


UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA



EVALUACIÓN DE ESTABILIDAD DE FRECUENCIA EN SISTEMA DE
POTENCIA CON BAJA INERCIA UTILIZANDO APRENDIZAJE
AUTOMÁTICO

por


ROLANDO PÉREZ GATTORNO

Como requisito para obtener el grado de MAESTRÍA EN
CIENCIAS DE LA INGENIERÍA ELÉCTRICA

Agosto de 2024

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA



EVALUACIÓN DE ESTABILIDAD DE FRECUENCIA EN SISTEMA DE
POTENCIA CON BAJA INERCIA UTILIZANDO APRENDIZAJE
AUTOMÁTICO

por

ROLANDO PÉREZ GATTORNO

Como requisito para obtener el grado de MAESTRÍA EN
CIENCIAS DE LA INGENIERÍA ELÉCTRICA

Agosto de 2024

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
Facultad de Ingeniería Mecánica y Eléctrica
Posgrado

Los miembros del Comité de Evaluación de Tesis recomendamos que la Tesis “Evaluación de estabilidad de frecuencia en sistema de potencia con baja inercia utilizando aprendizaje automático”, realizada por el estudiante Rolando Pérez Gattorno, con número de matrícula 2172438, sea aceptada para su defensa como requisito parcial para obtener el grado de Maestría en Ciencias de la Ingeniería Eléctrica.

El Comité de Evaluación de Tesis


Dr. Manuel Antonio Andrade Soto
Director

Dr. Ernesto Vázquez Martínez
Revisor

Dr. Alberto Cavazos González
Revisor

Dr. Daniel Guillén Aparicio
Revisor

Vo.Bo.


Dr. Simón Martínez Martínez
Subdirector de Estudios de Posgrado



Institución 190001

Programa 557520

Acta Núm. 4433

Ciudad Universitaria, a 22 de agosto de 2024.

Este trabajo de tesis se lo dedico a mi familia. El apoyo incondicional ha sido el sustento para cumplir mis metas y solventar los retos.

AGRADECIMIENTOS

Al claustro de profesores y a la coordinación del posgrado de la Maestría en Ciencias de la Ingeniería, por sus valores y compromiso en brindar una educación superior de calidad. Su sabiduría y orientación han sido fundamentales para complementar mi formación académica.

A mi asesor, el Dr. Manuel Andrade Soto, por su apoyo y dirección en la realización de esta tesis. Su guía ha sido una fuente constante de conocimientos. También agradezco el apoyo y acceso a la información brindado por mi amigo Reinier Herrera Casanova, siempre atento y disponible a consultas.

A la Universidad Autónoma de Nuevo León, en particular la Facultad de Ingeniería Mecánica y Eléctrica, gracias por ofrecerme la oportunidad de crecer y desarrollarme en un ambiente académico enriquecedor. Este camino ha sido posible gracias a las oportunidades y recursos proporcionados por esta institución.

También quiero agradecer al Consejo Nacional de Humanidades, Ciencias y Tecnologías por el apoyo económico brindado durante el posgrado.

RESUMEN

Rolando Pérez Gattorno

Fecha de graduación: agosto de 2024

Universidad Autónoma de Nuevo León

Facultad de Ingeniería Mecánica y Eléctrica

Título del estudio: EVALUACIÓN DE ESTABILIDAD DE FRECUENCIA EN SISTEMA DE POTENCIA CON BAJA INERCIA UTILIZANDO APRENDIZAJE AUTOMÁTICO

Número de páginas: 76

Candidato para el grado de Maestría en Ciencias de la Ingeniería Eléctrica

Propósito y método de estudio: La utilización de algoritmos de aprendizaje automático en el análisis de la estabilidad de frecuencia en sistemas eléctricos de potencia, constituye un tema recurrente de investigación. Varios estudios analizan los indicadores de frecuencia pos-contingencia ya sea considerando los valores absolutos o promedios. En el presente trabajo se llevó a cabo la implementación de algunos de los algoritmos de aprendizaje automático más representativos del estado del arte, y se adaptaron al análisis de la estabilidad de frecuencia por áreas del sistema eléctrico; con el objetivo de demostrar la diferencia de los indicadores de frecuencia entre las distintas áreas que conforman el sistema eléctrico, y así destacar la importancia del análisis de las características temporales y espaciales de la frecuencia a lo largo del sistema eléctrico. Para ello se elaboró un sistema de prueba y mediante la simulación de varios escenarios se construyó la base de datos sintéticos. Se estableció la metodología para la clasificación y organización de los datos sintéticos, así como del proceso de evaluación de los modelos.

Contribuciones y conclusiones: Se exploraron los modelos de redes neuronales más representativos, y se implementó el modelo de red neuronal autorregresiva no lineal con entradas exógenas (NARX), previamente no identificado en la evaluación de estabilidad de frecuencia de sistemas eléctricos. La estructuración de los datos propuesta, y el enfoque del análisis de la estabilidad de frecuencia por áreas, demuestra la diferencia en los indicadores observados entre las distintas áreas del sistema eléctrico.

Asesor: Dr. Manuel Antonio Andrade Soto.

TABLA DE CONTENIDO

Capítulo	Página
1. Introducción	1
1.1. Introducción a los sistemas eléctricos de potencia	1
1.2. Antecedentes y motivación	3
1.3. Problemática	4
1.4. Hipótesis	5
1.5. Objetivos	5
1.6. Estructura de la Tesis	6
2. Marco Teórico	7
2.1. Introducción al análisis de estabilidad en SEP	7
2.2. Estabilidad de frecuencia en SEP	7
2.2.1. Inercia	8
2.2.2. ROCOF	9
2.2.3. Desviación máxima (nadir o cenit)	10
2.2.4. Etapas de respuesta en frecuencia	11
2.3. Impacto de la generación basada en inversores en la estabilidad de frecuencia	12
2.3.1. Inversores seguidores de red y formadores de red	12
2.3.2. Inercia virtual	14
2.4. Propagación de perturbaciones en la red eléctrica	16
2.4.1. Unidades de medición fasorial	17
2.4.2. Sistemas de medición de área amplia	19
2.5. Aprendizaje automático aplicado a SEP	20
2.5.1. Algoritmos de ML	21
2.5.2. ML aplicado a SEP	24
2.5.3. ML aplicado a la evaluación de la estabilidad de frecuencia en SEP	25
2.5.4. Modelos de RNA implementados en el presente trabajo	27

2.5.5. Comparación entre los modelos seleccionados	30
2.6. Conclusiones del Capítulo	31
3. Metodología	32
3.1. Introducción a la metodología propuesta	32
3.2. Fase 1: Obtención de datos sintéticos	33
3.2.1. Sistema de prueba: Nordic32	33
3.2.2. Generación de datos sintéticos	34
3.3. Fase 2: Organización de datos	36
3.3.1. Clasificación de los datos	37
3.3.2. División de los datos	38
3.3.3. Estructuración de los datos. Etapa de entrenamiento	38
3.3.4. Estructuración de los datos. Etapa de prueba	40
3.4. Fase 3: Evaluación de modelos	42
3.4.1. Selección y ajuste de los modelos	42
3.4.2. Métricas de evaluación del desempeño	44
3.5. Conclusiones del Capítulo	46
4. Resultados	47
4.1. Introducción del Capítulo	47
4.2. Resultados para el modelo propuesto NARX	47
4.2.1. Selección de la longitud de ventana de datos	48
4.2.2. Variación en el error de las predicciones obtenidas	50
4.3. Comparación de resultados utilizando los modelos: NARX, TDNN y LSTM	52
4.4. Análisis por área de la desviación máxima de frecuencia	55
4.4.1. Evento de pérdida de generación	56
4.4.2. Evento de cortocircuito en línea de transmisión	57
4.5. Conclusiones del Capítulo	60
5. Conclusiones	61
5.1. Contribuciones	62
5.2. Trabajos futuros	63
Referencias	64
A. Sistema de prueba: Nordic 32	71
A.1. Diagrama unifilar sistema Nordic 32	71

A.2. <i>Hydro Turbine model</i>	72
A.3. <i>Steam Turbine model</i>	72
A.4. <i>AC Excitation System model</i>	73
A.5. <i>Droop Controlled Converter model</i>	73
A.6. <i>Grid Following Converter model</i>	74
A.7. Ajuste de parámetros de los modelos dinámicos	74

LISTA DE FIGURAS

Figura	Página
1. a) Sistema eléctrico dominado por generadores síncronos. b) Sistemas modernos con alta penetración de FER basada en inversores	1
2. Clasificación de estabilidad en SEP	7
3. Etapas de respuesta en frecuencia por ENTSO-E	11
4. Aproximación del control de los inversores: (a) GFI y (b) GFM	13
5. Concepto de inercia virtual	15
6. Propagación de ondas de frecuencia en un evento de disparo de generación-carga en Florida, 2008	17
7. Forma de onda sinusoidal: (a) dominio del tiempo y (b) forma fasorial	18
8. ML y DL como subconjuntos de la IA	20
9. Tipos de ML	22
10. Tipos de aprendizaje supervisado	23
11. Modelos de ML supervisado: regresión y clasificación	23
12. Arquitectura TDNN	28
13. Estructura del modelo LSTM. (a) Unidad de memoria a largo plazo y (b) Arquitectura LSTM	29
14. Arquitectura NARX	30
15. Fases de la metodología propuesta	32
16. Modificación del sistema de prueba N32	34
17. Metodología para la estructuración de los datos	37
18. Estructuración de datos etapa de entrenamiento	39
19. Estructuración de datos etapa de prueba (por modelo)	40
20. Estructuración de datos etapa de prueba (por área)	41
21. Metodología para la evaluación de modelos	42
22. Comparación de resultados para el modelo NARX entre diferentes longitudes de ventana	50

23. Valor real vs predicción del modelo NARX, considerando una longitud de ventana de 180 ms en el conjunto de datos de prueba. Vista ampliada de escenarios 37 y 89 51

24. Diagramas de dispersión para longitud de ventana de 180 ms, utilizando los modelos: (a) NARX, (b) TDNN y (c) LSTM 55

25. Frecuencia por áreas para evento de pérdida de generación 56

26. Frecuencia por áreas para evento de cortocircuito en área SE3 y sistema base S5 58

27. Frecuencia por áreas para evento de cortocircuito en área SE3 y sistema base S1 59

LISTA DE TABLAS

Tabla	Página
1. Porcentaje de penetración de FER en diferentes países con respecto a la capacidad de generación instalada	2
2. Aplicaciones de ML en SEP	25
3. Estado del arte de modelos basados en RNA aplicados a la predicción de la desviación máxima de frecuencia	26
4. Modelos utilizados para la generación síncrona, disponibles en el software <i>DIgSILENT PowerFactory</i>	34
5. Modelos utilizados para la generación basada en inversores, disponibles en el software <i>DIgSILENT PowerFactory</i>	35
6. Composición de la matriz de generación de los sistemas bases	35
7. Parámetros de ajustes del modelo TDNN	43
8. Parámetros de ajustes del modelo LSTM	43
9. Parámetros de ajustes del modelo NARX	44
10. Ajustes propuestos para el modelo NARX	48
11. Comparación de resultados para el modelo NARX entre diferentes longitudes de ventana	49
12. Ajustes propuestos para el modelo TDNN	52
13. Ajustes propuestos para el modelo LSTM	52
14. Comparación de modelos según métricas obtenidas por áreas	53
15. Parámetros y ajustes <i>AC Excitation System</i>	74
16. Parámetros y ajustes <i>Hydro Turbine regulator</i>	75
17. Parámetros y ajustes <i>Steam Turbine regulator</i>	75

CAPÍTULO 1

INTRODUCCIÓN

1.1 Introducción a los sistemas eléctricos de potencia

La gestión de estabilidad de los sistemas eléctricos de potencia (SEP) se basa en décadas de experiencia de las propiedades físicas y respuestas de control de los grandes generadores síncronos (GS), los cuales históricamente han dominado la matriz energética. Los SEP están en rápida transición hacia una proporción cada vez mayor de generación a partir de fuentes de energía renovable (FER), como la eólica y solar. La mayoría de las FER se integran al sistema eléctrico a través de inversores electrónicos de potencia. En la Figura 1 se ejemplifica la transición en la matriz energética de los SEP modernos [1, 2].

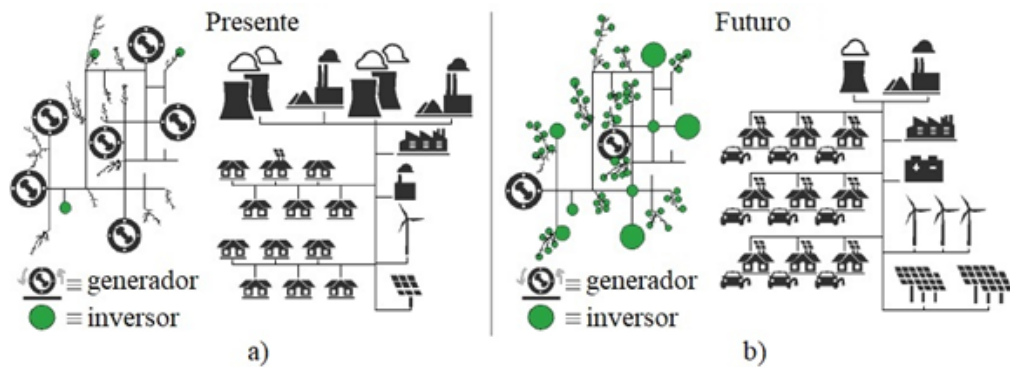


Figura 1. a) Sistema eléctrico dominado por generadores síncronos. b) Sistemas modernos con alta penetración de FER basada en inversores.

Las centrales eléctricas convencionales basadas en combustibles fósiles están siendo desmanteladas y sustituidas gradualmente por FER. Por lo tanto, los niveles de penetración de las FER están aumentando rápidamente en los SEP, para así alcanzar los objetivos de integración fijados por los distintos países. En la Tabla 1 se muestran los pronósticos trazados por diferentes países para el 2050 en cuanto al porcentaje de penetración de FER [3].

TABLA 1

Porcentaje de penetración de FER en diferentes países con respecto a la capacidad de generación instalada.

País	Penetración de FER 2015	Penetración de FER 2050
China	26 %	94 %
India	15 %	92 %
Europa	29 %	94 %
USA	14 %	78 %

La sustitución de las centrales de generación síncrona por FER basadas en inversores, reduce la inercia del sistema y provoca una mayor dispersión de la misma en el sistema. Además, la interfaz de electrónica de potencia presente en las FER desacopla la frecuencia de la red eléctrica. Por lo tanto, las FER no pueden proporcionar respuesta inercial ni participar en la regulación de frecuencia de forma intrínseca [4].

Por otro lado, el desplazamiento de la generación síncrona convencional por las FER basadas en inversores, está conllevando a una dispersión cada vez mayor de la inercia síncrona disponible en los sistemas eléctricos, provocando que se acentúe la oscilación de frecuencia en las áreas de menor inercia síncrona. La oscilación de frecuencia poscontingencia no se manifiesta en el mismo instante e igual magnitud a lo largo del sistema eléctrico. La perturbación se propaga desde el punto origen de ocurrencia en la red, al resto del sistema a través de las impedancias de la red e inercias síncronas de los generadores [5].

En resumen, la penetración a gran escala de las FER en los SEP provoca una reducción en la inercia, y esta a su vez se encuentra cada vez más dispersa dentro del sistema. Esto conlleva a que los cambios dinámicos en la frecuencia eléctrica entre las áreas del sistema sean más rápidos y bruscos y, por consiguiente, se alcancen valores superiores de desviación de frecuencia tras una contingencia.

1.2 Antecedentes y motivación

El aumento de la integración de FER plantea nuevos retos a los operadores del sistema eléctrico, y exige el desarrollo de nuevas estrategias y tecnologías para garantizar un funcionamiento fiable y estable de la red eléctrica. Diversas perturbaciones, como la desconexión de carga, fallo de un generador y cortocircuitos, pueden provocar desviaciones de frecuencia, que, si no se corrigen a tiempo, pueden provocar inestabilidad e incluso desconexiones de equipos en cascada.

Existen dos categorías principales de métodos en la evaluación de la estabilidad de frecuencia: (1) métodos basados en modelos físicos y (2) métodos basados en datos. La evaluación de la estabilidad de frecuencia basada en modelos [6–9] para grandes sistemas eléctricos es precisa, pero requiere importantes recursos informáticos y se utiliza principalmente para el análisis fuera de línea.

Con el desarrollo de los sistemas de medición de área amplia que aprovechan los Sistemas de Posicionamiento Global (GPS), los cuales proporcionan mediciones masivas en tiempo real para aplicaciones de supervisión y control [10, 11], se han propuesto diferentes estrategias basadas en datos para el análisis en línea de los SEP.

Para superar el reto de la evaluación de la estabilidad de frecuencia en línea, varios trabajos [12–17] utilizan modelos simplificados para reducir la carga computacional, y los parámetros del modelo se calibran utilizando datos de medición. Esta simplificación conlleva a una reducción en la precisión comparados con las simulaciones basadas en modelos físicos. Además, con estos últimos es posible que no se pueda estimar la inercia virtual proporcionada por las FER basadas en inversores si la dinámica de las FER no está emulada en los modelos o si se desconocen los esquemas de control [18].

En este sentido, las técnicas de inteligencia artificial ofrecen a los ingenieros de sistemas eléctricos un perfil amplio de modelos y herramientas de predicción y estimación. Con el rápido desarrollo de las técnicas de IA en los últimos años, las aplicaciones de aprendizaje automático en la evaluación de estabilidad y seguridad de los sistemas eléctricos se han convertido en un tema recurrente [19–35].

Una de las aplicaciones típicas de algoritmos de ML en la evaluación de la estabilidad de frecuencia, es la predicción de la desviación máxima pos-contingencia. Los estudios previos tienen la característica de predecir la desviación de frecuencia absoluta o promedio del sistema de potencia.

1.3 Problemática

La elevada penetración en los sistemas eléctricos de generación basada en inversores, y el consecuente desplazamiento de la generación síncrona convencional, conlleva a una disminución y dispersión cada vez mayor de la inercia síncrona disponible. Por consiguiente, la diferencia en la desviación máxima de frecuencia pos-contingencia entre las distintas áreas del sistema se acentúa, comprometiéndose la estabilidad de frecuencia del sistema eléctrico.

1.4 Hipótesis

Si se implementan modelos de aprendizaje automático con el enfoque de predicción de la desviación máxima de frecuencia por áreas del sistema eléctrico, entonces se mejorará el monitoreo de la estabilidad de frecuencia en comparación con los estudios que analizan los indicadores absolutos o promedios de todo el sistema eléctrico.

1.5 Objetivos

El objetivo general consiste en evaluar el comportamiento dinámico de la frecuencia utilizando métodos de aprendizaje automático, mediante el análisis de las diferentes áreas de operación de sistema de potencia con baja inercia.

Como objetivos particulares se tienen:

- Implementar sistema eléctrico de prueba con baja inercia en software *DIgSILENT PowerFactory*, y mediante simulaciones dinámicas conformar la base de datos sintéticos necesaria para llevar a cabo el estudio propuesto.
- Proponer una metodología para la clasificación y estructuración de los datos sintéticos, así como para la evaluación de los algoritmos de aprendizaje automático implementados.
- Examinar varios algoritmos de aprendizaje automático aplicados a la evaluación de estabilidad de frecuencia, y adaptar su estructura a la predicción del comportamiento dinámico de la frecuencia por áreas en SEP con baja inercia.

1.6 Estructura de la Tesis

En el Capítulo 1 se realiza una introducción a los sistemas eléctricos modernos, donde se destaca la influencia de la penetración creciente de FER en la estabilidad de frecuencia. Además, se mencionan los antecedentes de estudios realizados en la evaluación de la estabilidad de frecuencia, y se define la problemática y motivación que originan la presente investigación.

En el Capítulo 2 se presenta el marco teórico en el que se fundamenta el estudio propuesto. En este Capítulo se exponen los conceptos e indicadores que se utilizan en la evaluación de estabilidad de frecuencia en los SEP. Además, se examina el estado del arte de los algoritmos de aprendizaje automático aplicados en la evaluación de estabilidad de SEP.

En el Capítulo 3 se establecen las fases de la metodología utilizada para la ejecución del trabajo investigativo. En el mismo se abordan las características del sistema de prueba utilizado, el procedimiento para la conformación de la base de datos sintéticos, la estructuración de los datos propuesta y las métricas utilizadas en la evaluación de resultados. Además, se mencionan los modelos de aprendizaje automático seleccionados y los criterios considerados en su parametrización.

En el Capítulo 4 se exponen los resultados y se establece una comparación entre los modelos de aprendizaje automático implementados. Además, se emiten observaciones relacionadas al análisis de la desviación máxima de frecuencia entre las distintas áreas del sistema de prueba implementado.

Por último, en el Capítulo 5 se presentan las conclusiones del trabajo de investigación, y se proponen recomendaciones de aplicaciones del estudio propuesto.

CAPÍTULO 2

MARCO TEÓRICO

2.1 Introducción al análisis de estabilidad en SEP

La definición global de estabilidad en un SEP se conoce como la capacidad del sistema eléctrico para mantener el equilibrio en condiciones normales y restablecer el equilibrio tras perturbaciones [36, 37]. La estabilidad de un sistema eléctrico se clasifica en función de la respuesta del sistema ante una perturbación, como se muestra en la Figura 2.



Figura 2. Clasificación de estabilidad en SEP.

2.2 Estabilidad de frecuencia en SEP

La estabilidad de la frecuencia del sistema eléctrico se refiere a la capacidad de un sistema eléctrico de mantener su frecuencia dentro de un margen de operación seguro ante escenarios de cambio en la demanda (carga) y/o generación, así como otras condiciones de perturbación (fallas, desconexión, etc.).

Diversas perturbaciones, como la desconexión de carga o el fallo de un generador, pueden provocar desviaciones de frecuencia, que, si no se corrigen a tiempo, pueden provocar inestabilidad e incluso fallos en cascada. Por lo tanto, mantener la estabilidad de la frecuencia es fundamental para garantizar el funcionamiento fiable y seguro del sistema eléctrico [37].

La estabilidad de frecuencia en sistemas eléctricos se evalúa fundamentalmente mediante el análisis de 3 indicadores: (i) la inercia, (ii) la tasa de cambio en la frecuencia (ROCOF, por sus siglas en inglés), y (iii) la desviación máxima de frecuencia (nadir o cenit). Estos indicadores son esenciales para comprender y gestionar la estabilidad de frecuencia de los SEP.

2.2.1 Inercia

En la respuesta dinámica de los SEP, la inercia determina la velocidad de los cambios de frecuencia provocados por un desequilibrio en la potencia activa. Físicamente, esta ralentización en el cambio de frecuencia se debe a la energía cinética almacenada en las masas giratorias de los generadores. La energía de estas masas giratorias es convertida en energía eléctrica y transferida a la red cuando la frecuencia disminuye, o es tomada de la red cuando la frecuencia aumenta [36].

La inercia total del sistema eléctrico es la sumatoria de las inercias de los GS en servicio. La constante de inercia (H) individual de un GS expresada en segundos, se define como la energía cinética almacenada (J) en megajuoles a velocidad sincrónica (ω_s), dividida por la potencia nominal de la máquina (S_n) en MVA, tal que [38]:

$$H = \frac{0.5 \cdot J \cdot \omega_s^2}{S_n} \quad (1)$$

En efecto, H cuantifica la energía cinética del rotor a velocidad síncrona en términos del número de segundos que tarda el generador en proporcionar una cantidad equivalente de energía eléctrica cuando funciona a una potencia igual a su nominal. La inercia de las masas giratorias reduce el efecto del desequilibrio de potencia activa en la respuesta dinámica del SEP al limitar la velocidad de cambio de frecuencia y la magnitud de las oscilaciones. Este efecto positivo es directamente proporcional a la inercia del sistema.

2.2.2 ROCOF

Como se mencionó anteriormente, la inercia disponible del SEP influye notablemente en la frecuencia y magnitud de las oscilaciones provocadas por un cambio brusco en el balance de potencia activa. El ROCOF es el valor de la tasa de cambio de frecuencia de dichas oscilaciones en el momento inicial posterior al inicio de la perturbación [37]. La expresión para el ROCOF en términos de frecuencia medida puede expresarse como:

$$ROCOF = \frac{df(t)}{dt} = \frac{P_g - P_d}{S_t} \cdot \frac{f_s}{2H_t} \quad (2)$$

donde H_t es la constante de inercia total del SEP, P_g es la potencia generada total, P_d es la potencia demandada total, f_s es la frecuencia del sistema, y S_t es la capacidad de generación total conectada al SEP. Es apreciable de (2), como el ROCOF y H_t son inversamente proporcionales.

El ROCOF se utiliza como métrica valiosa para evaluar la estabilidad de frecuencia en sistemas eléctricos. Sin embargo, la precisión del cálculo del ROCOF (3) se ve influida significativamente por varios factores, como la duración de la ventana de cálculo (T), la calidad de los datos de medición y la precisión de la detección del tiempo de inicio de la falla.

$$ROCOF = \frac{f_{(n)} - f_{(n-N)}}{T} \quad (3)$$

Algunos operadores de SEP calculan el ROCOF inicial como el cambio en la frecuencia para una ventana de tiempo (T) de 0,5 segundos inmediatamente después de iniciada la perturbación [39]. Este período de tiempo se selecciona porque la respuesta del SEP durante este tiempo está dominada por el tamaño de la contingencia ($P_g - P_d$) y la respuesta inercial del sistema (H_t), antes de que la mayoría de los reguladores asociados a los GS respondan al cambio en la frecuencia percibida.

2.2.3 Desviación máxima (nadir o cenit)

Además de la inercia y el ROCOF, el nadir y cenit de frecuencia es una métrica frecuentemente utilizada para evaluar la estabilidad de frecuencia, ya que es fácil de medir e interpretar. El punto nadir es la frecuencia más baja durante la respuesta en frecuencia, mientras que el cenit es el punto de frecuencia más alto. En ambos casos, el valor registrado constituye la desviación máxima de frecuencia.

La desviación máxima promedio observada en varias ubicaciones del SEP se utiliza para estimar la desviación máxima absoluta. La desviación máxima de frecuencia se obtiene con mayor facilidad a partir de mediciones o herramientas de simulación, en comparación con el ROCOF, cuya precisión se ve afectada por otros factores [40].

2.2.4 Etapas de respuesta en frecuencia

En la Figura 3 se muestran las diferentes etapas de la respuesta en frecuencia según los gestores de transmisión de energía del sistema europeo (ENTSO-E) [41]. En caso de contingencia, las centrales eléctricas basadas en GS utilizan inmediatamente la energía cinética almacenada en las masas giratorias para reducir el ROCOF, lo que se conoce como respuesta inercial (RI) [42].

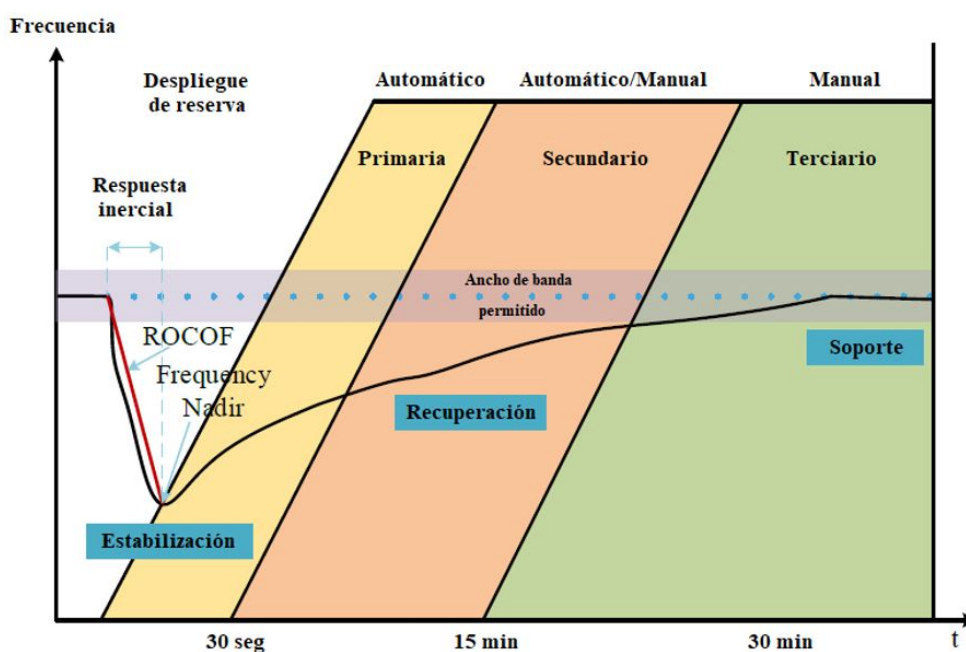


Figura 3. Etapas de respuesta en frecuencia por ENTSO-E.

Por otra parte, dependiendo de la disponibilidad de reserva, los GS participan en la regulación primaria de frecuencia (área amarilla) según los ajustes de estatismo. El nadir de frecuencia depende en gran medida de la cantidad de energía inyectada antes de que se alcance la desviación máxima, mientras que el ROCOF, está inversamente relacionado con la inercia del sistema [43, 44].

Para el presente estudio, el rango de tiempo de interés es el correspondiente al área blanca y amarilla de la Figura 3, el cual se encuentra en el orden de hasta los 30 segundos pos-contingencia. En este rango de tiempo, se produce la desviación máxima de frecuencia como resultado de la capacidad del sistema de inyectar o absorber potencia activa durante el evento transitorio.

2.3 Impacto de la generación basada en inversores en la estabilidad de frecuencia

El rápido desarrollo de las FER está provocando que la red eléctrica moderna evolucione desde un sistema dominado por generadores síncronos hacia un sistema dominado por inversores. Como consecuencia, la frecuencia del sistema eléctrico se ha vuelto más compleja y variable, con fluctuaciones en las FER y una reducción de la inercia del sistema. Estos cambios plantean nuevos retos a los operadores del sistema eléctrico y exigen el desarrollo de nuevas estrategias y tecnologías para garantizar un funcionamiento fiable y estable de la red.

Los sistemas fotovoltaicos y la mayoría de los aerogeneradores modernos se interconectan mediante inversores. Aunque esto es ventajoso desde el punto de vista de la explotación de energías limpias, la generación basada en inversores no proporciona ninguna respuesta mecánica inercial y, por lo tanto, compromete la estabilidad de frecuencia del SEP [45–47]. A medida que los generadores convencionales son desplazados por las FER, la respuesta inercial también disminuye. Esto provoca un aumento del ROCOF y de la desviación máxima de frecuencia.

2.3.1 Inversores seguidores de red y formadores de red

Un inversor tiene poca funcionalidad inherente y sus características de operación vienen definidas por sus algoritmos de control. Existen dos enfoques principales para lograr el control de potencia de las FER interconectadas mediante inversores [47]:

- Inversor de seguimiento de red (GFL, por sus siglas en inglés)
- Inversor formador de red (GFM, por sus siglas en inglés)

Un GFL mide la tensión en el punto de conexión común (PCC) para obtener el ángulo de fase (δ) mediante un bloque de seguimiento de fase (PLL), permitiendo variar la tensión terminal de forma que se alcancen las corrientes del eje directo y en cuadratura (I_d^* , I_q^*) deseadas. Básicamente, el soporte de potencia activa y reactiva de un inversor GFL se consigue controlando las corrientes I_d^* e I_q^* , como se muestra en la Figura 4 (a).

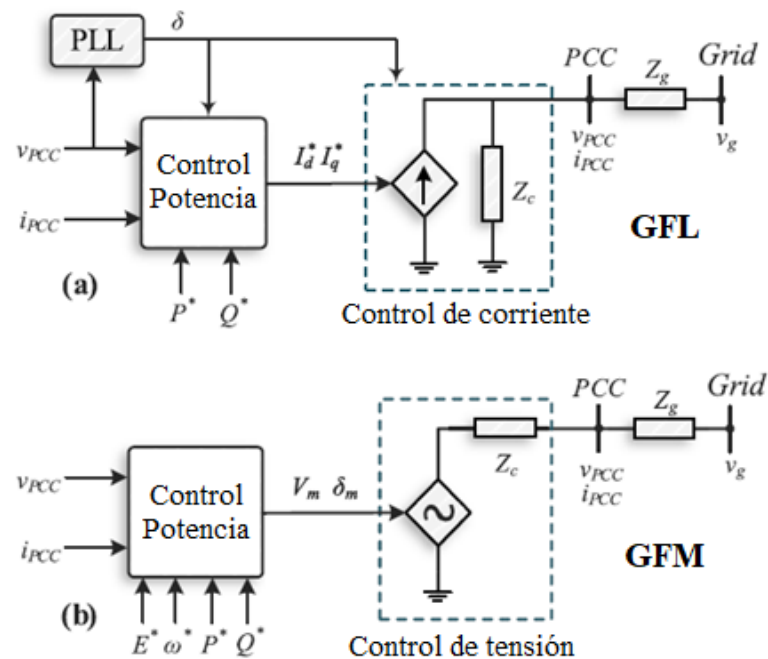


Figura 4. Aproximación del control de los inversores: (a) GFL y (b) GFM.

A diferencia de un inversor GFL, un GFM puede aproximarse como una fuente de tensión con una baja impedancia en serie, como se muestra en la Figura 4 (b). Al contrario de los GFL, los GFM no miden la tensión en el PCC con fines de sincronización, sino que la forman para regular su potencia de salida.

Otra diferencia importante es que los GFM pueden operar/suministrar las cargas locales en ausencia de conexión a la red estableciendo su propia tensión y frecuencia de referencia.

La mayoría de los inversores desplegados en la actualidad son de seguimiento de red, los cuales básicamente leen la tensión y la frecuencia de la red e inyectan corriente para proporcionar la cantidad adecuada de potencia activa y reactiva. El supuesto fundamental del diseño de los inversores GFL es que exista un número suficiente de generadores síncronos y/o inversores GFM que proporcionen una señal de tensión y frecuencia relativamente fuerte y estable, que los GFL puedan seguir.

2.3.2 Inercia virtual

Como se mencionó anteriormente, la disminución del valor de la inercia de los sistemas eléctricos provoca fluctuaciones de frecuencia más rápidas después de una perturbación. Por lo tanto, los operadores de los sistemas eléctricos se esfuerzan por limitar estos efectos negativos provocados por el aumento de la penetración de FER, y su consecuente disminución de la inercia. La reducción o eliminación de estos efectos no deseados, puede conseguirse introduciendo en los sistemas una inercia adicional, la cual se conoce como inercia virtual [36].

La inercia virtual adopta la forma de una inyección rápida de potencia activa al SEP forzada por un esquema de control adecuado. Las fuentes de dicha inyección pueden ser formas de energía (solar, eólica), cargas controladas, almacenamiento de energía (SAE) o dispositivos de sistemas flexibles de transmisión de corriente alterna (FACTS).

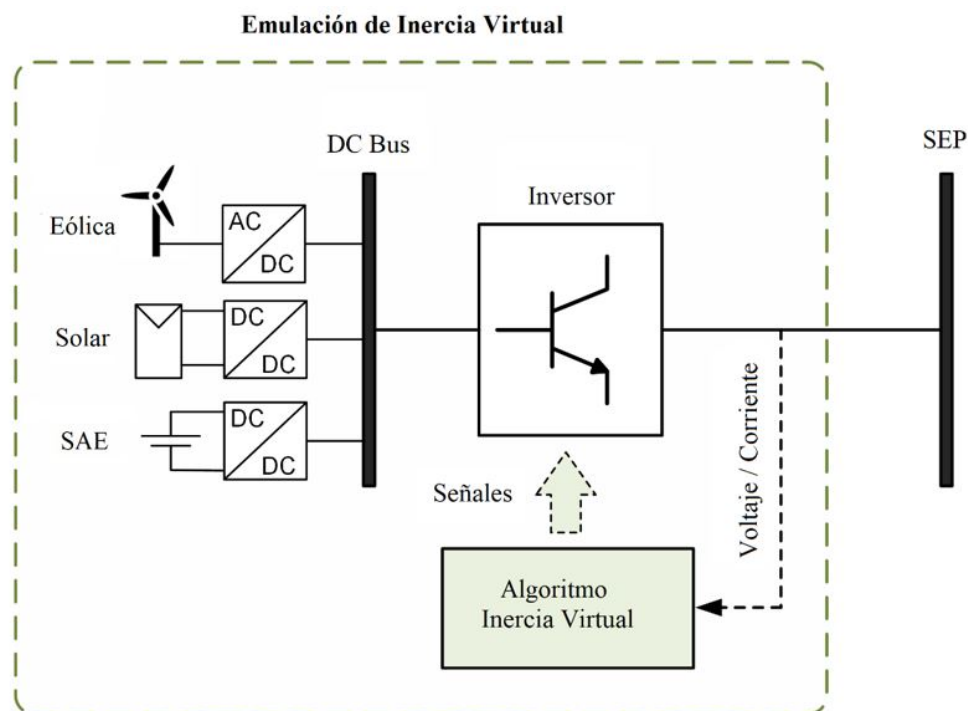


Figura 5. Concepto de inercia virtual.

El algoritmo de control de la inercia virtual permite que la potencia inyectada a la red dependa de la frecuencia del sistema. Algunas de las topologías más reconocidas en los inversores con las capacidad de proporcionar inercia virtual son los Synchronverters, Virtual Synchronous Machine, Virtual Synchronous Generators y Droop [47], los cuales además se clasifican dentro del grupo de inversores formadores de red.

La inercia virtual se considera la solución económica de los sistemas eléctricos modernos y futuros, en comparación con las instalaciones que suministran inercia natural (generación síncrona). Esto se debe a que la inercia virtual es sólo una de las muchas funciones que realizan los controladores asociados a los inversores.

2.4 Propagación de perturbaciones en la red eléctrica

Con el desarrollo de interconexiones entre sistemas regionales, los SEP modernos tendrán una distribución geográfica cada vez más amplia. El nivel de inercia de los distintos sub-sistemas será diferente debido a la distribución desigual de la generación síncrona con gran inercia y de las FER que no proporcionan soporte inercial [33]. Esto conlleva a que la oscilación de frecuencia que se produce en un SEP ante una contingencia no se produzca instantáneamente en todos los puntos del sistema.

En lugar de ello, el efecto de la perturbación se propaga desde el punto de desconexión al resto del sistema a través de las impedancias de la red e inercias de los generadores [5]. La Figura 6 muestra un evento de disparo de generación y carga en Florida, USA [5], en el cual se disparó más carga que generación, lo que provocó inicialmente un aumento de la frecuencia en el origen de la perturbación. La onda de frecuencia se desplazó de Florida a Tennessee, para llegar finalmente a Manitoba y Maine dos segundos después. La sincronización de las oscilaciones en Florida, Manitoba y Maine comenzó unos segundos más tarde.

La Figura 6 demuestra que el evento de frecuencia que se produce en distintos lugares del SEP, presenta diferentes características en la evaluación de la estabilidad de frecuencia. En Florida, se registraron los valores de cenit y nadir absolutos (valores máximos) del sistema, lo cual se justifica con el origen de la perturbación. Los valores de cenit y nadir en las restantes zonas fueron inferiores, lo cual está relacionado con la distancia eléctrica entre los diferentes subsistemas y el origen de la perturbación, además de la distribución desigual de la inercia a lo largo del sistema.

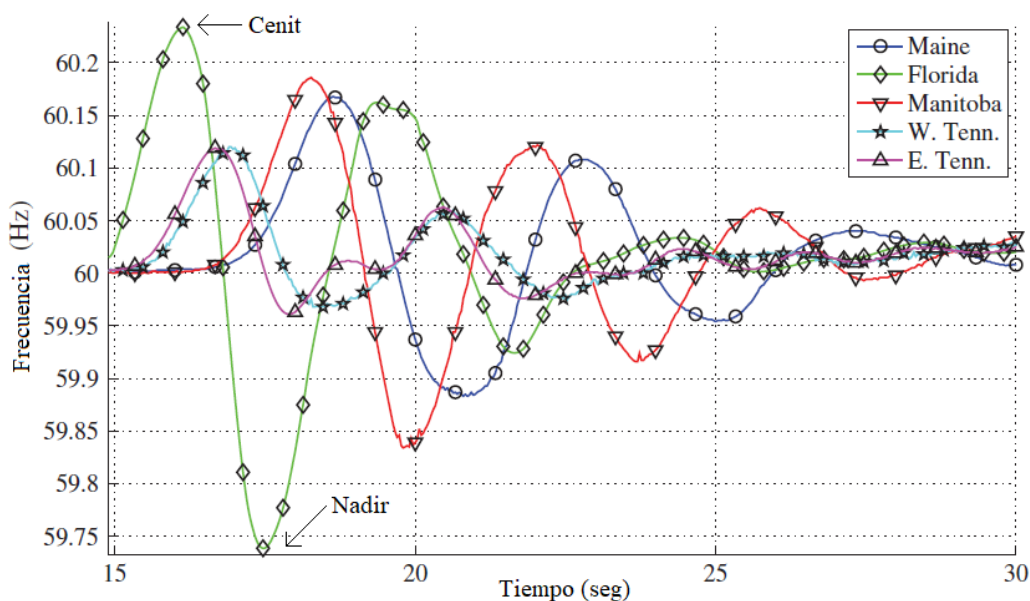


Figura 6. Propagación de ondas de frecuencia en un evento de disparo de generación-carga en Florida, 2008.

Los subsistemas de Tennessee (W. Tenn. y E. Tenn.) están eléctricamente más cercanos al origen de la perturbación, y a su vez, presentan una concentración de inercia síncrona superior a los subsistemas de Maine y Manitoba, es por ello que los valores de nadir y cenit registrados en Tennessee, son inferiores en magnitud que los registrados en Maine y Manitoba. Por otra parte, es apreciable como los intervalos de tiempo de propagación de la onda entre las diferentes zonas del sistema, puede llegar a ser del orden de segundos dependiendo de las distancias eléctricas. Todo ello reafirma la importancia del análisis de las características temporales y espaciales de la dinámica de frecuencia a lo largo del SEP.

2.4.1 Unidades de medición fasorial

Con las necesidades avanzadas de supervisión y protección de los SEP, se hace necesario medir la magnitud y fase de las formas de onda trifásicas del sistema para poder captar los fenómenos dinámicos. Una red de corriente alterna funciona con tensiones y corrientes sinusoidales a la frecuencia nominal del sistema.

Cada una de estas cantidades de tensión y corriente puede representarse mediante un fasor con una frecuencia, magnitud y fase. El cálculo fasorial es una tecnología digital de estimación de los componentes fasoriales a partir de las formas de onda analógicas medidas. Los dispositivos que realizan este procesamiento digital de señales se denominan unidades de medición fasorial (PMU) [5].

Una forma de onda cosenoidal en el dominio del tiempo se define como [5]:

$$x(t) = \sqrt{2}A \cos(\omega t + \phi) = \sqrt{2}A \cos(2\pi f t + \phi) \quad (4)$$

donde A es el valor eficaz de la amplitud, ω es la frecuencia en rad/seg y f es la frecuencia en Hz. La fase ϕ se define con respecto a una referencia temporal denotada por $t=0$, como se muestra en la Figura 7 (a).

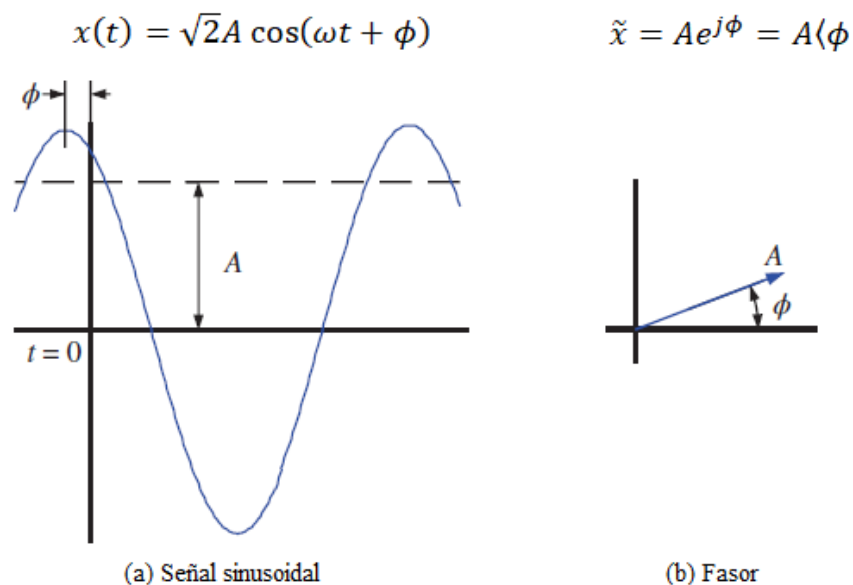


Figura 7. Forma de onda sinusoidal: (a) dominio del tiempo y (b) forma fasorial.

La señal puede representarse como un fasor (\tilde{x}) de la forma siguiente y como se muestra en la Figura 7 (b) [5]:

$$\tilde{x} = Ae^{j\phi} = A(\cos\phi + j\sin\phi) = X_r + jX_i \quad (5)$$

donde $X_r = A \cos(\phi)$ y $X_i = A \sin(\phi)$ son las partes real e imaginaria de \tilde{x} , la frecuencia f no se muestra explícitamente. En una PMU, la frecuencia f también se estima para tener en cuenta el funcionamiento fuera de la frecuencia nominal (50 Hz, 60 Hz).

Para el presente estudio se utilizan como característica de entrada a los modelos de aprendizaje automático los ángulos (ϕ) de los voltajes de los nodos de generación del sistema de prueba. Lo cual se justifica en la suposición de existencia de unidades PMU en distintos puntos del sistema eléctrico.

2.4.2 Sistemas de medición de área amplia

Las PMU se instalan normalmente en las subestaciones a lo largo del SEP, y básicamente se utilizan para medir los ángulos de tensión y las frecuencias de los buses. Algunas mediciones del sistema eléctrico no pueden combinarse para su análisis a menos que se registren al mismo instante de tiempo. Por lo tanto, junto con los pulsos de tiempo proporcionados por los sistemas de posicionamiento global (GPS, por sus siglas en inglés), las estimaciones de las PMU en zonas geográficamente dispersas, pueden analizarse como un sistema completo para observar la propagación y el impacto de las perturbaciones. Estas mediciones fasoriales sincronizadas en el tiempo también se denominan sincrofasores [48].

Los sistemas de medición de área amplia (WAMS, por sus siglas en inglés) pueden definirse como un sistema que realiza mediciones en la red eléctrica con un alto grado de granularidad. Los WAMS utilizan las mediciones (provenientes de los PMU) para mejorar la estabilidad de la red mediante el conocimiento de la operación del sistema en una zona amplia [48]. Además, posibilitan realizar un análisis avanzado basado en los datos recopilados (predicción, estimación, reducción de modelos).

2.5 Aprendizaje automático aplicado a SEP

El aprendizaje automático (ML, por sus siglas en inglés) y el aprendizaje profundo (DL, por sus siglas en inglés) se engloban bajo el marco de la inteligencia artificial (IA) (Figura 8). La IA es el término amplio que describe cualquier máquina que pueda aprender y realizar tareas que normalmente requieren inteligencia humana. Mientras que ML y DL son los habilitadores para crear aplicaciones basadas en IA.

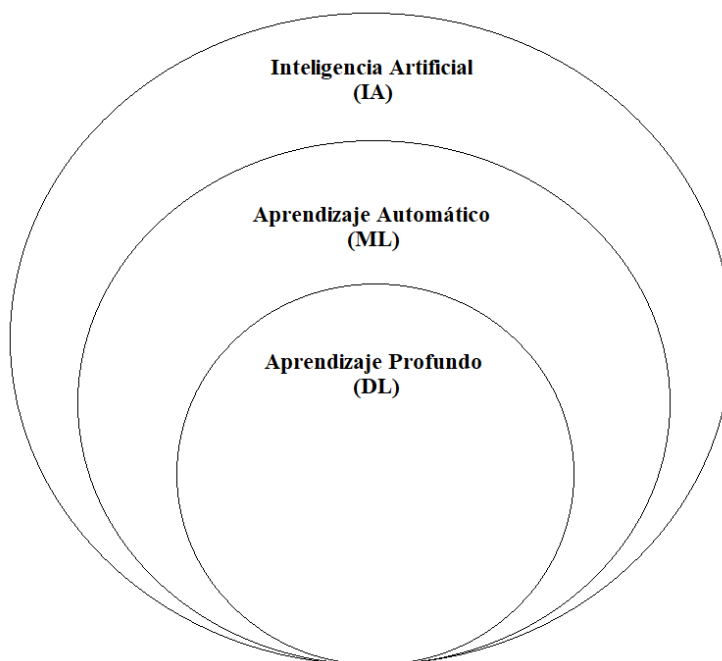


Figura 8. ML y DL como subconjuntos de la IA.

El ML es una técnica que permite a los programas informáticos aprender de los datos sin necesidad de ser programados explícitamente para ello. Similar al aprendizaje humano basado en experiencias, el ML capacita a los programas para aprender de datos históricos, permitiendo a los usuarios tomar decisiones basadas en tendencias y relaciones de datos [49, 50]. Por otro lado, el DL representa un subconjunto evolucionado del ML. El DL se destaca especialmente en problemas con grandes volúmenes de datos no estructurados o no etiquetados, o cuando la complejidad del problema supera los métodos tradicionales de ML. [51].

2.5.1 Algoritmos de ML

Los algoritmos de ML suelen pasar por dos etapas: entrenamiento y prueba. En la etapa de entrenamiento, los algoritmos aprenden las características de los datos; y en la etapa de prueba, se evalúan de acuerdo a la salida generada. Un algoritmo que ha pasado por la fase de entrenamiento se denomina modelo. De forma simplificada, se puede decir que un modelo de ML se considera una caja negra que produce una salida cuando se le proporciona una entrada [49].

Los algoritmos de ML son esencialmente construcciones matemáticas abstractas, y en función de los datos de entrada y las diferencias en el proceso de aprendizaje de los parámetros, se clasifica a grandes rasgos en tres tipos como se muestra en la Figura 9 [51].




Figura 9. Tipos de ML.

Para el objetivo del presente trabajo, el ML supervisado sería la clasificación de interés según el problema planteado. El aprendizaje supervisado se ocupa del entrenamiento de modelos para hacer predicciones o tomar decisiones basadas en datos etiquetados.

El modelo es alimentado con un conjunto de datos de entrenamiento que contienen etiquetas, con lo cual el modelo aprende patrones y relaciones, que utiliza para predecir las etiquetas de nuevas observaciones [49, 50]. En otras palabras, a los algoritmos de aprendizaje supervisado se les proporcionan datos históricos y se les pide que encuentren la relación que tenga el mejor poder predictivo.

Existen dos categorías de algoritmos de aprendizaje supervisado: los encargados de problemas de regresión y los de clasificación (Figura 10). Los métodos de aprendizaje supervisado basados en la regresión intentan predecir los resultados numéricos a partir de las variables de entrada. Los métodos de aprendizaje supervisado basados en la clasificación identifican a qué categoría o clase pertenece un conjunto de datos [51].

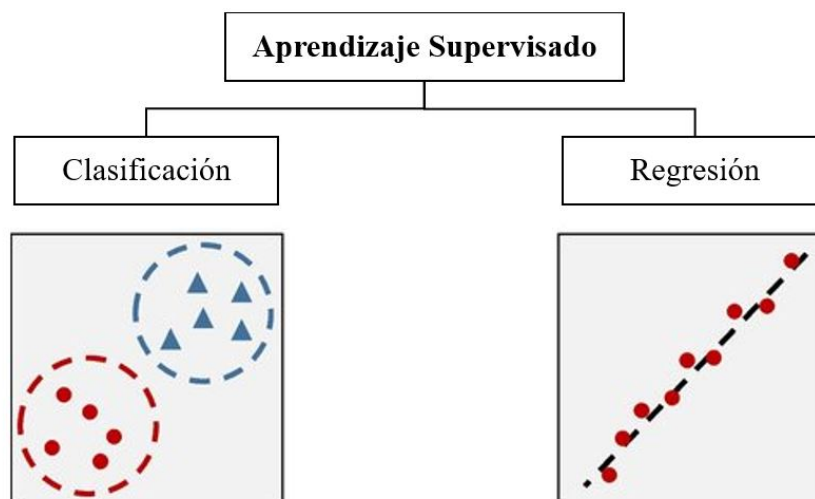


Figura 10. Tipos de aprendizaje supervisado.

Los problemas de los modelos predictivos varían entre clasificación y regresión. La clasificación consiste en predecir etiquetas de clases discretas, mientras que la regresión implica predecir cantidades continuas. A pesar de estas diferencias, ambos tipos comparten el concepto fundamental de utilizar variables conocidas para realizar predicciones, lo que genera un área de superposición significativa entre ellos. Algunos modelos pueden adaptarse fácilmente para funcionar en ambos tipos de problemas con ajustes mínimos, como se ejemplifica en la Figura 11.

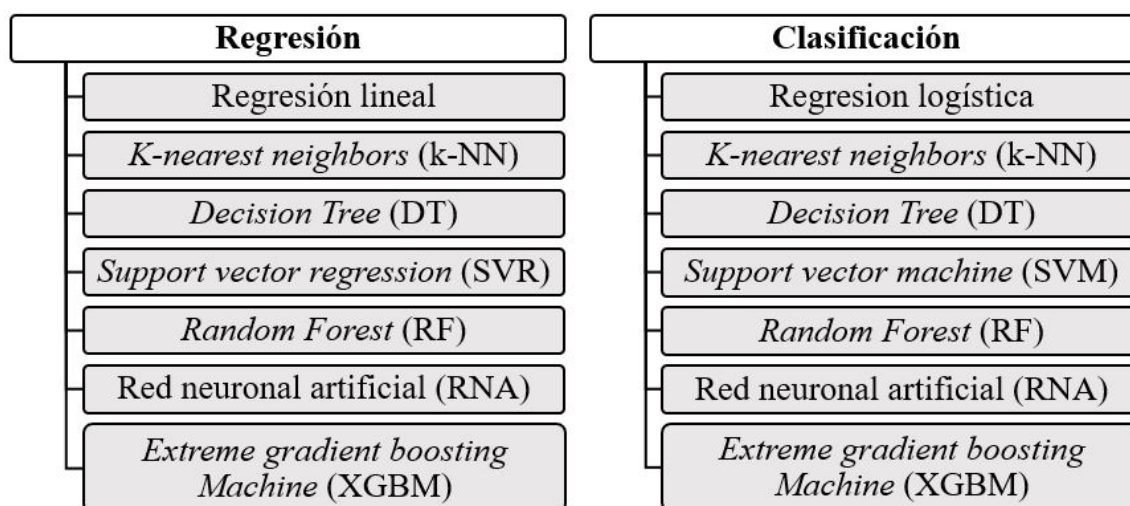


Figura 11. Modelos de ML supervisado: regresión y clasificación.

2.5.2 ML aplicado a SEP

El ML, con su capacidad para manejar conjuntos de datos elevados y complejos, y extraer características automáticamente, se ha convertido en una técnica frecuente aplicada al análisis de los SEP. La evaluación de los SEP utilizando algoritmos de ML es un enfoque basado en datos que no depende del conocimiento explícito de los principios físicos del sistema. Los algoritmos se entrenan utilizando datos de simulaciones o mediciones y realizan la evaluación basándose en las entradas de características del sistema.

Dentro de los algoritmos más utilizados en el análisis de los SEP se destacan: máquina soporte de vectores (SVM, por sus siglas en inglés) [52–54], árboles de decisión (DT, por sus siglas en inglés) [54, 55], *eXtreme Gradient Boost* (XGBM, por sus siglas en inglés) [56, 57], y redes neuronales artificiales (RNA) [54, 58–64]. Entre las aplicaciones específicas se encuentran la evaluación de estabilidad transitoria, estabilidad de voltaje, estabilidad de frecuencia, estimación de inercia, predicción de energía eólica y solar, y predicción de carga. En la Tabla 2 se resumen los algoritmos de ML identificados en la literatura y su área de aplicación dentro de los SEP.

Los estudios previos demuestran el potencial del ML en la identificación rápida, precisa y eficiente de posibles problemas de seguridad relacionados a los SEP. Esto posibilita la adopción rápida de medidas correctivas por parte de los operadores del sistema, conllevando a una explotación más segura, fiable y eficaz de los SEP.

TABLA 2
Aplicaciones de ML en SEP.

Referencia	Algoritmo de ML	Área de aplicación
[52]	SVM	Estabilidad transitoria
[53]	SVM	Estabilidad transitoria
[54]	SVM, DT, RNA	Estabilidad de voltaje
[55]	DT	Estabilidad de voltaje
[56]	XGBM, SVM	Estabilidad transitoria
[57]	XGBM	Estabilidad de frecuencia
[58]	RNA	Estabilidad de frecuencia
[59]	RNA	Estabilidad transitoria
[60]	RNA	Estimación de inercia
[61]	RNA	Predicción de energía eólica
[62]	RNA	Predicción de energía solar
[63]	RNA	Estimación de inercia
[64]	RNA	Estabilidad transitoria

2.5.3 ML aplicado a la evaluación de la estabilidad de frecuencia en SEP

En un sistema eléctrico convencional, la constante de inercia se selecciona como referencia valiosa para el control de la frecuencia; sin embargo, la constante de inercia se vuelve compleja y variable en el tiempo debido a la integración creciente de las FER, lo que dificulta su seguimiento por parte de los operadores.

Como se abordó en la Sección 2.2, la evaluación de la estabilidad de frecuencia de los SEP implica varios indicadores, entre los cuales se destacan la desviación máxima de frecuencia y el ROCOF. Por lo tanto, el objetivo de las aplicaciones de ML relacionadas con la estabilidad de frecuencia se centra fundamentalmente en la predicción de indicadores como el ROCOF [31–35] y la desviación máxima (nadir o cenit) [19–30].

En este sentido, varias investigaciones [19–23, 26–29], han demostrado cómo la predicción estadística de series temporales basadas en RNA posibilita la determinación de la desviación máxima de frecuencia basándose en datos anteriores. Además, se ha demostrado que los modelos de ML, específicamente basados en RNA, han mostrado mejores resultados para aplicaciones de predicción de series temporales cuando se comparan con otros modelos [22].

En la Tabla 3 se muestran los modelos de RNA más utilizados en la literatura aplicados a la evaluación de la estabilidad transitoria de frecuencia, específicamente en la predicción de la desviación máxima. Entre ellos, la *Feedforward Neural Network* (FFNN, por sus siglas en inglés), la *Time-Delay Neural Network* (TDNN, por sus siglas en inglés), la *Nonlinear Neural Network* (NAR, por sus siglas en inglés) y la *Long Short-Term Memory* (LSTM, por sus siglas en inglés) han demostrado eficacia en la captura de patrones temporales relevantes.

TABLA 3

Estado del arte de modelos basados en RNA aplicados a la predicción de la desviación máxima de frecuencia.

Referencia	Área de aplicación
[19]	TDNN
[20]	FFNN
[21]	NAR
[22]	LSTM, NAR
[23]	LSTM
[26]	LSTM
[27]	LSTM
[28]	FFNN
[29]	LSTM

Según la revisión bibliográfica realizada, no se han encontrado trabajos que aborden la evaluación de la estabilidad de frecuencia por áreas en los SEP utilizando algoritmos de ML. Demostrar la importancia del análisis de las características temporales y espaciales de la dinámica de frecuencia en el SEP, constituye una de las principales motivaciones del presente trabajo.

Hasta este punto, se han explorado y definido los modelos de RNA que se emplean con mayor frecuencia en la predicción de la desviación máxima de frecuencia en SEP. No obstante, se vislumbra una oportunidad relevante para investigar y comparar el desempeño de un modelo no aplicado a esta problemática en específico: el modelo Nonlinear Autoregressive with eXogenous inputs (NARX, por sus siglas en inglés). En este trabajo se pretende comparar el desempeño del modelo propuesto NARX con dos de los modelos más representativos del estado del arte: TDNN y LSTM.

2.5.4 Modelos de RNA implementados en el presente trabajo

Modelo TDNN

Los modelos de TDNN pueden describirse generalmente como una red neuronal que emplean entradas con retardos temporales a través del enfoque de desplazamiento temporal. Esta característica permite a los modelos capturar la dinámica temporal de los datos disponibles.

En la Figura 12 se representa la estructura general de la red TDNN, para este ejemplo el modelo aplica retardos de tiempo en la capa de entrada [65].




Figura 12. Arquitectura TDNN.

En una TDNN, las neuronas de la capa oculta reciben no solo el valor de entrada en el tiempo t , sino también los valores de entrada en los tiempos anteriores desde $t - 1$ hasta $t - n$, donde n define la longitud de la ventana temporal. El retardo de entrada determina la cantidad de pasos temporales pasados que se utilizan como entradas, lo que influye en la capacidad del modelo para capturar patrones temporales complejos en los datos. El número de neuronas en la capa oculta influye en la capacidad del modelo para aprender y representar relaciones no lineales en los datos.

Modelo LSTM

El modelo LSTM es un tipo de red neuronal recurrente que posee una arquitectura que incluye una celda de memoria adicional que puede retener información a largo plazo. Esta celda de memoria permite a la LSTM recordar información importante durante períodos prolongados, lo que la hace capaz de capturar dependencias a largo plazo en secuencias de datos [65, 66].

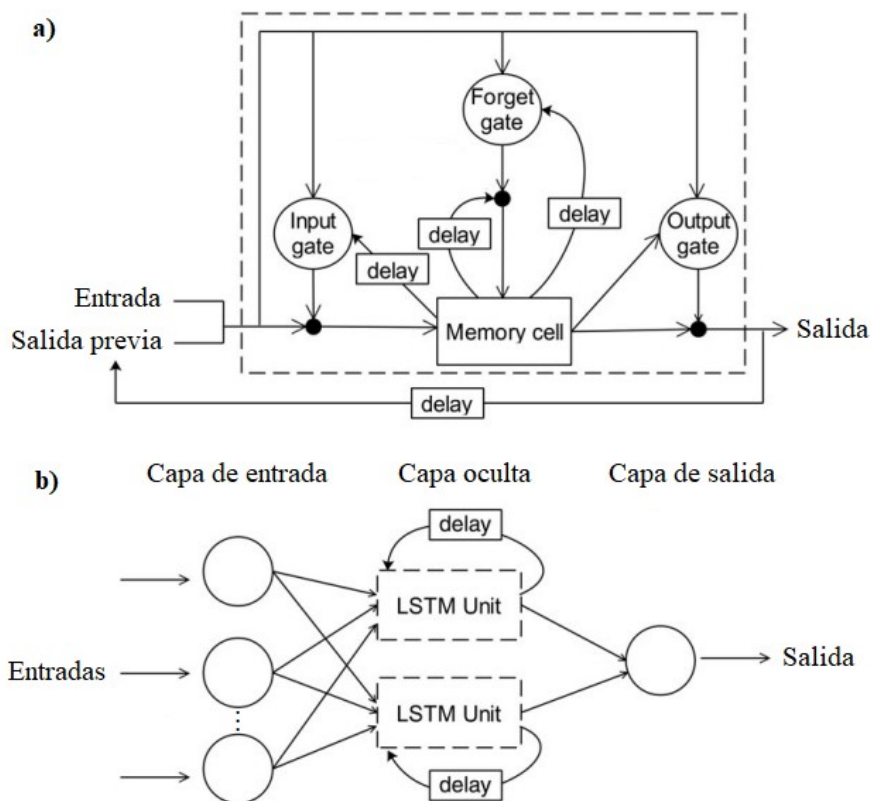


Figura 13. Estructura del modelo LSTM. (a) Unidad de memoria a largo plazo y (b) Arquitectura LSTM.

De la Figura 13, la célula (*memory cell*) actúa como la memoria, mientras que la puerta de entrada (*input gate*) decide qué información nueva se debe almacenar en ella. La puerta de olvido (*forget gate*) determina qué información debe eliminarse de la memoria, y la puerta de salida (*output gate*) regula cómo se utiliza la memoria para calcular la salida de la unidad LSTM.

Modelo NARX

El modelo NARX, a diferencia de otros modelos de RNA, tiene retroalimentación proveniente de la salida en lugar de las capas ocultas. Se ha demostrado que, en teoría, se pueden utilizar redes NARX, en lugar de redes recurrentes convencionales, sin ninguna pérdida computacional [67, 68].

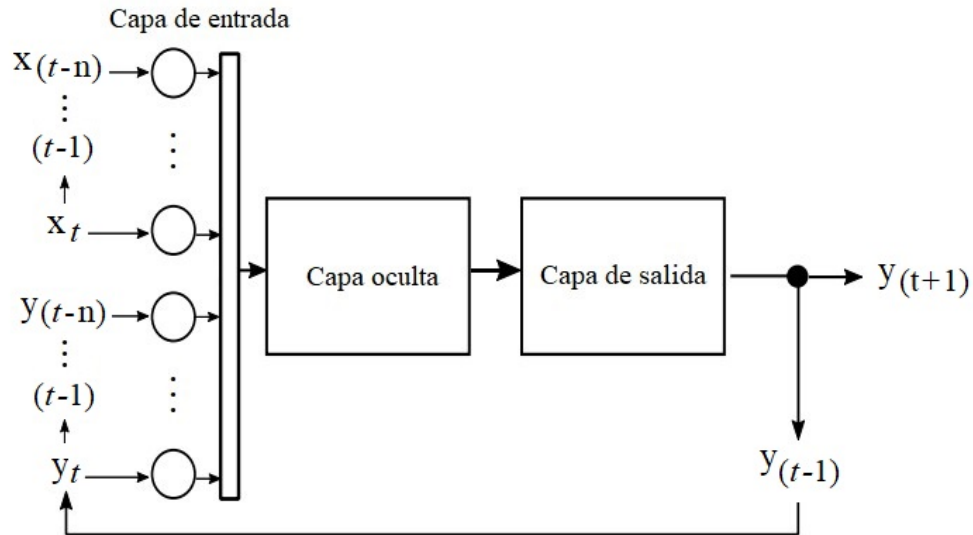


Figura 14. Arquitectura NARX.

Esta red tiene la característica específica de implicar líneas de retardo que almacenan los valores anteriores tanto de las secuencias de entrada $x(t)$, como las de salida $y(t)$, como se muestra en la Figura 14. Similar al modelo TDNN, n define la longitud de la ventana de datos. Para la red NARX, la retroalimentación (mediante retardos) utilizando los valores de salida $y(t)$, constituyen una secuencia adicional de entrada al modelo [69].

2.5.5 Comparación entre los modelos seleccionados

El funcionamiento de las redes TDNN se basa en la representación temporal de los datos disponibles mediante capas completamente conectadas que procesan secuencias temporales. Por su parte, las redes NARX utilizan términos exógenos para incorporar cierta cantidad de información externa adicional, lo que unido a la información pasada disponible les permite mejorar la precisión de los pronósticos, y obtener en muchos casos un desempeño superior en comparación con otros tipos de redes.

Por último, las redes LSTM se consideran una estructura más compleja de redes neuronales que se basa en una serie de compuertas que regulan el flujo de información durante el proceso de aprendizaje. A pesar de que pueden alcanzar buenos resultados en múltiples tareas, su complejidad computacional y el tiempo requerido para su entrenamiento son mucho mayores en comparación con las otras arquitecturas analizadas.

2.6 Conclusiones del Capítulo

En el análisis de la estabilidad de frecuencia, la desviación máxima emerge como una métrica destacada para su evaluación. A diferencia de otros indicadores como la inercia y el ROCOF, su principal ventaja radica en su fácil obtención e interpretación. Esta métrica permite a los operadores evaluar de manera efectiva la capacidad del sistema para mantener la frecuencia eléctrica dentro de los límites permitidos.

El desarrollo de interconexiones de FER en los SEP, así como el desplazamiento de GS, está generando una diversidad en los niveles de inercia entre las diferentes áreas que conforman el sistema. Esto acentúa que las oscilaciones de frecuencia ante una contingencia no se propaguen con igual magnitud a lo largo del sistema. En este sentido, los WAMS basados en PMU ofrecen la posibilidad de monitorear el SEP en tiempo real, proporcionando datos precisos y actualizados sobre la dinámica de frecuencia en diferentes áreas del sistema.

Se identificaron diversos algoritmos de RNA utilizados en la predicción de la desviación máxima de frecuencia, donde se destacan los modelos TDNN y LSTM. Como resultado de la revisión del estado del arte, se propone la implementación del modelo NARX, previamente no identificado en esta tarea. La introducción de términos exógenos en la red NARX, le permite aprovechar información adicional de gran relevancia para mejorar la calidad de los pronósticos en contextos donde la influencia de algunos de estos factores externos puede resultar significativa.

CAPÍTULO 3

METODOLOGÍA

3.1 Introducción a la metodología propuesta

En el proceso de investigación, la metodología desempeña un papel fundamental al proporcionar una estructura organizada y coherente para alcanzar los objetivos propuestos. En este capítulo, se presenta la metodología utilizada para abordar los retos del presente trabajo investigativo. En la Figura 15 se muestra el diagrama que resume las diferentes fases del proceso.

En la Fase 1 se fundamenta la selección del sistema de prueba y el proceso para la obtención de los datos sintéticos. En la Fase 2 se establece la división y estructuración de los datos. Mientras que en la Fase 3 se establecen las métricas para la evaluación de los resultados, así como los modelos de RNA implementados.

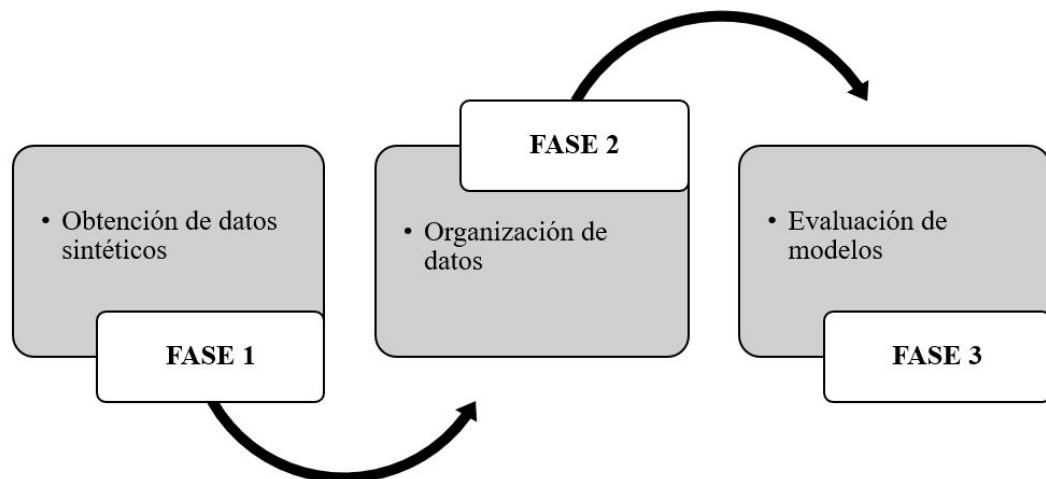


Figura 15. Fases de la metodología propuesta.

3.2 Fase 1: Obtención de datos sintéticos

El análisis de los SEP suele implicar simulaciones por ordenador, debido fundamentalmente a la complejidad que representa analizarlos analíticamente. Sin embargo, con fines educativos y de comprensión de determinados fenómenos, se utilizan sistemas de prueba reducidos especialmente diseñados para captar fenómenos de interés de forma analítica. Del mismo modo, incluso con la potencia de cálculo disponible hoy en día, se utilizan sistemas de prueba reducidos para estudiar fenómenos específicos mediante simulaciones por ordenador.

3.2.1 Sistema de prueba: Nordic32

El sistema de prueba Nordic32 (N32) se basa en la red de transmisión del SEP sueco, e inicialmente se creó para ilustrar el colapso de tensión que se produjo en Suecia en el año 1983 [70]. Existen trabajos previos relacionados al desarrollo y validación del sistema de prueba N32. En [71] se realiza un ajuste de los modelos dinámicos para conseguir un sistema de pruebas más representativo. En [72] se explica la implementación del sistema N32 en el software *DIgSILENT PowerFactory*, cuyo resultado se utiliza como base en este trabajo investigativo.

Los datos detallados relacionados a los elementos que conforman el sistema de prueba N32 se pueden consultar en [71]. La base de la generación síncrona la conforman la energía hidráulica y térmica [73]. En la Tabla 4 se representan los modelos dinámicos asociados a la generación síncrona utilizados para este estudio en específico. Los diagramas de control de los modelos, así como los ajustes de los parámetros se muestran en los apéndices A.2, A.3, A.4 y A.7.

TABLA 4

Modelos utilizados para la generación síncrona, disponibles en el software *DIGSILENT PowerFactory*.

Generación síncrona	<i>Composite model</i>	<i>Governor</i>	<i>Exciter</i>
Hidráulica	<i>Frame synchronous generator</i>	<i>Hydro turbine</i>	<i>AC Excitation system</i>
Térmica	<i>Frame synchronous generator</i>	<i>Steam turbine</i>	<i>AC Excitation system</i>

Una peculiaridad del SEP sueco es que está dividido en cuatro zonas geográficas diferentes: SE1, SE2, SE3 y SE4. En el contexto de esta investigación, la selección del sistema de prueba N32 como fuente para la obtención de los datos sintéticos, se justifica por su estructura por áreas (o zonas) bien identificadas. Para ellos se utilizó la delimitación por zonas del N32 realizada en [73]. En el apéndice A.1 se muestra el diagrama unifilar del sistema N32 utilizado en este estudio.

3.2.2 Generación de datos sintéticos

Como se mencionó en secciones anteriores, los sistemas eléctricos están evolucionando hacia una matriz energética dominada por FER basadas en inversores. Con el objetivo de reflejar esta transición, en el presente estudio se realizaron modificaciones a la matriz de generación del sistema de prueba base N32 [72]. Las modificaciones consisten en la reducción de la inercia, mediante el desplazamiento de generadores síncronos por FER basada en inversores.




Figura 16. Modificación del sistema de prueba N32.

En la Tabla 5 se muestran los modelos dinámicos utilizados para la simulación de los inversores GFL y GFM. Los diagramas de control asociados a los inversores se muestran en los apéndices A.5 y A.6.

TABLA 5

Modelos utilizados para la generación basada en inversores, disponibles en el software *DIGSILENT PowerFactory*.

Generación síncrona	<i>Composite model</i>
GFM	<i>Droop Controlled Converter</i>
GFL	<i>VSC Grid Following</i>

Para la conformación de la base de datos se establecieron 5 sistemas bases con diferentes porcentos de penetración de generación síncrona y FER, y a su vez diferentes porcentos de relación de inversores GFL y GFM. La composición resultante de la matriz energética de los sistemas bases se muestra en la Tabla 6.

TABLA 6

Composición de la matriz de generación de los sistemas bases.

Sistemas	% de GS y FER	% de GFL y GFM	Simulaciones
S1	26 % GS - 74 % FER	90 % GFL - 10 % GFM	109
S2	22 % GS - 78 % FER	85 % GFL - 15 % GFM	82
S3	18 % GS - 82 % FER	80 % GFL - 20 % GFM	82
S4	15 % GS - 85 % FER	75 % GFL - 25 % GFM	79
S5	13 % GS - 87 % FER	70 % GFL - 30 % GFM	78
Total			430

Para cada sistema base se simularon diferentes eventos o contingencias, entre ellos: fallas transitorias, fallas permanentes, variación de carga (desconexión de carga) y variación de generación (desconexión de generación). Para fallas transitorias se realizaron ciclos C-O-C (Closed-Open-Closed), y para fallas permanentes ciclos C-O-C-O (Closed-Open-Closed-Open). Se utilizaron tiempos de disparo para los interruptores de líneas de transmisión de 3 y 4 ciclos (incluye el tiempo de operación de las protecciones y del interruptor de potencia), mientras que los tiempos de recierre fueron de 15 y 30 ciclos (a frecuencia del sistema de 50 Hz). Se simularon fallas monofásicas, bifásicas, bifásicas a tierra y trifásicas, siendo la monofásica la más representativa (70 - 80 % aproximadamente). Para los tiempo de apertura considerados se

Las simulaciones realizadas en el software *DIGSILENT PowerFactory*, del tipo RMS, tuvieron una duración de 30 segundos, con inicio de la contingencia en $t = 1$ s. El paso de tiempo para las simulaciones dinámicas se fijó en 0,005 segundos. Para recopilar datos a una velocidad de 50 muestras/seg [10], se registraron medidas cada $\frac{0.02}{0.005} = 4$ pasos de tiempo. Se asumió que los buses de generación (15 kV) están equipados con dispositivos PMU. En total se realizaron 430 simulaciones, lo cual representó una base de datos total de 618 MB (648,354,435 bytes). Los datos se obtuvieron en aproximadamente 18 horas de simulación, utilizando una Laptop Dell, Windows 10 Professional, Versión 22H2, Intel(R) Core(TM) i7-7700HQ CPU @ 2.80GHz, 32 GB RAM.

3.3 Fase 2: Organización de datos

Una vez generada la base de datos sintética utilizando el software *DIGSILENT PowerFactory*, se procede con la organización de los datos. Como se puede apreciar en la Figura 17, la fase 2 contiene tres pasos intermedios: clasificación, división y estructuración de los datos.

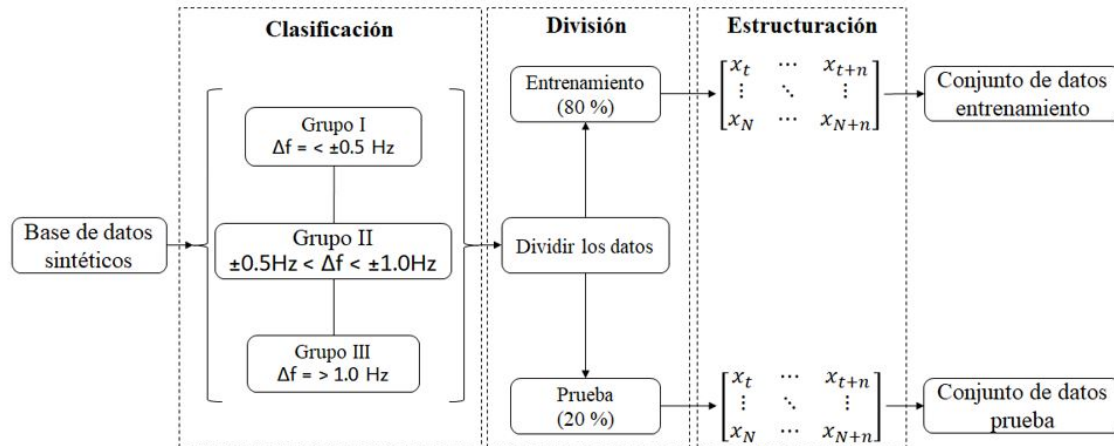


Figura 17. Metodología para la estructuración de los datos.

3.3.1 Clasificación de los datos

Para la clasificación de las simulaciones se tuvo en cuenta la desviación máxima de frecuencia (Δf) absoluta del sistema. Este enfoque permite discernir entre los diferentes niveles de perturbación, segmentando las simulaciones en tres grupos distintos:

- I. Leves: $\Delta f < \pm 0.5 \text{ Hz}$ - (318 simulaciones)
- II. Moderadas: $\pm 0.5 \text{ Hz} < \Delta f < \pm 1.0 \text{ Hz}$ - (92 simulaciones)
- III. Severas: $\Delta f > \pm 1.0 \text{ Hz}$ - (20 simulaciones)

El proceso de clasificación se realizó utilizando código plano y el software MATLAB, versión R2021B. Las simulaciones clasificadas como Grupo I fueron las más identificadas con 318 en total, mientras que las clasificadas como Grupo III fueron las menos identificadas con 20. Por su parte en el Grupo II resultaron un total de 92 simulaciones. Es apreciable como las simulaciones del Grupo III son minoría, lo cual se justifica por la naturaleza menos frecuente de perturbaciones severas (mayor desviación de frecuencia). El objetivo del análisis anterior es permitir que los modelos de RNA generalicen de manera efectiva, utilizando la representación de las situaciones más comunes y recurrentes en la operación de los SEP.

3.3.2 División de los datos

Una vez agrupadas las simulaciones, se procede a la división de los datos en conjuntos de entrenamiento y prueba, utilizando el enfoque de clasificación previamente abordado. Para ello, se selecciona el 80 % de las simulaciones de cada grupo para entrenamiento y el 20 % restante para prueba. Como resultado se generaron 344 simulaciones para el conjunto de datos de entrenamiento y 90 simulaciones para el conjunto de datos de prueba. En resumen, la clasificación y división de la base de datos, tiene como misión asegurar que los modelos de ML implementados se entrenen y evalúen con conjuntos de datos representativos y equilibrados.

3.3.3 Estructuración de los datos. Etapa de entrenamiento

Los conjuntos de datos obtenidos en la sección anterior están compuestos por series de tiempo. Para esta investigación, el arreglo de datos utilizado tiene la forma de predicción de la serie de salida $y(t)$ a partir de la serie de entrada $x(t)$.

En la Figura 18 se representa la estructura de datos utilizada para la etapa de entrenamiento. La justificación de utilizar los ángulos de voltaje como características de entrada al modelo, se debe a que la dinámica electromecánica de los SEP se refleja en los ángulos de voltaje primero que en la frecuencia eléctrica [19].

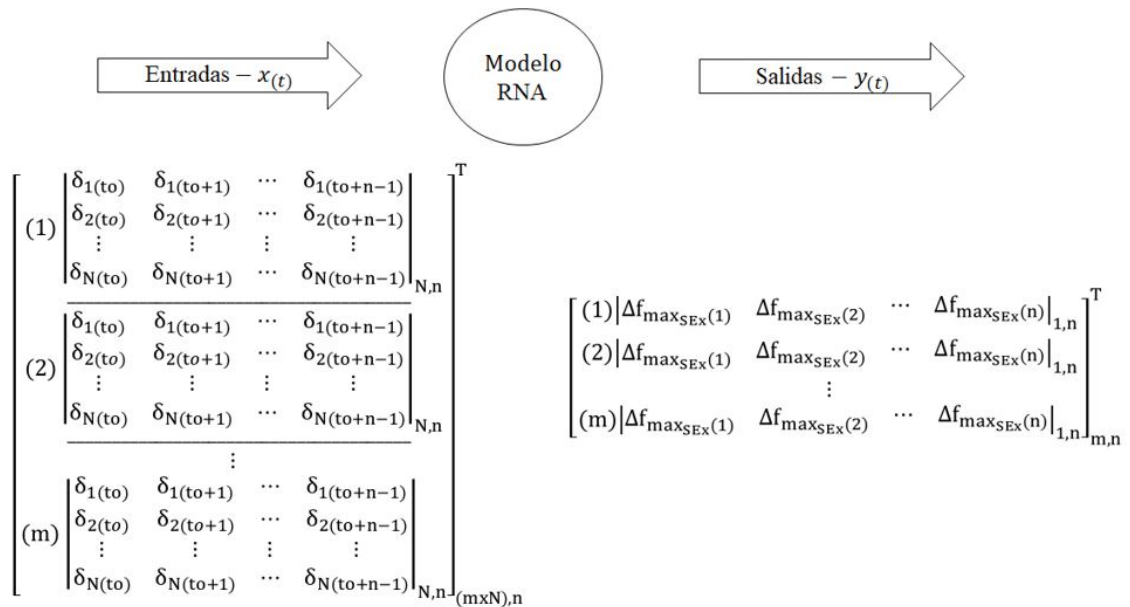


Figura 18. Estructuración de datos etapa de entrenamiento.

De la Figura 18, t_0 es el instante de tiempo inicial de la perturbación ($t_0=1$ s), n es el número de muestras que conforman la ventana de datos (longitud de la ventana), N es el número de buses de generación (Síncrona y FER), y m es la cantidad de simulaciones que forman el conjunto de datos de entrenamiento. La matriz de entrada al modelo la forman m submatrices concatenadas correspondientes a cada simulación, donde las submatrices contienen los ángulos de voltaje (δ) de los buses de generación. La matriz de salida está formada por m vectores filas concatenados, los cuales contienen n veces el valor de la desviación máxima de frecuencia ($\Delta f_{max_{SE_x}}$) del área x , correspondiente a cada simulación. Para la medición de frecuencia de cada área se tomaron como referencia los buses de interconexión entre las áreas, resultando los buses 4011, 4022, 4044 y 4062 (Ver Anexo), los buses de referencia para las áreas SE1, SE2, SE3 y SE4 respectivamente.

Para este arreglo de datos, el número de columnas de la matriz de entrada, coincide con el número de columnas de la matriz de salida. Lo anterior está determinado por la longitud de la ventana de datos (n). Ambas matrices se trasponen (T) antes de proporcionárselas al modelo para su entrenamiento.

3.3.4 Estructuración de los datos. Etapa de prueba

El arreglo de datos utilizado para la etapa de prueba se muestra en la Figura 19. La estructura de la matriz de entrada es similar a la utilizada en la etapa de entrenamiento, para este caso p representa la cantidad de simulaciones que forman el conjunto de datos de prueba. Para cada área se utilizaron 10 modelos de RNA en paralelo (MOD(1:10)).

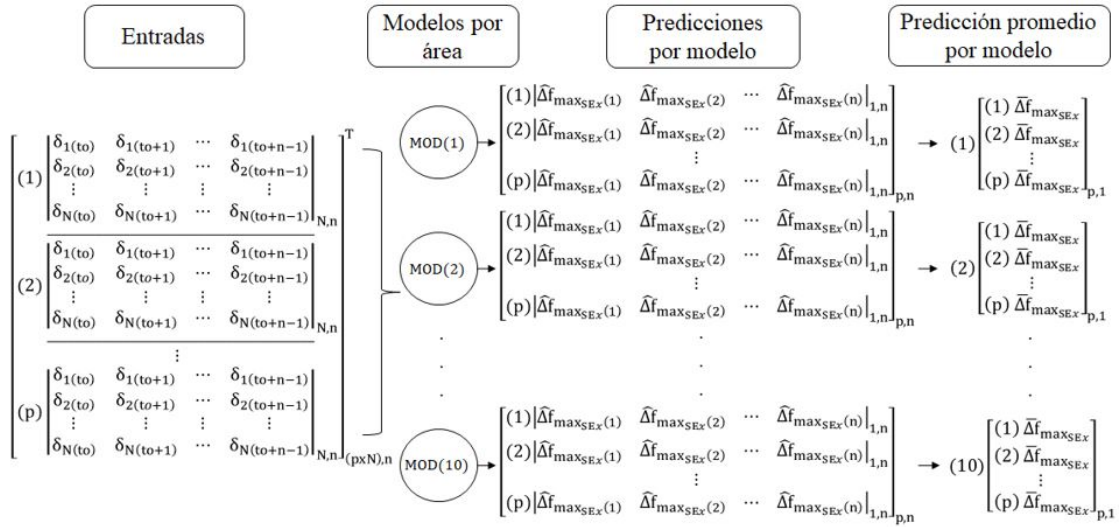


Figura 19. Estructuración de datos etapa de prueba (por modelo).

Las predicciones del área x ($\hat{\Delta}f_{maxSEx(1:n)}$) para cada simulación p y en cada intervalo n ($1, 2, \dots, n$), se promedian utilizando:

$$\bar{\Delta}f_{maxSEx(1:n)} = \sum_{i=1}^n \frac{\hat{\Delta}f_{maxSEx(i)}}{n} \quad (6)$$

Como resultado se obtiene un vector columna con las predicciones promedio ($\bar{\Delta}f_{maxSEx(1:n)}$) por modelo y simulación.

Una vez obtenidas las predicciones promedio por cada modelo, se procede con la obtención de la predicción final por área como se muestra en la Figura 20. Donde $CMOD_{SE(1:4)}$ es el conjunto de modelos en paralelo (aprendizaje en conjunto) para cada área (SE1,SE2,SE3 y SE4), y $\Delta f_{maxSE(1:4)}$ es la predicción final de la desviación máxima para cada simulación p del área correspondiente.

$$\Delta f_{maxSE(1:4)} = \sum_{i=1}^{10} \frac{\bar{\Delta f}_{maxSEi}}{10} \quad (7)$$

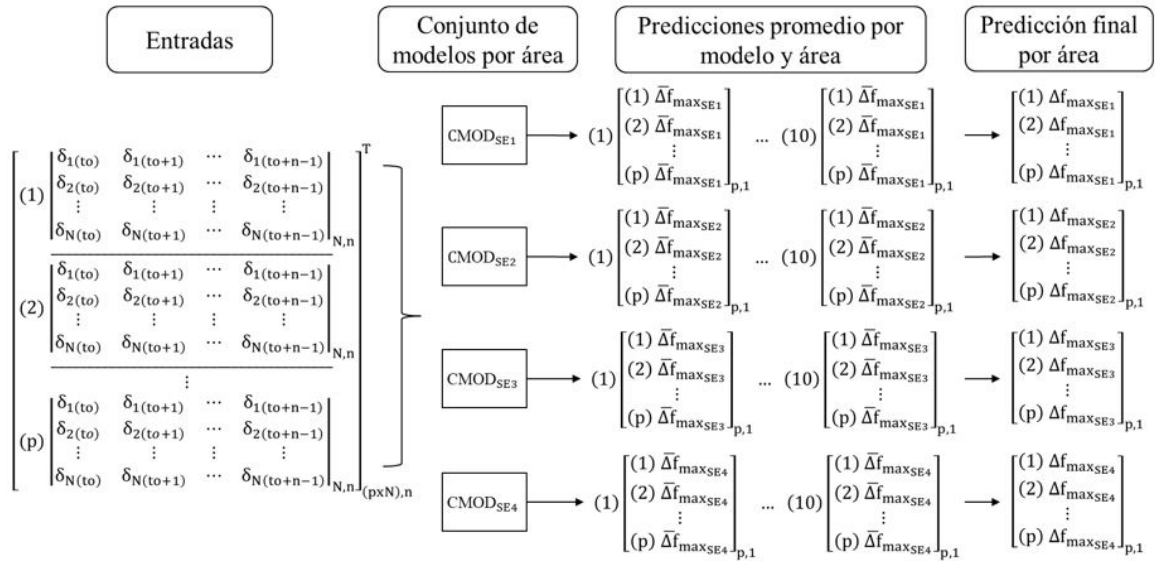


Figura 20. Estructuración de datos etapa de prueba (por área).

La predicción final para cada simulación p y cada área, se obtiene promediando el resultado de los 10 modelos en paralelo. Lo anterior se conoce como aprendizaje en conjunto, y constituye una técnica comúnmente utilizada en ML, la cual combina las predicciones de múltiples modelos para reducir la varianza en las predicciones, así como el error de generalización [51].

3.4 Fase 3: Evaluación de modelos

La última fase de la metodología propuesta, es la correspondiente a la evaluación del desempeño de los modelos seleccionados. Como se mencionó en el Capítulo 2, en este estudio se propone comparar el desempeño del modelo propuesto (NARX), con los modelos de RNA más aplicados a la predicción de la desviación máxima de frecuencia: TDNN y LSTM. En la Figura 21 se representa la metodología propuesta en la evaluación de modelos (Fase 3).

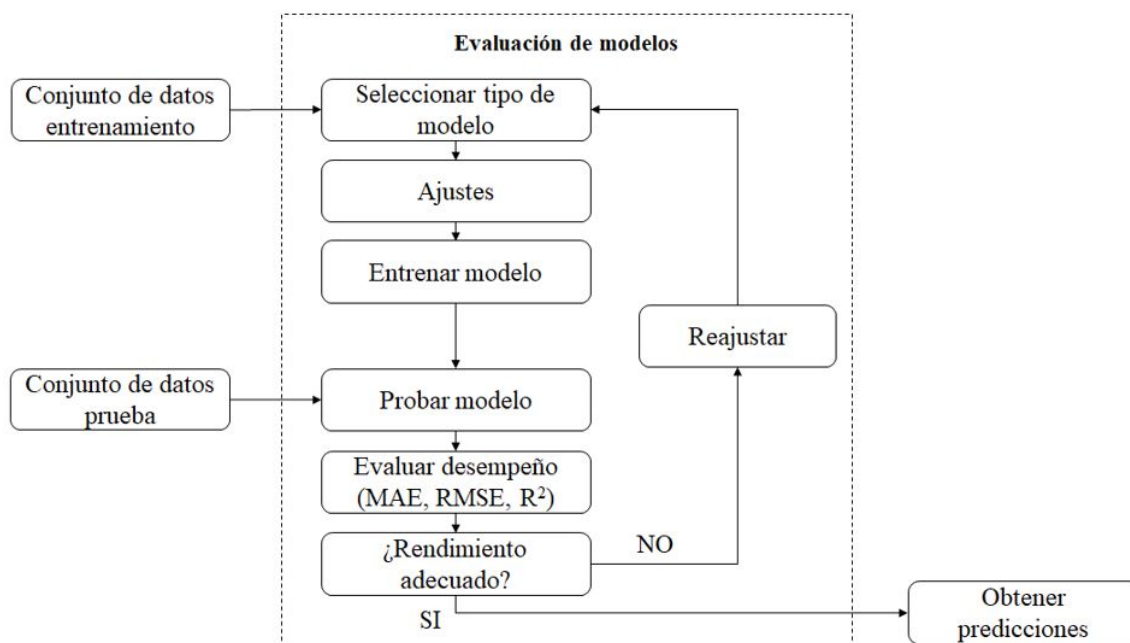


Figura 21. Metodología para la evaluación de modelos.

3.4.1 Selección y ajuste de los modelos

Como se mencionó en el Capítulo 2, en el presente estudio se pretende comparar los resultados en la predicción de la desviación máxima de frecuencia, utilizando el modelo propuesto NARX, y dos de los modelos más representativos del estado del arte: TDNN y LSTM.

En la parametrización de los modelos seleccionados, se utilizó un enfoque de prueba y error, explorando el efecto de las variaciones en los ajustes, en el rendimiento predictivo y la estabilidad del modelo. Entre los ajustes examinados se destacan el retardo de entrada, el número de neuronas en la capa oculta y el algoritmo de entrenamiento empleado.

En las Tablas 7, 8 y 9 se muestra la relación de ajustes examinados durante el proceso de parametrización en los modelos seleccionados.

TABLA 7

Parámetros de ajustes del modelo TDNN.

Parámetros
No. de capas ocultas
Retardo de entrada
No. de neuronas capa oculta
Algoritmo de entrenamiento
Métrica de desempeño
Función de activación capa oculta
Función de activación capa salida
Épocas de entrenamiento

TABLA 8

Parámetros de ajustes del modelo LSTM.

Parámetros
No. de capas ocultas
No. de unidades LSTM en la capa oculta
Algoritmo de entrenamiento
Métrica de desempeño
Épocas de entrenamiento

TABLA 9

Parámetros de ajustes del modelo NARX.

Parámetros
No. de capas ocultas
Retardo de entrada
No. de neuronas capa oculta
Algoritmo de entrenamiento
Métrica de desempeño
Función de activación capa oculta
Función de activación capa salida
Épocas de entrenamiento

El retardo de entrada determina la cantidad de pasos temporales pasados que se utilizan como entradas, lo que influye en la capacidad del modelo para capturar patrones temporales complejos en los datos. El número de neuronas en la capa oculta influye en la capacidad del modelo para aprender y representar relaciones no lineales en los datos. Mientras que el algoritmo de entrenamiento determina la velocidad de convergencia y la calidad de los resultados finales.

3.4.2 Métricas de evaluación del desempeño

Para evaluar el rendimiento de los modelos, se utilizarán métricas de uso común como el error cuadrático medio (RMSE), el error medio absoluto (MAE) y el coeficiente de determinación (R^2).

El RMSE es una métrica comúnmente utilizada para evaluar el rendimiento de un modelo de regresión. Se calcula como la raíz cuadrada del error cuadrático medio (MSE). El MSE es la media de todos los errores al cuadrado entre los valores predichos y los valores reales, y proporciona una indicación de cuánto se desvían los valores predichos de los reales.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (8)$$

El RMSE amplía el MSE conservando las mismas unidades que los valores predichos, y puede calcularse utilizando la fórmula que aparece en (8), donde N es el número de datos de prueba, \hat{y}_i es el valor de predicción del modelo, y y_i es el valor real.

El MAE se calcula como la media de las diferencias absolutas entre los valores predichos y los valores reales. Es una métrica robusta, ya que no se ve muy afectada por los valores atípicos, y proporciona una indicación de la magnitud media de los errores.

$$MAE = \frac{1}{n} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (9)$$

Por su parte, R^2 , es una métrica que mide el grado de correlación lineal entre los valores predichos y los valores reales. R^2 toma valores entre 0 y 1, donde un valor de 1 indica un ajuste perfecto y un valor de 0 indica que el modelo tiene un ajuste nulo.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (10)$$

El cálculo de R^2 se muestra en la ecuación (10), donde \bar{y} es la media de los valores reales.

3.5 Conclusiones del Capítulo

La metodología propuesta tiene la función de estructurar el proceso de clasificación y organización de los datos, así como la evaluación de los resultados en el estudio propuesto.

Para la clasificación se tuvo en cuenta la severidad de los eventos simulados, logrando una representación equitativa de los diferentes escenarios en los conjuntos de datos de entrenamiento y prueba.

La estructuración de los datos se basa en la selección de la longitud de la ventana de datos, en el arreglo propuesto para el aprendizaje en paralelo de los modelos, y en la obtención de predicciones por las distintas áreas del sistema.

En la evaluación de los modelos seleccionados, se definieron las métricas a utilizar, además de los ajustes examinados durante la parametrización de cada modelo.

CAPÍTULO 4

RESULTADOS

4.1 Introducción del Capítulo

En este capítulo se presentan y analizan los resultados al utilizar los modelos de ML en la predicción de la desviación máxima de frecuencia. Inicialmente, se describen los ajustes específicos para cada uno de los modelos, incluyendo el modelo propuesto NARX, y los modelos más representativos del estado del arte: TDNN y LSTM.

Posteriormente, se exponen las métricas de rendimiento alcanzadas por cada modelo examinado, y se realiza una comparación cuantitativa entre ellos. Las métricas utilizadas permiten evaluar la precisión y efectividad de las predicciones obtenidas por cada modelo.

Por último, utilizando algunos escenarios particulares de la base de datos, se analiza la desviación máxima de frecuencia que se produce en diferentes puntos del sistema de prueba. Esto con el objetivo de destacar la importancia del monitoreo de la frecuencia por áreas en los sistemas eléctricos modernos.

4.2 Resultados para el modelo propuesto NARX

En esta sección se presentan los resultados en la predicción de la desviación máxima de frecuencia, utilizando el modelo propuesto NARX. Como se mencionó en la Sección 3.4, el proceso de ajuste se realiza mediante el enfoque de prueba y error, ponderando el efecto de cada parámetro en el desempeño del modelo.

Los ajustes propuestos como resultado de la parametrización del modelo NARX se muestran en la Tabla 10.

TABLA 10
Ajustes propuestos para el modelo NARX.

Parámetros	Ajustes obtenidos
No. de capas ocultas	1
Retardo de entrada	1
No. de neuronas capa oculta	20
Algoritmo de entrenamiento	<i>Levenberg-Marquardt backpropagation</i>
Métrica de desempeño	MSE
Función de activación capa oculta	tanh
Función de activación capa salida	lineal
Épocas de entrenamiento	1000

Durante la parametrización se observó que el retardo de entrada no tuvo un efecto significativo sobre los resultados al utilizar el modelo NARX. Por lo tanto, se decidió seleccionar el valor mínimo (e igual a 1), simplificando así la configuración del modelo, sin comprometer su capacidad y velocidad predictiva.

4.2.1 Selección de la longitud de ventana de datos

En la evaluación del modelo NARX, se ponderó la influencia de la ventana de datos en la calidad de los resultados. Para ello, se exploraron diferentes longitudes de ventana, desde los 100 ms (n=5) hasta 220 ms (n=11), con el objetivo de evaluar su impacto en la capacidad predictiva del modelo.

Los resultados para cada una de las longitudes de ventana analizadas se presentan en la Tabla 11.

TABLA 11

Comparación de resultados para el modelo NARX entre diferentes longitudes de ventana.

Longitud ventana	Áreas	Métricas			Tiempo entrenamiento (s)
		MAE (Hz)	RMSE (Hz)	R^2 (p.u)	
100 ms (n=5)	SE1	0.0200	0.0301	0.9963	32.4
	SE2	0.0201	0.0300	0.9963	33.1
	SE3	0.0198	0.0299	0.9965	37.9
	SE4	0.0201	0.0301	0.9963	35.6
140 ms (n=7)	SE1	0.0141	0.0228	0.9977	41.6
	SE2	0.0121	0.0199	0.9980	43.8
	SE3	0.0135	0.0215	0.9979	44.9
	SE4	0.0125	0.0205	0.9980	42.3
180 ms (n=9)	SE1	0.0099	0.0161	0.9990	53.4
	SE2	0.0109	0.0168	0.9989	51.2
	SE3	0.0108	0.0165	0.9990	50.3
	SE4	0.0101	0.0156	0.9987	58.6
220 ms (n=11)	SE1	0.0104	0.0163	0.9988	67.2
	SE2	0.0109	0.0168	0.9989	69.5
	SE3	0.0098	0.0160	0.9990	63.8
	SE4	0.0100	0.0154	0.9990	66.1

Es apreciable en los resultados mostrados en la Tabla 11 una similitud en las métricas obtenidas por cada área. Esto sugiere una estabilidad en el rendimiento del modelo, y un adecuado desempeño del aprendizaje en conjunto por área. Por otro lado, las métricas demuestran una tendencia general de mejora a medida que aumenta la longitud de la ventana. Este fenómeno se justifica porque al proporcionar al modelo una mayor cantidad de datos, este tiende a generalizar con mayor efectividad, capturando así patrones más complejos y mejorando su capacidad predictiva. Sin embargo, la diferencia en los resultados a partir de la longitud de ventana de 180 ms es mínima.

Para una mejor apreciación de lo anterior, en la Figura 22 se muestra una gráfica comparativa de las métricas obtenidas para las longitudes de ventana de 180ms, 220ms y 260ms. La variación del desempeño del modelo NARX, para las diferentes ventanas antes mencionadas, se considera despreciable para fines del presente estudio.

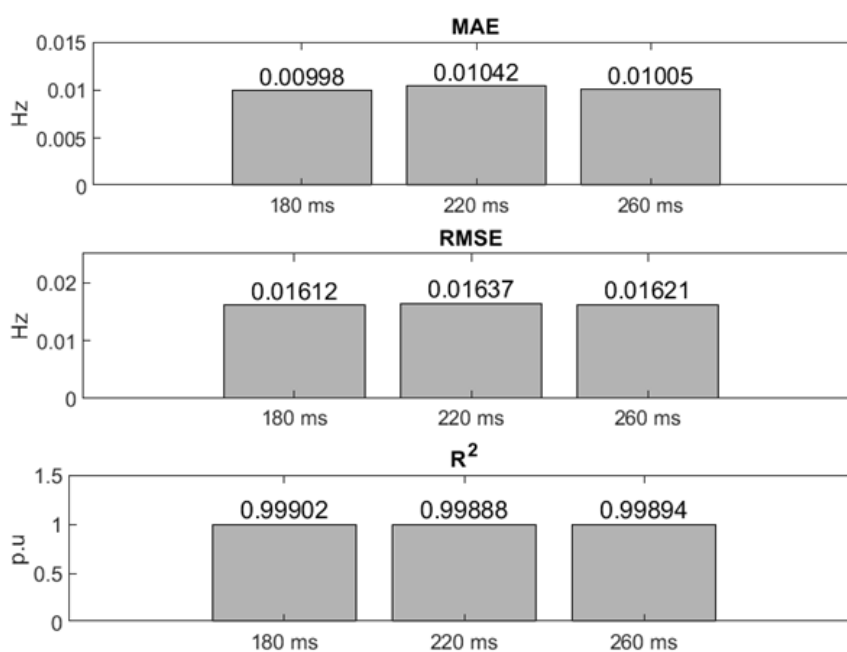


Figura 22. Comparación de resultados para el modelo NARX entre diferentes longitudes de ventana.

Por lo tanto, la propuesta de longitud de ventana a seleccionar es 180 ms, teniendo en cuenta que se desea predecir con rapidez, y que el resultado apenas varía al seguir aumentando la longitud de la ventana.

4.2.2 Variación en el error de las predicciones obtenidas

En esta sección se pretende destacar la diferencia en las predicciones obtenidas por el modelo NARX según la magnitud del escenario simulado. Teniendo en cuenta la totalidad del conjunto de datos de prueba (90 escenarios), en la Figura 23 se muestran los valores reales (sintéticos) y de predicción para la longitud de ventana de 180 ms.




Figura 23. Valor real vs predicción del modelo NARX, considerando una longitud de ventana de 180 ms en el conjunto de datos de prueba. Vista ampliada de escenarios 37 y 89.

En la Figura 23 además se muestran de forma ampliada los escenarios 37 y 89, clasificados como Grupo I (leves) y Grupo III (severos) respectivamente. Para el escenario 37 el error es de 20.2 mHz, mientras que para el escenario 89, el error es de 105.8 mHz. Como característica general, se observó que los errores en las predicciones obtenidas son proporcionales a la severidad de la perturbación asociada a cada escenario.

4.3 Comparación de resultados utilizando los modelos: NARX, TDNN y LSTM

En esta sección, se lleva a cabo una evaluación comparativa del desempeño del modelo propuesto NARX, con respecto a los modelos más representativos identificados en el estado del arte: TDNN y LSTM. Los ajustes obtenidos en la parametrización de los modelos TDNN y LSTM se muestran en las Tablas 12 y 13 respectivamente, como se muestra a continuación.

TABLA 12

Ajustes propuestos para el modelo TDNN.

Parámetros	Ajustes obtenidos
No. de capas ocultas	1
Retardo de entrada	10
No. de neuronas capa oculta	20
Algoritmo de entrenamiento	<i>Levenberg-Marquardt backpropagation</i>
Métrica de desempeño	MSE
Función de activación capa oculta	tanh
Función de activación capa salida	lineal
Épocas de entrenamiento	1000

TABLA 13

Ajustes propuestos para el modelo LSTM.

Parámetros	Ajustes obtenidos
No. de capas ocultas	1
No. de unidades LSTM en la capa oculta	45
Algoritmo de entrenamiento	<i>Adaptive Moment Estimation</i>
Métrica de desempeño	MSE
Épocas de entrenamiento	200

El proceso de ajuste del modelo TDNN es similar al utilizado en el modelo NARX, como diferencia fundamental, se observó una influencia significativa del retardo de tiempo en la calidad de los resultados. Por su parte, en la parametrización del modelo LSTM, se analizó la cantidad de capas y el número de unidades LSTM en cada capa que proporcionan la mejor combinación y calidad en los resultados.

Para la comparación de los resultados entre los modelos NARX, LSTM y TDNN se mantuvo constante la longitud de la ventana de datos (180 ms). La elección de la longitud se basó en los resultados durante el proceso de prueba y validación del modelo NARX. Este enfoque garantiza que cualquier diferencia en el rendimiento entre los modelos, se atribuya directamente a las diferencias en sus arquitecturas y capacidades inherentes de predicción, en lugar de a las diferencias en la manipulación de los datos de entrada. Las métricas obtenidas para cada modelo, así como el tiempo de entrenamiento, se muestran a continuación en la Tabla 14.

TABLA 14

Comparación de modelos según métricas obtenidas por áreas.

Modelo	Áreas	MAE (Hz)	RMSE (Hz)	R^2 (p.u)	Tiempo entrenamiento (s)
NARX	SE1	0.0099	0.0161	0.9990	53.4
	SE2	0.0109	0.0168	0.9989	51.2
	SE3	0.0108	0.0165	0.9990	50.3
	SE4	0.0101	0.0156	0.9987	58.6
TDNN	SE1	0.0141	0.0228	0.9977	3011
	SE2	0.0132	0.0220	0.9981	3054
	SE3	0.0138	0.0224	0.9980	3005
	SE4	0.0137	0.0221	0.9981	3028
LSTM	SE1	0.0202	0.0301	0.9963	219
	SE2	0.0205	0.0304	0.9964	198
	SE3	0.0195	0.0298	0.9968	204
	SE4	0.0198	0.0299	0.9969	210

Durante el análisis del modelo TDNN, al aumentar el retardo de entrada, el desempeño del modelo mostró una mayor capacidad para capturar relaciones temporales complejas en los datos. Sin embargo, este aumento en el retardo de entrada también conllevó un aumento notable en el tiempo de entrenamiento del modelo TDNN (en el orden de los 50 min), como se muestra en la Tabla 14. Este efecto directo se atribuye al incremento en la complejidad del modelo debido a la mayor cantidad de datos temporales considerados en cada paso.

Para una mejor visualización de los resultados, en la Figura 24 se muestran los diagramas de dispersión de los modelos (a) NARX, (b) TDNN y (c) LSTM, utilizando longitud de ventana de 180 ms. Cada punto en el gráfico (círculo azul) representa una observación que contiene el valor real (sintético) y la predicción del modelo.

Al comparar las observaciones con la línea de regresión perfecta, es apreciable la diferencia en el desempeño de los modelos. Las métricas de desempeño y los diagramas de dispersión obtenidas para cada modelo, demuestran que el modelo NARX exhibió ligeramente resultados superiores en comparación con los modelos TDNN y LSTM.

Sin embargo, no se puede concluir que un modelo de ML es universalmente superior y adaptable a todos los problemas en específico. La elección final del modelo depende en gran medida de las características del problema, la naturaleza de los datos y la adaptabilidad de los modelos. En este trabajo, para el problema de predicción de desviación máxima de frecuencia, utilizando la base de datos sintéticos generada, y la estructuración de los datos propuesta, el modelo NARX demostró ser más efectivo, seguido por el TDNN y el LSTM.




Figura 24. Diagramas de dispersión para longitud de ventana de 180 ms, utilizando los modelos: (a) NARX, (b) TDNN y (c) LSTM.

4.4 Análisis por área de la desviación máxima de frecuencia

Hasta el momento, se han analizado las métricas obtenidas por los diferentes modelos en la predicción de la desviación máxima de frecuencia. En esta sección se tiene como objetivo demostrar como el comportamiento dinámico de la frecuencia difiere entre las distintas área del sistema. Para ello, se utilizarán como referencia algunos escenarios en particular, los cuales se analizan a continuación.

4.4.1 Evento de pérdida de generación

En la Figura 25 se muestra el comportamiento de la frecuencia por áreas para un evento de pérdida de generación en $t=1$ s. Para este evento en particular, el comportamiento de la frecuencia en cada área del sistema no difiere significativamente en el punto de desviación máxima.




Figura 25. Frecuencia por áreas para evento de pérdida de generación.

Esta observación sugiere que tanto los GS, como las FER basadas en inversores, tienden a oscilar entre sí ante el desequilibrio de potencia, sin que se aprecien diferencias considerables en la desviación de frecuencia por área. El error promedio observado por área en la Figura 25 es de aproximadamente 70 mHz, lo cual se considera aceptable teniendo en cuenta que la operación del SEP no requiere una precisión elevada, a diferencia, por ejemplo, de los dispositivos de protección.

Otra apreciación de la Figura 25 es lo relacionado al margen de tiempo disponible, la desviación máxima ocurre aproximadamente 7 segundos posteriores al inicio del evento, lo cual posibilita un margen de respuesta suficiente por parte de la operación del sistema para tomar acciones de control en apoyo a la frecuencia.

4.4.2 Evento de cortocircuito en línea de transmisión

Al presentarse un evento de cortocircuito, el comportamiento por áreas de la frecuencia eléctrica varía en comparación al ejemplo anterior. En las Figuras 26 y 27 se muestra la dinámica de frecuencia de las dos áreas con comportamiento extremo (menor y mayor desviación máxima), ante un cortocircuito monofásico ($t=1s$) en línea de transmisión de 400kV.

La Figura 26 representa un evento del sistema base S5, el cual tiene una relación en la matriz de generación de 13 % de GS y 87 % de FER (70 % GFL – 30 % GFM). Mientras que la Figura 27 representa un evento del sistema base S1, con una relación en la matriz de generación de 26 % de GS y 74 % de FER (90 % GFL – 10 % GFM). Ambos cortocircuitos se originan en el área SE3, y en líneas de transmisión diferentes pero cercanas eléctricamente al bus 4045.

Para el evento del sistema base S5, la diferencia entre la desviación máxima de frecuencia entre el área SE1 y el área SE3 fue de 324.6 mHz. Mientras que para el evento del sistema base S1, la diferencia fue de 86.9 mHz. Esta variación de la desviación máxima entre áreas reafirma que la respuesta transitoria de la frecuencia difiere a lo largo del sistema eléctrico, y que esta depende de la distribución de la inercia (incluyendo la inercia virtual proporcionada por los inversores GFM) y las distancias eléctricas entre áreas.

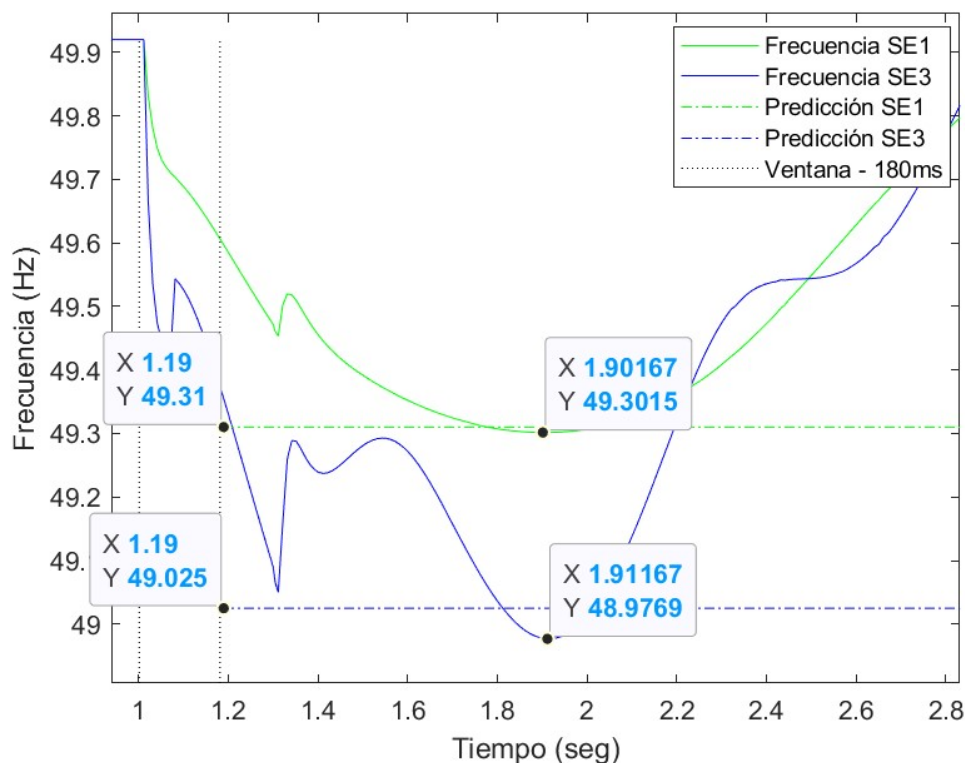


Figura 26. Frecuencia por áreas para evento de cortocircuito en área SE3 y sistema base S5.

Otra apreciación de las Figuras 26 y 27 es lo relacionado con el margen de tiempo de ocurrencia de la desviación máxima, el cual es considerablemente menor en comparación con el evento de pérdida de generación. Lo anterior dificulta la coordinación de acciones de control en apoyo a la frecuencia por parte de la operación del sistema. Esta problemática representa un desafío y es un tema de investigación recurrente.

En este sentido, los sistemas de control avanzado aplicados a inversores de potencia brindan la posibilidad de respuestas rápidas ante disturbios, abriendo nuevos horizontes en este campo. Varios operadores de sistemas han considerado un nuevo servicio de apoyo a la frecuencia: la Respuesta Rápida en Frecuencia (RRF) [39, 74]. Los servicios de RRF tienen la misión de contrarrestar el efecto negativo de la penetración creciente de FER, en la estabilidad de frecuencia de los sistemas eléctricos actuales y futuros.




Figura 27. Frecuencia por áreas para evento de cortocircuito en área SE3 y sistema base S1.

En resumen, para el escenario de alta penetración de FER y eventos críticos que involucren cortocircuito, la dinámica de la frecuencia se acentúa, y por consiguiente, la diferencia en la desviación máxima de frecuencia que se produce entre las distintas áreas del sistema se incrementa. Lo anterior conlleva a la conclusión de que el análisis por área de la estabilidad de frecuencia brinda mayor información a la operación del sistema ante el escenario de sistemas eléctricos con baja inercia.

Otra característica identificada que influye en el comportamiento de la frecuencia es la relación entre inversores GFL y GFM en la matriz energética del sistema. La penetración creciente de FER y el creciente auge de inversores GFM, conlleva a que este factor influya cada vez más en la estabilidad de frecuencia. Lo anterior sugiere la necesidad de profundizar en futuros estudios sobre la influencia de los porcentajes de penetración de FER y la relación entre inversores GFL-GFM en la dinámica de frecuencia del sistema.

4.5 Conclusiones del Capítulo

Se realizó un análisis para la determinación de la longitud de la ventana de datos en el modelo NARX. Este análisis se basó en la ponderación de las métricas obtenidas para distintas longitudes de ventana, y la necesidad de obtener predicciones de manera rápida y eficiente.

La implementación del modelo NARX en la problemática de predicción de desviación máxima de frecuencia, y la eficacia mostrada durante la etapa de evaluación, reafirma la aplicación exitosa de este modelo en estudios relacionados con la evaluación de estabilidad en SEP.

En la comparación del modelo propuesto NARX, con los modelos más identificados en este tipo de estudio: TDNN y LSTM, se determinó que el modelo NARX arrojó resultados cuantitativamente superiores, para la base de datos generada y la estructuración de los datos propuesta.

Para eventos específicos de la base de datos sintéticos, se evidenció una diferencia considerable en la desviación máxima de frecuencia reflejada en algunas áreas del sistema. Esta diferencia en los indicadores se debe fundamentalmente al estado de operación de la matriz de generación del sistema, y al tipo de evento asociado a la perturbación.

CAPÍTULO 5

CONCLUSIONES

A continuación, se mencionan las conclusiones alcanzadas en el presente trabajo de investigación:

- Se implementó sistema eléctrico de potencia con baja inercia partiendo del sistema de prueba original Nordic32. Una vez generado el sistema de prueba, mediante simulaciones dinámicas con diferentes características en la matriz de generación, se obtuvieron los datos sintéticos que conforman la base de datos para el estudio propuesto.
- Se propuso una metodología para el proceso de clasificación y organización de los datos a utilizar en los modelos de ML. Para la clasificación, se tuvo en cuenta la severidad de los eventos simulados, logrando una representación equitativa de los diferentes escenarios en los conjuntos de datos de entrenamiento y prueba. La estructuración de los datos y el arreglo de aprendizaje en paralelo por área demostraron resultados satisfactorios al evaluar los diferentes modelos.

- Se evidenció en algunos escenarios como la desviación de frecuencia difiere entre las áreas del sistema. Esta diferencia está influenciada por el estado de la matriz de generación del sistema, incluyendo el porcentaje de inversores GFM y GFL en operación, así como el tipo de perturbación asociada al evento.
- Se examinaron los modelos de redes neuronales artificiales más utilizados en la estabilidad de frecuencia de sistemas eléctricos de potencia, y se adaptaron a la predicción del comportamiento dinámico de la frecuencia por áreas. Se propuso la implementación del modelo NARX, y se comparó su desempeño con dos de los modelos más representativos del estado del arte. El modelo NARX mostró métricas de rendimiento superior para la base de datos generada y la estructuración de datos propuesta.

5.1 Contribuciones

- Se implementó satisfactoriamente el modelo de red neuronal autorregresiva no lineal con entradas exógenas (NARX), previamente no identificado en la evaluación de estabilidad de frecuencia de sistemas eléctricos.
- El enfoque de análisis de la estabilidad de frecuencia por áreas, demostró la diferencia en los indicadores observados entre las distintas áreas del sistema eléctrico, y por consiguiente, la importancia del análisis de las características temporales y espaciales de la frecuencia, especialmente ante el escenario de sistemas con baja inercia.

5.2 Trabajos futuros

Una aplicación directa de este trabajo investigativo sería combinar la predicción por áreas de la desviación máxima de frecuencia, con acciones de control locales sobre los servicios de respuesta rápida en frecuencia. Al predecir el comportamiento por áreas de la frecuencia y conocer la disponibilidad de la reserva local, se pueden alcanzar activaciones precisas que potencialmente conduzcan a una mejora global de la estabilidad de frecuencia. Esta integración permitiría una gestión eficiente de los recursos disponibles en apoyo a la frecuencia.

Otra aplicación recomendada sería analizar la influencia de los porcentajes de penetración de generación síncrona e inversores GFL y GFM en la desviación de frecuencia en las distintas áreas del sistema. Este análisis permitiría identificar posibles puntos críticos y diseñar estrategias de operación que mejoren la estabilidad de frecuencia, fundamentalmente en el escenario futuro de la creciente participación de fuentes de energía renovable en la operación y explotación de los sistemas eléctricos.

REFERENCIAS

1. J. S. Mohd. Ali y V. Krishnaswamy, *An assessment of recent multilevel inverter topologies with reduced power electronics components for renewable applications*. Renewable and Sustainable Energy Reviews, 82:3379–3399, Feb. 2018.
2. Yashen Lin, Joseph H Eto, Brian B Johnson, Jack D Flicker, Robert H Lasseter, Hugo N Villegas Pico, Gab Su Seo, Brian J Pierre y Abraham Ellis, *Research roadmap on grid-forming inverters*. Informe técnico, National Renewable Energy Lab.(NREL), Golden, CO (United States), 2020.
3. IRENA, *Global Energy Transformation: A Roadmap to 2050*. Informe técnico, International Renewable Energy Agency, 2019.
4. Umer Akram, N Mithulananthan, Rakibuzzaman Shah y Saad Abdul Basit, *Energy storage for short-term frequency stability enhancement in low-inertia power systems*. En *2020 Australasian Universities Power Engineering Conference (AUPEC)*, páginas 1–5. IEEE, 2020.
5. Peter W Sauer, Mangalore A Pai y Joe H Chow, *Power system dynamics and stability: with synchrophasor measurement and power system toolbox*. John Wiley & Sons, 2017.
6. Shutang You, Yong Liu, Xuemeng Zhang, Yu Su, Ling Wu, Yilu Liu y Stanton W Hadley, *Impact of high PV penetration on US eastern interconnection frequency response*. En *2017 IEEE Power & Energy Society General Meeting*, páginas 1–5. IEEE, 2017.
7. Yong Liu, Shutang You, Jin Tan, Yingchen Zhang y Yilu Liu, *Frequency response assessment and enhancement of the US power grids toward extra-high photovoltaic generation penetrations—An industry perspective*. IEEE Transactions on Power Systems, 33(3):3438–3449, 2018.
8. Hongyu Li, Ping Ju, Chun Gan, Shutang You, Feng Wu y Yilu Liu, *Analytic analysis for dynamic system frequency in power systems under uncertain variability*. IEEE Transactions on Power Systems, 34(2):982–993, 2018.
9. Shutang You, Yong Liu, Jin Tan, Melanie T Gonzalez, Xuemeng Zhang, Yingchen Zhang y Yilu Liu, *Comparative assessment of tactics to improve primary frequency response without curtailing solar output in high photovoltaic interconnection grids*. IEEE Transactions on Sustainable Energy, 10(2):718–728, 2018.

10. Kenneth E Martin, G Benmouyal, MG Adamiak, M Begovic, RO Burnett, KR Carr, A Cobb, JA Kusters, SH Horowitz, GR Jensen y cols., *IEEE standard for synchrophasors for power systems*. IEEE Transactions on Power Delivery, 13(1):73–77, 1998.
11. IEEE Standards Association y cols., *IEEE std c37. 118. 2-2011, IEEE Standard for Synchrophasor Data Transfer for Power Systems*. Informe técnico, Tech. Rep., Revision of the IEEE Std, 2011.
12. Qi Wang, Feng Li, Yi Tang y Yan Xu, *Integrating model-driven and data-driven methods for power system frequency stability assessment and control*. IEEE Transactions on Power Systems, 34(6):4557–4568, 2019.
13. Julius Susanto, Alireza Fereidouni, Pierluigi Mancarella y Dean Sharafi, *Closed-Form Solutions for a Low-Order System Fast Frequency Response Model*. En *2021 IEEE Madrid PowerTech*, páginas 1–6. IEEE, 2021.
14. Yuqian Zhang, Qinglai Guo, Yanzhen Zhou y Hongbin Sun, *Online frequency security assessment based on analytical model considering limiting modules*. CSEE Journal of Power and Energy Systems, 8(5):1363–1372, 2021.
15. Liu Liu, Weidong Li, Yu Ba, Jiakai Shen, Cuicui Jin y Kerui Wen, *An analytical model for frequency nadir prediction following a major disturbance*. IEEE Transactions on Power Systems, 35(4):2527–2536, 2020.
16. Ming Niu, Guanfeng Zhang, Yupeng Ren y Jiajue Li, *An Analytical Model for Frequency Nadir Prediction Based on Probabilistic Production Simulation*. En *2022 IEEE 5th International Conference on Automation, Electronics and Electrical Engineering (AUTEEE)*, páginas 89–95. IEEE, 2022.
17. Alireza Fereidouni, Julius Susanto, Pierluigi Mancarella, Nicky Hong, Teresa Smit y Dean Sharafi, *Online Security Assessment of Low-Inertia Power Systems: A Real-Time Frequency Stability Tool for the Australian South-West Interconnected System*. En *2021 31st Australasian Universities Power Engineering Conference (AUPEC)*, páginas 1–9. IEEE, 2021.
18. Bendong Tan, Junbo Zhao, Marcos Netto, Venkat Krishnan, Vladimir Terzija y Yingchen Zhang, *Power system inertia estimation: Review of methods and the impacts of converter-interfaced generations*. International Journal of Electrical Power & Energy Systems, 134:107362, 2022.
19. Jesús Alejandro Verduzco Cota, *Evaluación temprana de estabilidad y seguridad de sistemas de potencia con baja inercia utilizando machine learning*. Tesis de Doctorado, Universidad Autónoma de Nuevo León, 2021.
20. Dhanuja Lekshmi J, Zakir H Rather y Bikash C Pal, *Online Estimation of Disturbance Size and Frequency Nadir Prediction in Renewable Energy Integrated Power Systems*. IEEE Transactions on Power Systems, 39(1):1126–1137, 2024.

21. Harold R Chamorro, Alvaro D Orjuela-Cañón, David Ganger, Mattias Persson, Francisco Gonzalez-Longatt, Vijay K Sood y Wilmar Martinez, *Nadir frequency estimation in low-inertia power systems*. En *2020 IEEE 29th International Symposium on Industrial Electronics (ISIE)*, páginas 918–922. IEEE, 2020.
22. Harold R Chamorro, Alvaro D Orjuela-Cañón, David Ganger, Mattias Persson, Francisco Gonzalez-Longatt, Lazaro Alvarado-Barrios, Vijay K Sood y Wilmar Martinez, *Data-driven trajectory prediction of grid power frequency based on neural models*. *Electronics*, 10(2):151, 2021.
23. Yichao Zhang, Xiaoru Wang y Lijie Ding, *LSTM-Based Dynamic Frequency Prediction*. En *2020 IEEE Power & Energy Society General Meeting (PESGM)*, páginas 1–5. IEEE, 2020.
24. Xuebo Liu, Jian Xie, Xin Fang, Haoyu Yuan, Bin Wang, Hongyu Wu y Jin Tan, *A comparison of machine learning methods for frequency nadir estimation in power systems*. En *2022 IEEE Kansas Power and Energy Conference (KPEC)*, páginas 1–5. IEEE, 2022.
25. Hsin Wei Chiu y Le Ren Chang-Chien, *A supervised learning scheme for evaluating frequency nadir and fast response reserve in ancillary service market*. *IEEE Access*, 9:100934–100943, 2021.
26. Longyu Chen, Qingyue Chen y Xiaoru Wang, *A Spatial-temporal Frequency Nadir Prediction Method Based on ConvLSTM with Attention*. En *2022 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, páginas 1–6. IEEE, 2022.
27. Qingyue Chen, Xiaoru Wang, Jintian Lin y Longyu Chen, *Convolutional LSTM-based Frequency Nadir Prediction*. En *2021 4th International Conference on Energy, Electrical and Power Engineering (CEEPE)*, páginas 667–672. IEEE, 2021.
28. Xinlan Jia, Jiaojiao Dong, Yinfeng Zhao, Jin Tan y Yilu Liu, *ML-Based Power System Stability Assessment Considering Network Topology Changes: WECC 20,000+ Bus System Case Study*. En *2023 IEEE PES/IAS PowerAfrica*, páginas 1–5. IEEE, 2023.
29. Maitreyee Dey, Dilshan Wickramarachchi, Soumya P Rana, Clarke V Simmons y Sandra Dudley, *Power Grid Frequency Forecasting from μ PMU Data using Hybrid Vector-Output LSTM network*. En *2023 IEEE PES Innovative Smart Grid Technologies Europe (ISGT EUROPE)*, páginas 1–5. IEEE, 2023.
30. Jian Xie y Wei Sun, *A transfer and deep learning-based method for online frequency stability assessment and control*. *IEEE Access*, 9:75712–75721, 2021.
31. Akhilesh Panwar, Zakir Hussain Rather, Suryanarayana Doolla, Ariel Liebman y Roger Dargaville, *A Machine Learning Based Approach for Frequency Response Prediction in Low Inertia Power System*. En *2022 IEEE PES Innovative Smart Grid Technologies-Asia (ISGT Asia)*, páginas 175–179. IEEE, 2022.
32. Mingjian Tuo y Xingpeng Li, *Convolutional Neural Network-based RoCoF-Constrained Unit Commitment*. *XXIII Power Systems Computation Conference*, 2023.

33. Xiaoyu Deng, Ruo Mo, Pengliang Wang, Junru Chen, Dongliang Nan y Muyang Liu, *Review of RoCoF Estimation Techniques for Low-Inertia Power Systems*. *Energies*, 16(9):3708, 2023.
34. Mingjian Tuo y Xingpeng Li, *Selectively Linearized Neural Network Based RoCoF-Constrained Unit Commitment in Low-Inertia Power Systems*. En *2023 North American Power Symposium (NAPS)*, páginas 1–5. IEEE, 2023.
35. Sangwon Kim, *Improving ANN Training with Approximation Techniques for ROCOF Trajectory Estimation*. En *2023 IEEE Belgrade PowerTech*, páginas 01–06. IEEE, 2023.
36. Jan Machowski, Zbigniew Lubosny, Janusz W Bialek y James R Bumby, *Power System Dynamics: Stability and Control*. John Wiley & Sons, 2020.
37. Prabha S. Kundur y Om P. Malik, *Power System Stability and Control*. McGraw Hill; 2nd edition, 2022.
38. Nikos Hatziargyriou, Jovica Milanovic, Claudia Rahmann, Venkataramana Ajjarapu, Claudio Canizares, Istvan Erlich, David Hill, Ian Hiskens, Innocent Kamwa, Bikash Pal y cols., *Definition and classification of power system stability—revisited & extended*. *IEEE Transactions on Power Systems*, 36(4):3271–3281, 2020.
39. Working Group Paper, *Fast Frequency Response in the National Electricity Market (NEM). Future Power System Security Program*. Informe técnico, Australian Energy Market Operator (AEMO), 2017.
40. Yinfeng Zhao, *Deep Learning based Power System Stability Assessment for Reduced WECC System*. Tesis de Doctorado, University of Tennessee, 2023.
41. Umer Akram, *Energy Storage Systems for Frequency Stability in Modern Power Systems*. Tesis de Doctorado, The University of Queensland, 2022.
42. Daniel Fernández-Muñoz, Juan I Pérez-Díaz, Ignacio Guisández, Manuel Chazarra y Álvaro Fernández-Espina, *Fast frequency control ancillary services: An international review*. *Renewable and Sustainable Energy Reviews*, 120:109662, 2020.
43. MN Acosta, F Gonzalez-Longatt, S Denysiuk y H Strelkova, *Optimal settings of fast active power controller: Nordic case*. En *2020 IEEE 7th International Conference on Energy Smart Systems (ESS)*, páginas 63–67. IEEE, 2020.
44. Elyas Rakhshani, Arcadio Perilla, José L Rueda Torres, Francisco M Gonzalez-Longatt, Thiago Batista Soeiro y Mart AMM Van Der Meijden, *FAPIC controller for frequency support in low-inertia power systems*. *IEEE Open Access Journal of Power and Energy*, 7:276–286, 2020.
45. Julia Matevosyan, Jason MacDowell, B Badrzadeh, C Cheng, S Dutta, SD Rao, V Gevorgian, T Green, D Howard, D Kong y cols., *Grid-forming technology in energy systems integration*. ESIG High Share of Inverter-Based Generation Task Force: Report. Available online:

<https://www.esig.energy/wp-content/uploads/2022/03/ESIG-GFM-report-2022.pdf> (accessed on 20 June 2022), 2022.

46. Samuel Yusuf y Adamu Abubakar, *A Comprehensive Review on Grid-forming Inverter: Potential and Future Trends*. *Majlesi Journal of Electrical Engineering*, 17(1):1–27, 2023.
47. Roberto Rosso, Xiongfei Wang, Marco Liserre, Xiaonan Lu y Soenke Engelken, *Grid-forming converters: Control approaches, grid-synchronization, and future trends—A review*. *IEEE Open Journal of Industry Applications*, 2:93–109, 2021.
48. Rakesh B Bobba, Jeff Dagle, Erich Heine, Himanshu Khurana, William H Sanders, Peter Sauer y Tim Yardley, *Enhancing grid measurements: Wide area measurement systems, NASPInet, and security*. *IEEE Power and Energy Magazine*, 10(1):67–73, 2011.
49. Ryan G. McClarren, *Machine Learning for Engineers: Using Data to Solve Problems for Physical Systems*. Springer, 2021.
50. Osvaldo Simeone, *Machine Learning for Engineers*. Cambridge University Press, primera edición, 2022.
51. Ameet V Joshi, *Machine Learning and Artificial Intelligence*. Springer, segunda edición, 2023.
52. Fang Tian, Xiaoxin Zhou, Zhihong Yu, Dongyu Shi, Yong Chen y Yanhao Huang, *A preventive transient stability control method based on support vector machine*. *Electric Power Systems Research*, 170:286–293, 2019.
53. Zachary Pannell, Bhuvaneshwari Ramachandran y Dallas Snider, *Machine learning approach to solving the transient stability assessment problem*. En *2018 IEEE Texas Power and Energy Conference (TPEC)*, páginas 1–6. IEEE, 2018.
54. Mohammed Amroune, *Machine learning techniques applied to on-line voltage stability assessment: a review*. *Archives of Computational Methods in Engineering*, 28(2):273–287, 2021.
55. Luigi Vanfretti y VS Narasimham Arava, *Decision tree-based classification of multiple operating conditions for power system voltage stability assessment*. *International Journal of Electrical Power & Energy Systems*, 123:106251, 2020.
56. Qingyan Li, Tao Lin, Shuqin Sun, Song Ke y Hui Du, *Critical clearing time prediction of power system fault based on machine learning*. En *2020 IEEE Sustainable Power and Energy Conference (ISPEC)*, páginas 2360–2365. IEEE, 2020.
57. Xingyun Chen, Ye Liu, Qiao Kang y Junjie Xiao, *A Method of Frequency Security Margin Index Prediction of Post-disturbance Power System Based on Classification and Regression Model of XGBoost Algorithm*. En *2020 5th International Conference on Power and Renewable Energy (ICPRE)*, páginas 278–285. IEEE, 2020.
58. Haoyu Yuan, Jin Tan, Yingchen Zhang, Samanvitha Murthy, Shutang You, Hongyu Li, Yu Su y Yilu Liu, *Machine learning-based PV reserve determination strategy for frequency*


- control on the WECC system.* En *2020 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*, páginas 1–5. IEEE, 2020.
59. Yinfeng Zhao, Shutang You, Mirka Mandich, Lin Zhu, Chengwen Zhang, Hongyu Li, Yu Su, Yilu Liu, Huaiguang Jiang, Haoyu Yuan *y cols.*, *A fast and accurate transient stability assessment method based on deep learning: WECC case study.* En *2022 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*, páginas 1–5. IEEE, 2022.
 60. Mingjian Tuo y Xingpeng Li, *Machine Learning Assisted Inertia Estimation Using Ambient Measurements.* IEEE Transactions on Industry Applications, 2023.
 61. Yong Sun, Zhenyuan Li, Xinnan Yu, Baoju Li y Mao Yang, *Research on ultra-short-term wind power prediction considering source relevance.* Ieee Access, 8:147703–147710, 2020.
 62. Muhammad Qamar Raza, Nadarajah Mithulananthan, Jiaming Li, Kwang Y Lee y Hoay Beng Gooi, *An ensemble framework for day-ahead forecast of PV output power in smart grids.* IEEE Transactions on Industrial Informatics, 15(8):4624–4634, 2018.
 63. Abodh Poudyal, Ujjwol Tamrakar, Rodrigo D Trevizan, Robert Fournery, Reinaldo Tonkoski y Timothy M Hansen, *Multiarea inertia estimation using convolutional neural networks and federated learning.* IEEE Systems Journal, 16(4):6401–6412, 2021.
 64. Alejandro Verduzco, Paula Páramo Balsa, Francisco Gonzalez-Longatt, Manuel A Andrade, Martha Nohemi Acosta Montalvo, Jose Luis Rueda Torres y Peter Palensky, *Detection and Identification of Generator Disconnection Using Multi-layer Perceptron Neural Network Considering Low Inertia Scenario.* En *2022 IEEE 31st International Symposium on Industrial Electronics (ISIE)*, páginas 424–429. IEEE, 2022.
 65. Loan NN Do, Neda Taherifar y Hai L Vu, *Survey of neural network-based models for short-term traffic state prediction.* Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 9(1):e1285, 2019.
 66. Erdem Doğan, *Analysis and Comparison of LSTM Short-Term Traffic Prediction Performance.* Kirikkale University, March 2020.
 67. Hava T Siegelmann, Bill G Horne y C Lee Giles, *Computational capabilities of recurrent NARX neural networks.* IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 27(2):208–215, 1997.
 68. Bill Horne y C Giles, *An experimental comparison of recurrent neural networks.* Advances in neural information processing systems, 7, 1994.
 69. Hang Xie, Hao Tang y Yu He Liao, *Time series prediction based on NARX neural networks: An advanced approach.* En *2009 International conference on machine learning and cybernetics*, volumen 3, páginas 1275–1279. IEEE, 2009.
 70. Working Group 38.02.08, *Power system technical performance. Long term dynamics phase II final report.* Technical Report, CIGRE, 1995.

71. Thierry Van Cutsem y Mevludin Glavic, *Test Systems for Voltage Stability Analysis and Security Assessment*. Technical Report, IEEE Power and Energy Society, August 2015.
72. Luis David Pabón Ospina, Andrés Felipe Correa y Gustav Lammert, *Implementation and validation of the Nordic test system in DigSILENT PowerFactory*. En *2017 IEEE Manchester PowerTech*, páginas 1–6. IEEE, 2017.
73. Sharon Muller, *Development of Nordic 32 System Model and Performance Analysis Based on Real Operational Statistics*. Technical Report, Universität Stuttgart, Institut für Energieübertragung und Hochspannungstechnik, 2019.
74. Inverter Based Resource Performance Task Force (IRPTF), *Fast frequency Response Concepts and Bulk Power System Reliability Needs*. White paper, North American Electric Reliability Corporation (NERC), March 2020.

APÉNDICE A


SISTEMA DE PRUEBA: NORDIC 32

A.1 Diagrama unifilar sistema Nordic 32




A.2 Hydro Turbine model

gov_HYDRO: Simplified hydro turbine-governor model




A.3 Steam Turbine model


gov_STEAM: Simplified steam turbine-governor model



A.4 AC Excitation System model




A.5 Droop Controlled Converter model



A.6 Grid Following Converter model

VSC_GFL Frame:



A.7 Ajuste de parámetros de los modelos dinámicos

TABLA 15

Parámetros y ajustes *AC Excitation System*.

Parámetros	Ajuste
Measurement Delay [s]	0.02
Voltage regulator proportional gain [p.u]	20
Voltage regulator integral gain [p.u]	5
Voltage regulator derivative gain [p.u]	10
PID derivative channel lag time constant [s]	0.1
Exiter field proportional constant [p.u]	1
Minimum regulator output [p.u]	0
Minimum exciter voltage output [p.u]	0
Maximum regulator output [p.u]	6

TABLA 16Parámetros y ajustes *Hydro Turbine regulator*.

Parámetros	Ajuste
Permanent droop [p.u]	0.04
Filter time constant [s]	0.05
Temporary droop [p.u]	0.5
Washout time constant [s]	10
Gate servo time constant [s]	0.5
Water inertia time constant [s]	1
Turbine head [p.u]	1
No-load flow at nominal head [p.u]	0.08
Turbine gain [p.u]	1.2
Minimum power output [p.u]	0
Maximum power output [p.u]	1
Maximum gate velocity [p.u/s]	0.2

TABLA 17Parámetros y ajustes *Steam Turbine regulator*.

Parámetros	Ajuste
Governor gain [p.u]	25
Governor lag time constant [s]	0.2
Governor lead time constant [s]	0.15
Valve positioner time constant [s]	0.1
Second boiler pass time constant [s]	7
Third boiler pass time constant [p.u]	5
Fourth boiler pass time constant [p.u]	5
Fraction of first boiler pass [p.u]	0.3
Fraction of fourth boiler pass [p.u]	0.15
Maximum valve closing velocity [p.u]	-0.3
Maximum valve opening velocity [p.u]	0.3
Maximum valve opening [p.u]	1

RESUMEN AUTOBIOGRÁFICO

Rolando Pérez Gattorno

Candidato para el grado de Maestría en Ciencias de la Ingeniería Eléctrica

Tesis: EVALUACIÓN DE ESTABILIDAD DE FRECUENCIA EN SISTEMA DE POTENCIA CON BAJA INERCIA UTILIZANDO APRENDIZAJE AUTOMÁTICO

Biografía: Nacido en Santa Clara, Villa Clara, Cuba, el 8 de noviembre de 1991, hijo de Rolando Pérez González y Alicia Gattorno de León.

Educación: Asistió desde el 2010 a la Universidad Central "Marta Abreu" de Las Villas, Villa Clara, Cuba, donde estudió la especialidad de Ingeniería Eléctrica. En 2015, se graduó con honores por sus calificaciones y desempeño destacado en investigación. En 2022 ingresó a la Universidad Autónoma de Nuevo León, México, como estudiante de la Maestría en Ciencias de la Ingeniería Eléctrica.

Experiencia Profesional: Durante los años 2015-2022 se integró al departamento de Protecciones Eléctricas en la Empresa Eléctrica Villa Clara, Cuba. Durante ese tiempo colaboró como co-director de tesis de los estudiantes de Ingeniería Eléctrica de la Universidad Central "Marta Abreu" de Las Villas. Además, impartió laboratorios prácticos de Protecciones Eléctricas a los estudiantes de 5to Año.