 80% para entrenamiento y 20% para validación, (Géron, 2019).

### **3.1.8. Implementación de los algoritmos de ML**

Para la implementación de ML se hace uso de algoritmos supervisados, en concreto se usa la técnica de regresión, pues lo que se busca es predecir valores y no grupos. Para la elección de los algoritmos, se consideran los más desarrollados y que mayor interés han presentado en los últimos años, pero que, sobre todo han demostrado ser multidisciplinarios. Los algoritmos bajo estudio son:

- Decision Tree.
- Bagging & Pasting.
- Random Forest.
- SVR.
- ANN.

Antes de su implementación es necesario seleccionar las barras de interés, pues esta metodología no realiza una predicción general del voltaje en el sistema.

Las barras de interés seleccionadas, en su mayoría, son aquellas que están conectadas a las líneas que cumplen el criterio de cargabilidad superior, esto se debe a que estas barras tendrán perfiles de voltaje desmejorados producto de su cercanía a las

fallas, por ende, las excursiones de voltaje serán más severas. Adicionalmente, con el objetivo de que la base de datos cuente con caídas de voltaje leves y que los algoritmos puedan predecir cualquier excursión de voltaje sin importar su magnitud, se considera una barra que no se encuentre conectada directamente a las líneas con cargabilidad superior, logrando así mayor diversidad en los datos.

Con las barras de interés seleccionadas, cada algoritmo es entrenado con la porción de datos obtenida en la etapa anterior. El entrenamiento de los algoritmos es la etapa que más tiempo y recurso computacional toma, dependiendo de los algoritmos y de la cantidad de datos presentes.

Una vez que cada algoritmo es entrenado se realizan las predicciones de los datos pertenecientes al grupo de validación y se observan los resultados obtenidos.

### ***3.1.9. Importancia de las características relevantes***

Con los algoritmos de ML implementados para cada una de las barras de interés, se evalúa si las características relevantes elegidas en la etapa anterior son importantes en la predicción de estabilidad de voltaje. Para lograrlo se utilizan herramientas que poseen internamente ciertos algoritmos, las cuales permiten mostrar las ponderaciones con las que el algoritmo considera a cada característica. De esta manera se puede comprobar cuáles de ellas son las más influyentes en la predicción y cuales son innecesarias. En base a los resultados obtenidos se puede decidir si es necesario la selección de nuevas características relevantes y repetir la implementación de los algoritmos o a su vez, avanzar hacia la validación de los algoritmos para evaluar su desempeño en la predicción de la excursión de voltaje.

### ***3.1.10. Evaluación del desempeño de los algoritmos de ML***

Para evaluar el desempeño en las predicciones de estabilidad de voltaje se usa el criterio del RMSE para todos los algoritmos en cada una de las barras de interés. La

elección de esta métrica para algoritmos de regresión se debe a que las predicciones se basan en la creación de un modelo que se ajuste a los datos reales de interés, el RMSE mide la diferencia existente entre los puntos reales y las predicciones por parte del algoritmo en toda la trayectoria de la excursión de voltaje, es decir mientras menor sea el RMSE mejor es el modelo construido.

El valor de cada algoritmo que se considera para el análisis comparativo es el RMSE promedio obtenido a partir de los resultados en cada barra de interés.

### ***3.1.11. Post-validación del desempeño de los algoritmos de ML***

Finalmente, en esta etapa se realiza una última validación con los 2 algoritmos mejor puntuados en la etapa anterior mediante el uso de datos que representan fallas que derivaron en diferentes valores de caídas de voltaje (en p.u.) para así poder observar de manera gráfica y específica cuál es el mejor algoritmo al momento de predecir voltaje sin importar la magnitud de la falla generada.



los parámetros de operación para los GS, donde se especifican las potencias mínimas y máximas, rampas de toma de carga, tipo de central y costo de generación.

**Tabla 1**

*Parámetros para los SG*

Unidad	Barra	Pmax [MW]	Pmin [MW]	R+ [MW]	RU [MW/min]	Tipo de central	Costo [\$/MWh]
Unit_01	18	400	10	160	360	Hidro	0
Unit_02	21	400	10	160	360	Hidro	0
Unit_03	1	152	7.6	40	40	Carbón	13.32
Unit_04	2	152	7.6	40	40	Carbón	13.32
Unit_05	15	155	7.75	30	30	Carbón	10.52
Unit_06	16	155	7.75	30	30	Gas	10.52
Unit_07	23	310	15.5	60	60	Gas	10.52
Unit_08	23	350	17.5	40	40	Gas	10.89
Unit_09	7	350	17.5	70	70	Diesel	20.7
Unit_10	13	295.5	14.775	100	100	Diesel	20.93
Unit_11	13	295.5	14.775	100	100	Diesel	20.93
Unit_12	15	60	3	60	60	Diesel	26.11
Unit_13	22	400	10	160	360	Hidro	0

*Nota.* En esta tabla se muestran los parámetros correspondientes a cada uno de los generadores síncronos. Obtenido de, (Ordoudis, Pinson, Morales González, & Zugno, 2016).

En la Tabla 2, se muestran los parámetros de funcionamiento de las unidades de generación basadas en ERNC donde se especifican las potencias nominales de funcionamiento y el tipo de recurso primario que utilizan.

**Tabla 2**

*Parámetros de los generadores ERNC*

Unidad	Barra	Pnom [MW]	Tipo de central
Unit_14	3	179	Solar
Unit_15	10	179	Solar
Unit_16	13	179	Solar
Unit_17	14	179	Eólica
Unit_18	15	179	Eólica
Unit_19	17	179	Eólica

*Nota.* En esta tabla se muestran los parámetros de operación correspondientes a los generadores renovables.

Además de los generadores mostrados, el sistema de prueba está compuesto por un total de 20 cargas distribuidas en todo el sistema. 34 líneas de transmisión y 4 transformadores de potencia. Los parámetros de estos elementos se detallan en el Anexo 2. La potencia total instalada es de 4549 MW, donde el 25% de esta potencia corresponde a la inserción de ERNC.

Para realizar el despacho de las ERNC, es necesario definir los perfiles tanto de irradiancia para energía fotovoltaica y velocidad del viento para la energía eólica. Estos datos se obtuvieron de series de tiempo de acceso público disponibles en la web, (Chile, 2017). Las bases de datos obtenidas poseen mediciones de todo un año con una

resolución de 1 hora. Para este estudio se consideran 4 semanas representativas, una por cada estación del año, teniendo así un total de 672 horas a evaluar.

## Capítulo V

### 5. Análisis de resultados

En el presente capítulo se muestran los resultados de la metodología aplicada en el caso de estudio.

#### 5.1. Etapa 1.

##### 5.1.1. *Modelamiento en estado estacionario*

El modelo del sistema en estado estacionario se desarrolló en el software DiGSILENT Power Factory (PFD) (DiGSILENT Power Factory, 2022), aquí se diagrama el sistema de prueba presentado en el caso de estudio, para esto se utilizan los modelos pre-establecidos en sus librerías tanto para las líneas de transmisión (L/T), cargas, transformadores, barras y unidades de generación.

##### 5.1.2. *Despacho económico*

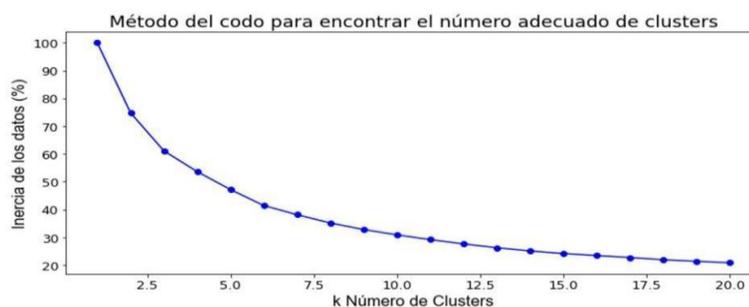
El problema de despacho económico fue implementado como un tipo multimodal haciendo uso de flujos DC utilizando el software Fico Xpress (FICO, 2022). El planteamiento de la función objetivo y restricciones a las cuales este caso de estudio está sujeto se presentan en el Anexo 1. Mediante su implementación se obtuvieron las 672 horas de despacho (P.O) referentes a la potencia activa requerida de las unidades de generación. Estas horas de despacho se obtienen a partir de 4 semanas representativas, una por cada estación del año, de manera que se refleje la variación en la disponibilidad de los recursos primarios para las energías renovables.

### 5.1.3. Proceso de agrupación de los P.O

El ajuste de las condiciones iniciales para los 672 P.O referentes al despacho de reactivos y regulación de voltaje en barras fue optimizado mediante su agrupación y selección de un punto representativo (centroide) con la etapa de clustering, la cual fue implementada en el software Python (Python, 2022), haciendo uso del algoritmo K-Means. Para la elección del número óptimo de clusters se utilizaron la regla del codo Figura 21, y el coeficiente de silueta Figura 22. Las definiciones de estas herramientas se especifican en el Capítulo II.

**Figura 21**

*Implementación de "regla de codo" para el caso de estudio*

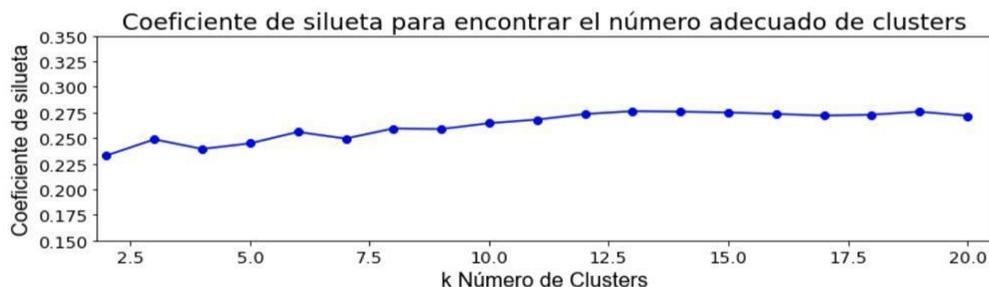


*Nota.* En esta figura se muestra la implementación de la regla del codo para este caso de estudio.

En la Figura 21, se puede observar que el punto de quiebre (codo) se da en 8 clusters, pero la pendiente de los datos sigue disminuyendo casi hasta 20 clusters, este comportamiento no refleja un número específico en los que se debe dividir la data. Para validar el número ideal de cluster se utilizó el coeficiente de silueta.

## Figura 22

### Implementación del coeficiente de silueta para el caso de estudio



*Nota.* En la figura se muestra el coeficiente de silueta aplicado en el caso de estudio, se utiliza para validar el número de clusters que se deben formar.

En la Figura 22, se muestra el coeficiente de silueta donde se puede observar que los números ideales de clusters en este sistema están entre 13 y 15, pues su valor es el más cercano a 1.

Tomando en cuenta los criterios de las Figuras 21-22, las horas de despacho son divididas en 15 clusters, se toma el valor más alto pues al realizar las TDS la cantidad de horas por cada cluster es menor, permitiendo optimizar tiempo y recursos computacionales.

Con los 15 clusters identificados se aplica el método de la distancia euclidiana el cual permite determinar el centroide de cada grupo. Esta hora de despacho es ajustada para cada cluster en el modelo estacionario previamente elaborado en PFD, mediante la creación de 15 escenarios de operación (uno por cada cluster), logrando automatizar las TDS haciendo uso de la programación propia del software (DPL: Digsilent Program Language).

## 5.2. Etapa 2.

### 5.2.1. Modelamiento en estado dinámico y modelo detallado

Para la implementación del modelo en estado dinámico del sistema se hace uso del software PFD ya que debido a la naturaleza variante que posee el voltaje es necesario agregar el modelo detallado de determinados elementos del SEP. En este caso de estudio se consideraron los modelos de AVR y gobernador para los GS y para el caso de las ERNC se consideraron sus modelos de planta.

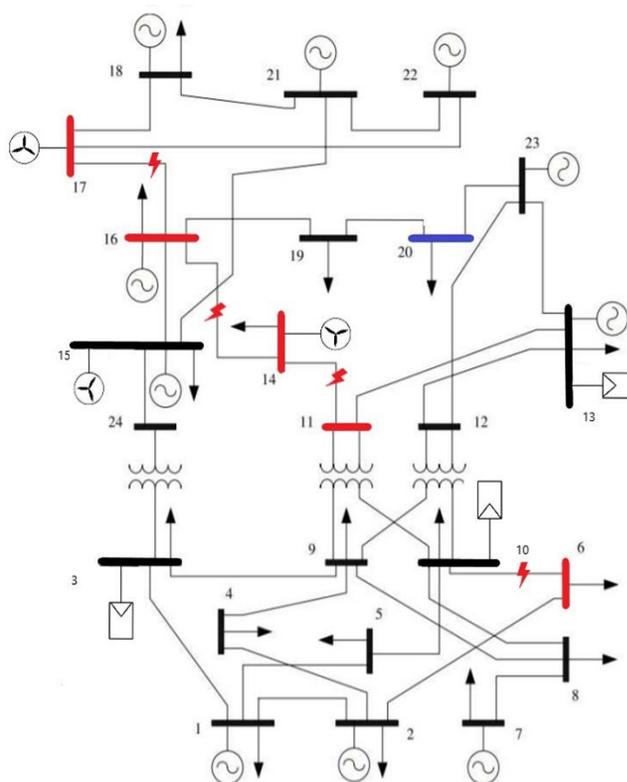
Para los GS con turbinas hidráulicas el modelo de gobernador es el IEEE G3, mientras que para los generadores térmicos es el IEEE G1. El modelo seleccionado para el AVR considerado en ambas tecnologías es el IEEE T1, (Verdugo, 2012). Los parámetros de estos elementos para este caso de estudio se presentan en el Anexo 3.

Los modelos de planta utilizados para las ERNC son: Full Rated converter (Zavadil, y otros, 2012), para el caso de los generadores eólicos y Template photovoltaic system (librerías de PFD) para los fotovoltaicos.

Para la implementación de las TDS, se crean eventos de ShC en las L/T donde el criterio de elección está basado en su cargabilidad. Para este trabajo de investigación se considera una cargabilidad superior al 60%. Las líneas que cumplieron este criterio con mayor frecuencia fueron 4 (Ver Figura 23), generando así un total de 719 contingencias distribuidas en todos los P.O considerados. Cabe recalcar que no en todos los P.O se generaron contingencias, pues gracias a la introducción de ERNC distribuidas en todo el SEP, los flujos en las L/T se repartieron de manera equilibrada, evitando así un alto porcentaje de cargabilidad.

**Figura 23**

*Representación de las barras y L/T de interés*



*Nota.* En la figura se muestra el diagrama unifilar del sistema de prueba de 24 nodos de la IEEE modificado, donde se especifican las barras y L/T de interés para este caso de estudio.

Las barras de interés para este caso de estudio en su mayoría fueron aquellas que se encuentran en los extremos de las L/T en las que se produjeron las contingencias, esto se debe a que por su cercanía a las fallas presentan caídas de voltaje más severas. Con el objetivo de que la base de datos contenga mayor diversidad, adicional a las barras mencionadas, se consideró una barra donde sus caídas de voltaje no son tan severas, pues no está conectada directamente a las L/T mencionadas. Con todas estas consideraciones el número de barras de interés seleccionadas fueron 6, las cuales se muestran resaltadas en la Figura 23.

### **5.3. Etapa 3.**

#### ***5.3.1. Datos sintéticos y posibles datos relevantes***

Los datos sintéticos para este caso de estudio fueron obtenidos a partir de las TDS y están formadas por las magnitudes de voltaje (variable dependiente) y ángulo en las barras del sistema junto con la potencia reactiva de los GS. Estas dos últimas magnitudes fueron elegidas debido a su estrecha relación con la variable de interés, además en investigaciones previas resaltan su eficacia al momento de la predicción de la excursión de voltaje, es por ello que son consideradas como las posibles características relevantes (variables independientes). Estas magnitudes fueron registradas para cada una de las barras de interés previamente seleccionadas.

#### ***5.3.2. Implementación de los algoritmos de ML***

Para la implementación de los algoritmos ML en la predicción de voltaje se utiliza el software Python. Es importante señalar que los parámetros con los que fueron configurados los algoritmos fueron los que el software establece por defecto con excepciones en ciertos algoritmos. Los parámetros que fueron modificados y los algoritmos en los que se realizaron estos cambios se muestran en el Anexo 4. El entrenamiento de los algoritmos se realizó para cada una de las barras de interés con un total de 719 contingencias por cada una de ellas, de manera que los algoritmos logren predecir con buen desempeño la inestabilidad de voltaje sin importar la magnitud de la excursión del mismo.

Debido a que el número de contingencias a simular fue elevado y que la cargabilidad de las líneas tendrá diferentes valores en función del PO a analizar, las caídas de voltaje producto de estas contingencias tendrán distintos valores, por lo que para proveer de un mejor contexto en la evaluación del desempeño de los algoritmos,

en la Tabla 3 se muestran los rangos de caídas de voltaje con su respectivo número de contingencias para cada una de las barras.

**Tabla 3**

*Número de contingencias por barra según el rango de su caída de voltaje*

Caídas de voltaje en [pu]	Número de contingencias por barra					
	Barra_6	Barra_11	Barra_14	Barra_16	Barra_17	Barra_20
0-0.2	201	0	477	316	315	0
0.2-0.4	403	491	40	188	188	0
0.4-0.55	115	208	0	13	7	342
0.55-0.7	0	20	202	0	7	175
0.7-0.99	0	0	0	202	202	202
Total de contingencias	719	719	719	719	719	719

*Nota.* En la tabla se muestra el número de contingencias por barra, en función del rango de caída de voltaje al que pertenece.

### **5.3.3. Evaluación del desempeño de los algoritmos de ML**

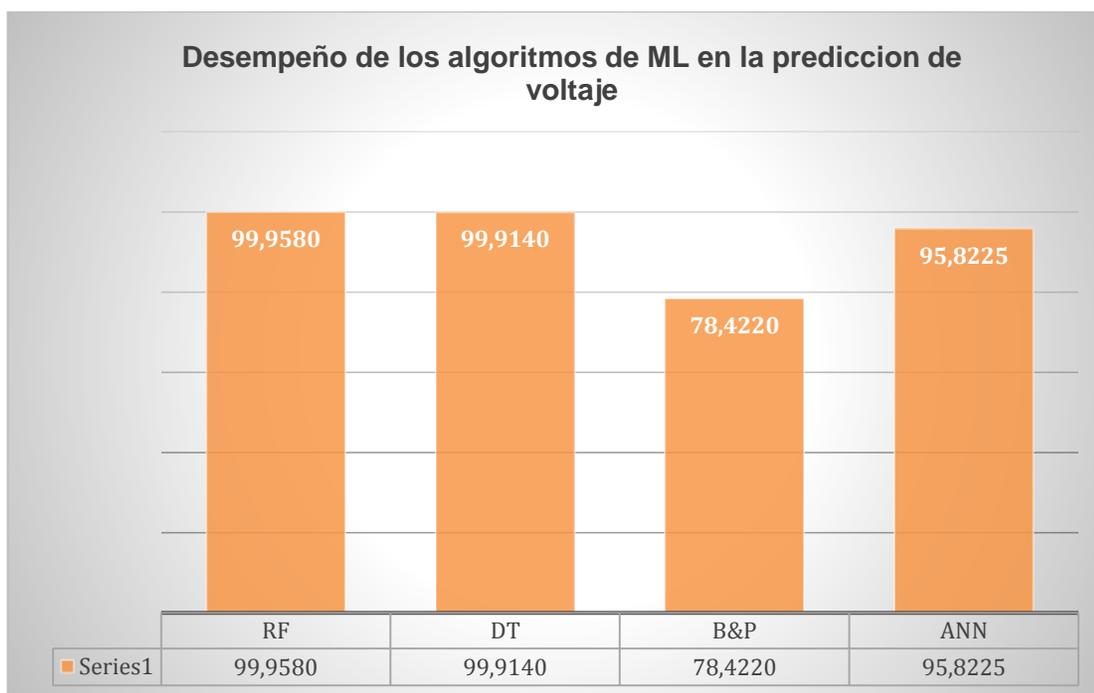
Una vez que los algoritmos fueron entrenados para cada una de las barras de interés con el 80% de los datos sintéticos, pertenecientes al grupo de entrenamiento designado anteriormente (es decir con los datos correspondientes a 575 contingencias simuladas), las predicciones son evaluadas con el criterio de RMSE. Para su análisis se tomó en cuenta el valor promedio de su desempeño en todas las barras.

En la Figura 24 se muestran los porcentajes de desempeño de los algoritmos al momento de predecir una excursión de voltaje. Se recalca que los porcentajes presentados hacen referencia al 20% del total de las contingencias simuladas (conjunto de validación). Es decir que los porcentajes obtenidos se encuentran en función de los datos que corresponden a 144 contingencias simuladas. De esta manera se puede ver

que las mejores predicciones de la excursión de voltaje luego de ocurrida una contingencia se obtuvieron de: RF con un desempeño del 99.95% y DT con un 99.91%. Si bien DT tiene buenos resultados para este caso de estudio no se lo toma en cuenta como una buena alternativa para su aplicación, pues en investigaciones previas aplicadas al área eléctrica (Yun, Tengyu, Bing, Jing, & Zhongje, 2015) se ha demostrado que es muy casuístico ya que al cambiar de SEP por uno más complejo tiende a fallar, esto se debe a que no maneja bien las incertidumbres. Por lo tanto, se elige el siguiente algoritmo que es ANN con un desempeño de 95.82%.

#### Figura 24

*Resultados de desempeño de los algoritmos en las predicciones*



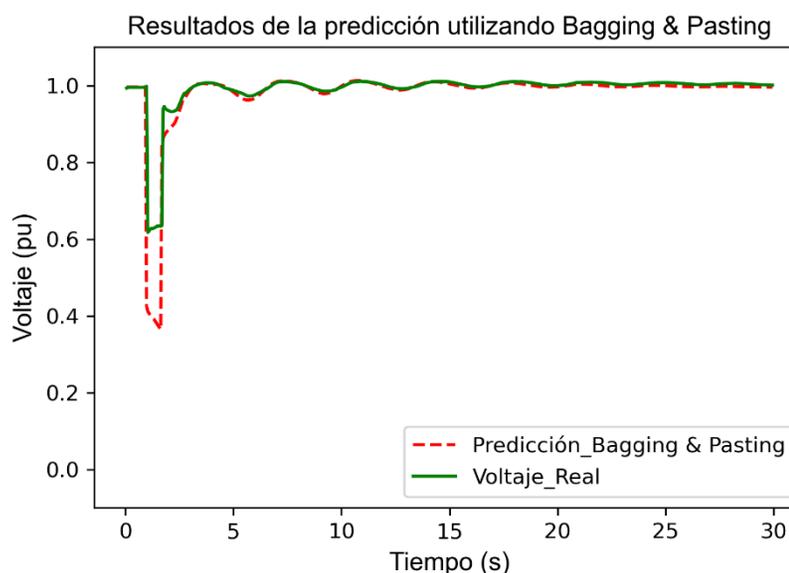
*Nota.* En la figura se muestran los resultados promedio del desempeño de los algoritmos en la predicción de voltaje.

En el caso de B&P, se observó que es el algoritmo con menor desempeño (78.42%). Su baja puntuación en este caso de estudio se debe a que al utilizar la

función de Bagging se incrementa la aleatoriedad en la etapa de entrenamiento, y tomando en cuenta que las fallas de voltaje son de corto plazo el entrenamiento con estos datos se ve disminuido, por lo tanto, las predicciones de estos valores no son acertados. Esto se puede observar en la Figura 25, donde se muestran los valores de predicción y valores reales del voltaje para una barra. Corroborando que en caídas severas de voltaje el algoritmo no logra predecir estos valores. Sin embargo, para la predicción del fenómeno en general posee un desempeño aceptable.

### Figura 25

*Comparación de valores reales con las predicciones aplicando B&P*



*Nota.* En esta figura se muestran las curvas de voltaje a partir de los valores reales y con las predicciones, utilizando el algoritmo B&P.

En cuanto a SVR no se obtuvieron resultados ya que no logró converger después de 48 horas de simulación para la cantidad de datos que se usaron en este estudio (15, 728 535), y con los recursos computacionales mostrados en el Anexo 5.

Esto se debe a que en su diseño el algoritmo no es apto para grandes bases de datos y necesita de gran capacidad computacional.

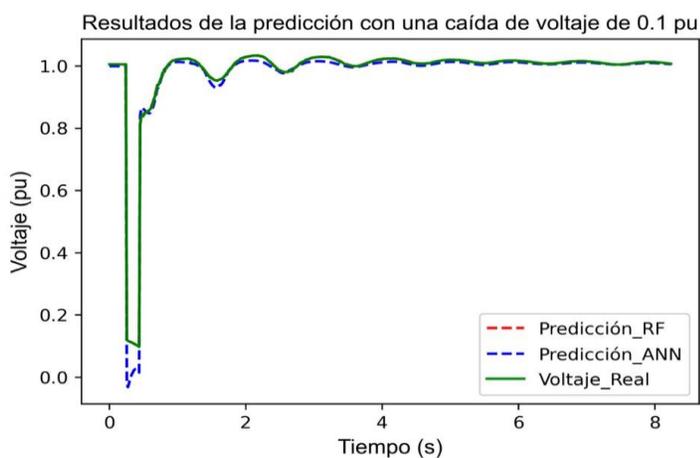
### 5.3.4. Post-validación de los resultados

Para la post-validación de los resultados se toma en cuenta los algoritmos con mejor desempeño, es decir: RF y ANN. Esta etapa se realizó con el objetivo de evaluar el desempeño de estos algoritmos al predecir diferentes caídas de voltaje considerando excursiones leves (0.8 en p.u) hasta excursiones graves (0.1 en p.u).

En la Figura 26, se muestran los resultados de las predicciones usando RF y ANN para una caída de voltaje de 0.1 en p.u. Como se puede observar RF es capaz de predecir casi en su totalidad los valores durante todo el fenómeno simulado, haciendo que su gráfica se sobreponga a la real, mientras que ANN tiene complicaciones de predicción en valores de voltaje menores a 0.2 pues como se observa en la gráfica, para el algoritmo todo valor menor a este tenderá a cero, sin embargo, para el resto del fenómeno posee un buen desempeño.

**Figura 26**

*Resultados de predicción con una caída de voltaje de 0.1 en p.u*

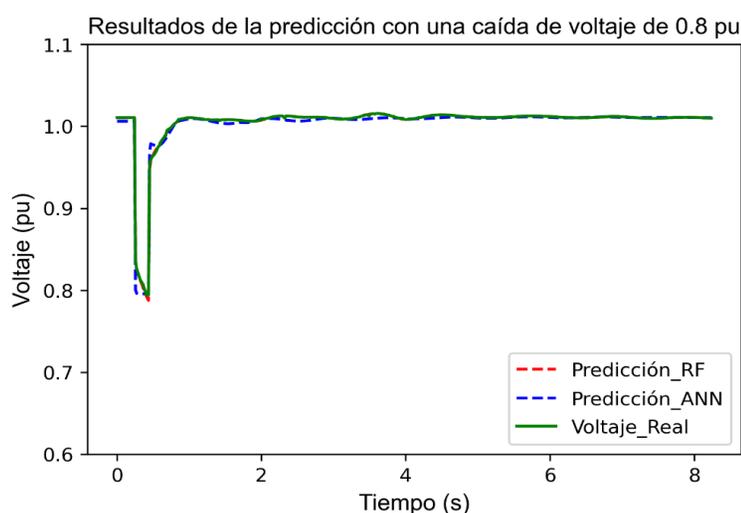


*Nota.* En la figura se muestran las curvas de voltaje formados con los valores de predicción de voltaje y valores reales para una caída de voltaje de 0.1 en p.u.

En la Figura 27, se muestran los resultados de las predicciones usando RF y ANN para una caída de voltaje de 0.8 en p.u. En este caso ANN mejora su desempeño ya que su gráfica es muy cercana a la real. En el caso de RF su desempeño sigue teniendo buenos resultados, sobreponiéndose una vez más a los valores reales de voltaje.

### Figura 27

*Resultados de predicción con una caída de voltaje de 0.8 en p.u*



*Nota.* En la figura se muestran las curvas de voltaje formados con los valores de predicción y valores reales para una caída de voltaje de 0.8 en p.u.

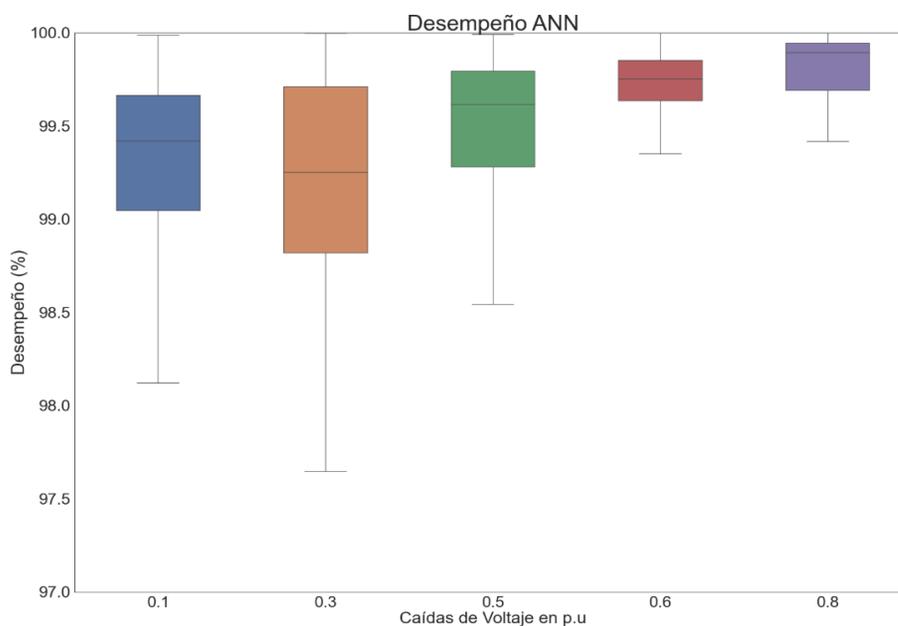
Adicionalmente se realizaron simulaciones para caídas de voltaje con valores de 0.3, 0.5 y 0.6 en p.u las cuales se muestran en el Anexo 6. Al analizarlas se concluye que RF presenta un excelente desempeño sin importar la magnitud de la caída de voltaje, mientras que en el caso de ANN se puede observar que su desempeño va mejorando a medida que la caída de voltaje es menos severa.

Para visualizar desde otro punto de vista el desempeño de los algoritmos en la predicción de diferentes caídas de voltaje, en las Figuras 28-29, se muestra el diagrama de cajas generado a partir de los valores de RMSE promedio de cada algoritmo para los

eventos simulados, este diagrama muestra los valores máximos, mínimos y medios del desempeño de los algoritmos al momento de realizar predicciones de voltaje. Aquí se puede observar que la media de los RMSE es menor en fallas con valores de 0.6 y 0.8 en p.u de caída de voltaje para ambos algoritmos, 99.9% para RF y de 99.7% para ANN. Sin embargo, en fallas de 0.1, 0.3 y 0.5 en p.u de caída de voltaje se ve como RF tiene valores medios menores de alrededor de 99.8% con valores mínimos de error que no decaen del 99.5%, mientras que ANN posee valores medios de error de alrededor de 99.3% pero sus valores mínimos de desempeño llegan hasta valores de 97.5% verificando que tiene problemas al momento de predecir fallas severas.

### Figura 28

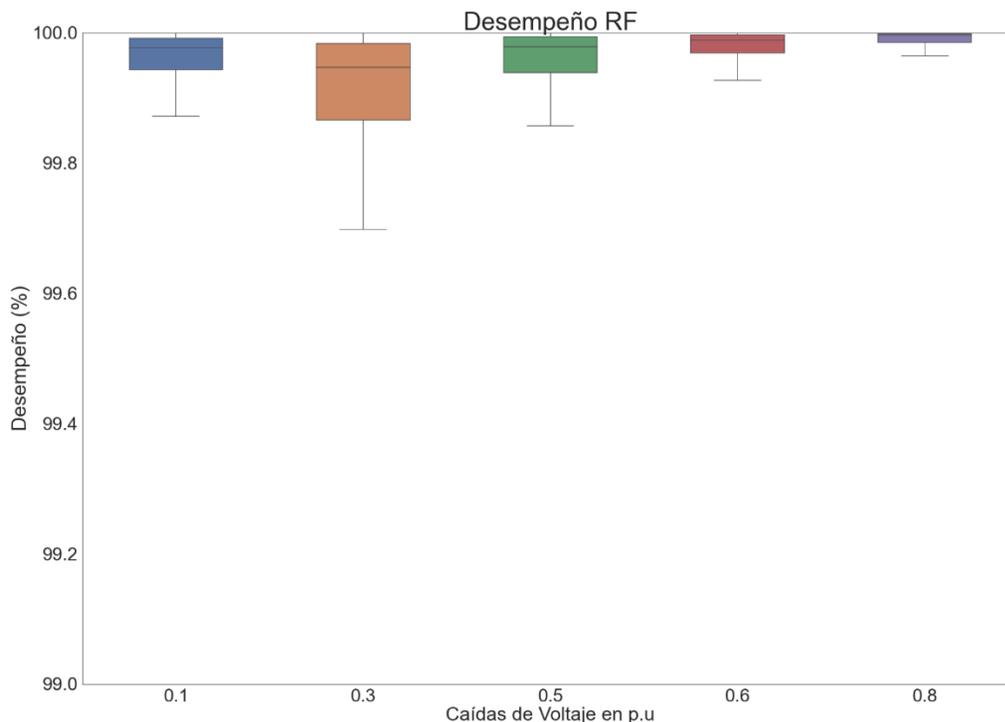
*Desempeño de ANN en las predicciones con diferentes caídas de voltaje*



*Nota.* En esta figura se muestra el diagrama de cajas para representar el desempeño de ANN en la predicción de voltaje.

**Figura 29**

*Desempeño de Random Forest en las predicciones*



*Nota.* En esta figura se muestra el diagrama de cajas para representar el desempeño de Random Forest en la predicción de voltaje.

### **5.3.5. Importancia de las características relevantes.**

Una vez realizada la etapa de post-validación con los 2 mejores algoritmos (RF y ANN), como etapa final se realiza un análisis adicional para identificar si las posibles características relevantes influyen en la predicción del voltaje. La importancia que toma cada característica es propia para cada algoritmo y variará según la base de datos.

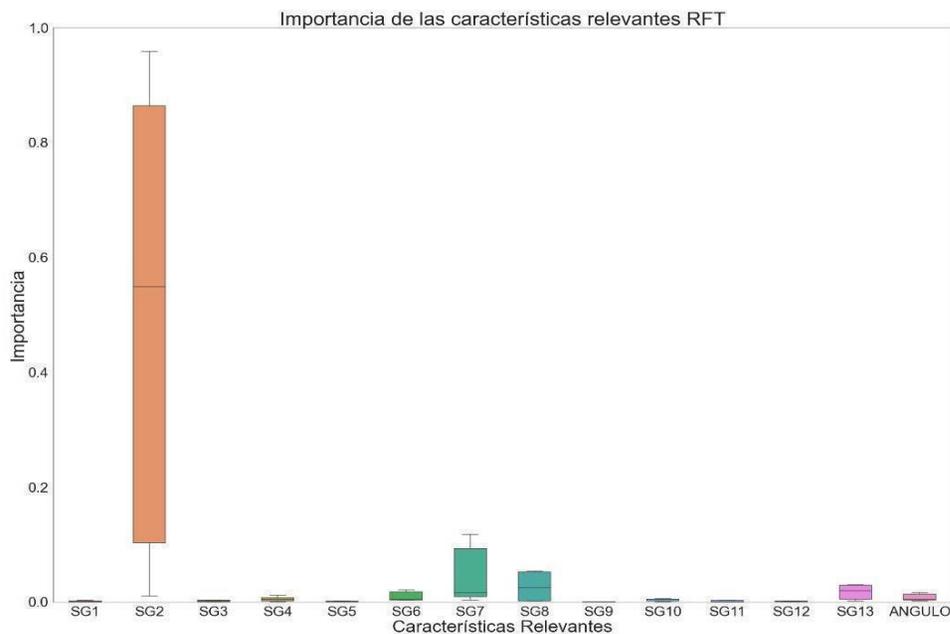
En la Figura 30, se muestra el diagrama de cajas que relaciona las características que se utilizaron para el entrenamiento de RF y su importancia. Este diagrama permite mostrar los valores máximos, mínimos y medios de la importancia de cada característica. Así se observa que para el algoritmo son irrelevantes las potencias

reactivas de los generadores: 1,3,4,5,9,10,11,12. Esto se debe a que sus valores máximos, mínimo y medio tienden a cero. El motivo de este comportamiento es porque muchos de ellos no participan en el despacho debido al costo de su recurso primario (diésel y carbón), mientras que otros tienen capacidad de potencia instalada inferior en comparación a otros generadores del sistema.

Dentro de las características importantes para RF se encuentran las potencias reactivas de los generadores: 2 y 7. En el caso de estos generadores se puede observar que los datos se encuentran más dispersos, lo que significa que existe mayor inyección de reactivos al ocurrir una contingencia, lo que indica que la excursión de voltaje depende fuertemente de la dinámica de estos generadores. Adicionalmente se puede comprobar que estos generadores son los que más participan en el despacho y poseen mayor capacidad de almacenamiento de potencia reactiva. Una peculiaridad que se puede observar es que al existir 2 o más generadores gemelos (Ej: GS1 y GS2), el algoritmo los detecta, discriminando uno de ellos pues lo considera una característica repetida.

**Figura 30**

*Importancia de las características para la predicción de voltaje para RF*

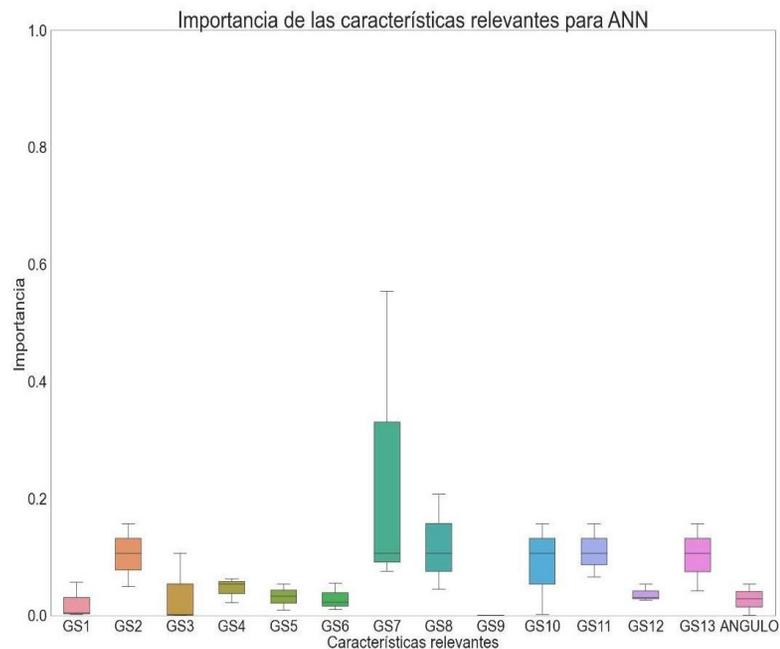


*Nota.* En esta figura se muestra que el fenómeno queda bien caracterizado utilizando únicamente el GS2 y un poco usando GS7.

En la Figura 31, se muestra el diagrama de cajas que relaciona las características que se utilizaron para el entrenamiento de ANN y su importancia. Aquí se puede observar que el algoritmo da mayor importancia a todas las características a diferencia de RF en donde existían características con importancia de cero. Sin embargo, las características que son relevantes para el algoritmo son la potencia reactiva de los generadores: 2, 7 y 8, características que también son consideradas por RF. En conclusión, para este caso de estudio los valores de potencia reactiva de estos generadores son los más relevantes para la predicción de voltaje.

**Figura 31**

*Importancia de las características para la predicción de voltaje para ANN*



*Nota.* En esta figura se muestra el diagrama donde se representa la importancia de las características para la predicción de voltaje en ANN.

Como se puede observar en ambos algoritmos, la característica que representa al ángulo en barra no es muy relevante al momento de realizar una predicción de voltaje pues el algoritmo detecta que sus variaciones son menores en comparación a las variaciones producidas en las potencias reactivas de los generadores durante una caída de voltaje, más no significa que se deban eliminar pues al hacerlo existe una disminución en el desempeño de las predicciones. Cabe recalcar que se realizaron pruebas colocando todos los ángulos de las barras estudiadas como características de entrada para el entrenamiento de la predicción de voltaje en una barra, sin embargo, el tiempo que esto requiere no representa una mejoría notable en las predicciones, mostrando desempeños similares a los obtenidos con la metodología mostrada. Con

todas estas consideraciones y gracias a los excelentes desempeños obtenidos en la predicción de excursiones de voltaje se comprueba que la elección de las posibles características relevantes fue la correcta para este caso de estudio.

## Capítulo VI

### 6. Conclusiones y recomendaciones

#### 6.1. Conclusiones

- La metodología desarrollada en este estudio es capaz de realizar un análisis comparativo entre los diferentes algoritmos de ML, y seleccionar el mejor para realizar predicciones de las excursiones de voltaje que experimenta un SEP luego de ocurrida una contingencia (ShC).
- Se implementó un despacho económico multi nodal con flujos DC para el sistema de prueba de 24 barras IEEE modificado, donde se considera la inserción de generación ERNC que corresponde al 25% de la potencia total instalada, el horizonte de tiempo de evaluación considerado fue de 4 semanas características del año, una por cada estación, obteniendo un total de 672 P.O.
- Se desarrolló e implementó un modelo detallado del sistema permitiendo realizar simulaciones dinámicas referentes a cortocircuitos en líneas cuya cargabilidad superó el 60%, logrando registrar la evolución en el tiempo de las señales de interés generando así una base de datos que refleje el comportamiento del SEP ante estas contingencias.
- Para este caso de estudio las características más relevantes son la potencia reactiva de los generadores y el ángulo en barra pues dada su estrecha relación con el voltaje son las características que más influyen al momento de predecir la inestabilidad de voltaje. La relevancia de estas características fue evaluada con herramientas propias de los algoritmos implementados, las cuales adicionalmente mostraron que, para esta metodología, la potencia reactiva de

los generadores más grandes del sistema es mucho más relevante que de aquellos que poseen potencias inferiores y que el ángulo de barra.

- El desempeño de los algoritmos implementados fue evaluado bajo el criterio del RMSE donde los mejores resultados para este caso de estudio al momento de predecir la inestabilidad de voltaje se obtuvieron de: RF con un desempeño del 99.9%, seguido de ANN con un desempeño del 95.8%.
- En el caso de Decision Tree a pesar que para este caso de estudio tuvo un buen desempeño, su baja capacidad de manejar incertidumbres no lo hace apto para aplicaciones más complejas en el área eléctrica.

## 6.2. Recomendaciones

- Si se desean realizar proyectos en el área eléctrica utilizando B&P se recomienda que sean casos de clasificación, pues la teoría demuestra que los mejores resultados se obtienen con esta técnica.
- No se recomienda el uso de SVR en estudios de estabilidad donde la base de datos supere los 6 millones de datos si se poseen recursos computacionales similares a los usados en este trabajo de investigación. Pero si la base de datos contiene menor cantidad de datos a este valor el algoritmo presenta muy buenos resultados.
- Para la implementación de ANN en la asignación del número de neuronas se recomienda mantener un valor que no supere a la mitad del número de características que se utilicen para el entrenamiento, esto se realiza para evitar la división en muchas capas de la red lo que causaría mayores tiempos de entrenamiento sin una mejora en el rendimiento. Además, el número de iteraciones no debe ser menor a 100.
- En posteriores estudios de predicción de la estabilidad de voltaje se recomienda usar como datos de entrada los valores de ángulo de las 2 barras que estén conectadas a la línea en la que sucede una contingencia pues en un SEP real las PMU miden la diferencia entre estas magnitudes.
- Para estudios posteriores se recomienda el uso de esta metodología en aplicaciones de tiempo real en la operación de un SEP, (Ej. Esquemas de protección dinámicos).

## Bibliografía

- Anjos, M., & Conejo, A. (2017). Unit Commitment in Electric Energy Systems. NOW.
- Bachero, S. (Octubre de 2015). Universidad Nacional de Lujan. Obtenido de <http://www.labredes.unlu.edu.ar/sites/www.labredes.unlu.edu.ar/files/site/data/bdm/coeficiente-silueta.pdf>
- Belhadj, C., Duwaish, H. A., Shwehdi, M., & Farag, A. (1998). Voltage stability estimation and prediction using neural network. International Conference on Power System Technology, 8(2), 1464-1467.
- Betancurth, R. (2021). Estabilidad de Voltaje en un SEP. Universidad Juarez Autooma de Tabasco.
- Bulmaro, N. (10 de Junio de 2020). [www.ingenieriaquimicareviews.com](http://www.ingenieriaquimicareviews.com). Obtenido de <https://www.ingenieriaquimicareviews.com/2020/06/estado-estacionario-concepto.html>
- Candelo, J. E., Caicedo, G., & Castro, F. (2008). Métodos para el Estudio de la Estabilidad de Voltaje en Sistemas de Potencia . Información Tecnológica, 19(5), 97-110.
- Case, D. (11 de 03 de 2020). A Review of Artificial Intelligence Classification. Obtenido de <https://www.signally.ai/blog/a-review-of-ai-classification>
- Castaño, M. R., & Torres, L. A. (2009). ANÁLISIS DE ESTABILIDAD DE PEQUEÑA SEÑAL ANÁLISIS DE ESTABILIDAD DE PEQUEÑA SEÑAL. Pereira: UNIVERSIDAD TECNÓLOGICA DE PEREIRA FACULTAD DE TECNOLOGÍAS PROGRAMA DE TECNOLOGÍA ELÉCTRICA.

- Chamba, M., Vargas, W., & Cepeda, J. (2018). Probabilistic assessment of transient stability considering the uncertainty of the demand and risk management. CELEC EP.
- Chih-Wen, L., Chang, C.-S., & Su, M.-C. (1998). Neuro-Fuzzy networks for voltage security monitoring based on synchronized phasor measurements. *IEEE Transactions on Power Systems*, 13(2), 326-332.
- Chile. (2017). Explorador Eólico. Obtenido de <https://eolico.minenergia.cl/inicio>
- Cisa, A. (2015). Instituto de energía Eléctrica. Obtenido de <https://iie.fing.edu.uy/potencia/es/modelado-y-simulacion-de-sistemas-electricos-de-potencia/>
- CONELEC. (2008). [regulacion.gob.ec](http://regulacion.gob.ec). Obtenido de <https://www.regulacionelectrica.gob.ec/wp-content/uploads/downloads/2016/02/Regulacion-No.-CONELEC-006-08.pdf>
- Constantino, A., & Aquino, D. (2021). Control de Voltaje y Estabilidad del SEP. Universidad Tecnológica de Puebla.
- DiGSILENT Power Factory. (10 de febrero de 2022). [www.digsilent.de](http://www.digsilent.de). Obtenido de <https://www.digsilent.de/en/products.html>
- FICO. (10 de febrero de 2022). [www.fico.com](http://www.fico.com). Obtenido de <https://www.fico.com/en/products/fico-xpress-optimization>
- Géron, A. (2019). Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow. Canadá: Kiwisoft S.A.S.
- Hatziafyriou, N., Milanović, J., & Rahmann, C. (2020). Definition and Classification of Power System Stability – Revisited & Extended. *IEEE*, 1-12.
- Jiawei, H., & Kamber, M. (2007). *Data Mining: Concepts and Techniques*. Champaign, Illinois, USA. University of Illinois.

- Kiril, E., & Potenves, H. (2020). Machine Learning from A-Z: Hands on. USA: Udemy.
- Kotari, D., & Nagra, J. (2008). SISTEMAS ELÉCTRICOS DE POTENCIA. MÉXICO: MC GRAW HILL.
- Kundur, P. (2009). POWER SYSTEM STABILITY AND CONTROL. Toronto: McGraw-Hill.
- Li, H., Yeo, H., L, B., & T, J. O. (2017). The Creation and Validation of Load Time Series Synthetic Electric Power Sustrms. University Collage of Londo.
- Liu, F. (2018). Predictability of Failure Event Occurrences in Decentralized Discrete-Event Systems and Polynomial-Time Verification. IEEE TRANSACTIONS ON AUTOMATION SCIENCE AND ENGINEERING, 16(1), 498-504.
- Llanos, J., & Ortiz, D. (2016). Economic Dispatch for Optimal Management Isolated Micro-grids. 2016 IEEE 36th Central American and Panama Convention (CONCAPAN XXXVI).
- López, L. (2008). ANÁLISIS DE ESTABILIDAD DE TENSIÓN EN EL SISTEMA DE TRANSMISION REGIONAL (STR). Pereira.
- Ortiz, D., Rahmann, C., Alvarez, R., Canizares, C., & Chritoph, S. (2020). Practical Framework for Frequency Stability Studies in Power Systems With Renewable Energy Sources. IEEE Access.
- Oviedo, U. (octubre de 2003). isa.uniovi.es. Obtenido de [http://isa.uniovi.es/~idiaz/ADSTel/Tema2a\\_ADS.pdf](http://isa.uniovi.es/~idiaz/ADSTel/Tema2a_ADS.pdf)
- Python. (10 de febrero de 2022). www.python.org. Obtenido de <https://www.python.org/about/>

- Rahmann, C., Ortiz, D., Villalba, R., & Álvarez, M. (2017). Methodology for Selecting Operating Points and Contingencies for Frequency Stability Studies .
- Riad, J., Chen, J., Sánchez-Sinencio, d., & Li, P. (2020). Variation-Aware Heterogeneous Voltage Regulation for Multi-Core Systems-on-a-Chip with On-Chip Machine Learning . 21st Int'l Symposium on Quality Electronic Design. Texas.
- Ríos, M., Torres, A., & Torres, M. (2000). ESTABILIDAD DE VOLTAJE EN SISTEMAS DE POTENCIA -CASO DE APLICACION A LA EEB-. REVISTA DE INGENIERÍA UNIANDES, 19-24.
- Sevilla, U. (2015). <http://bibing.us.es>. Recuperado el 1 de Junio de 2021, de <http://bibing.us.es/proyectos/abreproy/70611/fichero/07+C4+Estabilidad+de+voltage+en+el+SIN.pdf>
- Singh, P., Parida, S. K., Chauhan, B., & Choudhary, N. (2021). Online Voltage Stability Assessment Using Artificial Neural Network considering Voltage stability indices. 2020 21st National Power Systems Conference (NPSC), 2020, pp. 1-5. Gandhinagar, India.
- Tilottama, G., & Uponika, B. R. (2019). Predictive Model for Classification of Power System Faults using Machine Learning. 2019 IEEE Region 10 Conference (TENCON 2019). Tenecon.
- Verdugo, X. (2012). Metodología de sintonización de parámetros del estabilizador del sistema de potencia (PSS) utilizando el programa computacional Digsilete Power Factory. Quito.
- Villamarín, A., Haro, J., Aguirre, M., & Ortiz, D. (2021). Evaluación de Resiliencia en el Sistema Eléctrico Ecuatoriano frente a Eventos Sísmicos. CENACE.
- Wang, Z., Elyas, S. H., & Thomas, R. J. (s.f.).

- Yun, T., Tengyu, H., Bing, L., Jing, T., & Zhongje, Z. (2015). Regional Voltage Stability Prediction based on decision tree Algorithm. Liaoning Province, China: Shenyang University of Technology.
- Zavadil, R., Zheglov, V., Kazachkov, Y., Gong, B., Sanchez, J., & Li, J. (18 de 09 de 2012). OSTI.GOV. Obtenido de <https://www.osti.gov/biblio/1051403>
- Zhao, J. (2007). On-Line Voltage Stability Monitoring and Control (VSMC) System in Fujian power grid. IEEE Power Engineering Society General Meeting, (págs. 1-6).

**Anexos**