



Análisis comparativo de técnicas basadas en máquinas de aprendizaje para predecir la excursión de frecuencia en sistemas eléctricos de potencia

Andrade Pobeá, Carlomagno Alberto y Endara Sumba, Francisco Sebastián

Departamento de Eléctrica y Electrónica

Carrera de Ingeniería en Electromecánica

Trabajo de Titulación, previo a la obtención del título de Ingeniero en Electromecánica

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

17 de febrero del 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 excursión de frecuencia en sistemas eléctricos de potencia**”. fue realizado por los señores **Andrade Pobeá, Carlomagno Alberto y Endara Sumba, Francisco Sebastián**, 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



Tesis excursion de Frecuencia Andrade Endara.pdf
Scanned on: 18:45 February 17, 2022 UTC



Identical Words	17
Words with Minor Changes	12
Paraphrased Words	181
Omitted Words	37





ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA

CARRERA DE INGENIERÍA EN ELECTROMECAÁNICA

RESPONSABILIDAD DE AUTORÍA

Nosotros, señores **Andrade Pobeá, Carlomagno Alberto y Endara Sumba, Francisco Sebastián**; con cédulas de ciudadanía 0503509705 y 1723598155 respectivamente declaramos que el trabajo de titulación “**Análisis comparativo de técnicas basadas en máquinas de aprendizaje para predecir la excursión de frecuencia en sistemas eléctricos de potencia**”, es de nuestra autoría y responsabilidad, cumpliendo con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos de terceros y referenciando las citas bibliográficas.

Consecuentemente el contenido de la investigación mencionada es veraz.

Latacunga, 17 de febrero del 2022

Andrade Pobeá, Carlomagno Alberto
C.C.: 0503509705

Endara Sumba, Francisco Sebastián;
C.C.: 1723598155



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA

CARRERA DE INGENIERÍA EN ELECTROMECAÁNICA

AUTORIZACIÓN DE PUBLICACIÓN

Nosotros, señores **Andrade Pobeá, Carlomagno Alberto y Endara Sumba, Francisco Sebastián**; con cédulas de ciudadanía 0503509705 y 1723598155 declaramos que el trabajo de titulación “**Análisis comparativo de técnicas basadas en máquinas de aprendizaje para predecir la excursión de frecuencia en sistemas eléctricos de potencia**”, en el Repositorio Institucional, cuyo contenido, ideas y criterios son de nuestra responsabilidad.

Latacunga, 17 de febrero del 2022

Andrade Pobeá, Carlomagno Alberto
C.C.: 0503509705

Endara Sumba, Francisco Sebastián;
C.C.: 1723598155

Dedicatoria

El presente trabajo de titulación está dedicado:

A Dios, a la Virgen Dolorosa del Colegio y al Divino Niño Jesús, quienes siempre nos cuidaron y siguen cuidando de todo mal, a mis padres, a mi hermano y a mí.

A mis Padres Azucena y Carlos, quienes desde mi primer segundo de vida me llenaron de amor y cariño, fueron mis primeros maestros y aun sigo aprendiendo de ustedes, son mi ejemplo de superación.

A mi Hermano Carlos Adrián, quién siempre me cuida y protege, sin importar la distancia o circunstancia sé que puedo contar con El.

A mis Familiares que estuvieron conmigo, en las buenas y en las malas, pendientes de mí.

A mis Docentes, quienes además de enseñar de Ciencia, enseñan sobre la vida.

A mis Amigos con quienes compartimos muchas experiencias y los mismos objetivos.

Carlomagno Andrade Pobeá

Dedicatoria

Este trabajo lo dedico a Clelio y Rosa, mis padres, ya que toda mi vida académica he intentado dar lo mejor y destacar para que así se sientan orgullosos, esto es más para ustedes que para mí. A mi hermano Daniel, que siempre lo he visto como ejemplo e inspiración pase lo que pase.

A mi familia, mi tía “mamita del campo”, mis primas/o Xime, Nory, Jenny y Fercho que desde niño siempre han estado conmigo en cada etapa de mi vida.

A mis amigos, Chesco, Israel, Christian y José, con su amistad me han estrechado una mano cuando lo he necesitado.

Todo esto lo he hecho con el fin de que se sientan orgullosos de mí, esto es para ustedes con todo cariño.

Francisco Endara S.

Agradecimiento

Agradezco:

A Dios, a la Virgen Dolorosa del Colegio y al Divino Niño Jesús, por los padres y hermano que tengo, además por siempre iluminar y guiar mi camino.

A mi Madre Azucena, le agradezco por tener un carácter tan fuerte y al mismo tiempo tan delicado, por siempre exigirnos ser nuestra mejor versión y dar todo de nosotros, por siempre estar pendiente y llenarnos de mucho amor.

A mi Padre Carlos, le agradezco por enseñarme muchas cosas que me motivaron a seguir esta carrera, a nunca pensar que yo no lo voy a lograr, siempre seguir adelante.

A mi Hermano Carlos Adrián, le agradezco por ser ese ejemplo de estudio y dedicación, por siempre estar conmigo en las buenas y en malas, por todas esas experiencias vividas y por vivir.

A mis mejores amigos Paul, Rosita y Bryan, les agradezco por compartir muchas cosas y situaciones, por siempre estar para nosotros y siempre apoyarnos.

A mis Familiares, Carmen Guerrero por siempre estar pendiente de mí, aconsejarme y cuidarme, Paulina Freire y Diego Molina por siempre estar cuando más los necesitaba, y explicarme materias con mucha paciencia, Xavier Andrade por siempre aconsejarme y motivarme a seguir adelante, a no darme por vencido.

A todos mis Docentes, pero en especial al Ing. Diego Ortiz, por brindarme esta oportunidad de trabajar con él, de cambiar de mentalidad, de aprender muchas cosas, a no ponernos límites académicos y en especial por brindarme una amistad, por aconsejarme y por muchas cosas más.

A mi gran Docente, Ing. Misael Pazmiño quien siempre supo elevar mis ánimos con buenos consejos, y enseñarnos que los Electromecánicos somos de gustos refinados.

A mis compañeros de fórmula, Alejandro, Santiago y Francisco, sin nuestro esfuerzo y empeño este trabajo no se hubiera logrado.

Carlomagno Andrade Pobea

Agradecimiento

“Gracias a la vida, que me ha dado tanto” - Violeta Parra

Gracias a mis padres por todo el sacrificio que han hecho para permitirme llegar a este punto de mi vida, por darme todo lo que estuvo a su alcance para forjarme como persona de bien, que desde que tengo memoria, lo he tenido todo.

Gracias a Chesco e Israel, que desde épocas del colegio me han brindado su amistad y lealtad compartiendo unas de las mejores etapas de mi vida y que sigamos siendo grandes amigos.

A Christian y José, mis amigos universitarios que se convirtieron en familia en tierra ajena, sin ustedes no hubiera sido lo mismo esta aventura universitaria.

Gracias a cada experiencia buena y mala que he tenido que pasar porque gracias a eso he podido crecer y madurar.

Durante toda mi vida académica he tenido grandes maestros que han sembrado en mí muchos conocimientos y valores que me han inspirado a alcanzar mis metas académicas y personales, gracias a cada uno de ellos y un agradecimiento especial al Dr. Diego Ortiz que llegó con una visión diferente que ha plasmado en mi persona otra forma de ver las cosas, gracias por su tiempo, paciencia, consejos y guía que, a más de el desarrollo de este trabajo, me servirá para la vida.

A Carlomagno, por su entrega y compromiso para poder elaborar este trabajo que fue un gran reto, ya que empezamos sin norte ni sur y a medida que íbamos trabajando, logramos finalizar con éxito.

Y finalmente un agradecimiento a la Universidad de las Fuerzas Armadas ESPE por darme la oportunidad de formarme en sus aulas donde he vivido una de las mejores etapas de mi vida.

Francisco Endara S.

Tabla de Contenidos

Carátula.....	1
Certificación	2
Reporte de verificación de contenido	3
Responsabilidad de autoría.....	4
Autorización de publicación.....	5
Dedicatoria.....	6
Agradecimiento.....	8
Tabla de Contenidos	10
Índice de Figuras.....	14
Índice de Tablas	16
Resumen	17
Abstract.....	18
Problemática.....	19
Antecedentes.....	19
Justificación e Importancia.....	20
Objetivos	22
<i>Objetivo General.....</i>	22
<i>Objetivos específicos</i>	22
Estado del Arte.....	24
Estabilidad de frecuencia.....	24

11	
	11
Tiempo de estudio de la estabilidad	25
Inercia del Sistema	27
Control de Frecuencia	28
<i>Respuesta Inercial del sistema</i>	29
<i>Control primario de frecuencia (CPF)</i>	30
<i>Control secundario de frecuencia (CSF)</i>	30
Ecuación de Oscilación (Swing Equation)	30
Regulador Automático de Velocidad (Governor)	33
Máquinas de Aprendizaje (MA)	34
<i>Aprendizaje Supervisado</i>	35
<i>Aprendizaje no supervisado</i>	37
<i>Aprendizaje semi supervisado</i>	38
<i>Aprendizaje reforzado</i>	39
<i>Entrenamiento y validación del algoritmo</i>	40
<i>Ajuste de hiper-parámetros y selección del modelo</i>	41
Metodología	43
Características técnicas del SEP	44
Despacho económico	44
Modelo detallado del SEP	45
Simulaciones en el dominio del tiempo	46
<i>Clasificación de puntos de operación</i>	47

<i>Desarrollo de simulaciones en el dominio del tiempo</i>	48
Entrenamiento y validación de los modelos de las máquinas de aprendizaje. ..	49
Caso de estudio	53
Análisis de resultados.....	58
Modelamiento en estado estacionario (Características Técnicas del SEP)	58
Despacho económico	58
Modelo detallado del SEP	58
Clasificación de los puntos de operación.....	59
Simulaciones en el Dominio del tiempo (TDS)	61
Señales de excursión de frecuencia (Datos Sintéticos)	61
Implementación de los algoritmos de MA.....	61
<i>Decision Tree</i>	62
<i>Random Forest</i>	63
<i>Gradient Boosting</i>	64
<i>Support Vector Machine (SVM)</i>	65
<i>Ensemble Learning (EL)</i>	66
Evaluación del desempeño de los algoritmos de MA	67
Importancia de las características relevantes.....	67
Conclusiones y Recomendaciones	71
Conclusiones.....	71
Recomendaciones	72

Bibliografía	74
Anexos	79

Índice de Figuras

Figura 1 <i>Oscilación de la frecuencia de un SEP</i>	25
Figura 2 <i>Etapas del control de frecuencia</i>	29
Figura 3 <i>Aprendizaje no supervisado</i>	38
Figura 4 <i>Aprendizaje semisupervisado</i>	39
Figura 5 <i>Aprendizaje reforzado</i>	40
Figura 6 <i>Diagrama metodológico</i>	43
Figura 7 <i>Formulación del Problema de Optimización</i>	44
Figura 8 <i>Modelo detallado del SEP</i>	45
Figura 9 <i>Simulación en el dominio del tiempo</i>	47
Figura 10 <i>Configuración y entrenamiento de los modelos de máquinas de aprendizaje</i>	50
Figura 11 <i>Sistema de prueba de 24 barras del IEEE con inserción de ERNC</i>	53
Figura 12 <i>Características Técnicas del Sistema de Prueba</i>	54
Figura 13 <i>Distribución de la potencia instalada para el caso de estudio</i>	57
Figura 14 <i>Implementación de la “regla del codo”</i>	59
Figura 15 <i>Implementación del “Coeficiente de silueta”</i>	60
Figura 16 <i>Resultado de excursión de frecuencia del algoritmo de DT de 4 casos diferentes</i>	62
Figura 17 <i>Resultado de excursión de frecuencia del algoritmo de RF de 4 casos diferentes</i>	63
Figura 18 <i>Resultado de excursión de frecuencia del algoritmo de GB de 4 casos diferentes</i>	64
Figura 19 <i>Resultado de excursión de frecuencia del algoritmo de DT de 4 casos diferentes</i>	65

Figura 20 <i>Resultado de excursión de frecuencia del algoritmo de EL de 4 casos diferentes.....</i>	66
Figura 21 <i>Evaluación del desempeño de los modelos de MA</i>	67
Figura 22 <i>Características relevantes Random Forest.....</i>	68
Figura 23 <i>Características relevantes Gradient Boosting.....</i>	69
Figura 24 <i>Características relevantes Decision Tree.....</i>	70

Índice de Tablas

Tabla 1 <i>Tiempos de estudio de la estabilidad</i>.....	26
Tabla 2 <i>Características de las unidades de ERNC</i>	55
Tabla 3 <i>Características de las unidades convencionales</i>	56

Resumen

El presente trabajo de titulación desarrolla una metodología con el objetivo de realizar un análisis comparativo de los distintos algoritmos utilizados en las Máquinas de Aprendizaje (MA) para la predicción de la excursión de frecuencia de un Sistema Eléctrico de Potencia luego de ocurrida una perturbación, sin hacer uso de las simulaciones en el dominio del tiempo y así evitar los impactos negativos a consecuencia de dichas perturbaciones, siendo estos sociales o económicos, con el fin de garantizar la continuidad del servicio eléctrico manteniendo al sistema con un servicio confiable y continuo. El proyecto incluye el modelamiento de un test system modificado considerando la inserción de energías renovables no convencionales (ERNCC) como la energía eólica y energía solar fotovoltaica. Mediante uso de herramientas computacionales usadas en el campo eléctrico, se obtuvieron los datos sintéticos del sistema, esto mediante el uso de simulaciones en el dominio del tiempo (TDS) considerando como entradas las condiciones operacionales obtenidas del despacho económico previamente desarrollado en un periodo de tiempo definido; estos datos sintéticos del sistema permitieron entrenar las MA para predecir la excursión de frecuencia luego de ocurrida una contingencia. Una vez obtenidos los datos, se procedió a la selección de características relevantes que influyeron en la excursión de frecuencia para obtener información para el correcto entrenamiento de las distintas MA y finalmente se realizó el análisis comparativo entre los resultados obtenidos, verificando cuál de ellas tiene el mejor desempeño en términos de aproximación a los valores obtenidos de manera tradicional.

Palabras clave:

- **MÁQUINAS DE APRENDIZAJE**
- **FRECUENCIA – SISTEMAS ELECTRICOS DE POTENCIA**
- **ENERGÍAS RENOVABLES NO CONVENCIONALES**

Abstract

The main idea is to avoid performing time-domain simulations to know the frequency excursion to prevent activation under frequency load shedding schemes avoiding social and economic impacts. The project includes modelling a modified test system considering the insertion of non-conventional renewable energies (NCRE) such as wind energy and photovoltaic solar energy. Then an economic dispatch is implemented to establish the steady-state conditions of the power system. The synthetic data is generated using a computational tool used in the electric field through time-domain simulations (TDS). The synthetic data is used to train the ML algorithms to predict the frequency excursion after a contingency. Once the data was obtained, we selected relevant features that influenced the frequency excursion. Finally, a comparative analysis between the obtained results was performed, verifying which ML algorithm has the best performance in terms of approximation to the values obtained traditionally.

Keywords:

- **MACHINE LEARNING.**
- **FREQUENCY – POWER SYSTEM**
- **NON-CONVENTIONAL RENEWABLE ENERGIES**

Capítulo I

1. Problemática

1.1 Antecedentes

Según (Kazerooni et al., 2014) , define que los Sistemas Eléctricos de Potencia (SEP), son el conjunto de redes interconectadas cuyo objetivo principal es transportar energía a los distintos consumidores, las mismas que se encuentran en constante innovación y desarrollo, con el fin de garantizar la continuidad en el servicio eléctrico, mantener un sistema eléctrico de potencia con un servicio confiable y continuo. Se establece que, no detectar una falla tiene impactos negativos tanto sociales como económicos; en algunos casos, el impacto de la falla puede resultar en apagones (Yi et al., 2017). El SEP cuenta con dispositivos de medición, que adquieren un gran volumen de datos, por lo cual es necesario incorporar técnicas de procesamiento de datos, que permitan obtener el análisis en tiempo real del estado del sistema.

Según (Yi et al., 2017), se determinó que los factores que alteran las características dinámicas de la frecuencia después de una contingencia son: tipo de falla, ubicación de la falla, estado de operación de la red eléctrica, parámetros del generador, carga y topología de la red. Los operadores del sistema buscan herramientas computacionales que permitan monitorear el estado del sistema de forma rápida y precisa, mejorando los tiempos de respuesta por parte de los operadores para mantener al sistema en condiciones estables, evitando pérdidas de suministro energético y pérdidas económicas. (Idehen et al., 2019) en su estudio establece que, la aplicación de predicción de eventos de fallas, permite realizar un análisis previo a la misma evitando así daños en el sistema, dado que, luego de ocurrida una contingencia, las variables importantes que influyen en el estado del SEP como voltaje y frecuencia se ven afectadas. En la actualidad los operadores de red están enfocados en la

implementación de modelos basados en Máquinas de Aprendizaje (MA) en la operación del SEP, con el objetivo de predecir el comportamiento de las variables ante fallas que afecten al estado normal y poder implementar medidas correctivas que permitan, en el menor tiempo posible, corregir el funcionamiento del mismo en caso de ser necesario.

Dado el avance en las herramientas computacionales, como las utilizadas en el campo de la Inteligencia Artificial (IA), se han mejorado de forma considerable los algoritmos empleados en las áreas de MA y Deep Learning (DL). (Chen, 2019) en su estudio plantea que, los modelos de IA permiten el desarrollo de investigaciones en un SEP para la previsión de carga y generación de energía renovable, optimización del despacho del sistema de energía, también se lleva a cabo varios estudios que utilizan tecnologías de MA en la evaluación de estabilidad del sistema de energía.

Mediante el uso de modelos de MA, el enfoque tradicional de predicción de las variables de un SEP, toma un rumbo distinto al tradicional. (Yi et al., 2017) en su estudio establece que, empleando el método de Redes Neuronales y el método de Elección de Características, se puede predecir la señal de frecuencia. El empleo de los modelos de MA, permiten mejorar los tiempos al momento de predecir el comportamiento de varias señales del sistema, por lo cual el operador puede mantener las condiciones favorables para su correcto funcionamiento, por lo tanto, el desarrollo de modelos de MA para predecir la estabilidad en los SEP es una gran alternativa para generar herramientas computacionales que apoyen en el proceso de toma de decisiones a los operadores de red.

1.2 Justificación e Importancia

Actualmente, para el desarrollo de un país tanto en el aspecto social como económico es necesario contar con recursos, fundamentalmente con energía eléctrica.. El despliegue a gran escala de diversas fuentes de ERNC poseen varios factores

positivos para el medio ambiental y al agotamiento de los combustibles fósiles, dando lugar a una importante implementación de ERNC en los SEP actuales que se encuentran en constante cambio en su infraestructura e innovación.

Desde el punto de vista de la estabilidad de frecuencia, los retos surgen principalmente porque la mayoría de las ERNC no contribuyen significativamente a la respuesta inercial del sistema durante las contingencias del sistema eléctrico ya que la interfaz del convertidor de potencia desacopla total o parcialmente las fuentes de generación de la red. Mantener la frecuencia del sistema en torno a su valor nominal durante las condiciones normales de funcionamiento y después de desequilibrios o perturbaciones importantes entre la generación y la carga es un requisito obligatorio para el funcionamiento estable y continuo del SEP evitando consecuencias sociales y económicas que los grandes apagones pueden causar en la sociedad. (Ortiz-Villalba et al., 2020)

Para prevenir la inestabilidad del SEP, los operadores realizan diferentes estudios mediante simulaciones off-line y considerando el peor de los casos con contingencias relevantes, todo esto con el propósito de detectar posibles fallas para adoptar medidas preventivas y/o correctivas para mantener la integridad del sistema ante los posibles eventos que puedan alterar el normal funcionamiento del SEP.

El uso de la IA en el análisis de la estabilidad de los SEP es un área de investigación activa que ha recibido una atención significativa en los últimos años. La IA se ha utilizado con éxito para la evaluación de la estabilidad dinámica como: estabilidad de frecuencia, estabilidad del ángulo del rotor, estabilidad de la tensión y localización, detección y diagnóstico de fallos.

En la literatura existen varios trabajos asociados al estudio de la predicción del comportamiento ante fallas tanto de voltaje, así como de la frecuencia de un SEP,

empleando el método tradicional de simulaciones en el dominio del tiempo, por lo que el presente trabajo de investigación propone una metodología para determinar la excursión de frecuencia mediante el uso de datos sintéticos y MA, disminuyendo los tiempos de simulación y esfuerzo computacional.

1.3 Objetivos

1.3.1 Objetivo General

Desarrollar un estudio comparativo de los distintos modelos de máquinas de aprendizaje para la realización de estudios de estabilidad de frecuencia empleando herramientas computacionales utilizadas en la industria eléctrica.

1.3.2 Objetivos específicos

- Implementar un modelo de despacho económico para un periodo de tiempo establecido, de un test system modificado tomando en cuenta la inserción de energías renovables no convencionales mediante el uso de herramientas de optimización para obtener las condiciones de operación del mismo.
- Desarrollar el modelo detallado del test system modificado mediante el uso de una herramienta computacional empleada en el sector eléctrico, con el objetivo de llevar a cabo simulaciones en el dominio del tiempo (TDS) para obtener las señales de las principales variables eléctricas.
- Elegir las variables más relevantes que influyen en la excursión de frecuencia, con el objetivo de tener información adecuada para el correcto entrenamiento de las máquinas de aprendizaje mediante el uso de técnicas de selección de características relevantes.
- Evaluar el desempeño obtenido de las distintas máquinas de aprendizaje a partir de los datos sintéticos del test system modificado y compararlas entre

sí para definir el modelo que garantice la mejor predicción del comportamiento de la frecuencia ante contingencias.

Capítulo II

2. Estado del Arte

2.1 Estabilidad de frecuencia.


Un sistema eléctrico de potencia se debe mantener estable en todo momento para su correcto funcionamiento, es así que una de las principales variables que pueda verse afectada es la frecuencia ya que al presentarse una perturbación puede causar el desbalance entre demanda y generación para lo cual el sistema debe tener la capacidad de mantener estable dicha variable y esto se le conoce como estabilidad de frecuencia. (P. S. Kundur, 1994)

La estabilidad de frecuencia tiene su análisis a largo y corto plazo, dependiendo del equilibrio de la potencia activa. Al existir cambios en la demanda de potencia activa en cierto punto de operación, tiene su respuesta en el cambio de la frecuencia. (P. S. Kundur, 1994)

En la figura 1 se presenta la variación repentina de la señal de frecuencia del sistema, donde se visualiza una excursión severa de frecuencia debido a desconexión de carga y su recuperación a su valor nominal a partir del tiempo establecido. Las severas variaciones de frecuencia activan los esquemas de desconexión de generación y/o demanda. Los factores asociados con el problema de estabilidad de frecuencia son una deficiente respuesta inercial del sistema, mala coordinación de los esquemas de protección y control o por falta de reserva de generación. (P. Kundur et al., 2004)

Figura 1

Oscilación de la frecuencia de un SEP



Nota: Oscilación de la frecuencia de un SEP con caída brusca de frecuencia.

En sistemas aislados, los valores de voltaje se pueden alterar de manera significativa cuando existieron oscilaciones de frecuencia que afectan el equilibrio entre generación y la demanda. (Gómez et al., 2002)

2.2 Tiempo de estudio de la estabilidad

Los sistemas eléctricos de potencia tienen características dinámicas, por lo cual presentan variaciones desde los micro-segundos (descargas atmosféricas), hasta llegar a horas. La estabilidad de frecuencia presenta mayores problemas en el lapso de los segundos hasta los minutos. La tabla 1 presenta el criterio sobre los tiempos de análisis de la estabilidad en un SEP.

Tabla 1*Tiempos de estudio de la estabilidad*

Tipo de estabilidad	Corto plazo	Largo plazo	Dinámica de los equipos
Estabilidad de pequeña señal		10 – 20 [s]	
Estabilidad transitoria	3 – 5 [s] y 10 – 20 [s]		Consideración de equipos de actuación rápida y/o lenta
Estabilidad del voltaje	Varios segundos	Varios minutos	
Estabilidad de la frecuencia	Fracciones de segundos	Varios minutos	

Nota: Criterio sobre la consideración de los tiempos de estudio de la estabilidad

Según (Gómez et al., 2002), Los generadores y los sistemas de control primario son características dinámicas que afectan directamente a la estabilidad de corto plazo. Los generadores sincrónicos al ser las principales fuentes de energía, así como los sistemas de regulación secundaria de frecuencia-potencia y los reguladores voltaje-reactiva, afectan a la estabilidad del sistema a largo plazo.

La estabilidad de frecuencia principalmente está gobernada por:

- La inercia de las masas de los rotores de los grupos generadores.
- La regulación primaria de frecuencia de los generadores.
- El tamaño del sistema y el número de generadores.

En la actualidad existe mayor penetración de fuentes de energía renovable no sincrónica y esto es un gran problema ya que causa la reducción de la inercia del sistema. (Kovaltchouk et al., 2016). Los aerogeneradores de velocidad variable y los inversores fotovoltaicos no tienen inercia, pero influyen considerablemente en la

estabilidad de frecuencia y conduce a un rápido cambio de rango de frecuencia y a caídas de frecuencia más profundas. (Sánchez, 2020)

2.3 Inercia del Sistema.

Después de ocurrido el desbalance entre demanda y generación, la variable frecuencia del sistema caerá a una tasa determinada que depende de la inercia total del sistema. (Mullane & O'Malley, 2005). Según el estudio de (Lalor et al., 2005), al presentar una baja inercia sistémica, mayor será la excursión de frecuencia del SEP. La inercia promedio del SEP, es el resultado de la combinación de la inercia de todas las unidades de generación convencionales presentes en el sistema, como se expone en la ecuación (1):

$$H_{sist} = \frac{\sum_{i=1}^n H_i S_i}{\sum_{i=1}^n S_i} \quad (1)$$

H_{sist} = Inercia del sistema

H_S = inercia de cada generador

S = potencia aparente

Los generadores sincrónicos poseen reguladores de velocidad que al producirse una falla se demoran en actuar, es por esto que los generadores no son capaces de generar inmediatamente la potencia adicional necesaria para mantener el equilibrio de energía en el sistema luego de producida una contingencia. La energía cinética es producida por los generadores sincrónicos la cual es la encargada de cubrir la diferencia de energía que se produce entre la potencia generada y la carga. Para cubrir la respuesta inercial del sistema, son considerados los generadores ya que si una variación de frecuencia produce un cambio de velocidad rotacional y consecuentemente un cambio en la energía cinética. (Walker et al., 2011). Esto genera una reducción en la

velocidad de las máquinas hasta lograr un valor de cero en la tasa de cambio de frecuencia. (Erlich & Wilch, 2010). Este tipo de respuesta se llama respuesta inercial. (Keung et al., 2009). Las máquinas sincrónicas poseen esta reacción natural que viene dada por la ley de rotación de Newton:

$$2H \frac{dw}{dt} = T_m - T_e \quad (2)$$

Donde:

H: es la constante de inercia en segundos.

w: es la velocidad rotacional del generador.

T_m: es el torque mecánico.

T_e: es el torque electromagnético.

En función a la ecuación (2), los generadores sincrónicos ejercen una respuesta opuesta durante un lapso de tiempo en segundos, cuando existen desajustes entre demanda y generación. Por lo cual, al existir cambios intempestivos en generación, se compensa por la energía cinética almacenada en las masas rotóricas de las unidades de generación convencional.

2.4 Control de Frecuencia


Para mantener el SEP en un correcto funcionamiento es indispensable mantener el equilibrio durante todo el tiempo entre la generación y la demanda, incluyendo pérdidas. La frecuencia es uno de los parámetros que deben permanecer dentro de los límites permisibles para que el sistema tenga un correcto funcionamiento y así garantizar el suministro eléctrico.

En el SEP se generan pequeños desbalances de potencia que afectan al equilibrio ya sea por fallas o variaciones de demanda y eso da a lugar a variaciones de frecuencia que las alejan de su valor nominal, teniendo como consecuencias apagones o colapso del sistema. Para evitar este tipo de alteraciones existe la denominada regulación de frecuencia del SEP. (Chávez et al., 2014).

La regulación de frecuencia se divide en 3 etapas de control como muestra la figura 2:

Figura 2

Etapas del control de frecuencia



Nota: Tiempo de acción de reserva inercial, control primario y secundario de frecuencia

2.4.1 Respuesta Inercial del sistema

La respuesta inercial del sistema, es el primer método para mantener la frecuencia del sistema en su valor nominal, evitando así la activación de cualquier sistema de control. Al presentarse una conexión intempestiva de demanda o desconexión intempestiva de generación, la respuesta inercial toma la energía almacenada en las masas rotóricas de las unidades de generación convencional, obteniendo un lapso de tiempo en el cual el operador de red puede tomar medidas correctivas. (Villanueva Mayr, 2016)

2.4.2 Control primario de frecuencia (CPF)

Es un mecanismo de regulación automático que poseen los generadores que participan en este control. Tiene como objetivo corregir de manera inmediata los desequilibrios entre la generación y demanda en un rango entre 5 a 30 segundos, aunque en ciertas ocasiones pueden tardar el orden de minutos. Otro objetivo es el de protección de la máquina: si la velocidad de giro es muy baja, pueden producirse cavitaciones y, por otro lado, si la velocidad de giro es muy alta, la máquina puede embalsarse y ocasionar sobre esfuerzos lo que puede causar la destrucción de la misma. Tiene su actuación de forma local en cada generador sincrónico, ocupándose de la velocidad rotacional del eje, la velocidad de este control se limita por la propia inercia de las unidades de generación provocada por la reserva en giro. Luego de la acción del CPF, la frecuencia no volverá a su valor nominal si no que quedará desplazado con respecto al valor de referencia. (Villanueva Mayr, 2016)

2.4.3 Control secundario de frecuencia (CSF)

Tiene como objetivos solucionar el error que queda en el control primario de frecuencia y devolver las reservas en giro. El tiempo de operación es de los 30 segundos hasta los 30 minutos. El control secundario de frecuencia se puede realizar de forma manual (operador de red) o de forma automática. (Villanueva Mayr, 2016)

2.5 Ecuación de Oscilación (Swing Equation)

La ecuación de oscilación (Swing Equation) es una ecuación diferencial que relaciona el torque de aceleración y la aceleración angular (Jena & Prusty, 2014),

$$J \frac{d^2\theta}{dt^2} = T_a = T_m - T_e \quad (3)$$

donde,

J Momento total de inercia en $Kg - m^2$

θ Desviación angular del rotor con respecto al eje estacionario en radianes

T_m Par mecánico en $N - m$

T_e Par eléctrico en $N - m$

T_a Par de aceleración en $N - m$

En condiciones estables del sistema, el par mecánico y el par eléctrico son iguales, por lo cual la aceleración es cero. Si el par mecánico es mayor que el par eléctrico, el generador acelera, caso contrario desacelera. El ángulo rotórico se mide en base al eje de rotación sincrónico como en la ecuación 4.

$$\theta_m = \omega_{sm}t + \delta_m \quad (4)$$

donde,

ω_{sm} Velocidad sincrónica en rad/seg

δ_m Desviación angular del rotor en rad

Para determinar (3) en δ , se deriva (4)

$$J \frac{d^2\delta_m}{dt^2} = T_a = T_m - T_e \quad (5)$$

Si

$$\omega_m = \frac{d\theta_m}{dt} \quad (6)$$

Para expresar la ecuación de oscilación en unidades de potencia se multiplica (5) por ω_m ,

$$\omega_m * J \frac{d^2 \delta_m}{dt^2} = \omega_m * T_m - \omega_m * T_e \quad (7)$$

Se sabe que,

$$\omega_m * T_m = P_m \quad (8)$$

$$\omega_m * T_e = P_e \quad (9)$$

Sustituyendo (8) y (9) en (7), se obtiene:

$$M \frac{d^2 \delta_m}{dt^2} = P_m - P_e = P_a \quad (10)$$

Donde,

$M = \omega_m * J$ Inercia de la máquina

P_m Potencia mecánica

P_e Potencia eléctrica

Cuando una máquina síncrona se encuentra funcionando en condiciones normales, la diferencia entre la velocidad del rotor y la velocidad síncrona es muy pequeña, pero al presentarse una perturbación en el sistema, la diferencia aumenta y la máquina pierde sincronismo. El término M en (10) varía constantemente y depende de la capacidad de la máquina. Se define otra constante de Inercia H (11), representando la energía cinética almacenada. (Zaidi & Cheng, 2018)

$$H = \frac{\frac{1}{2} J \omega_{sm}^2}{S_{mach}} \quad (11)$$

H Inercia

S_{mach} Potencia nominal en MVA

A continuación, se expone la relación entre la constante de inercia H y M :

$$M = \frac{2H}{\omega_{sm}} S_{mach} \quad (12)$$

Entonces

$$\frac{2H}{\omega_{sm}} S_{mach} \frac{d^2 \delta_m}{dt^2} = P_a = P_m - P_e \quad (13)$$

Para expresar la potencia de la ecuación en por unidad, se asume que la capacidad nominal de la máquina en MVA es la potencia aparente del sistema.

$$\frac{2H}{\omega_{sm}} \frac{d^2 \delta_m}{dt^2} = \frac{P_m - P_e}{S_{mach}} \quad (14)$$

donde

$\frac{P_m}{S_{mach}}$ Potencia mecánica en por unidad

$\frac{P_e}{S_{mach}}$ Potencia eléctrica en por unidad

Finalmente, se presenta la ecuación de swing en por unidad.

$$\frac{2H}{\omega_{sm}} \frac{d^2 \delta_m}{dt^2} = P_{a.p.u} = P_{m.p.u} - P_{e.p.u} \quad (15)$$

2.6 Regulador Automático de Velocidad (Governor)

Cuando se produce un intempestivo incremento en la carga en un generador, la potencia eléctrica supera a la potencia mecánica de la unidad. Esta falta de potencia es

abastecida por la energía cinética almacenada en el sistema giratorio, disminuyendo la velocidad de la turbina y la frecuencia del generador. (Saadat, 2009). La Comisión Electrotécnica Internacional (IEC), establece al governor como la asociación de varios dispositivos y mecanismos que detecta el cambio de velocidad de la turbina y permite variar el curso del servomotor principal. (IEC, 2005). El governor permite conseguir el balance entre la energía consumida y la energía generada, mediante una señal de activación. En centrales térmicas el governor cambia la posición de una válvula de vapor y en centrales hidráulicas la apertura de las compuertas con el propósito de incrementar la potencia mecánica para recuperar el balance de energía. (Pourbeik et al., 2013)

Idealmente una red eléctrica debería operar con precisión a su frecuencia nominal, pero tiene variaciones de frecuencia en torno a su valor nominal, debido a las variaciones de demanda. El governor no debe equilibrar estas pequeñas variaciones de frecuencia porque una válvula de control es un dispositivo de actuación mecánica, que presentaría un desgaste excesivo. (Chow & Sanchez-Gasca, 2020). En el diseño del governor se define un “deadband”, es un límite donde el governor no responde a variaciones de frecuencia, cuando las variaciones de frecuencia superan esta banda muerta, el governor se activa y hace la corrección de frecuencia. (Kou et al., 2016). Las pequeñas variaciones de frecuencia son anuladas por la respuesta inercial del sistema. (Villanueva Mayr, 2016).

2.7 Máquinas de Aprendizaje (MA)

El aprendizaje artificial es la ciencia de programar computadoras para que sean capaces de aprender desde una base de datos. Es el área de estudio que brinda a las unidades computacionales la habilidad de aprender sin la necesidad de programarlas explícitamente. (Geron, 2019)

Las máquinas de aprendizaje son utilizadas para:

- Encontrar la solución a problemas cuyas respuestas tradicionalmente necesitaban de una extensa y puntual programación o extensas restricciones. Un algoritmo de MA reduce el código y obtiene mejores desempeños que las formas tradicionales.
- Son capaces de modificar su ámbito de aplicación, adaptándose a diferentes bases de datos y a actualizaciones. Además, proveen información interna sobre los problemas que se encuentran resolviendo ya que se puede acceder a su base de datos y observar las decisiones que están tomando (Data mining).

Los tipos de sistemas dentro de MA se suelen clasificar en:

Supervisados - No supervisados: Esta clasificación hace referencia a la cantidad de supervisión que el algoritmo dispone cuando este se encuentra en la etapa de entrenamiento. Existen 4 subcategorías en las que se los clasifica:

2.7.1 Aprendizaje Supervisado

El aprendizaje supervisado hace referencia a un “supervisor” que es el encargado de dar las instrucciones al sistema de aprendizaje acerca de las etiquetas que se deben asociar a los distintos ejemplos de entrenamiento. Los modelos de aprendizaje supervisado obtienen modelos en base a los datos de entrenamiento y estos modelos son capaces de clasificar otros tipos de datos no etiquetados. (Lidy & Rauber, 2008)

El aprendizaje supervisado es la formalización de la idea de aprender a partir de ejemplos, es decir, el alumno (el algoritmo), recibe dos conjuntos de datos que son el conjunto de prueba y entrenamiento. La idea es que el alumno aprenda de un conjunto de ejemplos etiquetados en el conjunto de entrenamiento para así identificar los

ejemplos no etiquetados en el conjunto de prueba intentando lograr la mayor precisión posible. El objetivo del alumno es desarrollar o crear una regla o procedimiento que clasifique nuevos ejemplos en el conjunto de prueba, analizando los ejemplos que se le han dado y que ya posee una etiqueta de clase. (Learned-Miller, 2014)

Los principales algoritmos de aprendizaje supervisado son:

- k-Nearest Neighbors
- Regresión lineal
- Regresión logística
- Support Vector Machines (SVM)
- Árboles de decisión y bosques aleatorios
- Redes neuronales

a. Regresión lineal. Este tipo de algoritmo se maneja de una manera más simple, es decir, se dibuja una línea recta la cual indicará la tendencia de un conjunto de datos continuos.

De forma general, el modelo de regresión lineal predice de manera simple calculando una suma ponderada de las características de entrada y una constante llamada término de sesgo. (Geron, 2019)

b. Regresión logística. Este algoritmo trabaja con el conjunto de series datos de entrada o características cuya salida será discreta mas no continua. Se utiliza generalmente para estimar la probabilidad de que una instancia pertenezca a una clase determinada. (Geron, 2019)

c. Support Vector Machines (SVM). Es un modelo de aprendizaje automático versátil y potente que tiene la capacidad de realizar la clasificación ya sea esta lineal o no lineal, una regresión o incluso la detección de valores atípicos. Es uno de los modelos más

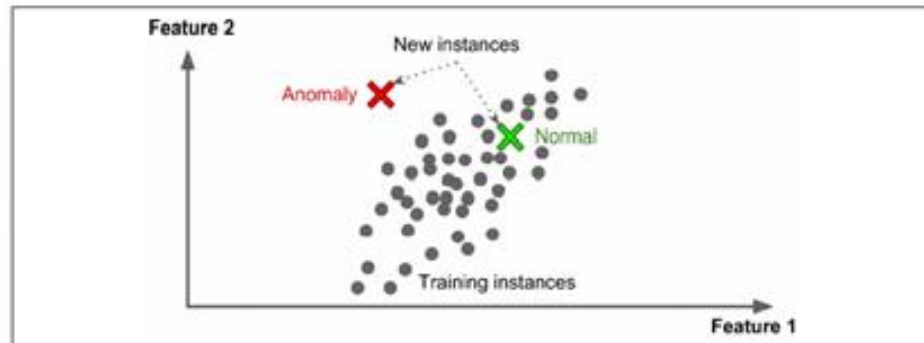
usados en el aprendizaje automático y son más adecuadas para clasificar conjuntos de datos más complejos de tamaño pequeño o mediano. (Geron, 2019)

d. Decision Tree y Random Forest. Decision Tree se representa mediante gráficas de las posibles soluciones a una decisión basadas en ciertas condiciones, este algoritmo puede ser usado tanto para clasificación como para regresión. Para llegar a obtener un árbol óptimo y que cada subdivisión tenga un valor entre todos los árboles posibles y obtener un nodo raíz y los subsiguientes, el algoritmo debe medir las predicciones logradas de alguna manera y valorarlas para posteriormente compararlas entre todas y obtener la mejor. Decision Tree son elementos que conforman el algoritmo Random Forest, este es uno de los algoritmos más potente en la actualidad. (Bagnato, 2020)

Random Forest es la agrupación de Decision Trees y este algoritmo introduce una variabilidad adicional al hacer desarrollar los árboles y en lugar de encontrar la mejor característica al dividir un nodo, este busca la mejor característica entre un subconjunto aleatorio de características. El algoritmo genera una mayor diversidad de árboles, lo que implica un mayor sesgo a cambio de una menor varianza y con esto da lugar a un modelo que tiene un desempeño superior de forma global. (Geron, 2019)

2.6.2 Aprendizaje no supervisado

En este tipo de aprendizaje el algoritmo recibe los datos sin ninguna clasificación previa de los mismos. Los datos ingresan sin pertenecer a una clase o tipo y el algoritmo trata de encontrar características similares entre ellos y formar grupos en base a esas similitudes. De la misma manera son considerados para detectar cambios o alteraciones dentro de un grupo de datos cuando encuentra características inusuales y que salen del patrón. Este tipo de algoritmos pueden ayudar a encontrar fallas en un sistema.

Figura 3*Aprendizaje no supervisado*

Nota: Ejemplo base para el aprendizaje no supervisado

Los algoritmos más empleados en el aprendizaje no supervisado son:


- Agrupación: K Means, DBSCAN, Análisis de clasificación jerárquica (HCA)
- Detección de alteraciones y detección de cambios: Subclase de SVM, Isolation Forest
- Visualización y reducción dimensional: Análisis de componentes principales (PCA), Kernel PCA, Inclusión local lineal (LLE), t- distributed stochastic Neighbor embedding (t- SNE).
- Aprendizaje de reglas de asociación: A priori, Eclat.

2.6.3 Aprendizaje semi supervisado

Este tipo de aprendizaje nace debido a que clasificar datos en la base de datos antes de colocarlos en el algoritmo requiere de tiempo y dinero, es por ello que una alternativa es etiquetar ciertas categorías de datos y dejar otras sin etiquetar, para que el algoritmo se haga cargo de los datos no etiquetados.

Figura 4

Aprendizaje semisupervisado



Nota: Ejemplo base para el aprendizaje semi supervisado


Como ejemplo se tiene el algoritmo Deep belief network (DBN's), el cual se basa en modelos no supervisados llamados Boltzmann machines (RBM'S) de manera continua, así la primera clasificación se vuelve un modelo supervisado sobre la siguiente, así hasta construir todo el modelo.

2.6.4 Aprendizaje reforzado

Este modelo cuenta con un subsistema llamado "agente" el cual se configura con un sistema de ganancias y sanciones en su funcionamiento, de esta manera el algoritmo al evaluar un dato en base a la respuesta obtenida (positiva o negativa) aprende a solo elegir la positiva en el siguiente intento. (Geron, 2019).

Figura 5

Aprendizaje reforzado



Nota: Ejemplo base para el aprendizaje reforzado

2.6.5 Entrenamiento y validación del algoritmo

La única manera de comprobar si el algoritmo funciona de manera correcta es probándolo en nuevos casos relacionados a los datos con los que fue modelado, sin embargo, hacerlo directamente en campo no es una buena idea, debido a que si el algoritmo funciona mal o si fue entrenado con datos erróneos el cliente o usuario presentará quejas y podría incluso desinteresarse en el mismo.

La mejor manera de hacerlo es dividiendo los datos totales disponibles en dos grupos. Un porcentaje servirá para su entrenamiento y el restante para su validación. La tasa de error que el modelo podría presentar en casos reales o casos nuevos de aplicación se conoce como “error generalizado o error fuera de muestra” y en la etapa de validación se puede estimar el porcentaje de este error. Este valor indica que tan bien se comportará el algoritmo en instancias totalmente nuevas. Si el error de

entrenamiento es bajo, pero el error general es alto, significa que el modelo tiene demasiados datos en la etapa de entrenamiento.

Comúnmente se utiliza el 80% para la etapa de entrenamiento y el 20% para la validación. Sin embargo, depende mucho del tamaño de la base de datos. Si contiene por ejemplo 10 millones de instancias, reservar el 1% de los datos para la validación significa disponer de 100000 instancias, probablemente más que suficientes para obtener un buen valor de error generalizado. (Geron, 2019)

2.6.6 Ajuste de hiper-parámetros y selección del modelo

Evaluar un modelo puede ser sencillo, simplemente introducir datos para entrenarlo y ver sus resultados. Pero qué pasa si existe la duda de que tipo de modelo usar (lineal, polinomial, etc.) La opción más sencilla sería entrenar a los dos con los mismos parámetros y ver cuál funciona mejor, pero, ¿cómo decidir qué porcentaje de datos se reserva para validar para cada uno de los modelos?

El programador podría caer en el error de cambiar el porcentaje de datos de manera tan repetitiva con el objetivo de disminuir el error generalizado para elegir un modelo específico tal vez porque le resulta más familiar o es más sencillo de trabajar. Lo que va a ocurrir es que el modelo se entrenará con un “hiper parámetro” lo que quiere decir que el modelo se acostumbra demasiado a esa base de datos haciéndolo propenso a fallar con datos nuevos.

Una manera de resolver este problema es realizar validaciones cruzadas de manera repetitiva usando grupos de datos pequeños. Cada modelo es evaluado una vez por grupo de datos después de su etapa de entrenamiento con el resto de datos restantes. Mediante el promedio de los resultados de todas las validaciones se puede obtener una mayor precisión de su desempeño. Sin embargo, existe un problema, el

tiempo de entrenamiento se multiplica por el número de veces que se vaya a realizar la validación, todo el proceso de preparar el algoritmo se vuelve mayor. (Geron, 2019)

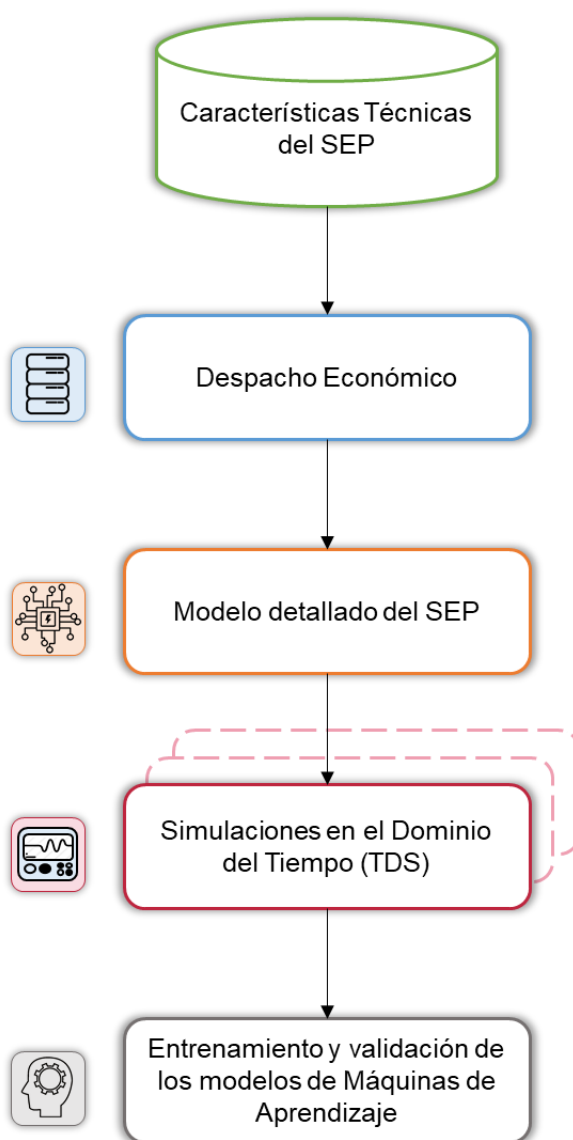
Capítulo III

3. Metodología

En este capítulo se exponen las etapas que forman parte de la metodología propuesta, esta se compone de cinco etapas, como se puede observar en la Figura 6.

Figura 6

Diagrama metodológico



Nota: Diagrama metodológico del trabajo de investigación.

3.1 Características técnicas del SEP

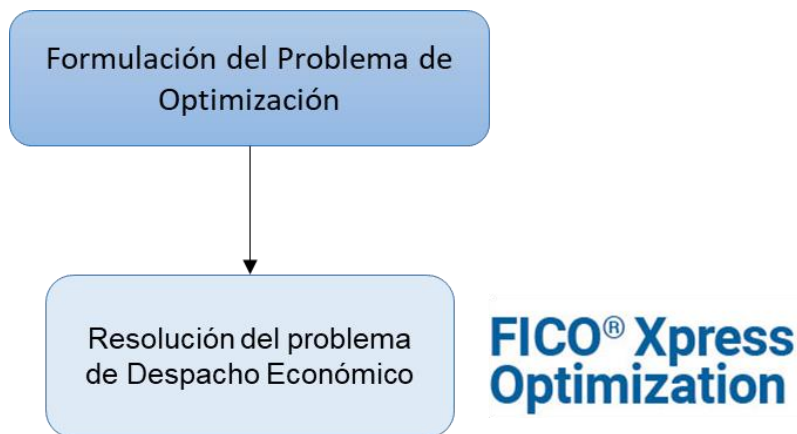
En la primera etapa de la metodología se selecciona un sistema, del cual se obtendrá información que especifique los parámetros de operación de todos los elementos que conforman el sistema.

3.2 Despacho económico

La segunda etapa de la propuesta metodológica consiste en el desarrollo del problema de optimización (Despacho Económico) para un horizonte de tiempo a evaluar con el objetivo de minimizar los costos de operación para cada hora; se emplean las características técnicas del sistema, como se indica en la Figura 7.

Figura 7

Formulación del Problema de Optimización



Nota: Diagrama metodológico de la etapa del despacho económico.

A continuación, se resuelve el problema de optimización que consiste en realizar el despacho económico multinodal en función de los datos obtenidos, considerando las restricciones de las unidades de generación y de las líneas de transmisión del sistema. (Alex et al., 2021)

El principal objetivo del despacho económico es distribuir la demanda total del sistema, de forma óptima entre los generadores disponibles (convencionales o no convencionales), llegando a obtener un costo de operación mínimo del sistema respetando las limitaciones técnicas. Se plantea la función objetivo en la cual se incluyen las unidades de generación consideradas junto con el costo de su recurso primario.

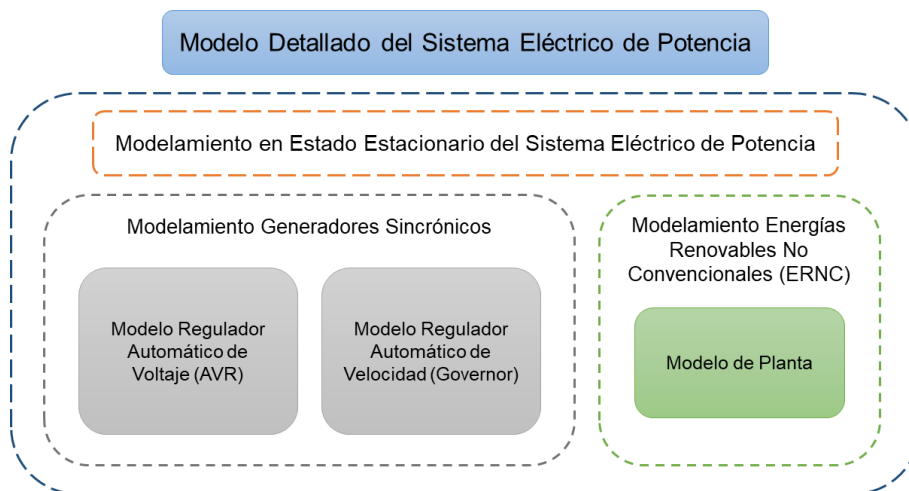
Además, se plantean las restricciones de igualdad y desigualdad de cada elemento del sistema. La formulación completa del problema de optimización se encuentra en el Anexo 1.

3.3 Modelo detallado del SEP

La tercera etapa de la metodología es el modelamiento detallado del sistema, el cual consiste además de modelar en estado estacionario los componentes del SEP, se integran los modelos de planta de cada una de las unidades de generación convencional y ERNC.

Figura 8

Modelo detallado del SEP



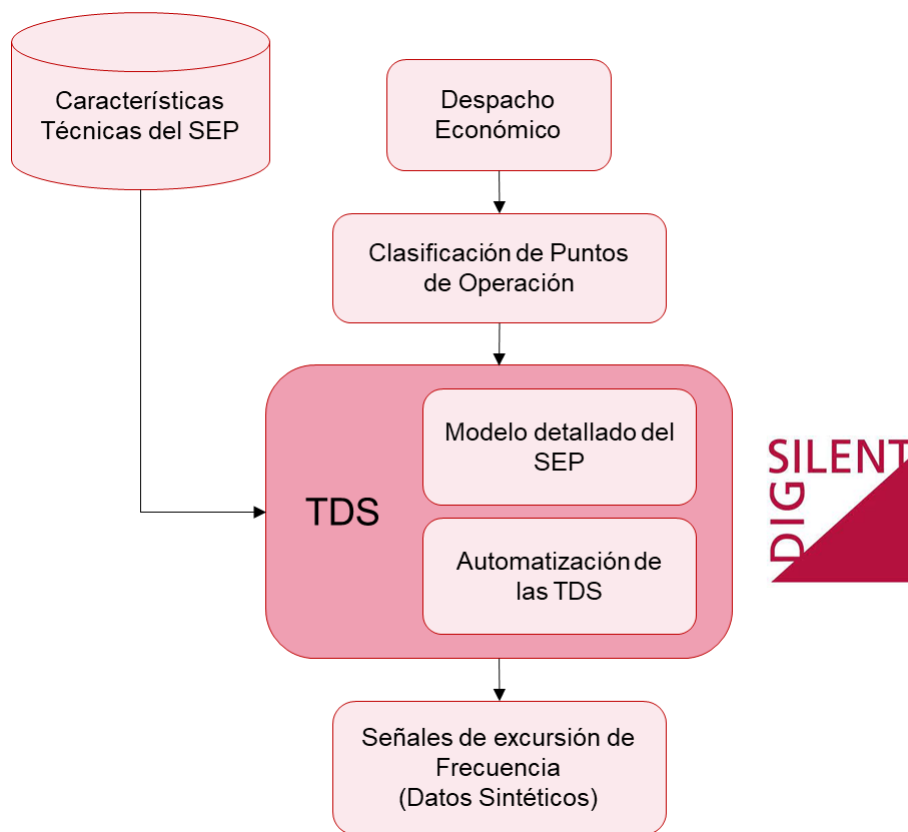
Nota: Modelo detallado del SEP

El modelamiento de los GS en estado estacionario, no permite observar el comportamiento de las unidades de generación ante una contingencia, para ello se incluye el modelamiento detallado, que consiste en agregar el modelo de planta a las unidades que conforman el sistema. El modelo de planta consiste, en agregar los controladores de las unidades de generación, siendo los principales el Regulador Automático de Voltaje (AVR) y el Regulador Automático de Velocidad (RAV), para esta metodología se utilizan modelos normalizados por el IEEE.

El modelamiento detallado de las unidades de ERNC, consiste en agregar el modelo de planta que incluye el modelo de la turbina y conversor en el caso de la energía eólica y en el caso de la energía solar fotovoltaica se incluye el modelo de los paneles además de los convertidores, permitiendo observar el comportamiento de las unidades de generación en transcurso del tiempo y ante una contingencia, para el desarrollo de estos modelos se emplean modelos normalizados por los diferentes programas de simulación usados en área eléctrica.

3.4 Simulaciones en el dominio del tiempo

La cuarta etapa de la propuesta metodológica consiste en el desarrollo de las Simulaciones en el Dominio del Tiempo (TDS). Esta etapa tiene como objetivo generar los datos sintéticos que representan el comportamiento del sistema ante contingencias, estos datos serán utilizados para la siguiente etapa de la metodología.

Figura 9*Diagrama metodológico TDS*

Nota: Diagrama metodológico de la etapa de Simulaciones en el Dominio del Tiempo

3.4.1 Clasificación de puntos de operación

Como resultado de la etapa de resolución del problema de optimización se obtuvo el despacho económico del sistema, el mismo que entrega la potencia inyectada por cada uno de los generadores.

La solución del despacho económico no incluye la regulación de voltaje ni regulación de reactivos; si se implementa directamente la respuesta del despacho, es muy probable que las simulaciones en el dominio del tiempo incluyan errores, debido a que las condiciones iniciales no son las adecuadas, debido a que no reflejan las condiciones reales del sistema. Para resolver este desafío se considera la clasificación

de los puntos de operación (horas de despacho), mediante técnicas de agrupamiento “Clustering”.

Las técnicas de agrupamiento permiten fraccionar y agrupar los puntos de operación que poseen características similares, con el objetivo de encontrar el punto de operación más representativo, es decir, aquel que tiene mayor grado de similitud con los demás puntos de operación miembros del grupo, el punto representativo es conocido como centroide. Este punto de operación (centroide) dado que tiene características similares al resto de puntos de operación que son miembros del grupo, los ajustes que se realicen en él (regulación de voltaje y despacho de reactivos) sirven para todos los puntos de operación miembros del grupo. De esta manera las condiciones iniciales de todos los puntos de operación quedan definidas con la ayuda del centroide y permite el desarrollo de las TDS para todo el conjunto de puntos de operación bajo estudio.

3.4.2 Desarrollo de simulaciones en el dominio del tiempo

Las simulaciones en el dominio del tiempo (TDS) permiten simular la operación del sistema durante un determinado periodo de tiempo y además permiten obtener información relevante del estado del sistema, así como de los principales componentes que conforman el mismo durante una contingencia. Para el desarrollo de las TDS es necesario utilizar el modelo detallado del SEP previamente obtenido y los puntos de operación que representan las condiciones iniciales adecuadas.

Además, mediante el uso del lenguaje de programación integrado en los programas de simulación utilizados en el campo de la ingeniería eléctrica, se pueden automatizar varios eventos en el SEP bajo estudio, con el propósito de obtener la evolución de las variables eléctricas monitoreadas luego de simular una contingencia.

Se determinan las unidades de generación que, al presentar una desconexión repentina, afectan de forma significativa a la estabilidad de frecuencia del sistema. Bajo este criterio se consideran las unidades de generación con mayor potencia inyectada al sistema en ese punto de operación.

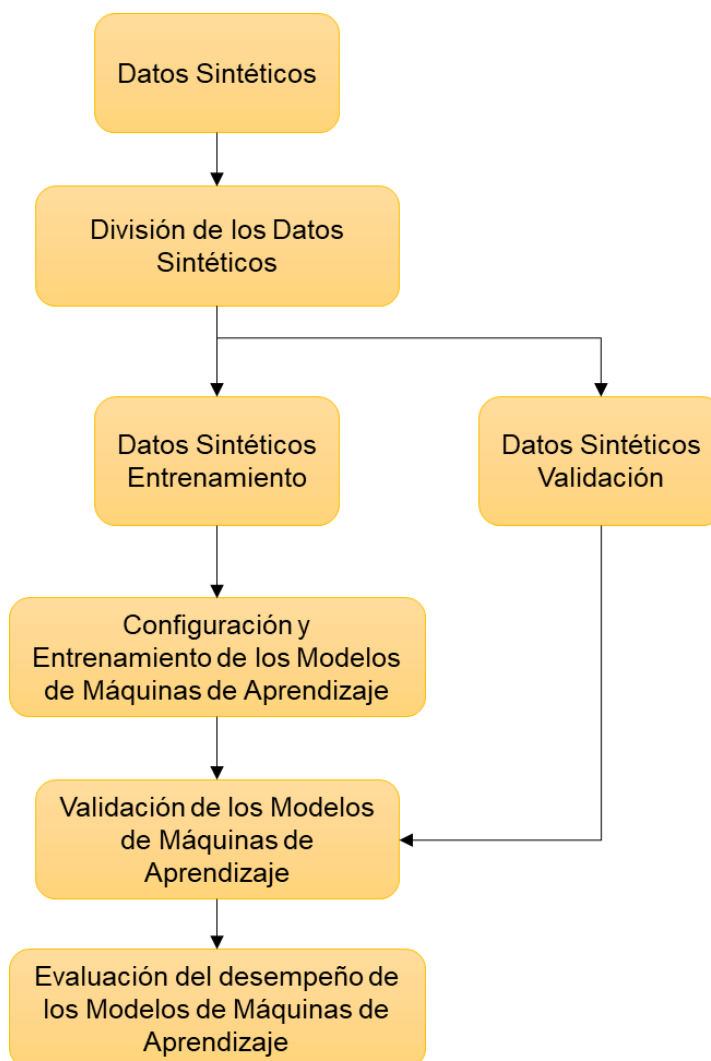
Además, se modelan eventos de desconexión de interruptores, que permiten visualizar la respuesta dinámica del sistema ante una desconexión intempestiva de generación. Obteniendo la inercia del sistema, así como las señales de potencia mecánica, potencia eléctrica, entre otras señales, que forman parte de los datos sintéticos del sistema. Estas características serán evaluadas en los pasos posteriores de la metodología para evaluar si son relevantes o no en el proceso de predicción de la excursión de frecuencia.

3.5 Entrenamiento y validación de los modelos de las máquinas de aprendizaje.

Por último, la quinta etapa de la metodología consiste en el entrenamiento y evaluación de los distintos modelos de MA con los datos sintéticos y las características relevantes seleccionadas, con el propósito de predecir las excursiones de frecuencia y obtener el desempeño de cada modelo. Además, en esta etapa se realiza un análisis comparativo entre todos los modelos MA utilizados con el propósito de determinar el modelo con mejor desempeño.

Figura 10

Configuración y entrenamiento de los modelos de máquinas de aprendizaje



Nota: Diagrama metodológico de la configuración y entrenamiento de los modelos de máquinas de aprendizaje

Los operadores de red son los encargados del funcionamiento estable y continuo del SEP, pero un SEP, es un sistema que está sujeto constantemente a cambios que pueden afectar su correcto funcionamiento, por ejemplo, conexión intempestiva de carga, desconexión intempestiva de generación, en el caso de las ERNC, cambios repentinos en el recurso primario, entre otros.

Para evitar la inestabilidad del SEP, los operadores realizan simulaciones en el dominio del tiempo y consideran contingencias relevantes que pueden llevar a grandes apagones, obteniendo como resultados acciones correctivas que permiten mantener la integridad del sistema, pero las TDS conllevan mucho tiempo de ejecución, requieren de muchos recursos computacionales y humanos.

Por lo cual se propone el uso de algoritmos de máquinas de aprendizaje, que, mediante datos obtenidos del sistema, pueden predecir las excursiones de frecuencia que puede presentar un sistema eléctrico de potencia después de sucedida una falla.

Los resultados obtenidos de la anterior etapa metodológica, permiten el entrenamiento de los algoritmos de MA. Mediante las TDS se pueden monitorear y obtener datos de los componentes del sistema, pero es necesario seleccionar un grupo de posibles características relevantes, en función de la variable que se desea predecir.

Los algoritmos de MA empleados para predicción, son algoritmos supervisados de regresión, además se consideran los modelos de MA más desarrollados en los últimos años. Los algoritmos bajo estudio son:

- Decision Tree
- Random Forest
- Gradient Boosting
- SVM
- Ensemble Learning

Seleccionadas las máquinas de aprendizaje a usar, se procede a dividir los datos sintéticos en dos grupos, el primer grupo corresponde a los datos de entrenamiento, los cuales permiten configurar y entrenar el algoritmo de MA. El segundo grupo corresponde a los datos de validación, los cuales permiten verificar si los datos

obtenidos de predicción por los algoritmos de MA son similares a los datos reales de validación. Para determinar el desempeño de cada algoritmo de MA se utiliza el criterio del error cuadrático medio (RMSE).

El RMSE determina la diferencia que existe entre los puntos reales y los puntos de predicción por parte del algoritmo MA, a través de la trayectoria de la excursión de la señal de frecuencia.


Capítulo IV

4. Caso de estudio

Para el desarrollo del trabajo de investigación se emplea como caso de estudio el sistema IEEE de 24 barras, conocido en la literatura como “The IEEE Reliability Test System”, utilizado en estudios de confiabilidad en sistemas eléctricos de potencia a gran escala. (Grigg et al., 1999). En la figura 11 se muestra el diagrama unifilar del sistema.

Figura 11

Sistema de prueba de 24 barras del IEEE con inserción de ERNC

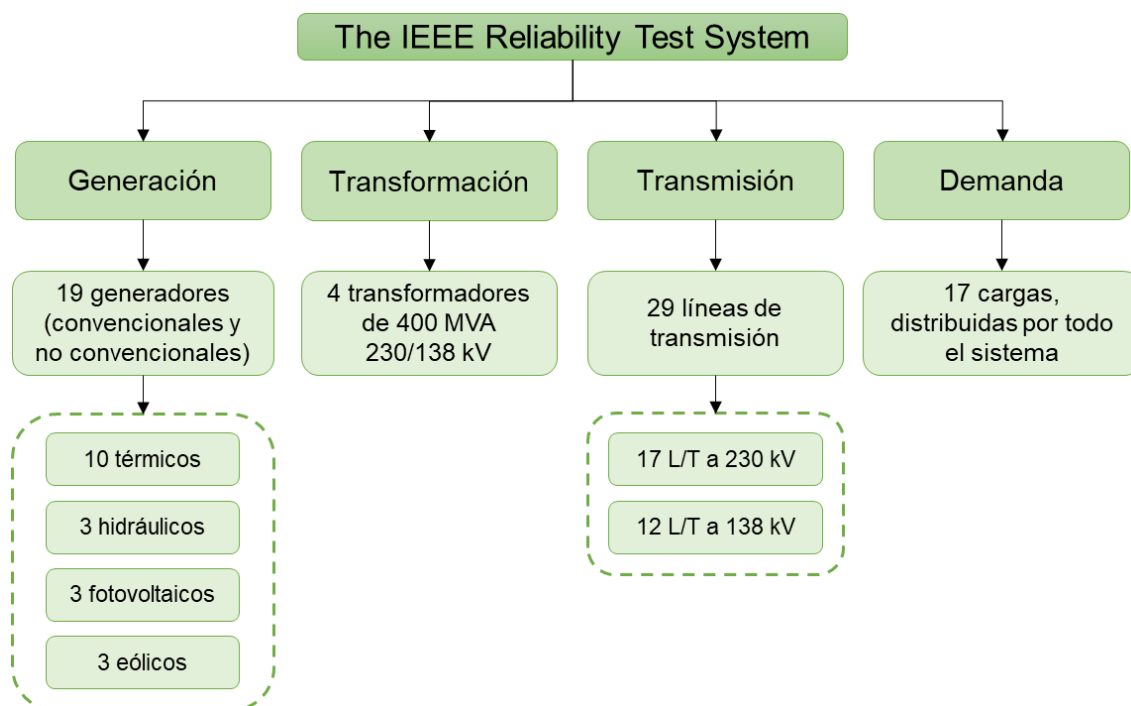


Nota: Sistema de 24 barras, para estudios de confiabilidad.

El sistema está formado por 24 barras, 4 transformadores, 29 líneas de transmisión, 13 generadores convencionales y 17 cargas distribuidas por todo el sistema, como se puede visualizar en la figura 12.

Figura 12

Características Técnicas del Sistema de Prueba



Nota: El sistema de prueba original no cuenta con ERNC, para este caso de estudio se considera la inserción de energía solar fotovoltaica y eólica.

Con el propósito de obtener una alta inserción de ERNC, al sistema de prueba se incluye generación eólica y fotovoltaica. La generación eólica agregada, cuenta con una capacidad instalada de 537 [MW], distribuido en 3 parques por igual. Cada parque generador cuenta con una capacidad de generación de 179 [MW] y se encuentran en las barras 14, 15 y 17.

De igual forma, se incluye generación solar fotovoltaica, cuenta con una capacidad instalada de 537 [MW], distribuidos en 3 parques. Cada parque generador cuenta con una capacidad de generación de 179 [MW] y se encuentran en las barras 3, 10 y 13.

Tabla 2

Características de las unidades de ERNC

Unidad	Barra	Tipo de unidad	P. Instalada [MW]
14	3	Solar fotovoltaico	179
15	10	Solar fotovoltaico	179
16	13	Solar fotovoltaico	179
17	14	Eólico	179
18	15	Eólico	179
19	17	Eólico	179

Nota: La tabla 2 presenta la barra, tipo de unidad y potencia instalada de las unidades de ERNC.

Para el modelamiento de las ERNC, se obtuvieron bases de datos de series de viento y de radiación solar de buscadores meteorológicos disponibles en la web (Explorador Solar, 2022), con resolución horaria de todo un año. Para este caso de estudio se definió una semana por cada estación del año (672 horas).

Con respecto a la generación convencional, se consideran 13 generadores, de distinta tecnología, con una capacidad instalada total de 3475 [MW]. En la tabla 3 se presentan las características de los generadores convencionales.

Tabla 3

Características de las unidades convencionales


Unidad	Barra	Tipo de unidad	P. Instalada [MW]
1	3	Térmico	152
2	4	Térmico	152
15	5	Térmico	155
16	6	Térmico	155
23	7	Térmico	310
23	8	Térmico	350
7	9	Térmico	350
13	10	Térmico	295.5
13	11	Térmico	295.5
15	12	Térmico	60
18	1	Hidráulico	400
21	2	Hidráulico	400
22	13	Hidráulico	400

Nota: La tabla 3 presenta la barra, tipo de unidad y potencia instalada de las unidades de generación convencional.

Considerando las variaciones realizadas, la generación del sistema de prueba modificado presenta una distribución como la presentada en la Figura 3. El 75% corresponde a generadores convencionales, el 12.5% es de origen solar fotovoltaico y el 12.5% corresponde a tecnología eólica, teniendo un porcentaje de penetración de energía renovable de 25%.

Figura 13

Distribución de la potencia instalada para el caso de estudio



Nota: El sistema de prueba modificado tiene un total del 25% de ERNC, de tecnología eólica y fotovoltaica.

Capítulo V

5. Análisis de resultados

5.1. Modelamiento en estado estacionario (Características Técnicas del SEP)

El modelamiento en estado estacionario se llevó a cabo en el software de simulación “Power Factory - DigSILENT” (DigSILENT GmbH, 2022), implementando el sistema de prueba modificado expuesto en el caso de estudio, considerando las características técnicas del SEP y empleando los modelos existentes en las librerías del programa de simulación, para unidades de generación (convencionales y renovables), transformadores, líneas de transmisión y cargas.

5.2. Despacho económico

Se desarrolló un despacho económico multinodal, empleando el software FICO Xpress. (FICO, 2022). El planteamiento del problema de despacho económico para este caso de estudio se encuentra en el Anexo 1. Como resultado del despacho económico se obtuvo la potencia inyectada por los generadores que además representan los puntos de operación (PO) (Proaño et al., 2016), obteniendo 672 PO, con un horizonte de tiempo de 4 semanas, una semana por cada estación del año.

5.3. Modelo detallado del SEP

Para el desarrollo del modelo detallado del SEP, se utilizó el software PFD, se agregaron los modelos de planta de ciertos elementos del SEP. Para este caso de estudio se emplearon los modelos de los controladores de las unidades de generación, siendo estos el modelo del AVR y governor; para el caso de las ERNC se incluyeron los modelos de planta de los generadores eólicos y solar fotovoltaico.

El modelamiento de los GS se realizó en base a modelos normalizados por IEEE, en el caso de las unidades de generación hidráulicas, el modelo del governor es

el IEEE G3, y para las unidades de generación térmicas es considerado el IEEE G1. El AVR para las dos tecnologías es el IEEE T1 (Verdugo, 2012), la configuración de los controladores para este caso de estudio se presenta en el Anexo 2.

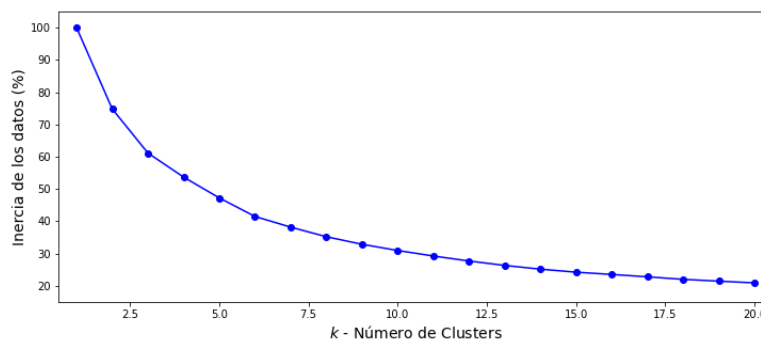
En el caso de las ERNC, para las unidades de generación eólica, se utiliza el inversor Full Rated Converter (Zavadil et al., 2012), y para las unidades de generación solar fotovoltaicas se emplea el modelo photovoltaic system propio de las librerías de PFD.

5.4. Clasificación de los puntos de operación

Obtenidos los 672 PO del despacho económico, se procedió a agrupar los puntos de operación que presentan características similares, mediante la técnica de agrupamiento conocida como “clustering”, empleando el algoritmo “K-Means”, desarrollado mediante el lenguaje de programación “Python” (Python, 2022), encontrando así el punto más representativo (centroide) que es aquel con el mayor grado de similitud con los demás PO del grupo. Ajustando las condiciones iniciales en relación a la regulación de voltaje y despacho de reactivos (Rahmann et al., 2017)

Figura 14

Implementación de la “regla del codo”




Nota: En esta figura se presenta la curva de la “regla del codo” para este caso de estudio

Para la selección del número ideal de clusters se utilizó la ley del codo, en la Figura 14 se puede observar que el punto de inflexión (codo) se obtiene en 8 clusters, pero la pendiente no tiende a normalizarse hasta 20 clusters, sin poder definir un número adecuado de clusters para dividir los PO. Un método más preciso para determinar el número propicio de clusters es el coeficiente de silueta.

Figura 15

Implementación del “Coeficiente de silueta”



Nota: En esta figura se presenta el “coeficiente de silueta” para este caso de estudio.

En la Figura 15, se expone el resultado obtenido mediante el coeficiente de silueta, donde se puede apreciar que el número ideal de clusters están entre 13 y 15, pues son los valores más cercanos a 1.

Tomando en consideración los métodos mencionados, los puntos de operación son divididos en 15 clusters mediante la distancia euclidiana, teniendo una distribución adecuada de los PO y sus respectivos centroides, obteniendo 15 escenarios de operación con condiciones iniciales adecuadas permitiendo optimizar los recursos computacionales al momento de realizar las TDS.

5.5. Simulaciones en el Dominio del tiempo (TDS)

Para el desarrollo de las TDS se utilizaron los escenarios de operación previamente obtenidos y el modelo detallado del SEP, además se incluye eventos de apertura de interruptores en las unidades de generación. Para este caso de estudio se consideran los GS con mayor potencia inyectada al sistema en cada punto de operación y además las unidades gemelas que se encuentran conectadas en las mismas barras. Mediante el uso del lenguaje de programación propio de PFD (DigSilent Programming Language - DPL), se pudo automatizar varios eventos en el SEP y las TDS.

5.6. Señales de excursión de frecuencia (Datos Sintéticos)

De los 672 puntos de operación obtenidos anteriormente, aproximadamente en cada PO fallan 4 generadores, no obstante, dependiendo de la hora de despacho pueden ser 3 generadores que tienden a fallar, llegando a tener un total de 2600 fallas aproximadamente y de este número total de fallas el conjunto se divide en conjunto de test y de validación; el número de fallas para validar los algoritmos es de 650 aproximadamente.

Los datos sintéticos para este caso de estudio son el resultado de las TDS y están compuestos por las mediciones de potencia eléctrica y potencia mecánica de las unidades de generación, además de la inercia del sistema. Estas características fueron seleccionadas por la relación con la variable de interés y en investigaciones previas sugieren el uso de estas características para predicción de excursiones de frecuencia ante contingencias.

5.7. Implementación de los algoritmos de MA

Para la implementación de algoritmos de MA en la predicción de la excursión de frecuencia, se utiliza el lenguaje de programación Python haciendo uso de los


algoritmos desarrollados para MA y los modelos usados son Ensemble Learning, SVM, Gradient Boosting, Decision Tree y Random Forest como se presenta a continuación.

5.7.1. Decision Tree

Una vez implementado el algoritmo de Decision Tree, se obtienen predicciones de excursiones de frecuencia como se indica en la Figura 16. Se puede apreciar la señal de excursión de frecuencia tanto la predicción como la señal real, Decision Tree tiene una adecuada predicción, pero en ciertos puntos la predicción difiere del valor real.

Figura 16

Resultado de excursión de frecuencia del algoritmo de DT para 4 casos diferentes.




Nota: a) DT para el caso 1. b) DT para el caso 2. c) DT para el caso 3. d) DT para el caso 4

5.7.2. Random Forest

Una vez implementado el algoritmo de Random Forest, se obtienen predicciones de excursiones de frecuencia como se muestra en la Figura 17. Se puede apreciar las señales de excursión de frecuencia obtenidas mediante Random Forest, presentando una señal de gran similitud con la original, logrando obtener niveles de desempeño adecuados para el caso de estudio.

Figura 17

Resultado de excursión de frecuencia del algoritmo de RF para 4 casos diferentes.




Nota: a) RF para el caso 1. b) RF para el caso 2. c) RF para el caso 3. d) RF para el caso 4

5.7.3. Gradient Boosting

Una vez implementado el algoritmo de Gradient Boosting, se obtienen predicciones de excursiones de frecuencia como se muestra en la Figura 18. Se presenta las predicciones de las señales de excursión de frecuencia mediante Gradient Boosting, la predicción es muy significativa, pero se pueden observar ciertas desviaciones entre la señal original y la predicción.

Figura 18

Resultado de excursión de frecuencia del algoritmo de GB para 4 casos diferentes.




Nota: a) GB para el caso 1. b) GB para el caso 2. c) GB para el caso 3. d) GB para el caso 4

5.7.4. Support Vector Machine (SVM)

Una vez implementado el algoritmo de SVM, se obtienen predicciones de excursiones de frecuencia como se muestra en la Figura 19. Se puede observar los resultados obtenidos mediante el uso de SVM, la predicción presenta desviaciones muy representativas, obteniendo señales de excursiones de frecuencia, nada similares a la original, obteniendo un desempeño muy bajo en comparación a los modelos anteriormente detallados.

Figura 19

Resultado de excursión de frecuencia del algoritmo de SVM para 4 casos diferentes.




Nota: a) SVM para el caso 1. b) SVM para el caso 2. c) SVM para el caso 3. d) SVM para el caso 4

5.7.5. Ensemble Learning (EL)

Una vez implementado el algoritmo de Ensemble Learning se obtienen predicciones de excursiones de frecuencia como se muestra en la Figura 20. Se puede observar los resultados obtenidos mediante Ensemble Learning, las señales de predicción obtenidas siguen el contorno de la señal original, pero presentan variaciones en varios puntos, por lo cual su desempeño no es el adecuado.

Figura 20

Resultado de excursión de frecuencia del algoritmo de EL para 4 casos diferentes.



Nota: a) EL para el caso 1. b) EL para el caso 2. c) EL para el caso 3. d) EL para el caso

5.8. Evaluación del desempeño de los algoritmos de MA

Una vez obtenidas las predicciones de excursión de frecuencia se realizó la evaluación del desempeño de las mismas mediante el criterio del error cuadrático medio (RMSE), en base a las 650 fallas del conjunto de validación, obteniendo los resultados que se expone en la Figura 21. SVM con el 87.22%, Ensemble Learning con el 99.04%, Gradient Boosting con el 99.97%, Decision Tree con el 99.97% y finalmente Random Forest con el 99.98% siendo esta la MA con el mejor desempeño.

Figura 21

Evaluación del desempeño de los modelos de MA



Nota: En la figura se presentan los resultados promedios obtenidos de las distintas máquinas de aprendizaje.


5.9. Importancia de las características relevantes

Realizada la etapa de evaluación del desempeño de los modelos de MA, se procedió a realizar el análisis de las características relevantes, para los modelos de MA con mejor desempeño.

En el caso de Random Forest, el porcentaje de importancia se distribuye en una mayor cantidad de características de forma similar, debido a la estructura propia del algoritmo que distribuye los datos de entrenamiento y combina los resultados, compensando los errores entre sí y obteniendo mejores niveles de predicción.

Figura 22

Características relevantes Random Forest




Nota: En la figura se indican las características relevantes usando Random Forest: potencia eléctrica (PSG) y potencia mecánica (MSG)

Como se puede observar en la Figura 22, las características con mayor porcentaje de importancia corresponden a la potencia mecánica de las unidades de generación: 3,4,6,9,10,12 y adicional a la potencia eléctrica generada por la unidad 131.

Figura 23

Características relevantes Gradient Boosting




Nota: En la figura se indican las características relevantes usando Gradient Boosting: potencia eléctrica (PSG) y potencia mecánica (MSG)

Para Gradient Boosting, el porcentaje de importancia se distribuye en un número similar de características al igual que en Random Forest, pero no distribuye de forma equitativa los porcentajes como se puede observar en la Figura 23, la característica con mayor porcentaje de importancia es la potencia mecánica de la unidad de generación 6.

Figura 24

Características relevantes Decision Tree



Nota: En la figura se indican las características relevantes usando Gradient Boosting: potencia eléctrica (PSG) y potencia mecánica (MSG)

Por último, en Decision Tree el porcentaje de importancia se distribuye en un número muy pequeño de características como se puede observar en la Figura 24, la característica con mayor porcentaje de importancia es la potencia mecánica de la unidad de generación 6, seguida por la unidad de generación 12. Por esta razón DT no es recomendable debido a que si estas características fueran retiradas el desempeño disminuiría considerablemente.

Capítulo VI

6. Conclusiones y Recomendaciones

6.1. Conclusiones

- La metodología propuesta y desarrollada en este trabajo de investigación, permite realizar un análisis comparativo entre los diferentes modelos de MA y seleccionar el mejor modelo para predecir excursiones de frecuencia que presenta un SEP luego de ocurrida una contingencia (desconexión intempestiva de generación).
- Random Forest obtuvo el mejor desempeño en comparación con las distintas máquinas de aprendizaje evaluadas en 650 punto de operación con falla obteniendo un desempeño del 99.98%, por otro lado, SVM es la máquina de aprendizaje que tiene un menor desempeño con un 87.22% de precisión. Decision Tree obtuvo un porcentaje del 99.97 % cercano a Random Forest, pero Decisión Tree es considerado casuístico pues al introducir nuevos datos tiende a fallar debido a que no maneja las incertidumbres asociadas al fenómeno.
- Para este caso de estudio se implementó un despacho económico multinodal para el sistema de prueba 24 barras del IEEE modificado; se obtuvo series de datos de las 4 estaciones del año, una semana por cada estación, obteniendo un total de 672 horas o puntos de operación con el fin de obtener niveles de generación variada para el modelamiento de las energías renovables no convencionales siendo estas energías eólica y solar fotovoltaica que representan el 25% de la generación total del sistema.
- Se desarrolló e implementó el modelo detallado del sistema de prueba modificado el cual permitió realizar simulaciones dinámicas relacionadas a desconexiones intempestivas de las unidades de generación.

- Mediante el uso de las simulaciones en el dominio del tiempo se logró obtener los datos sintéticos del sistema de prueba modificado, además se seleccionaron las características relevantes que intervienen en el entrenamiento de las máquinas de aprendizaje, estas son: potencia eléctrica, potencia mecánica e inercia del sistema debido a su estrecha relación con la estabilidad de frecuencia.
- El desempeño de los algoritmos utilizados fue evaluado mediante el criterio del error cuadrático medio, de una total de 650 fallas del conjunto de validación, obteniendo los siguientes resultados: SVM con el 87.22%, Ensemble Learning con el 99.04%, Gradient Boosting con el 99.97%, Decision Tree con el 99.97% y finalmente Random Forest con el 99.98%.

6.2 Recomendaciones

- Para el modelamiento de las centrales de generación renovables no convencionales, se recomienda seleccionar datos representativos y de diferentes estaciones del año, que permitan tener niveles de generación variada que aporten al sistema.
- Se recomienda el uso de la máquina de aprendizaje Random Forest para futuros trabajos, debido a la estructura propia del algoritmo que distribuye los datos de entrenamiento y agrupa los resultados, compensando los errores entre sí y obteniendo mejores niveles de predicción.
- Para obtener resultados válidos de las distintas máquinas de aprendizaje, se recomienda considerar la correcta configuración de los hiper-parámetros que conforman cada máquina, ya que se podrían obtener predicciones erróneas.

- Para el desarrollo de simulaciones en el dominio del tiempo, se recomienda el uso de equipos con niveles de procesamiento elevados, debido a que permitirán optimizar el tiempo de implementación.

Bibliografía

- Alex, V., Haro, R., Aguirre, M., & Ortíz, D. (2021). Evaluación de Resiliencia en el Sistema Eléctrico Ecuatoriano frente a Eventos Sísmicos. *Revista Técnica "Energía&Quot;*, 17(2), PP. 18-28.
<https://doi.org/10.37116/revistaenergia.v17.n2.2021.440>
- Bagnato, J. I. (2020). *Aprende Machine Learning Teoría+ Práctica Python*.
- Chávez, H., Baldick, R., & Sharma, S. (2014). Governor rate-constrained OPF for primary frequency control adequacy. *IEEE Transactions on Power Systems*, 29(3), 1473–1480. <https://doi.org/10.1109/TPWRS.2014.2298838>
- Chen, K. (2019). Indirect PCA Dimensionality Reduction Based Machine Learning Algorithms for Power System Transient Stability Assessment. *2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)*, 4175–4179.
<https://doi.org/10.1109/ISGT-Asia.2019.8881370>
- Chow, J. H., & Sanchez-Gasca, J. J. (2020). *Power System Modeling, Computation, and Control*. <http://www.wiley.com/go/permissions>.
- DIGSILENT GmbH. (2022). *DIGSILENT Power Factory*. <https://www.digsilent.de/en/>
- Erlich, I., & Wilch, M. (2010). Primary frequency control by wind turbines. *IEEE PES General Meeting*, 1–8. <https://doi.org/10.1109/PES.2010.5589911>
- Explorador Solar. (2022). *Explorador Solar*. <https://solar.minenergia.cl/inicio>
- FICO. (2022). *FICO*. <https://www.fico.com/>
- Geron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (2nd ed.). O'Reilly Media, Inc.

- Gómez, A., Abur, A., Alvarado, F. L., Carlos, C., Bel, C., Otero, A. F., Galiana García, F., Mayordomo, J. G., Ramos, J. L. M., Velasco, J. A. M., Ignacio, J., Arriaga, P., Quintana, V. H., Abbad, M. R., Rouco Rodríguez, L., & García, J. U. (2002). *Análisis y operación de sistemas de energía eléctrica*.
- Grigg, C., Wong, P., Albrecht, P., Allan, R., Bhavaraju, M., Billinton, R., Chen, Q., Fong, C., Haddad, S., Kuruganty, S., Li, W., Mukerji, R., Patton, D., Rau, N., Reppen, D., Schneider, A., Shahidehpour, M., & Singh, C. (1999). The IEEE Reliability Test System-1996. A report prepared by the Reliability Test System Task Force of the Application of Probability Methods Subcommittee. *IEEE Transactions on Power Systems*, 14(3), 1010–1020. <https://doi.org/10.1109/59.780914>
- Idehen, I., Jang, W., & Overbye, T. (2019). PMU Data Feature Considerations for Realistic, Synthetic Data Generation. *2019 North American Power Symposium (NAPS)*, 1–6. <https://doi.org/10.1109/NAPS46351.2019.9000335>
- IEC. (2005). *IEC 60308 - Hydraulic turbines – Testing of control systems | Engineering360*. <https://standards.globalspec.com/std/15283/IEC%2060308>
- Jena, D., & Prusty, B. R. (2014). *Power system analysis : operation and control*. 420.
- Kazerooni, M., Zhu, H., & Overbye, T. J. (2014). Literature review on the applications of data mining in power systems. *2014 Power and Energy Conference at Illinois (PECI)*, 1–8. <https://doi.org/10.1109/PECI.2014.6804567>
- Keung, P.-K., Li, P., Banakar, H., & Ooi, B. T. (2009). Kinetic Energy of Wind-Turbine Generators for System Frequency Support. *IEEE Transactions on Power Systems*, 24(1), 279–287. <https://doi.org/10.1109/TPWRS.2008.2004827>

- Kou, G., Markham, P., Hadley, S., King, T., & Liu, Y. (2016). Impact of Governor Deadband on Frequency Response of the U.S. Eastern Interconnection. *IEEE Transactions on Smart Grid*, 7(3), 1368–1377.
<https://doi.org/10.1109/TSG.2015.2435258>
- Kovaltchouk, T., Debusschere, V., Bacha, S., Fiacchini, M., & Alamir, M. (2016). Assessment of the impact of frequency containment control and synthetic inertia on intermittent energies generators integration. *2016 Eleventh International Conference on Ecological Vehicles and Renewable Energies (EVER)*, 1–8.
<https://doi.org/10.1109/EVER.2016.7476361>
- Kundur, P., Paserba, J., Ajarapu, V., Andersson, G., Bose, A., Canizares, C., Hatziargyriou, N., Hill, D., Stankovic, A., Taylor, C., van Cutsem, T., & Vittal, V. (2004). Definition and classification of power system stability IEEE/CIGRE joint task force on stability terms and definitions. *IEEE Transactions on Power Systems*, 19(3), 1387–1401. <https://doi.org/10.1109/TPWRS.2004.825981>
- Kundur, P. S. (1994). *Power System Stability and Control* (1st Edición). McGraw Hill.
- Lalor, G., Mullane, A., & O'Malley, M. (2005). Frequency control and wind turbine technologies. *IEEE Transactions on Power Systems*, 20(4), 1905–1913.
<https://doi.org/10.1109/TPWRS.2005.857393>
- Learned-Miller, E. G. (2014). *Introduction to Supervised Learning*.
- Lidy, T., & Rauber, A. (2008). Machine Learning Techniques for Multimedia. *Machine Learning Techniques for Multimedia*, 11, 249–285. <https://doi.org/10.1007/978-3-540-75171-7>

- Mullane, A., & O'Malley, M. (2005). The inertial response of induction-machine-based wind turbines. *IEEE Transactions on Power Systems*, 20(3), 1496–1503.
<https://doi.org/10.1109/TPWRS.2005.852081>
- Ortiz-Villalba, D., Rahmann, C., Alvarez, R., Canizares, C. A., & Strunck, C. (2020). Practical Framework for Frequency Stability Studies in Power Systems with Renewable Energy Sources. *IEEE Access*, 8, 202286–202297.
<https://doi.org/10.1109/ACCESS.2020.3036162>
- Pourbeik, P., Chown, G., Feltes, J., Modau, F., Sterpu, S., Boyer, R., Chan, K., Hannett, L., Leonard, D., Lima, L. T. G., Hofbauer, W., Gerin-Lajoie, L., Patterson, S., Undrill, J., & Langenbacher, F. (2013). *Dynamic Models for Turbine-Governors in Power System Studies*.
- Proaño, J. L., Villalba, D. O., Saez, D., & Quero, D. O. (2016). Economic dispatch for optimal management of isolated microgrids. *2016 IEEE 36th Central American and Panama Convention (CONCAPAN XXXVI)*, 1–6.
<https://doi.org/10.1109/CONCAPAN.2016.7942382>
- Python. (2022). *Python.org*. <https://www.python.org/>
- Rahmann, C., Ortiz-Villalba, D., Álvarez, R., & Salles, M. (2017). Methodology for selecting operating points and contingencies for frequency stability studies. *2017 IEEE Power Energy Society General Meeting*, 1–5.
<https://doi.org/10.1109/PESGM.2017.8274423>
- Saadat, H. (2009). *Power system analysis / Hadi Saadat*. WCB/McGraw-Hill.
- Sánchez, P. (2020). *ESTABILIDAD DE FRECUENCIA EN SISTEMAS ELÉCTRICOS DE POTENCIA CONSIDERANDO GENERACIÓN NO INERCIAL*.

Verdugo, P. (2012). *METODOLOGÍA DE SINTONIZACIÓN DE PARÁMETROS DEL ESTABILIZADOR DEL SISTEMA DE POTENCIA (PSS) UTILIZANDO EL PROGRAMA COMPUTACIONAL DIGSILENT POWER FACTORY* .

Villanueva Mayr, T. I. (2016). *Estrategias de regulación de frecuencia en unidades generadoras hidráulicas*. <https://repositorio.uchile.cl/handle/2250/140037>

Walker, S. S. W., Sooriyaarachchi, N. K., Liyanage, N. D. B., Abeynayake, P. A. G. S., & Abeyratne, S. G. (2011). Comparative analysis of speed of convergence of MPPT techniques. *2011 6th International Conference on Industrial and Information Systems*, 522–526. <https://doi.org/10.1109/ICIINFS.2011.6038125>

Yi, T., Cui, H., & Wang, Q. (2017). Prediction Model of the Power System Frequency Using a Cross-Entropy Ensemble Algorithm. *Entropy*, *19*, 552. <https://doi.org/10.3390/e19100552>

Zaidi, A., & Cheng, Q. (2018). An Approximation Solution of the Swing Equation Using Particle Swarm Optimization. *2018 IEEE Conference on Technologies for Sustainability (SusTech)*, 1–5. <https://doi.org/10.1109/SusTech.2018.8671355>

Zavadil, R., Zheglov, V., Kazachkov, Y., Gong, B., Sanchez, J., & Li, J. (2012). *Documentation, User Support, and Verification of Wind Turbine and Plant Models*. <https://doi.org/10.2172/1051403>

Anexos