


Universidad Técnica Federico Santa María
Departamento de Ingeniería Eléctrica
Santiago de Chile



Predicción del desempeño dinámico de la tensión ante contingencias utilizando técnicas de Inteligencia Artificial

Propuesta de tesis para optar al grado de
magíster en ciencias de la ingeniería eléctrica

Cristian Zavala Rojas

Profesor guía:
Ricardo Álvarez



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☐ Memoria o trabajo de título ☒ Tesis de Postgrado

Título del trabajo: Predicción del desempeño dinámico de la tensión ante contingencias utilizando técnicas de Inteligencia Artificial

Nombre del candidato(a): Cristian Isaías Nicolás Zavala Rojas

Carrera / Grado: Ingeniería Civil Eléctrica / Magíster en Ciencias de la Ingeniería Eléctrica

Campus: San Joaquín Departamento: Ingeniería Eléctrica

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Ricardo Álvarez Malebrán, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.


☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años


Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 11/06/2026 Firma: 

Estudiante o Candidato(a):

Fecha: 11/06/2026 Firma: 

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

Propuesta de tesis para optar al grado de
Magíster en ciencias de la ingeniería eléctrica

Título de tesis

Predicción del desempeño dinámico de la tensión ante contingencias utilizando técnicas de
Inteligencia Artificial

Candidato

Cristian Zavala Rojas

Universidad Técnica Federico Santa María

Departamento de Ingeniería Eléctrica

Profesor guía

Ricardo Álvarez

Santiago, 10 de marzo de 2026

Índice de contenido

Introducción.....	11
1.1. Motivación.....	11
1.2. Hipótesis.....	13
1.3. Objetivos.....	13
Estado del arte.....	14
2.1. Robustez de tensión.....	14
2.1.1. Relación entre la fortaleza de red y el nivel de cortocircuito	14
2.1.2. Limitación del nivel de cortocircuito para estimar robustez en sistemas con alta participación de IBR.....	17
2.2. Índices de evaluación del comportamiento de la tensión	18
2.2.1. Short circuit ratio (SCR).....	18
2.2.2. Weighted short circuit ratio (WSCR)	19
2.2.3. Composite short circuit ratio (CSCR)	19
2.2.4. Índice ISCR	20
2.2.5. Voltage Stability Index (VSI)	22
2.2.6. Transient Voltage Severity Index (TVSI)	22
2.2.7. Root-mean-squared Voltage Dip Severity Index (RVSI).....	23
2.2.8. Alcances y limitaciones de los índices	24
2.3. Variables eléctricas relevantes en el comportamiento de la tensión durante falla	25
2.4. Generación y tratamiento de datos de entrada y salidas objetivo para modelos de IA.....	27
2.5. Técnicas de inteligencia artificial	28
2.5.1. Random Forest (RF).....	29
2.5.2. Extra Trees (ET)	31

2.5.3.	Perceptrón multicapa (MLP)	32
2.5.4.	Recurrent Neural Network (RNN)	33
2.5.5.	Long Short-Term Memory (LSTM)	34
2.5.6.	Transformer	35
2.6.	Métricas de desempeño para evaluación de las técnicas de inteligencia artificial	36
Metodología.....		38
3.1.	Esquema general.....	38
3.2.	Etapla 1: Generación de base de datos con condiciones operacionales.....	39
3.3.	Etapla 2: Simulación dinámica y cálculo de índices	40
3.3.1.	Automatización de simulaciones RMS en PowerFactory	40
3.3.2.	Extracción de variables y construcción de atributos	40
3.4.	Construcción de la base de datos.....	42
3.4.1.	Escenarios operacionales y despachos energéticos	43
3.4.2.	Contingencias y fallas simuladas.....	43
3.4.3.	Curvas temporales de tensión	44
3.4.4.	Parámetros eléctricos e índices derivados	44
3.5.	Entrenamiento y predicción mediante modelos de IA	45
Caso de estudio y resultados.....		46
4.1.	Caso de estudio.....	46
4.1.1.	Escenarios de operación	46
4.1.2.	Contingencias analizadas.....	47
4.2.	Configuración de los modelos de IA	48
4.2.1.	Extra Trees.....	48
4.2.2.	Random Forest.....	48
4.2.3.	MLP	49

4.2.4.	RNN.....	50
4.2.5.	LSTM	51
4.2.6.	Transformer	52
4.3.	Resultados de predicción y desempeño global de los modelos	53
4.4.	Análisis cualitativo de la reconstrucción de la señal	54
4.5.	Eficiencia computacional	58
4.6.	Discusión técnica.....	59
Conclusiones.....		61
5.1.	Trabajos futuros	62
Bibliografía.....		63

Índice de Figuras

Figura 1: Sistema de un generador sincrónico conectado frente a una fuente infinita.	15
Figura 2: Desempeño dinámico de la tensión para diferentes niveles de cortocircuito en un sistema dominado por generación sincrónica (Imagen extraída de [24]).	16
Figura 3: Trayectorias de tensión bajo una misma contingencia que ilustran la dependencia de la robustez de tensión respecto de la tecnología conectada: GFL con y sin FRT, GFM y generación síncrona (Imagen extraída de [24]).	18
Figura 4: Representación del Índice de Desempeño Dinámico (Imagen extraída de [34]).	21
Figura 5: IDD en función de la métrica de robustez ISCR (Imagen extraída de [34]).	21
Figura 6: Ilustración del concepto de TVDI en un ejemplo de caída de tensión inducida por una falla (Imagen extraída de [39]).	23
Figura 7: Ilustración gráfica de RVSI (Imagen extraída de [41]).	24
Figura 8: Esquema de Random Forest para modelo de regresión.	30
Figura 9: Esquema del modelo Extra Trees aplicado a un problema de regresión.	31
Figura 10: Esquema de un modelo MLP.	32
Figura 11: Representación esquemática de una RNN y su despliegue temporal para una secuencia de entradas $X_1, X_2, \dots, X_T$	33
Figura 12: Estructura interna de una celda LSTM.	34
Figura 13: Esquema general de un Transformer.	35
Figura 14: Esquema metodológico propuesto.	39
Figura 15: Distribución de datos con y sin presencia de GFM.	48
Figura 16: Arquitectura del modelo MLP utilizado para la reconstrucción de la curva de tensión.	49
Figura 17: Curva de pérdida de entrenamiento y validación del modelo MLP.	50
Figura 18: Arquitectura del modelo RNN utilizado para la reconstrucción de la curva de tensión.	50
Figura 19: Curva de pérdida de entrenamiento y validación del modelo RNN.	51
Figura 20: Arquitectura del modelo LSTM utilizado para la reconstrucción de la curva de tensión.	51

Figura 21: Curva de pérdida de entrenamiento y validación del modelo LSTM.	52
Figura 22: Curva de pérdida de entrenamiento y validación del modelo Transformer.	53
Figura 23: Reconstrucción de la trayectoria de tensión con RF para tres casos: el caso con el menor error (arriba), el caso con un error promedio (al centro) y el caso con el peor error (abajo).	55
Figura 24: Reconstrucción de la trayectoria de tensión con LSTM para tres casos: el caso con el menor error (arriba), el caso con un error promedio (al centro) y el caso con el peor error (abajo).	57
Figura 25: Reconstrucción de la trayectoria de tensión para un caso representativo, comparando la señal real con las predicciones de los modelos RF, LSTM y Transformer en el horizonte completo de análisis.	57
Figura 26: Acercamiento de la reconstrucción en el intervalo transitorio, destacando diferencias en la representación de la caída de tensión, el sobreimpulso posterior al despeje de la falla y la recuperación inicial.	58

Índice de Tablas

Tabla 1: Comparación de características de los principales índices de robustez de red y estabilidad de tensión utilizados en sistemas eléctricos de potencia.	25
Tabla 2: Variables globales de despacho de potencia activa utilizadas como entrada del modelo.	41
Tabla 3: Parámetros eléctricos equivalentes por barra del sistema.	42
Tabla 4: Base de datos de despachos energéticos por tipo de controlador y escenario operativo.	43
Tabla 5: Base de datos de fallas simuladas por escenario operativo.	44
Tabla 6: Base de datos de curvas de tensión por simulación.	44
Tabla 7: Base de datos con parámetros e indicadores de desempeño por simulación.	45
Tabla 8: Escenarios de operación considerados en el estudio, con los respectivos despachos de potencia activa por tipo de tecnología.	46
Tabla 9: Desempeño de los modelos en términos de MAE y RMSE para la reconstrucción de la trayectoria temporal de tensión, evaluado en distintos regímenes dinámicos (<i>pre-fault</i> , <i>fault-on</i> y <i>post-fault</i>) y en el horizonte completo de 5 s, sobre el conjunto de prueba (15% de las simulaciones), correspondiente a escenarios no utilizados durante el entrenamiento.	53
Tabla 10: Tiempos de entrenamiento e inferencia de distintos modelos.	58
Tabla 11: Hiperparámetros por defecto en modelo de árboles (<i>scikit-learn</i>) [82].	72
Tabla 12: Parámetros predeterminados de los componentes utilizados en el modelo MLP implementado en TensorFlow/Keras.	73
Tabla 13: Parámetros predeterminados de la capa SimpleRNN y del optimizador utilizados como referencia para la implementación del modelo RNN en TensorFlow/Keras.	74
Tabla 14: Parámetros predeterminados reportados por la documentación oficial de TensorFlow/Keras para los componentes utilizados como base en la implementación del modelo LSTM.	74
Tabla 15: Parámetros predeterminados reportados por la documentación oficial de TensorFlow/Keras para los principales componentes utilizados como base en la implementación del modelo Transformer.	75

Agradecimientos

En primer lugar, quiero agradecer a mi familia, especialmente a mis padres, Isaías y Yinet, quienes fueron fundamentales durante todo este proceso, brindándome su apoyo y motivación en esta etapa. Asimismo, agradezco a mi hermano Alfredo y mi hermana Claudia por su constante apoyo, preocupación y palabras de aliento, que fueron una fuente importante de fortaleza para alcanzar esta meta. Mi título profesional va dedicado a ellos.

En segundo lugar, quisiera agradecer al profesor Ricardo por el tiempo, la dedicación y la orientación que me brindó durante el desarrollo de esta tesis. Su guía fue fundamental para superar los distintos desafíos que surgieron a lo largo del proceso. Asimismo, agradezco profundamente a José y Miguel, quienes siempre estuvieron dispuestos a ayudarme cuando tenía dudas o enfrentaba temas que no dominaba por completo. El apoyo, conocimiento y disposición de cada uno de ellos fueron esenciales para avanzar tanto en el desarrollo de los códigos como en la elaboración de los documentos, contribuyendo significativamente a la culminación exitosa de este trabajo.

En tercer lugar, quiero agradecer a todos mis amigos y amigas que formaron parte de este proceso. A mis amigos de El Salvador, quienes, a pesar de la distancia, siempre estuvieron presentes con mensajes de ánimo y apoyo. A mis compañeros de universidad con quienes inicié esta carrera: Valencia, Nico, Jano, Tito, Cris, Martin, Castillo, Braulio, Jorge y Juampi, con quienes compartí innumerables experiencias y desafíos a lo largo de estos años. También quiero agradecer a los compañeros que conocí durante la época de pandemia, Diego, Pelayo, Danilo, JP, Ángel y Feña, quienes fueron fundamentales durante la etapa online y contribuyeron de distintas maneras a que este camino fuera más llevadero. Juntos nos acompañamos hasta esta etapa final, superando dificultades que finalmente dieron sus frutos. Por último, agradezco a mis amigos que conocí de forma virtual durante la pandemia: Alejandro, Gabriel, Samuel, Jaime, Abril, Tam, Agus, Mila, Agos, Isabel, Roma y Nani, quienes fueron una parte importante de mi día a día y me brindaron espacios de distracción y apoyo que me permitieron despejar la mente y continuar adelante con este trabajo.

Finalmente, quiero agradecer a todas las personas que, de una u otra manera, fueron parte de este proceso y contribuyeron a que esta meta pudiera hacerse realidad. Cada palabra de apoyo, consejo, gesto de confianza y compañía tuvo un valor inmenso a lo largo de este camino. Este logro no es solo mío; también les pertenece a ustedes. Por ello, este título está dedicado a cada una de las personas que me acompañaron y dejaron una huella en esta etapa tan importante de mi vida.

~ Cristian Isaías Nicolás Zavala Rojas

Capítulo 1

Introducción

1.1. Motivación

La descarbonización energética se ha consolidado como un objetivo prioritario a nivel mundial, impulsado por compromisos internacionales como el Acuerdo de París y por organismos multilaterales como la Agencia Internacional de Energías Renovables (IRENA), que proyecta que hacia 2050 más del 80% de la electricidad global podría provenir de fuentes renovables, como solar fotovoltaica y eólica [1]. Este proceso ya presenta avances concretos: a finales del 2024, la capacidad instalada de energías renovables alcanzó los 4,45 TW a nivel mundial, tras un incremento récord de 585 GW en un solo año, impulsado principalmente por la energía solar fotovoltaica, con 452 GW adicionales, y por la energía eólica, con 113 GW [2]. En Chile, esta transición adquiere particular relevancia, con 11,64 GW en centrales fotovoltaicas y 5,83 GW en generación eólica, que en conjunto equivalen al 46% de la capacidad instalada del Sistema Eléctrico Nacional (SEN) [3]. Asimismo, se ha establecido un plan de retiro progresivo de centrales a carbón, con la meta de cerrar todas las unidades a más tardar en 2040, proyectando para 2030 una matriz con más del 70% de participación renovable y alcanzando la carbono-neutralidad al 2050 [4]. Una característica distintiva de este tipo de centrales es que se conectan al sistema eléctrico a través de convertidores electrónicos de potencia, lo que hace que su operación quede desacoplada de la frecuencia de la red.

La creciente penetración de tecnologías de generación conectadas mediante convertidores electrónicos de potencia ha transformado de manera significativa el comportamiento dinámico de los sistemas eléctricos de potencia (SEP). A diferencia de los generadores sincrónicos, que aportan de manera inherente inercia rotacional y soporte de tensión, los convertidores no entregan estos atributos de forma natural, reduciendo la robustez de los SEP [5]. La disminución de la robustez de tensión implica que, ante una contingencia, la estabilidad de tensión a corto plazo puede verse comprometida, llegando incluso a provocar colapsos en cuestión de segundos [6], [7]. En particular, la creciente sustitución de generadores sincrónicos por unidades basadas en convertidores, en su mayoría de tipo *grid-following* (GFL), ha limitado la capacidad del sistema para sostener la robustez de tensión, ya que estos dispositivos en su gran mayoría no reproducen de manera inherente los servicios que tradicionalmente aportan las máquinas sincrónicas [8].

Tradicionalmente, la evaluación del desempeño dinámico de la tensión en los SEP se realizan simulaciones en el dominio del tiempo (RMS), las cuales requieren modelos dinámicos complejos y una alta capacidad computacional [9]. Más aun, la inserción masiva de convertidores hace cada vez más necesario el uso de simulaciones electromagnéticas (EMT) para representar con precisión el desempeño dinámico del sistema, lo que eleva la complejidad y el recurso computacional. En efecto, una simulación EMT de 30 segundos podría durar más de 24 horas en sistemas a gran escala [10], a diferencia de una simulación RMS, que usualmente demora entre 15 minutos y una hora. Surge entonces la necesidad de explorar metodologías más eficientes para evaluar el desempeño dinámico del SEP de gran escala con alta presencia de convertidores. En este contexto, una técnica que ha cobrado gran relevancia en los últimos años es el uso de la inteligencia artificial (IA). A diferencia de simulaciones en el dominio del tiempo, la

IA se basa en algoritmos capaces de aprender patrones y modelar relaciones no lineales a partir de datos históricos o de simulación, evitando así la necesidad de resolver las ecuaciones algebraico-diferenciales que gobiernan la dinámica del sistema. La IA ha impulsado las transformaciones disruptivas en ámbitos amplios como la automatización de procesos, la traducción automática y la interacción hombre-máquina, permitiendo que tareas antes limitadas por la capacidad humana se realicen hoy con mayor rapidez y precisión. Estos avances han marcado un cambio de paradigma tecnológico. En el contexto de evaluación del desempeño dinámico de la tensión en los SEP, la IA se ha consolidado como una alternativa prometedora a los enfoques convencionales, permitiendo reducciones significativas en los tiempos de cómputo, con reportes que indican mejoras de entre 10 y hasta 1000 veces en cuanto a reducción de tiempos de cómputo, con niveles altos de precisión [11]. De esta forma, la IA permite estimar rápidamente la estabilidad para una gran cantidad de condiciones operativas, lo que le da al operador de red la posibilidad de identificar condiciones eventualmente críticas y tomar medidas preventivas [12], [13]. Su capacidad para identificar relaciones dinámicas y no lineales entre variables operativas (a menudo invisibles para los enfoques convencionales) explica por qué estas metodologías han logrado resolver problemáticas que antes requerían modelos analíticos más extensos y detallados [14], [15]. Un ejemplo de ello es la experiencia de Siemens y Ercros en España, donde se utilizó IA para detectar anomalías de tensión en redes de 11 kV en tiempo real, superando la dependencia de mediciones puntuales y análisis fuera de línea (*offline*) que retrasaban la detección de fallas, fortaleciendo así las estrategias de mantenimiento predictivo [16]. De manera similar, en Brasil, Eletrobras implementó una plataforma de IA para el monitoreo en tiempo real de su red de transmisión, lo que permite detectar y resolver fallas de forma más rápida, mejorando la resiliencia del sistema eléctrico frente a eventos críticos [17]. En China, se han desarrollado sistemas de restauración autónoma de redes de 110 kV basados en IA, capaces de identificar fallas y restablecer el servicio sin intervención humana con un nivel de precisión en la predicción de fallas superior al 98 %, mejorando drásticamente la eficiencia en la detección de defectos en equipos [18].

Motivado por estos avances, este trabajo propone desarrollar un modelo basado en IA para predecir la respuesta dinámica de la tensión posterior a cortocircuitos en barras del SEN. Para ello, se entrenan, comparan y evalúan distintas técnicas de IA, utilizando variables pre-falla e indicadores de robustez de red como entradas del modelo, con el propósito de identificar condiciones operacionales críticas asociadas a la estabilidad de tensión de corto plazo.

1.2. Hipótesis

La principal hipótesis de este trabajo es que el uso de técnicas de IA, junto con indicadores de fortaleza de red adecuados, permite estimar con alta precisión el desempeño dinámico de la tensión en el Sistema Eléctrico Nacional (SEN). Para ello, se realizarán simulaciones dinámicas ante fallas en un modelo detallado del SEN, cuyos resultados se utilizarán para entrenar y validar distintos modelos de IA orientados a estimar la evolución temporal de la tensión durante la falla.

Esta hipótesis se sustenta en el hecho de que, actualmente, existen modelos basados en IA capaces de predecir la estabilidad de tensión ante contingencia, con alta precisión. Sin embargo, la gran mayoría de estos modelos han sido implementados en sistemas de prueba pequeños. Solo unos pocos modelos han sido implementados en sistemas reales y ninguno ha sido implementado en un modelo detallado del SEN. Esto sugiere que su desempeño en la predicción de la estabilidad de tensión en el SEN podría diferir de los resultados reportados en otros entornos de prueba y que eventualmente no alcancen la precisión necesaria para su uso práctico.

1.3. Objetivos

El objetivo principal de este trabajo es desarrollar un modelo para estimar el desempeño de la tensión durante contingencias en el Sistema Eléctrico Nacional (SEN), utilizando técnicas de IA.

Los objetivos específicos son:

1. Revisar el estado del arte en cuanto a i) técnicas de inteligencia artificial aplicadas a la predicción de la estabilidad de tensión de corto plazo, junto con los principales indicadores de entrada utilizados; y ii) métricas de estabilidad de tensión y de fortaleza de red (*stiffness* o robustez de tensión) en sistemas eléctricos de potencia, poniendo especial énfasis en aquellas que puedan ser incorporadas como variables de entrada en modelos de IA para la predicción de estabilidad.
2. Generar una base de datos con registros de la evolución de la tensión en distintas barras del SEN ante contingencias, junto con los valores de los principales indicadores que permiten caracterizar el desempeño del sistema.
3. Implementar distintas técnicas de inteligencia artificial para predecir el desempeño dinámico de la tensión del SEN durante contingencias.
4. Evaluar el desempeño de los modelos de IA desarrollados, en cuanto a tiempos de entrenamiento, tiempos de predicción y precisión en la predicción.

Capítulo 2

Estado del arte

2.1. Robustez de tensión

La robustez de tensión, también denominada fortaleza de red o *system strength* en la literatura internacional, hace referencia a la capacidad de un sistema eléctrico de potencia para mantener y controlar la forma de onda de la tensión en cualquier punto de la red dentro de márgenes aceptables, tanto en condiciones normales de operación como frente a perturbaciones severas [19]. Este concepto es fundamental para garantizar la estabilidad y la seguridad del sistema, ya que una red robusta es capaz de absorber variaciones de potencia sin que se produzcan desviaciones significativas de tensión, facilitando así la operación de las unidades generadoras y la adecuada coordinación de protecciones.

La robustez de tensión se encuentra estrechamente vinculada con la sensibilidad de la tensión respecto de la potencia reactiva ($\partial V/\partial Q$). Cuando dicha sensibilidad es baja, el sistema se considera robusto, ya que las tensiones no sufren cambios significativos frente a variaciones acotadas en la inyección o absorción de potencia reactiva. Por el contrario, valores elevados de $\partial V/\partial Q$ son características de una red débil [20], en la cual incluso perturbaciones de pequeña magnitud pueden ocasionar desvíos significativos de tensión y dificultar la recuperación tras una falla.

La robustez de tensión depende de diversos factores estructurales y operativos de la red, entre los que destacan: (i) el nivel de enmallamiento del sistema, ya que un mayor grado de interconexión reduce la impedancia equivalente y produce tensiones más rígidas frente a perturbaciones locales; (ii) la distancia eléctrica a los centros de generación, dado que las barras alejadas de grandes generadores presentan una mayor susceptibilidad a variaciones de tensión, mientras que aquellas próximas a fuentes de gran potencia exhiben un comportamiento más robusto; y (iii) la presencia de tecnologías formadoras de red, en particular generadores sincrónicos e inversores en modo *grid-forming* (GFM), que aportan corrientes de falla de gran magnitud e imponen referencias firmes de tensión y frecuencia durante contingencias. En contraste, los inversores en modo *grid-following* (GFL) no contribuyen a fortalecer la red, sino que requieren conectarse en puntos eléctricamente robustos para operar de manera estable.

2.1.1. Relación entre la fortaleza de red y el nivel de cortocircuito

Tradicionalmente, la fortaleza de red se ha cuantificado a partir del nivel de cortocircuito (SCL) en las barras del sistema. En sistemas eléctricos dominados por la generación sincrónica, este indicador resulta altamente representativo, ya que la sensibilidad de la tensión frente a variaciones en la potencia reactiva ($\partial V/\partial Q$) se aproxima al inverso de la potencia de cortocircuito disponible en la barra. De manera simplificada, puede expresarse como:

$$\frac{\partial V}{\partial Q} \approx \frac{1}{SCL}$$

de lo anterior se desprende que un mayor nivel de cortocircuito implica una menor impedancia equivalente vista desde la barra, lo que se traduce en una respuesta de tensión más rígida y, por tanto, en un sistema más robusto frente a perturbaciones [21]. Este vínculo teórico puede interpretarse a partir del modelo equivalente de Thévenin del sistema eléctrico visto desde la barra de estudio, el cual se representa mediante una fuente de tensión en serie con una impedancia equivalente. Bajo este enfoque, el nivel de cortocircuito puede expresarse como:

$$SCL_{MVA} = \frac{V^2}{X_{Th}}$$

donde V corresponde a la tensión nominal de la barra y X_{Th} es la reactancia equivalente de Thévenin del sistema vista desde dicho punto. Esta expresión pone de manifiesto que un mayor nivel de cortocircuito está asociado a una menor impedancia equivalente de red, lo que se traduce en una mayor rigidez de la tensión frente a perturbaciones.




Figura 1: Sistema de un generador sincrónico conectado frente a una fuente infinita.

Este vínculo teórico se ilustra mediante el modelo simplificado de un generador sincrónico conectado a una red infinita, como se muestra en la Figura 1. En dicho esquema, la impedancia Thévenin equivalente vista desde el generador disminuye a medida que aumenta el nivel de cortocircuito de la red. En términos físicos, esto significa que la barra se encuentra inmersa en un entorno eléctricamente más robusto, capaz de sostener la tensión frente a perturbaciones. La relación entre el nivel de cortocircuito y la impedancia equivalente puede expresarse en por unidad como:

$$X_{s,pu} = \frac{X_s}{X_n} = \frac{V_n^2}{SCL} \cdot \frac{S_{gs}}{V_n^2} = \frac{S_{gs}}{SCL} = \frac{P_{gs}}{SCL} \cdot \frac{1}{\cos(\varphi_{gs})}$$

de esta expresión se concluye que, a mayor SCL, menor será $X_{s,pu}$; es decir, la impedancia equivalente de la red disminuye y la tensión se vuelve más rígida frente a cambios en la potencia reactiva. A su vez, este fenómeno tiene un impacto directo en la estabilidad transitoria. La potencia eléctrica crítica que el generador es capaz de transferir en régimen transitorio se calcula como:

$$P'_{e,cr} = \frac{E'_q \cdot V_s}{x_d} = \frac{E'_q \cdot V_s}{X'_{d,pu} + X_{t,pu} + X_{s,pu}}$$

donde E'_q corresponde a la fuerza electromotriz transitoria interna del generador, V_s es la tensión de la red infinita, y X'_d , X_s y $X_{s,pu}$ representan las reactancias del generador, del transformador y de la red, respectivamente. Un mayor nivel de cortocircuito reduce $X_{s,pu}$, aumentando así la potencia crítica $P'_{e,cr}$. Esto se traduce en un mejor margen de estabilidad transitoria, que puede evaluarse mediante el coeficiente:

$$C_t = \frac{P'_{e,cr} - P_m}{P'_{e,cr}}$$

donde P_m es la potencia mecánica (o despacho) del generador. Un valor más elevado de C_t refleja que el generador dispone de una mayor holgura para permanecer estable frente a perturbaciones.

A partir de lo anterior, es posible interpretar el nivel de cortocircuito no solo como un indicador estático de la fortaleza de red, sino también como un parámetro que condiciona directamente el desempeño dinámico de la tensión frente a perturbaciones severas. En particular, el valor de SCL influye tanto en la magnitud de la caída inicial de tensión durante una falla como en la capacidad del sistema para recuperar su estado estable una vez despejada la contingencia.

Este comportamiento puede analizarse mediante la evolución temporal de la tensión en una barra ante una perturbación. En sistemas con un alto nivel de cortocircuito, la caída de tensión durante la falla tiende a ser menos pronunciada y la recuperación posterior se produce de manera rápida, con menores oscilaciones y una restitución eficiente hacia su valor nominal. Por el contrario, en sistemas con bajo SCL, la caída inicial de tensión suele ser más profunda y la recuperación más lenta, presentando mayores oscilaciones e incluso dificultades para restablecer completamente el nivel de tensión previo a la perturbación [22], [23]. Esto permite distinguir claramente entre barras eléctricamente robustas (alto SCL) y barras eléctricamente débiles (bajo SCL), en función de su respuesta dinámica frente a contingencias.

Este análisis puede complementarse mediante la representación de las curvas de tensión bajo condiciones de falla para distintos niveles de SCL, como se muestra en la Figura 2. Se observa que, para valores elevados de nivel de cortocircuito, la caída inicial de tensión es menos pronunciada y la recuperación posterior resulta más rápida y estable. En cambio, cuando el SCL es menor, la desviación inicial de tensión es más profunda y la recuperación más lenta, lo que evidencia un sistema eléctricamente más débil.




Figura 2: Desempeño dinámico de la tensión para diferentes niveles de cortocircuito en un sistema dominado por generación sincrónica (Imagen extraída de [24]).

En este contexto, el nivel de cortocircuito no solo constituye un indicador descriptivo de la fortaleza de red, sino que también puede ser utilizado como una variable predictiva del desempeño dinámico del sistema. En particular, el conocimiento del SCL en una barra permite anticipar su comportamiento frente a contingencias, identificando condiciones eléctricamente débiles asociadas a mayores desviaciones de tensión y a una recuperación más lenta tras perturbaciones severas. Esta propiedad lo convierte en un parámetro clave en estudios de estabilidad de tensión y en el análisis de múltiples escenarios operativos.

A nivel internacional, los operadores de sistemas eléctricos han utilizado el SCL como criterio práctico para establecer umbrales mínimos en la conexión de nuevas unidades generadoras [21]. Un ejemplo de ello es el código de transmisión alemán, que impone requisitos mínimos de nivel de cortocircuito (del orden de varias veces la suma de las potencias nominales de las unidades conectadas) con el fin de asegurar márgenes adecuados de estabilidad transitoria ante tiempos de despeje de falla acotados [25]. Este tipo de requerimientos busca que la red disponga de la rigidez necesaria para soportar fallas severas, coordinar las protecciones y mantener un comportamiento dinámico seguro.

En conjunto, estos resultados confirman que el nivel de cortocircuito constituye un indicador adecuado de robustez en sistemas dominados por generación sincrónica. No obstante, en escenarios con alta penetración de recursos basados en inversores, este criterio se vuelve insuficiente para caracterizar correctamente el comportamiento dinámico del sistema, tal como se discutirá en la siguiente subsección.

2.1.2. Limitación del nivel de cortocircuito para estimar robustez en sistemas con alta participación de IBR

La relación entre el SCL y la fortaleza de red resulta adecuada en sistemas dominados por generación sincrónica, donde la dinámica de la tensión está gobernada principalmente por la impedancia equivalente de la red y por el aporte de corriente de falla de los generadores. Sin embargo, este vínculo se debilita significativamente en sistemas con alta penetración de recursos basados en inversores (IBR), debido a que estos dispositivos no se comportan como fuentes físicas de tensión, sino como elementos controlados electrónicamente cuya respuesta depende del esquema de control y del modo de operación implementado.

Por una parte, los inversores “grid following” (GFL) dependen de una referencia externa de tensión y frecuencia para su sincronización y presentan una capacidad limitada de aporte de corriente de falla. Por otra parte, los inversores “grid forming” (GFM), pueden regular activamente la tensión y la frecuencia en bornes, emulando el comportamiento de una fuente de tensión y aportando soporte dinámico al sistema ante perturbaciones. Como consecuencia, la robustez de la tensión deja de estar determinada únicamente por la impedancia de la red y pasa a depender de la interacción entre la fortaleza estructural del sistema y el comportamiento dinámico de los convertidores [26]. Para ilustrar esta diferencia, en la Figura 3 se presenta un caso de estudio donde se aplicó una falla trifásica en una barra puntual, bajo las mismas condiciones de red y punto de conexión, variando únicamente la tecnología de generación conectada (generación sincrónica, inversor GFL sin FRT, inversor GFL con FRT e inversor GFM). En todos los casos, el valor del SCL en la barra fue el mismo. La evolución temporal de la tensión ante las distintas conexiones se muestra en la Figura 3. Como se puede ver de la figura, aún bajo un mismo entorno eléctrico, la respuesta de tensión difiere de forma significativa entre generación sincrónica, inversores GFL (con y sin FRT) e inversores GFM, lo que demuestra que barras con un mismo SCL pueden exhibir desempeños dinámicos radicalmente distintos.




Figura 3: Trayectorias de tensión bajo una misma contingencia que ilustran la dependencia de la robustez de tensión respecto de la tecnología conectada: GFL con y sin FRT, GFM y generación síncrona (Imagen extraída de [24]).

Estos resultados ponen de manifiesto que el SCL captura principalmente la severidad de la caída inicial de tensión, pero no describe adecuadamente la dinámica de recuperación ni las interacciones de control que dominan la respuesta post-falla en sistemas con alta penetración de IBR. En este contexto, la robustez de tensión deja de depender únicamente de la fortaleza estructural de la red y pasa a estar condicionada por la coexistencia y proporción de las distintas tecnologías de generación conectadas. Por lo tanto, para evaluar y predecir el comportamiento dinámico del sistema resulta indispensable conocer no solo el nivel de cortocircuito disponible, sino también el nivel de penetración y el tipo de tecnologías basadas en inversores presentes en cada barra. A continuación, se muestran los principales índices de robustez de tensión encontrados en la literatura técnica.

2.2. Índices de evaluación del comportamiento de la tensión

La evaluación del comportamiento de la tensión en sistemas eléctricos modernos durante contingencias requiere el uso de métricas que permitan caracterizar de manera objetiva tanto la fortaleza estructural de la red como su interacción con recursos basados en electrónica de potencia y su respuesta dinámica frente a perturbaciones. Si bien el SCL, presentado en la sección anterior, constituye una base fundamental para este análisis, en escenarios con alta penetración de convertidores resulta necesario complementarlo con índices que capturen de mejor forma la relación entre la capacidad de cortocircuito, la potencia conectada y la dinámica de recuperación de la tensión. En este contexto, la literatura ha propuesto diversos indicadores, tales como el Short Circuit Ratio (SCR) y sus variantes (WSCR, CSCR, ISCR), así como métricas basadas en la respuesta temporal de la tensión, incluyendo el Voltage Stability Index (VSI), el Transient Voltage Severity Index (TVSI) y otros indicadores asociados a la severidad de la caída de tensión, tal como se muestra a continuación.

2.2.1. Short circuit ratio (SCR)

El SCR es uno de los indicadores más utilizados para evaluar la robustez de una barra de un sistema eléctrico frente a la conexión de IBR. Este índice permite estimar la relación entre la fortaleza eléctrica de la red y la capacidad de generación conectada mediante convertidores en un determinado punto del

sistema. En términos generales, el SCR entrega una medida relativa de cuán “fuerte” o “débil” es la red desde la perspectiva de la interacción entre el sistema eléctrico y los convertidores. Su expresión matemática es:

$$SCR_i = \frac{SCL_i}{P_i^{IBR}}$$

donde SCL_i corresponde a la potencia de cortocircuito del sistema en el punto de conexión y P_i^{IBR} corresponde a la potencia nominal de los IBR conectados en dicho nodo. Este indicador es ampliamente utilizado debido a su simplicidad, ya que permite estimar rápidamente la robustez del sistema utilizando información que normalmente está disponible en los estudios eléctricos [27]. En términos prácticos, valores bajos de SCR se asocian a redes eléctricamente débiles, mientras que valores altos representan redes más robustas [28].

A pesar de su amplio uso, el SCR presenta ciertas limitaciones cuando se aplica a sistemas con alta penetración de IBR. En particular, este indicador no considera la interacción entre múltiples recursos basados en convertidores conectados eléctricamente cercanos, por lo que su aplicación es más adecuada como una herramienta preliminar para evaluar la fortaleza del sistema [27].

2.2.2. Weighted short circuit ratio (WSCR)

El WSCR es una métrica desarrollada para evaluar la robustez de una barra del sistema eléctrico cuando existen múltiples IBR conectados eléctricamente cercanos. A diferencia del SCR convencional, el WSCR considera de manera agregada la influencia de varias unidades basadas en convertidores conectadas en una misma zona del sistema, permitiendo obtener una estimación más representativa de la fortaleza de red en escenarios con alta penetración de IBR [29]. Su expresión matemática es:

$$WSCR = \frac{\sum_{i=1}^N SCL_i \cdot P_{IBR,i}}{(\sum_{i=1}^N P_{IBR,i})^2}$$

donde SCL_i corresponde a la potencia de cortocircuito en la barra i , $P_{IBR,i}$ corresponde a la potencia nominal del i -ésimo IBR conectado al sistema, y N representa el número total de IBR considerados en el análisis. Esta formulación permite ponderar el aporte de cada punto de conexión en función de la potencia instalada, entregando una estimación más realista de la fortaleza del sistema cuando varias plantas basadas en convertidores interactúan eléctricamente [29].

A pesar de capturar el impacto de los convertidores, el WSCR también presenta limitaciones. Este indicador asume que los IBR cercanos eléctricamente se encuentran conectados a un mismo nodo equivalente, por lo que no representa de forma explícita la topología detallada de la red ni las interacciones dinámicas entre los convertidores. Como consecuencia, en sistemas eléctricos con configuraciones de red complejas o con una distribución espacial significativa de los IBR, el WSCR puede no capturar completamente los efectos de interacción entre plantas, requiriéndose estudios más detallados para evaluar adecuadamente la estabilidad del sistema [27].

2.2.3. Composite short circuit ratio (CSCR)

El CSCR es un indicador utilizado para evaluar la fortaleza del sistema eléctrico cuando múltiples IBR se encuentran conectados eléctricamente en una misma región de la red. A diferencia del SCR

convencional, que relaciona el nivel de cortocircuito con la potencia nominal de un único convertidor, el CSCR considera la potencia total de los convertidores presentes en el área analizada, permitiendo obtener una estimación más representativa de la fortaleza de red en sistemas con múltiples unidades basadas en electrónica de potencia [28]. Su expresión matemática es la siguiente:

$$CSCR = \frac{SCL}{\sum_{i=1}^N P_{IBR,i}}$$

donde SCL corresponde a la potencia de cortocircuito disponible en la barra de estudio, $P_{IBR,i}$ representa la potencia nominal del i -ésimo recurso basado en convertidor conectado en dicha zona, y N corresponde al número total de IBR considerados en el análisis. Esta formulación permite evaluar la relación entre la fortaleza del sistema eléctrico y la potencia total de convertidores conectados en el área [28], proporcionando una medida agregada de la capacidad de la red para absorber perturbaciones y mantener condiciones estables de operación.

Al igual que el SCR y el WSCR, este índice también presenta ciertas limitaciones, ya que considera únicamente el nivel de cortocircuito en la barra de estudio y la potencia total de los convertidores conectados, sin representar explícitamente la topología detallada de la red ni la distribución espacial de los IBR dentro del sistema eléctrico [27]. Como consecuencia, en redes eléctricas con configuraciones complejas o con convertidores distribuidos en distintos puntos de conexión, el CSCR puede no capturar completamente las interacciones eléctricas entre plantas, requiriéndose estudios adicionales para evaluar de forma más precisa la estabilidad del sistema.

2.2.4. Índice ISCR

En sistemas eléctricos con alta penetración de recursos basados en convertidores, la robustez de tensión está determinada por la relación entre la fortaleza de la red y la magnitud de la potencia controlada electrónicamente conectada en su entorno eléctrico. En este contexto, el ISCR se utiliza como un índice que normaliza el nivel de cortocircuito de una barra respecto de la potencia nominal total de los recursos basados en convertidores conectados a dicho nodo, permitiendo caracterizar el grado de dominancia de la red desde la perspectiva del convertidor [5], [27]. La formulación del ISCR asociado a la barra i es:

$$ISCR_i = \frac{SCL_i}{\sum_{j \neq i}^N |D_{ij}| \cdot P_j}, \forall i \in SEP$$

donde SCL_i es el nivel de cortocircuito local, P_j corresponde a la potencia de las unidades CIG conectadas en la barra j , y D_{ij} es una medida de distancia eléctrica obtenida a partir de la matriz de impedancias del sistema [30]. Mediante esta formulación, el índice incorpora no solo la fortaleza estructural local de la red, sino también la influencia efectiva de la generación basada en convertidores distribuida en el sistema.

Desde un punto de vista físico, valores elevados de ISCR se asocian a entornos eléctricamente robustos, mientras que valores reducidos reflejan escenarios de red débil, en los cuales la interacción entre la dinámica de los convertidores y la red adquiere un rol predominante en la respuesta de tensión frente a perturbaciones [31], [32]. En el marco de este trabajo, el ISCR resulta particularmente adecuado al constituir un indicador físicamente interpretable, calculable a partir de información en estado estacionario y capaz de capturar de manera compacta el entorno eléctrico efectivo visto por cada barra, permitiendo caracterizar la robustez de tensión sin recurrir a simulaciones dinámicas exhaustivas, enfoque que ha sido

ampliamente adoptado en la literatura para el análisis de robustez de tensión y planificación en sistemas eléctricos de gran escala [33].

Desde una perspectiva de validación, distintos trabajos han propuesto contrastar indicadores estructurales como el ISCR con métricas dinámicas de desempeño de tensión. En este contexto, en [34] se introduce el Índice de Desempeño Dinámico (IDD), el cual cuantifica la severidad de la respuesta de tensión ante perturbaciones mediante la evaluación conjunta de la profundidad y duración de las caídas de tensión, tal como se ilustra en la Figura 4.




Figura 4: Representación del Índice de Desempeño Dinámico (Imagen extraída de [34]).

A partir de este indicador, se establece una relación entre el ISCR y el comportamiento dinámico del sistema, evidenciando que valores elevados de ISCR se correlacionan con respuestas de tensión más robustas (mayores valores de IDD), mientras que valores bajos de ISCR se asocian a condiciones de mayor debilidad y peor desempeño dinámico. Esta correlación, presentada en la Figura 5, permite vincular directamente un indicador estructural con una métrica de desempeño dinámico.




Figura 5: IDD en función de la métrica de robustez ISCR (Imagen extraída de [34]).

En consecuencia, los resultados obtenidos en [34] muestran que el ISCR no solo constituye un indicador de la fortaleza estructural de la red, sino que además presenta una adecuada capacidad para

representar el comportamiento dinámico de la tensión frente a perturbaciones. De esta forma, se justifica su utilización como métrica de robustez en estudios de estabilidad de tensión de corto plazo, permitiendo inferir el desempeño dinámico del sistema a partir de variables en estado estacionario, evitando la necesidad de realizar simulaciones dinámicas exhaustivas.

2.2.5. Voltage Stability Index (VSI)

El VSI es un indicador utilizado para identificar áreas débiles del sistema eléctrico desde el punto de vista de la estabilidad de tensión. Este índice evalúa la sensibilidad de la tensión ante variaciones en las condiciones de operación del sistema, permitiendo estimar qué tan susceptible es una barra para experimentar problemas de estabilidad frente a perturbaciones o cambios en la inyección de potencia [35], [36]. La expresión matemática de este índice es:

$$VSI_i = \left[1 + \left(\frac{I_i}{V_i} \right) \left(\frac{\Delta V_i}{\Delta I_i} \right) \right]^\alpha$$

donde V_i e I_i corresponden a la tensión y la corriente en la barra i en el punto de operación base, respectivamente, mientras que ΔV_i y ΔI_i representan las variaciones de tensión y corriente producidas por una perturbación aplicada al sistema. El parámetro α es un coeficiente que depende de los parámetros del sistema eléctrico y del modelo utilizado para el análisis. Esta formulación permite evaluar la relación entre los cambios de tensión y corriente en la barra analizada, proporcionando una medida de la robustez del sistema frente a perturbaciones [37]. No obstante, el VSI también presenta ciertas limitaciones, ya que depende de la condición de operación utilizada como referencia y de la perturbación aplicada para calcular las variaciones de tensión y corriente. En consecuencia, los valores obtenidos pueden variar según el escenario operativo analizado. Además, al basarse en una aproximación local del comportamiento del sistema, este índice puede no capturar completamente los fenómenos dinámicos asociados a la estabilidad de tensión en sistemas eléctricos de gran escala o con alta penetración de convertidores [38].

2.2.6. Transient Voltage Severity Index (TVSI)

El TVSI es un indicador cuantitativo utilizado para medir la severidad de las desviaciones de tensión durante transitorios en sistemas eléctricos. Este índice es especialmente útil para capturar tanto la magnitud como la duración de las violaciones de tensión en el sistema, considerando solo aquellas barras que experimentan desviaciones significativas de tensión durante el periodo transitorio. Su expresión matemática es la siguiente:

$$TVSI = \frac{\sum_{i=1}^N \sum_{t=T_c}^T TVDI_{i,t}}{N \times (T - T_c)}$$

donde N_b corresponde a la cantidad de barras del sistema consideradas para obtener el índice, T es el final del marco de tiempo considerado para el análisis, T_c es el tiempo de eliminación de la falla y $TVDI_{i,t}$ es el índice de desviación de tensión transitoria para la barra i en el tiempo t . El valor de $TVDI_{i,t}$ de cada una de las barras se obtiene de acuerdo a la siguiente expresión:

$$TVDI_{i,t} = \begin{cases} \frac{|V_{i,t} - V_{i,0}|}{V_{i,0}}, & Si \frac{|V_{i,t} - V_{i,0}|}{V_{i,0}} \geq \mu \\ 0, & de lo contrario \end{cases} \quad \forall t \in [T_c, T]$$

donde $V_{i,0}$ corresponde al valor inicial de la tensión de la barra i en valor unitario, $V_{i,t}$ es la tensión en el tiempo t desde que ocurre el evento, y μ corresponde a un umbral (threshold) que define la desviación máxima de tensión, por debajo de la cual la tensión se considera inaceptable, tal como se ilustra en la Figura 6.




Figura 6: Ilustración del concepto de TVDI en un ejemplo de caída de tensión inducida por una falla (Imagen extraída de [39]).

El índice TVSI se utiliza particularmente para diseñar estrategias de mitigación y control adecuadas, ya que permite identificar no solo cuándo y dónde ocurren las inestabilidades de tensión, sino también cuán severas son estas en términos de impacto en la operación del sistema eléctrico. En resumen, el TVSI es un índice útil para el análisis y la mejora continua de la seguridad y estabilidad de los sistemas de potencia, especialmente en escenarios con alta penetración de fuentes de energías renovable y cargas dinámicas complejas [40].

2.2.7. Root-mean-squared Voltage Dip Severity Index (RVSI)

El RVSI es un indicador utilizado para evaluar la severidad de la caída de tensión en un sistema eléctrico durante un evento o perturbación. Este índice se basa en el cálculo del promedio cuadrático de los valores de severidad de la caída de tensión (*dip*) de todas las barras consideradas en el sistema, permitiendo obtener una medida agregada del comportamiento global de la red ante disturbios [41]. La expresión matemática del índice es:

$$RVSI = \sqrt{\frac{\sum_{i=1}^{N_b} VSI_i^2}{N_b}}$$

donde N_b corresponde al número de barras consideradas en el análisis y VSI_i representa el índice de severidad de la caída de tensión en la barra i . En este contexto, el término VSI_i no corresponde al Voltage Stability Index presentado en la sección 2.2.5, sino que se obtiene integrando en el tiempo la magnitud de la caída de tensión durante el período de análisis:

$$VSI_i = \int_{t_0}^T D_{i,t} dt$$

donde $D_{i,t}$ representa la profundidad de la caída de tensión (*dip*) en la barra i en el instante t , y se calcula de acuerdo con la siguiente expresión:

$$D_{i,t} = \begin{cases} \frac{V_{i,0} - V_{i,t}}{V_{i,0}}, & \text{Si } V_{i,t} \leq \mu V_{i,0} \\ 0, & \text{de lo contrario} \end{cases} \quad \forall t \in [t_0, T]$$

donde $V_{i,0}$ corresponde al valor inicial de la tensión en la barra i antes del evento, $V_{i,t}$ corresponde al valor de la tensión en el instante t , y μ representa el umbral mínimo de tensión considerado para identificar una caída de tensión. De esta forma, el índice permite cuantificar la profundidad y duración de la caída de tensión experimentado en cada barra del sistema, tal como se ilustra en la Figura 7.




Figura 7: Ilustración gráfica de RVSI (Imagen extraída de [41]).

Cabe destacar que este indicador depende del conjunto de barras consideradas en el análisis y de la selección del umbral de tensión utilizado para definir la caída de tensión. Asimismo, al basarse en una agregación de los índices individuales de cada barra, el RVSI entrega una medida global del comportamiento del sistema, pero no permite identificar directamente qué nodos específicos son responsables de la mayor severidad observada durante el evento.

2.2.8. Alcances y limitaciones de los índices

Con el objetivo de establecer una comparación sistemática entre los distintos indicadores presentados, la siguiente tabla muestra un resumen con las principales características de los índices, desde el punto de vista de la robustez de red y su aplicabilidad en sistemas eléctricos con presencia de IBR. En particular, se evalúan aspectos como la naturaleza del índice, su dependencia del nivel de cortocircuito, la consideración de múltiples IBR y su capacidad para representar la topología de la red. Esta comparación permite identificar las fortalezas y limitaciones de cada indicador, así como su pertinencia para el análisis desarrollado en este trabajo.

De acuerdo con la Tabla 1, los índices analizados se agrupan en dos categorías: por una parte, aquellos basados en el nivel de cortocircuito, como SCL, SCR, WSCR, CSCR e ISCR, que permiten evaluar la fortaleza estructural de la red a partir de variables estacionarias y han sido ampliamente utilizados para caracterizar la robustez del sistema frente a la conexión de recursos basados en inversores [27], [42]. Por otra parte, están los índices de estabilidad de tensión, como VSI, TVSI y RVSI, cuyo cálculo depende de la evolución temporal de las variables eléctricas ante perturbaciones específicas, por lo que requieren información dinámica del sistema y se encuentran condicionados por el escenario analizado [43], [44]. En el contexto de este trabajo, orientado a caracterizar la robustez del sistema eléctrico frente a la integración de IBR desde una perspectiva estructural, resulta más adecuado emplear indicadores que puedan ser calculados de manera rápida a partir de información pre-falla, sin necesidad de ejecutar simulaciones dinámicas para cada nueva condición operacional.

Tabla 1: Comparación de características de los principales índices de robustez de red y estabilidad de tensión utilizados en sistemas eléctricos de potencia.

Característica	SCL	SCR	WSCR	CSCR	ISCR	VSI	TVSI	RVSI
Índice estático	Sí	Sí	Sí	Sí	Sí	No	No	No
Representa Fortaleza estructural de la red	Sí	Sí	Sí	Sí	Sí	No	No	No
Considera potencia de IBR	No	Sí	Sí	Sí	Sí	No	No	No
Considera múltiples IBR	No	No	Sí	Sí	Sí	No	No	No
Incorpora distancia eléctrica entre barras	No	No	Parcial	Parcial	Sí	No	No	No
Incorpora topología de red	No	No	No	No	Sí	No	No	No
Requiere simulación temporal	No	No	No	No	No	Sí	Sí	Sí
Permite identificar barras débiles	Sí	Sí	Sí	Sí	Sí	Sí	Sí	No
Útil para planificación	Sí	Sí	Sí	Sí	Sí	No	No	No

En este sentido, el índice SCL constituye una característica relevante para el análisis, dado que representa directamente el nivel de cortocircuito disponible en cada barra y entrega una primera aproximación de la fortaleza estructural de la red [27]. No obstante, su principal limitación radica en que no considera explícitamente la presencia ni la interacción de múltiples recursos basados en convertidores, aspecto que se vuelve relevante en sistemas eléctricos con alta penetración de IBR [42]. Para superar esta limitación, el índice ISCR extiende el análisis al integrar explícitamente la potencia de los IBR, su acoplamiento eléctrico y la topología de la red, permitiendo representar de manera más precisa los efectos asociados a su penetración [45]. De esta forma, la utilización conjunta de SCL e ISCR proporciona una caracterización complementaria de la robustez del sistema, capturando tanto su fortaleza estructural como las implicancias derivadas de la integración de tecnologías basadas en electrónica de potencia. Sin embargo, si bien SCL e ISCR pueden ser utilizados como aproximaciones para inferir la robustez del sistema, por sí solos pueden resultar insuficientes para predecir la trayectoria temporal completa de la tensión durante una falla, ya que no describen explícitamente la evolución dinámica posterior a la contingencia [44]. Es por esto que, en la siguiente sección, se presenta un análisis de las variables eléctricas que impactan en la evolución temporal de la tensión durante falla y que pueden aportar al desarrollo de un modelo de predicción basado en técnicas de inteligencia artificial.

2.3. Variables eléctricas relevantes en el comportamiento de la tensión durante falla

La estabilidad de tensión de corto plazo o *Short-Term Voltage Stability* (STVS) depende principalmente de la infraestructura de la red, las condiciones operacionales del sistema pre-falla, y los recursos disponibles para el manejo de la contingencia, en particular en aquellos con capacidad de respuesta durante los primeros segundos posteriores a la falla. A continuación, se presenta una revisión de las principales variables que impactan la STVS.

Las potencias activas y reactiva de la generación y la demanda han sido identificadas como variables clave para contextualizar el nivel de estrés operativo del sistema durante la fase transitoria inicial. Diversos trabajos han mostrado que el despacho de potencia, la distribución espacial de generación y demanda, así como las reservas de potencia reactiva, impactan directamente la profundidad de las caídas de tensión y la en la recuperación del sistema post-falla, especialmente bajo condiciones de carga variable y presencia de motores de inducción u otros elementos dinámicos [23]. Por una parte, el nivel de carga de las centrales

térmicas impacta en su capacidad de aporte con potencia activa y reactiva luego de ocurrida la falla. Por otra parte, en sistemas eléctricos modernos con alta penetración de recursos basados en convertidores, la potencia activa controlada electrónicamente y el tipo de tecnología de los inversores conectados adquieren un rol determinante en la respuesta dinámica de la tensión. La distinción entre modos de control GFL y GFM ha sido estudiada específicamente por su impacto sobre la capacidad de soporte dinámico de tensión, mostrando diferencias significativas en la caída inicial y recuperación post-contingencia [46], [47].

Una segunda característica relevante para el comportamiento de la tensión luego de una falla es la inercia del sistema. La inercia corresponde a la energía cinética almacenada en los generadores síncronos, la cual se representa mediante la constante de inercia $H = E_k / S_{base}$, con $E_k = J\omega^2/2$. La inercia influye en la evolución de la tensión tras una perturbación, ya que determina la rapidez de la respuesta del sistema: en escenarios con alta penetración de recursos basados en convertidores, la reducción de la inercia disponible modifica la dinámica del sistema, lo que puede intensificar las caídas de tensión y dificultar su recuperación [48], [49]. Estudios recientes han mostrado que niveles reducidos de inercia pueden exacerbar la severidad de eventos de STVS y retardar la recuperación de tensión, particularmente en escenarios de alta participación renovable [32], [50].

En conjunto, estas variables eléctricas (incluyendo niveles de tensión, condiciones de carga, inercia equivalente y características tecnológicas de los recursos conectados) constituyen la base física de los principales enfoques actuales para la evaluación de la estabilidad de tensión de corto plazo. Sin embargo, en el caso de la potencia activa, su efecto dependerá fuertemente de la distancia eléctrica a la barra donde se quiere evaluar la estabilidad de tensión. En sistemas eléctricos de potencia, la influencia de los distintos elementos sobre la tensión en una barra depende del grado de acoplamiento eléctrico entre los nodos de la red. Este acoplamiento está determinado por la topología del sistema y por las impedancias de interconexión, lo que implica que la respuesta de tensión en una barra está condicionada no solo por los elementos conectados directamente a ella, sino también por aquellos que se encuentran eléctricamente cercanos dentro del sistema. En consecuencia, cada barra percibe el resto del sistema a través de un equivalente eléctrico local, cuya dinámica está influenciada por su entorno eléctrico inmediato [22].

Para capturar este comportamiento, la literatura ha introducido el concepto de distancia eléctrica como una medida de la impedancia de transferencia entre barras, la cual permite cuantificar el grado de influencia eléctrica entre nodos del sistema [51]. Una formulación ampliamente utilizada define la distancia eléctrica entre las barras i y j como:

$$D_{ij} = Z_{ii} + Z_{jj} - 2 Z_{ij}$$

donde Z_{ij} corresponde a los elementos de la matriz de impedancias del sistema, obtenida a partir del equivalente de Thévenin del SEP. Esta métrica refleja la “lejanía” eléctrica entre barras en términos de impedancia efectiva. Además de la distancia geográfica, depende también de la topología de la red, de las impedancias en serie que conectan las barras y de las condiciones eléctricas del sistema.

La distancia eléctrica adquiere especial relevancia en sistemas con alta penetración de IBR, donde la interacción entre distintas unidades no depende únicamente de su ubicación física, sino de su cercanía eléctrica dentro de la red. En este contexto, barras eléctricamente cercanas pueden presentar una fuerte interacción, de modo que la operación de un convertidor puede influir significativamente en la respuesta de tensión de otros nodos. Por el contrario, los convertidores que se encuentran conectados en barras eléctricamente alejadas a la falla presentan un acoplamiento reducido, limitando su impacto en la dinámica de la tensión durante la falla y después de despejada. De esta forma, la distancia eléctrica permite

identificar qué nodos presentan una mayor influencia mutua, constituyendo una herramienta fundamental para representar la interacción entre múltiples IBR.

A partir de este concepto, es posible construir magnitudes equivalentes “vistas desde una barra”, en las cuales las contribuciones del resto del sistema se ponderan en función de su cercanía eléctrica. Por ejemplo, el aporte de un generador a la estabilidad de tensión de una barra durante falla depende fuertemente de la distancia eléctrica: mientras menor sea esta distancia eléctrica, mayor es el aporte efectivo del generador. Este enfoque permite capturar de manera más realista la influencia efectiva de distintos elementos sobre una barra de interés, reduciendo la complejidad del sistema sin perder información relevante. En este trabajo, la distancia eléctrica será utilizada como base para caracterizar las variables relevantes que impactan a la dinámica de la tensión durante la falla, lo cual resulta especialmente adecuado en escenarios con alta penetración de IBR [52].

Finalmente, una última variable que impacta el comportamiento de la tensión durante y después de una falla es la caída de tensión inicial (inmediatamente después de ocurrida la falla). Caídas profundas de tensión implican una mayor exigencia sobre los mecanismos de recuperación del sistema, pudiendo generar fenómenos como desconexión de cargas o inversores, lo que aumenta el riesgo de inestabilidad de tensión de corto plazo [49]. Para estimar la tensión inmediatamente después de ocurrida la falla, V_{t0+} , se puede estimar considerando la siguiente relación entre la tensión pre- y post-falla, la impedancia de falla y la impedancia de Thévenin:

$$V_{t0+} \approx V_{pref} \cdot \frac{Z_f}{Z_f + Z_{th}}$$

Dado que la impedancia de Thévenin se relaciona con la tensión nominal de la barra y el SCL a través de $Z_{th} \approx V_{nom}^2 / SCL$ [53], la tensión inmediatamente después de ocurrida la falla se puede estimar como:

$$V_{t0+} \approx V_{pref} \cdot \frac{SCL \cdot Z_f}{V_{nom}^2 + SCL \cdot Z_f}$$

En resumen, las variables aquí mencionadas serán utilizadas como dato de entrada a los modelos de inteligencia artificial para predecir la evolución de la tensión luego de ocurrida una falla. El aporte efectivo de cada una de estas variables será cuantificado una vez obtenidos los modelos, lo que permitirá determinar, en base a los resultados, el aporte que tienen para el desarrollo de modelos de inteligencia artificial para predecir la evolución de la tensión durante falla.

2.4. Generación y tratamiento de datos de entrada y salidas objetivo para modelos de IA

Uno de los requisitos fundamentales para aplicar IA en la evaluación de la STVS es disponer de una base de datos amplia, diversa y de buena calidad. De lo contrario, si el modelo se entrena con información insuficiente o sesgada, pierde capacidad de generalización [12]. En la literatura, estos conjuntos se construyen principalmente mediante simulaciones dinámicas en el dominio del tiempo (TDS) bajo múltiples condiciones operativas y contingencias. No obstante, el alto costo de ejecutar un gran número de TDS limita su uso en sistemas de tamaño realista, lo que explica la falta de modelos para predecir estabilidad de tensión, validados en sistemas realistas.

En la literatura sobre evaluación basada en IA de la STVS, las entradas más utilizadas corresponden a mediciones/salidas de operación disponibles en SCADA/PMU y/o variables de flujo de potencia: típicamente magnitudes de tensión en barras (y sus trayectorias post-falla), ángulos, cargas y salidas de generación (entre otras mediciones del estado operativo), las cuales alimentan clasificadores o regresores para evaluar rápidamente el desempeño dinámico post-contingencia [54]. En cuanto a las salidas, además de la clasificación binaria de eventos, se ha avanzado hacia índices continuos de severidad, como el *transient voltage severity index* (TVSI), para caracterizar la desviación dinámica de tensión considerando magnitud y duración de las violaciones. De forma complementaria, se han propuesto esquemas jerárquicos capaces de detectar inestabilidad y, cuando corresponde, predecir índices cuantitativos asociados a *fault-induced delayed voltage recovery* (FIDVR), por ejemplo, mediante la predicción del *root-mean-squared voltage-dip severity index* (RVSI) como medida de severidad de la recuperación retardada inducida por falla [41]. Asimismo, en el ámbito de evaluación de margen/áreas de control de tensión, se han planteado índices agregados como *vcaRVSA*, calculado como suma ponderada de índices *real-time voltage stability assessment* (RVSA) para estimar el estado operativo y el margen a colapso desde la perspectiva de áreas de control de tensión [55].

En sistemas eléctricos de gran escala, el tratamiento de los datos de entrada requiere considerar que los parámetros eléctricos no influyen de manera uniforme en todas las barras: la contribución efectiva de generadores, cargas y dispositivos de compensación se atenúa por la red y depende de la impedancia de interconexión. En consecuencia, una barra percibe el sistema a través de un equivalente eléctrico local, cuyo comportamiento está condicionado por su entorno inmediato y por su “cercanía” eléctrica a las fuentes que aportan rigidez de tensión [22]. En este contexto, la distancia eléctrica puede interpretarse como una medida de dicha cercanía (en términos de impedancia efectiva) y permite justificar esquemas de agregación o ponderación mediante los cuales parámetros globales (por ejemplo, aportes de soporte, reservas o indicadores de fortaleza) se transforman en magnitudes locales “vistas por la barra” [51]. Este tipo de representación resulta especialmente relevante en escenarios con alta penetración de recursos basados en convertidores, donde la topología y la ubicación relativa de los recursos influyen de manera determinante en la respuesta dinámica post-falla [52].

En síntesis, el estado del arte muestra que los modelos de IA para STVS se apoyan principalmente en variables medidas o simuladas del sistema (en muchos casos incluyendo información post-falla) y en salidas definidas como clasificación (estable/inestable) o índices de severidad dinámica. No obstante, se observa que, en general, los enfoques existentes no buscan reconstruir explícitamente la trayectoria completa de la tensión, sino que operan directamente sobre ventanas temporales o sobre indicadores derivados de dichas trayectorias, lo cual puede incrementar las exigencias de datos y procesamiento cuando se evalúan múltiples barras y escenarios en sistemas de gran escala. En este marco, resulta atractivo explorar representaciones más compactas basadas en el estado estacionario pre-falla y en variables que capturen el entorno eléctrico efectivo de cada barra; en particular, el uso de parámetros ponderados mediante distancia eléctrica ofrece una vía conceptualmente consistente para construir equivalentes locales informativos, reduciendo la complejidad espacial del problema y habilitando enfoques orientados a estimar de forma más eficiente la respuesta dinámica de tensión.

2.5. Técnicas de inteligencia artificial

En los últimos años, la aplicación de técnicas de inteligencia artificial ha demostrado un enorme potencial para abordar los problemas asociados a la estabilidad de tensión a corto plazo en sistemas eléctricos de potencia. A diferencia de los métodos tradicionales, que dependen de modelos matemáticos detallados y de un elevado costo computacional, los enfoques basados en IA permiten aprender

directamente de datos históricos y de simulación, capturando relaciones no lineales entre variables del sistema que suelen pasar inadvertidas en análisis convencionales.

Entre las técnicas más empleadas destacan los algoritmos de aprendizaje supervisado, como los árboles de decisión y sus variantes, Random Forest [56] y Extra Trees [57], y las redes neuronales artificiales, en sus distintas arquitecturas: desde los perceptrones multicapas (MLP) [58] hasta configuraciones más avanzadas como las redes recurrentes (RNN, LSTM) [59] y los modelos basados en Transformers [60] para el procesamiento de secuencias y series de tiempo. Estas técnicas han mostrado eficacia tanto en la predicción de condiciones críticas de tensión como en la clasificación de escenarios de inestabilidad, aportando rapidez y precisión en la detección de riesgos operativos. A continuación, se presentan con más detalle las principales técnicas de IA utilizadas para la predicción de estabilidad de SEP. Otros modelos, como Support Vector Machines, k-Nearest Neighbors, modelos de boosting avanzado, redes convolucionales, redes neuronales gráficas o arquitecturas híbridas, también han sido utilizados en problemas de predicción y clasificación en sistemas eléctricos [61], [62]. Sin embargo, no se incluyen en esta revisión para mantener el alcance acotado y enfocado en los modelos más utilizados y representativos de las principales familias de aprendizaje supervisado. En particular, los métodos basados en SVM o k-NN pueden presentar limitaciones de escalabilidad para bases de datos de gran tamaño. Las CNN y GNN requieren una formulación espacial o topológica más específica [63], como se observa en enfoques que combinan redes convolucionales de grafos con LSTM para capturar tanto dependencias espaciales como temporales en STVS [64]. Por su parte, los modelos híbridos o de boosting avanzado pueden ser abordados como extensiones futuras una vez establecida una línea base de comparación [65].

A continuación, se describen las principales técnicas de inteligencia artificial empleadas en este campo, destacando su fundamento, ventajas y aplicaciones en el análisis de estabilidad de tensión a corto plazo.

2.5.1. Random Forest (RF)

Random Forest es un método de aprendizaje supervisado que integra múltiples árboles de decisión para obtener una predicción más robusta [56]. Cada árbol se entrena a partir de muestras aleatorias de las observaciones y en cada partición se considera un subconjunto aleatorio de variables. En la etapa de inferencia (predicción), el modelo agrega las salidas (resultados de predicción) de cada árbol: en problemas de clasificación, se adopta la clase con mayor votación y en problemas de regresión, se toma el valor promedio de todos los árboles (véase la Figura 8). Este mecanismo reduce la varianza del estimador (en comparación con un árbol individual) y ayuda a mitigar sobreajustes, lo que suele traducirse en un mejor desempeño predictivo y más robusto frente a datos ruidosos.




Figura 8: Esquema de Random Forest para modelo de regresión.

El desempeño de un modelo RF depende, entre otros factores, de un conjunto de parámetros, denominados hiperparámetros, que controlan la construcción y agregación de los árboles de decisión. Uno de los principales parámetros es el número de árboles en el bosque ($n_estimators$), que define cuántos modelos individuales participan en la decisión conjunta. En general, mientras más árboles, menor será la variabilidad de las predicciones, aunque aumenta el costo computacional. Un segundo parámetro relevante es la profundidad máxima de cada árbol (max_depth), que determina el nivel de detalle con que se particiona el espacio de datos. Árboles muy profundos pueden aprender patrones muy específicos del conjunto de entrenamiento, lo que puede resultar en un sobreajuste, mientras que árboles poco profundos tienen a capturar solo tendencias generales. Otros parámetros relevantes son $min_samples_split$ y $min_samples_leaf$, que establecen la cantidad mínima de muestras para dividir un nodo y conformar una hoja, respectivamente, evitando particiones sustentadas en un número muy reducido de observaciones. Finalmente, el número máximo de características consideradas en cada división ($max_features$) introduce aleatoriedad en el proceso de construcción de árboles, promoviendo la diversidad entre ellos y evitando que todos utilicen siempre las mismas variables. Un ajuste adecuado de estos hiperparámetros permite balancear precisión, capacidad de generalización y costo computacional, lo que explica la versatilidad de RF en aplicaciones de sistemas eléctricos y en otras áreas.

En el ámbito de la predicción de la estabilidad de tensión a corto plazo, RF ha sido una de las técnicas más utilizadas debido a su capacidad para manejar bases de datos de alta dimensionalidad y con ruido. En [66], se utilizó un clasificador de RF para la evaluación en tiempo real de la estabilidad de tensión de corto plazo. El modelo fue entrenado con series temporales multivariadas de magnitud de tensión, compuestas por mediciones PMU registradas en múltiples barras del sistema antes, durante y después de la contingencia, las cuales fueron transformadas mediante técnicas de representación simbólica. Con esta configuración, se logró una clasificación multiestado del sistema eléctrico, distinguiendo las categorías normal, alerta, emergencia e inestable, con un error inferior al 2%, empleando una ventana post-contingencia de 0,58 s. El modelo permitió anticipar el colapso de tensión rápida (FVC) y una recuperación tardía de la tensión después de la falla (FIDVR). Esto permite, entre otros, diseñar estrategias de control que actúen de manera rápida y evitar, así, el colapso del sistema y mejorar la recuperación una vez despejada la falla. En [67], la técnica se extendió mediante un ensamble ponderado entre RF y una máquina de incremento de gradiente ligera (LightGBM), utilizando como entradas las magnitudes y ángulos de fase de tensión en barras obtenidos de simulaciones dinámicas bajo escenarios N-1 y N-2. La incorporación de un preprocesamiento basado en gradientes permitió atenuar el ruido de las mediciones PMU y mejorar la discriminación de estados inestables. Con ello, el método demostró ser robusto tanto al ruido de los

datos como a cambios en la topología de la red, alcanzando elevados valores de exactitud y F1-score. El modelo fue validado en el sistema IEEE 118-bus y en una red real de 166 barras de 400 y 230 kV. Finalmente, en [68] se abordó el problema de los datos faltantes (*missing data*) en PMUs mediante un modelo de ensamble adaptativo con unidades RF, capaz de ajustar dinámicamente las entradas según el nivel de observabilidad disponible. Este enfoque mantuvo una alta precisión, aún en escenarios con pérdida significativa de mediciones, mostrando tolerancia frente a fallas de observabilidad y variaciones estructurales del sistema. En conjunto, estos resultados consolidan a RF como una técnica altamente efectiva para la evaluación en tiempo real de la STVS, combinando altas tasas de precisión, capacidad de detección temprana de fenómenos críticos y resiliencia frente a condiciones adversas de medición.

2.5.2. Extra Trees (ET)

Extra Trees (Extremely Randomized Trees) [57] es un modelo de aprendizaje supervisado de conjunto basado en múltiples árboles de decisión, similar al Random Forest, pero con un grado mayor de aleatoriedad en el proceso de construcción de los árboles. La principal diferencia radica en que, mientras en RF la mejor división se selecciona entre un subconjunto aleatorio de características, en Extra Trees las características y los puntos de corte se eligen de forma aleatoria. Además, cada árbol suele entrenarse con el conjunto completo de datos, sin aplicar muestreo con reemplazo (*bootstrap*), lo que acelera el entrenamiento y genera una mayor diversidad entre los árboles. En la fase de inferencia, la predicción final se obtiene mediante votación mayoritaria (para problemas de clasificación) o mediante el promedio de las salidas de los árboles (para problemas de regresión), tal como se muestra en la Figura 9.




Figura 9: Esquema del modelo Extra Trees aplicado a un problema de regresión.

Al igual que con RF, el desempeño de Extra Trees depende de los hiperparámetros que controlan la complejidad de cada árbol y el grado de diversidad dentro del conjunto. El número de árboles ($n_{estimators}$) determina cuántos modelos individuales contribuyen a la predicción agregada: un mayor número tiende a estabilizar los resultados, aunque incrementa el costo computacional. La profundidad máxima (max_depth) regula cuán detalladas son las particiones del espacio de datos, de modo que profundidades grandes permiten capturar patrones complejos, pero pueden favorecer el sobreajuste si no se combinan con otros límites. Los parámetros $min_samples_split$ y $min_samples_leaf$ especifican el número mínimo de muestras requeridas para dividir un nodo o formar una hoja, evitando divisiones basadas en muy pocos datos. Por último, el número de características consideradas en cada división ($max_features$) introduce aleatoriedad adicional en la selección de las variables usadas para generar los puntos de corte. Esta mayor aleatoriedad, característica de Extra Trees, potencia la diversidad entre los

árboles y suele traducirse en una mejor capacidad de generalización en problemas de alta dimensionalidad o con ruido, siempre que el conjunto incluya un número suficiente de árboles.

En conjunto, Extra Trees ofrece como principales ventajas la rapidez de entrenamiento, la eficiencia para manejar un gran número de variables y un buen desempeño frente a datos ruidosos o con relaciones no lineales. Como desventaja, el alto grado de aleatoriedad puede generar una mayor variabilidad en las predicciones cuando el número de árboles es reducido, y la interpretación del modelo sigue siendo limitada en comparación con métodos más simples, como un árbol de decisión individual.

2.5.3. Perceptrón multicapa (MLP)

El perceptrón multicapa [58] es un modelo de aprendizaje profundo supervisado que pertenece a la familia de las redes neuronales artificiales (ANN). Su arquitectura está compuesta por una capa de entrada, una o varias capas ocultas y una capa de salida, tal como se muestra en la Figura 10. Cada capa contiene un conjunto de neuronas interconectadas, donde cada conexión posee un peso que se ajusta durante el entrenamiento para mapear la salida con las entradas. El flujo de información avanza de manera directa desde la entrada a la salida (*feedforward*). En cada nodo se aplica una función de activación no lineal que permite capturar relaciones complejas entre variables. El proceso de entrenamiento se basa en el algoritmo de retropropagación del error (*backpropagation*), que ajusta los pesos de las conexiones mediante gradiente descendiente con el fin de minimizar una función de pérdida.




Figura 10: Esquema de un modelo MLP.

Los hiperparámetros de un MLP controlan su capacidad de representación y su comportamiento durante el entrenamiento. En primer lugar, el número de capas ocultas y la cantidad de neuronas en cada capa determinan la complejidad del modelo: arquitecturas más profundas y densas pueden aproximar patrones altamente no lineales, pero también aumentan el riesgo de sobreajuste y el costo computacional. Además, requieren una mayor cantidad de datos de entrenamiento. En segundo lugar, el tipo de función de activación (por ejemplo, *sigmoid*, *tanh* o *ReLU*) influye en la no linealidad introducida y en la propagación del gradiente a lo largo de la red. Adicionalmente, parámetros de optimización como la tasa de aprendizaje, el tamaño del lote (*batch size*) y el número de épocas de entrenamiento definen la forma en que el modelo recorre el espacio de parámetros y la velocidad con que converge. Entre las principales ventajas del MLP se encuentran su versatilidad para aproximar relaciones no lineales y su aplicabilidad tanto a problemas de clasificación como de regresión en múltiples dominios. Como desventaja, puede requerir un elevado costo computacional, presentar riesgo de sobreajuste cuando no se aplican técnicas de regularización y resultar poco interpretable debido a la naturaleza distribuida de sus parámetros.

En el campo de la evaluación de la STVS, los modelos de MLP han mostrado un notable potencial al combinar rapidez de predicción con robustez frente a condiciones adversas. En [69], se propuso un esquema basado en MLP para predecir estabilidad de tensión. A diferencia de muchos enfoques de aprendizaje profundo aplicados a STVS, este método no utiliza información post-falla para realizar la clasificación, sino que se basa en información disponible durante el período de falla. El modelo fue entrenado con más de 17.000 simulaciones dinámicas en los sistemas IEEE 39 y 118 barras, considerando múltiples contingencias de cortocircuito y variaciones en el tiempo de despeje de la falla. Como entradas se utilizaron mediciones directas de PMUs instaladas en barras de carga, capturadas durante la falla. Los resultados evidenciaron que el clasificador MLP alcanzó tasas de precisión superiores al 99% en ambos sistemas de prueba, incluso frente a ruido en las mediciones o pérdida de datos de los PMUs más relevantes, demostrando resiliencia y generalización frente a escenarios de observabilidad limitada.

2.5.4. Recurrent Neural Network (RNN)

Las Redes Neuronales Recurrentes [59] constituyen una arquitectura de aprendizaje profundo diseñada para procesar datos secuenciales o con dependencia temporal. A diferencia de un perceptrón multicapa tradicional, las RNN incorporan conexiones recurrentes que permiten que la información de estados previos influya en el procesamiento de nuevas entradas. Esta retroalimentación interna dota al modelo de una memoria dinámica especialmente útil para abordar problemas de predicción de series temporales, procesamiento de lenguaje natural o, en general, modelado de secuencias. La Figura 11 muestra de manera ilustrativa una RNN, mostrando cómo el estado oculto, asociado a cada instante, se actualiza a partir de la entrada actual y del estado anterior, generando así una salida asociada a cada paso de la secuencia. El entrenamiento se realiza mediante retropropagación a través del tiempo (*backpropagation through time*), un procedimiento que ajusta los pesos considerando dependencias entre múltiples pasos consecutivos.




Figura 11: Representación esquemática de una RNN y su despliegue temporal para una secuencia de entradas $X_1, X_2, \dots, X_T$.

Los hiperparámetros más relevantes de una RNN son el número de capas recurrentes y la cantidad de neuronas por capa, que determinan la complejidad del modelo; la longitud de la secuencia considerada durante el entrenamiento, que fija el horizonte temporal de dependencias que la red puede aprender; y parámetros de optimización como la tasa de aprendizaje, el tamaño del lote y el número de épocas. Sus principales ventajas radican en la capacidad de capturar dependencias temporales y modelar relaciones dinámicas en datos secuenciales, lo que amplía su aplicabilidad a tareas de predicción de demanda, análisis de señales o reconocimiento de voz. No obstante, presentan limitaciones relevantes: tienden a sufrir problemas de desvanecimiento y explosión del gradiente, lo que dificulta el aprendizaje de dependencias de largo plazo. Además, su entrenamiento suele ser computacionalmente más costoso que el de arquitecturas estáticas más simples, como los árboles de decisión.

En el ámbito de la STVS, las redes RNN han demostrado ser una herramienta poderosa para capturar las dependencias temporales en series de tensiones y potencias medidas por PMUs. En [70], se propuso

un esquema basado en RNN tipo LSTM con atención espacial para la evaluación online de la STVS. El modelo emplea como entradas series temporales multivariadas de tensión, potencia activa y potencia reactiva medidas por PMUs en barras de carga, capturadas desde la ocurrencia de la falla y durante la etapa inicial post-falla. La metodología fue validada en el sistema Nordic y en la red de Guangdong, mostrando alta precisión y robustez frente a ruido y pérdida de datos. Por otra parte, en [71] se presenta un modelo de aprendizaje multitarea que combina datos de PMU incompletos con la clasificación de estabilidad, empleando una arquitectura híbrida Transformer-GRU; este esquema mejoró la robustez frente a ventanas de observación cortas y altos niveles de pérdida de datos. Asimismo, se ha demostrado que las variantes de RNN, como LSTM y GRU, ofrecen ventajas claras sobre modelos estáticos al modelar la evolución dinámica de los perfiles de tensión bajo contingencias severas [64].

2.5.5. Long Short-Term Memory (LSTM)

Las redes LSTM son una variante avanzada de las redes neuronales recurrentes [59]. Fueron diseñadas para superar las limitaciones que presentan las RNN tradicionales para aprender dependencias de largo plazo. El aporte fundamental de esta arquitectura consiste en la introducción de una celda de memoria interna y un conjunto de compuertas que regulan el flujo de información, permitiendo retener datos relevantes durante períodos prolongados y atenuar los problemas de desvanecimiento y explosión del gradiente. La Figura 12 muestra el esquema de una celda LSTM, donde se observa el funcionamiento de los distintos componentes que intervienen en la actualización de la memoria y la generación de la salida.




Figura 12: Estructura interna de una celda LSTM.

En esta arquitectura, la compuerta de olvido (f) determina qué parte del estado anterior debe descartarse, la compuerta de entrada (i) regula la incorporación de nueva información y se complementa con la actualización candidata (g), mientras que la compuerta de salida (o) controla qué información de la memoria se utiliza para producir la salida actual. La Figura 12 no representa una red LSTM completa con varias capas, sino la estructura interna de una celda LSTM individual. Una capa LSTM se forma al repetir esta celda a lo largo de la secuencia temporal, mientras que una red profunda puede apilar varias de estas capas, una sobre otra. Esta arquitectura dota a las LSTM de una memoria más estable y flexible en comparación con las RNN simples. En una red LSTM completa, el desempeño depende, además, de parámetros como el número de capas, la cantidad de neuronas por capa, la longitud de la secuencia de entrada, la tasa de aprendizaje y el tamaño del lote. Entre sus principales ventajas se encuentran la capacidad de modelar dependencias temporales de largo alcance, la robustez frente a problemas de gradiente y su amplia aplicabilidad en la predicción de series temporales, el procesamiento de lenguaje natural y el análisis de señales.

En el ámbito de los SEP, las redes LSTM han demostrado una eficacia notable en la predicción y evaluación de estabilidad de tensión a corto plazo (STVS). Diversos estudios han reportado precisiones superiores al 95% en la clasificación de escenarios estables e inestables, utilizando métricas como la exactitud, el área bajo la curva ROC (AUC) y el F1-score para validar su desempeño [59], [64]. La capacidad de estas redes para modelar la evolución temporal de las variables eléctricas posteriores a fallas las convierte en una herramienta idónea para aplicaciones en tiempo real, donde es necesario anticipar comportamientos inestables y activar esquemas de control preventivo, como la desconexión selectiva de cargas o la redistribución de potencia reactiva [72].

2.5.6. Transformer

El Transformer [60] es una arquitectura de aprendizaje profundo diseñada inicialmente para el procesamiento de lenguaje natural, que ha revolucionado el análisis de secuencias gracias al mecanismo de autoatención (*self-attention*). En este esquema, cada elemento de la entrada se relaciona con todos los demás en la secuencia, asignando pesos según su relevancia contextual, de modo que el modelo puede capturar dependencias de corto y largo plazo sin recurrir a estructuras recurrentes. La implementación habitual se organiza en bloques *encoder* compuestos por capas de autoatención multi-cabeza y redes *feed-forward* posicionales, intercaladas con conexiones residuales y etapas de normalización. Esta estructura permite explotar el paralelismo a nivel de secuencia y mejorar la escalabilidad del modelo frente a conjuntos de datos de alta dimensionalidad (véase la Figura 13).




Figura 13: Esquema general de un Transformer.

La Figura 13 muestra una representación general de la arquitectura Transformer, en la que se distinguen sus bloques principales de entrada, codificación posicional, codificación (*encoder*), decodificación (*decoder*) y salida. Esta imagen permite visualizar de manera conceptual el flujo de información dentro del modelo, aunque no detalla explícitamente los hiperparámetros que determinan su configuración interna. En ese sentido, los hiperparámetros de un Transformer influyen en la capacidad de aprendizaje del modelo y su costo computacional. En primer lugar, el número de capas apiladas (*num_layers*) fija la profundidad de la arquitectura: más capas permiten extraer representaciones progresivamente más abstractas, pero también aumentan el riesgo de sobreajuste y el tiempo de entrenamiento. En segundo lugar, la dimensión de las representaciones internas (*d_model*) define el tamaño de los vectores con que se

codifica cada elemento de la secuencia: valores pequeños pueden resultar insuficientes para capturar la complejidad del problema, mientras que dimensiones excesivas aumentan el costo computacional y pueden introducir ruido. El número de cabezas de atención (*num_heads*) controla cuántos mecanismos de atención operan en paralelo en cada capa, permitiendo que el modelo analice simultáneamente distintas relaciones dentro de la secuencia. Por su parte, la dimensión de la red interna de transformación no lineal (*d_ff*) regula la capacidad de procesamiento aplicada a cada posición de la secuencia. Finalmente, las codificaciones posicionales (*positional encoding*) permiten incorporar la posición temporal de cada dato dentro de la secuencia, mientras que técnicas como *dropout* y la normalización por capas (*layer normalization*) contribuyen a mejorar la capacidad de generalización y la estabilidad numérica del entrenamiento.

En el contexto de la estabilidad en sistemas de potencia, los Transformers han comenzado a emplearse para distintas variantes del problema de evaluación de la estabilidad. En [60] se propone un modelo de *Stability assessment Transformer* (StaaT) para la evaluación de la estabilidad de tensión de corto plazo bajo fuertes desbalances de clases, combinado con una red generativa adversaria Wasserstein condicional (CWGAN-GP) para sintetizar muestras de la clase minoritaria. Los resultados obtenidos mostraron una alta precisión y robustez frente a ruido y alta penetración de renovables incluso con razones de desbalance del orden de 100:1. En [73], se implementó un *Vision Transformer* (ViT) para la evaluación en línea de la estabilidad transitoria y la identificación de generadores inestables, a partir de trayectorias temporales medidas por PMUs, las que fueron organizadas como parches bidimensionales. El esquema permitió monitorear la estabilidad en cada instante operativo sin depender de la detección exacta de la falla ni de la desconexión de elementos de red, resultando especialmente útil ante fallas de relés y errores de sincronización. Por último, en [74] se emplea un ViT combinado con selección de características basada en entropía *copula* para la predicción de estabilidad de frecuencia, construyendo entradas tipo imagen a partir de datos de operación de alta dimensión y utilizando un índice de seguridad de frecuencia con distintos niveles de margen (“inseguro”, “relativamente seguro”, “absolutamente seguro”). Este enfoque ha mostrado un alto desempeño para la predicción de estabilidad en sistemas testeados con distintos niveles de penetración no síncrona, manteniendo robustez ante ruido y pérdida parcial de mediciones. En conjunto, estos trabajos posicionan a los Transformers como una alternativa competitiva para la evaluación rápida y precisa de estabilidad en sistemas eléctricos complejos.

2.6. Métricas de desempeño para evaluación de las técnicas de inteligencia artificial

El desempeño de las técnicas de IA se realiza, en general, a partir de métricas de error y de ajuste, complementadas por indicadores de costo computacional. En el contexto de problemas de regresión (como la predicción de tensiones post-falla, índices de robustez de tensión o márgenes de estabilidad) las métricas más empleadas son el error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE), tal como se evidencia en estudios recientes de pronóstico de carga en sistemas de potencia [75], [76], y en trabajos de evaluación de condición y vida útil de equipos de maniobras y relés, donde se comparan algoritmos de RF, Gradient Boosting y XGBoost mediante estos mismos indicadores [77]. Estas medidas permiten cuantificar de manera coherente el desempeño de enfoques clásicos, como los modelos basados en árboles de decisión, y de arquitecturas más recientes, como redes neuronales profundas o modelos tipo Transformer.

Dado un conjunto de N observaciones con valor real y_i y predicción $\hat{y}_i$, el MAE y el RMSE se definen respectivamente como

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

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

En numerosos trabajos, el MAE se utiliza como indicador principal por su interpretación directa en las mismas unidades físicas de la magnitud estudiada (por ejemplo, kV o pu), mientras que el RMSE resulta especialmente útil cuando se busca penalizar con mayor severidad los errores grandes, lo que es relevante en aplicaciones donde desviaciones importantes de tensión pueden comprometer la operación segura del sistema.

En los últimos años, además de las métricas de error, el estado del arte ha incorporado de forma explícita criterios relacionados con los tiempos de entrenamiento y de predicción (inferencia). En particular, la revisión presentada en [78] destaca que las técnicas avanzadas de inteligencia artificial para pronóstico de carga tienden a mejorar las métricas de precisión, pero a costa de arquitecturas más complejas, tiempos de entrenamiento más prolongados y una mayor demanda de recursos computacionales. En este contexto, los modelos de ensamble basados en árboles (como RF, ET) suelen ofrecer un compromiso favorable entre desempeño y tiempo de inferencia, lo que los hace atractivos para análisis masivos de escenarios. En contraste, arquitecturas de redes profundas (como LSTM o Transformer) presentan tiempos de entrenamiento significativamente mayores, pero a cambio ofrecen una mayor capacidad para modelar dependencias temporales y relaciones altamente no lineales. En aplicaciones donde se requiere recalibrar los modelos con frecuencia (por ejemplo, ante cambios en la topología de red o en la matriz de generación), esta diferencia en los tiempos de entrenamiento se vuelve un factor decisivo en la elección del método.

En la literatura reciente se ha destacado que la elección de una técnica de inteligencia artificial no puede basarse únicamente en las métricas de error, sino que debe considerar explícitamente el costo computacional y los tiempos de entrenamiento e inferencia. Por ejemplo, en [76] se propone un modelo profundo para pronóstico de carga que logra mejorar significativamente la precisión respecto de modelos más simples, pero cuyos autores reconocen que los procesos de entrenamiento y optimización son complejos y requieren recursos computacionales elevados, especialmente para datos de gran escala. En el ámbito de la estabilidad de tensión, en [79] se muestra que un esquema basado en XGBoost no solo reduce métricas como RMSE y MAPE frente a otros algoritmos, sino que además resulta más rápido, tanto en la fase de entrenamiento como en la predicción, lo que lo hace adecuado para aplicaciones de evaluación en línea del índice de estabilidad. De forma más general, la revisión presentada en [78] muestra que los modelos avanzados de IA para pronóstico de carga (deep learning, *ensemble learning*, etc.) tienden a mejorar la exactitud, pero a costa de una mayor complejidad y costo computacional, por lo que la selección del modelo debe equilibrar precisión, tiempo de cómputo y recursos de hardware disponibles.

Capítulo 3

Metodología

3.1. Esquema general

La Figura 14 muestra un resumen de la metodología para la obtención de modelos de IA para predecir el desempeño dinámico de la tensión durante contingencias. Como se puede ver de la figura, la metodología consta de cuatro etapas. La primera etapa consiste en obtener una base de datos con diversas condiciones operacionales del SEN en el software Digsilent PowerFactory. Esto requiere, por cada condición de operación, ajustar el modelo oficial del SEN para que los flujos por los elementos de red y las tensiones cumplan con la Norma Técnica de Seguridad y Calidad de Servicio (NTSyCS), que no existan modos inestables y que las simulaciones dinámicas sin falla sean estables y no presenten oscilaciones. En la segunda etapa, se ejecutan simulaciones en el dominio del tiempo para un conjunto de fallas previamente determinadas. Como resultado, por cada punto de operación y falla se obtiene la trayectoria temporal completa de tensión $V(t)$ en las barras de interés y las características (features) que serán utilizadas para entrenar los modelos de IA. En la tercera etapa se integran las características y las series temporales con la evolución de las tensiones durante falla en una base de datos centralizada, la cual es sometida a un preprocesamiento (por ejemplo, normalización de los datos), necesario para asegurar la consistencia de las variables de entrada, mejorar la estabilidad del proceso de entrenamiento y evitar que diferencias de escala entre las variables afecten el desempeño de los modelos de IA. Finalmente, en la cuarta etapa se entrenan y validan distintos modelos de IA, y se comparan sus rendimientos. En el marco de esta tesis se implementaron los siguientes modelos de IA: RF, ET, MLP, RNN, LSTM y Transformer. Estos modelos se seleccionaron porque son los más utilizados en la literatura técnica para predecir estabilidad de SEP y son representativos de las principales familias de aprendizaje supervisado.

El objetivo de implementar distintos modelos es para identificar qué modelo permite estimar de mejor manera la evolución temporal de la tensión durante falla ya que, tal como se mostró en la sección 2, no existe ninguna técnica que supera al resto. La técnica más apta depende de la naturaleza del problema y los datos disponibles.

A continuación, se presenta con más detalle cada una de las etapas metodológicas.




Figura 14: Esquema metodológico propuesto.

3.2. Etapa 1: Generación de base de datos con condiciones operacionales

La base de datos se construye a partir de N escenarios operacionales del SEN (demanda y despacho de los generadores) los que establecen las condiciones de operación con las que se desarrollarán los modelos de IA. Los escenarios debieran considerar distintos niveles de participación de GS y ERV. La selección de escenarios busca representar de la mejor manera las condiciones de operación del SEN en un año y en toda su extensión geográfica (zona norte, centro y sur).

A partir de cada escenario, se selecciona un conjunto N_{bus} de barras ubicadas en subestaciones distribuidas a lo largo del SEN, con el objetivo de evaluar la respuesta dinámica en nodos representativos del sistema de transmisión. Sobre estas barras se definen las contingencias a simular, las cuales corresponden a fallas trifásicas aplicadas de manera uniforme. Para todas las simulaciones se fija el instante de inicio de la falla en $t_f = 1$ s y un tiempo de despeje $t_{cl} = 120$ ms posterior al inicio, coherente con lo establecido por la NTSyCS [80].

Por cada condición de operación, lo primero que se hace es cargar el punto de operación en el modelo oficial del SEN en el software DIGSILENT PowerFactory y ajustar los parámetros para que los flujos por los elementos de red y las tensiones cumplan con la NTSyCS. Una vez logrado esto, el siguiente paso consiste en verificar que no existan modos inestables y que las simulaciones dinámicas sin falla sean estables y no presenten oscilaciones. Este procedimiento asegura que las condiciones iniciales de las simulaciones dinámicas sean reproducibles y que los resultados obtenidos reflejen la respuesta del sistema frente a la contingencia definida. Cabe destacar que este es un proceso iterativo que consume hartos tiempos.

3.3. Etapa 2: Simulación dinámica y cálculo de índices

Con los escenarios operacionales cargados y ajustados en PowerFactory, se ejecutan simulaciones dinámicas en el dominio del tiempo, bajo aproximación RMS, para cada una de las fallas definidas en la etapa 1. Por cada simulación dinámica, se registran las curvas de tensión en un horizonte de 0 a 5 s para cada simulación y caso de estudio. Estas curvas constituyen la salida objetivo principal de la metodología y el insumo central para el entrenamiento de los modelos de IA, que buscan reconstruir la trayectoria de tensión post-falla en base a datos de operación pre-falla. Además, a partir de las mismas simulaciones se calculan indicadores de robustez que se incorporan como características de entrada, sin reemplazar el objetivo principal de predicción basado en la curva completa.

3.3.1. Automatización de simulaciones RMS en PowerFactory

Para asegurar repetitividad, trazabilidad y escalabilidad en la generación de casos, se desarrolló un script en Python que interactúa con PowerFactory mediante su interfaz de automatización. El script ejecuta las simulaciones RMS realizando de manera estandarizada: (i) la carga del escenario operacional, (ii) la verificación de convergencia del punto de operación mediante una ejecución sin eventos, y (iii) la parametrización e inserción del evento de contingencia en la barra bajo análisis, manteniendo condiciones homogéneas entre casos. Finalmente, el flujo ejecuta la simulación en el horizonte definido y extrae/exporta la serie temporal de tensión $V(t)$ (salida objetivo principal del estudio) junto con los metadatos del escenario y de la falla necesarios para la construcción de la base de datos. Esta automatización reduce la intervención manual, minimiza errores de configuración y asegura consistencia entre corridas, condición esencial para generar un volumen elevado de simulaciones destinadas al entrenamiento y validación comparativa de los modelos de IA. Cabe destacar que esta automatización solo es posible gracias a que cada condición de operación fue previamente ajustada, de manera manual, con tal de que los flujos por los elementos de red y las tensiones en las barras cumplan con la NTSyCS, que no existan modos inestables y que las simulaciones dinámicas en el dominio del tiempo sin falla sean estables y no presenten oscilaciones.

3.3.2. Extracción de variables y construcción de atributos

A partir de los resultados obtenidos en las simulaciones dinámicas, se construye una base de datos con las características utilizadas como entradas de los modelos de inteligencia artificial. Estas variables buscan caracterizar tanto el estado operativo global del sistema como la condición eléctrica local de cada barra de análisis. Para ello, se utiliza exclusivamente información asociada al estado estacionario pre-falla y a descriptores eléctricos equivalentes por barra. De este modo, se evita utilizar directamente las trayectorias temporales post-falla como entrada, reservándolas únicamente como salida objetivo del modelo. Los atributos utilizados para entrenar los modelos de IA se clasifican en 3 grupos: i) variables globales independientes de la falla, ii) variables locales independientes de la falla, y iii) variables locales dependientes de la falla.

En primer lugar, las variables globales (i) consideradas corresponden al despacho de potencia activa por tipo de tecnología de generación. Estas variables permiten describir la composición tecnológica del sistema en cada escenario operativo y cuantificar la participación relativa de las distintas familias de recursos energéticos. En particular, se consideran los despachos agregados de ERV (*Dispatch_ERV*), generación sincrónica (*Dispatch_GS*) y unidades basadas en convertidores operando en modos GFL (*Dispatch_GFL*) y GFM (*Dispatch_GFM*), tal como se muestra en la Tabla 2.

Tabla 2: Variables globales de despacho de potencia activa utilizadas como entrada del modelo.

Parámetros	Definición
Dispatch_ERV	Potencia activa despachada por las unidades ERV.
Dispatch_GS	Potencia activa despachada por las centrales GS.
Dispatch_GFL	Potencia activa despachada por las unidades de control GFL.
Dispatch_GFM	Potencia activa despachada por las unidades de control GFM.

Estas variables son ampliamente utilizadas en la literatura técnica y pueden ser relevantes para los modelos de IA, ya que la literatura técnica muestra que el grado de penetración de generación tradicional (GS) y no síncrona impacta en la estabilidad del sistema.

En cuanto a las variables locales independientes de la falla (ii), se construyen atributos equivalentes por nodo, con tal de caracterizar la fortaleza eléctrica local “vista” desde cada barra. Para ello, se utiliza la noción de distancia eléctrica, definida a partir de la matriz de impedancias nodales del sistema. En particular, para cuantificar la cercanía eléctrica entre una barra de análisis i y una barra j , se utiliza la impedancia de Thévenin equivalente entre ambas barras, definida como:

$$Z_{th,ij} = Z_{ii} + Z_{jj} - 2Z_{ij}$$

donde Z_{ij} corresponde a la impedancia mutua entre ambas barras, mientras que Z_{ii} y Z_{jj} representan sus respectivas autoimpedancias. Dado que esta magnitud no se encuentra normalizada, se define el coeficiente de cercanía eléctrica d_{ij} como:

$$d_{ij} = 1 - \frac{Z_{th,i,j}}{Z_{ii} + Z_{jj}} = \frac{2Z_{ij}}{Z_{ii} + Z_{jj}}$$

Para barras con niveles de tensión comparables, donde $Z_{ii} \approx Z_{jj}$, este coeficiente puede aproximarse como:

$$d_{ij} \approx \frac{Z_{ij}}{Z_{ii}}$$

Esta distancia permite ponderar el aporte de las características locales de distintas barras que impactan en la estabilidad de tensión, de acuerdo con su cercanía eléctrica respecto de la barra de análisis. Así, una característica local c_j , asociada a la barra j (por ejemplo, la potencia inyectada por GS o GFL), se incorpora a través de un equivalente local “visto por la barra i ” mediante:

$$c_i^{eq} = \sum_{j \in \mathcal{S}} d_{ij} c_j$$

donde d_{ij} corresponde al peso normalizado asociado a la distancia eléctrica entre i y j y $\mathcal{S}$ corresponde al conjunto de barras consideradas en la construcción del atributo equivalente. La Tabla 3 presenta las características locales cuantificadas mediante este procedimiento. Como se puede ver de la tabla, estas características incluyen potencias equivalentes, el número equivalente de unidades por tecnología y la inercia. Cabe destacar que, de las características presentadas en la Tabla 3, la tensión pre-falla es la única que no es necesario normalizar mediante el procedimiento recién descrito.

Tabla 3: Parámetros eléctricos equivalentes por barra del sistema.

Parámetros	Definición
Tensión [kV]	Valor de tensión pre-falla.
S_{GS} [MVA]	Potencia aparente equivalente de las GS vista por la barra.
NC_{GS}	Número equivalente de unidades síncronas (GS) vistas por la barra.
P_{GFL} [MW]	Potencia activa equivalente de las unidades GFL vista por la barra.
NC_{GFL}	Número equivalente de unidades en modo GFL vistas por la barra.
P_{GFM} [MW]	Potencia activa equivalente de las unidades GFM vista por la barra.
NC_{GFM}	Número equivalente de unidades en modo GFM vistas por la barra.
H [MVAs]	Constante de inercia equivalente vista por la barra.
V_{t0+} [kV]	Tensión estimada al momento de la falla.

Finalmente, las características locales dependientes de la falla utilizadas para entrenar los modelos de IA son la estimación de la tensión inmediatamente luego de ocurrida la falla, V_{t0+} [kV], el SCL y el ISCR. En particular, el SCL y el ISCR permiten representar la rigidez de la barra analizada y el grado de influencia de la generación basada en convertidores en el entorno local de la barra.

Las variables descritas en esta subsección conforman el vector de características de entrada de los modelos de inteligencia artificial. Todas ellas se obtienen a partir de información de estado estacionario pre-falla, de equivalentes eléctricos locales por barra y, cuando corresponde, de atributos asociados a la contingencia. En contraste, las trayectorias temporales de la tensión obtenidas mediante simulaciones RMS, en un horizonte de 5 s, se utilizan exclusivamente como salida objetivo. Esto permite evaluar la capacidad de los modelos para reconstruir la respuesta dinámica de tensión post-falla solo con variables disponibles antes de la falla.

Cabe destacar que este conjunto de variables se seleccionó en base a atributos utilizados en la literatura técnica y a criterios eléctricos relevantes en el desempeño dinámico de la tensión durante falla presentado en el capítulo 2 de esta tesis. La importancia efectiva de cada característica para predecir la evolución temporal de la tensión durante una falla será evaluada posteriormente, a partir de los resultados obtenidos con cada modelo.

3.4. Construcción de la base de datos

La construcción de la base de datos constituye una etapa central de la metodología, ya que permite organizar de manera estructurada y trazable la información generada a partir de las simulaciones dinámicas realizadas en PowerFactory. El objetivo es disponer de un repositorio coherente que relacione explícitamente los escenarios operacionales, las contingencias simuladas, las variables eléctricas de entrada y las trayectorias temporales de tensión utilizadas como salida objetivo de los modelos de inteligencia artificial.

La base de datos se diseña bajo un enfoque relacional, en el cual cada simulación dinámica queda identificada de forma única y vinculada tanto al escenario operativo como a la falla aplicada. Esta organización permite asegurar consistencia, reproducibilidad y flexibilidad en el análisis posterior, así como facilitar los procesos de preprocesamiento, entrenamiento y validación de los modelos.

En términos generales, la base de datos se compone de cuatro bloques principales:

- (i) Escenarios operacionales y despachos energéticos.
- (ii) Contingencias y fallas simuladas.
- (iii) Curvas temporales de tensión.

- (iv) Parámetros eléctricos e índices derivados.

3.4.1. Escenarios operacionales y despachos energéticos

Previo a la incorporación de resultados dinámicos, la base de datos se estructura a partir de los escenarios operacionales, los cuales definen el punto de operación pre-falla desde el cual se evalúa la respuesta dinámica del sistema ante contingencias. Estos escenarios permiten representar distintas composiciones tecnológicas y niveles de despacho, entregando el contexto eléctrico global necesario para interpretar los resultados dinámicos posteriores.

La Tabla 4 presenta la estructura de la base de datos en la cual se recopila información del despacho eléctrico activo bajo distintos escenarios operativos. Cada uno de los registros corresponde a un escenario único, identificado por un código (*Id_op*) y asociado a un nombre de base de dato (*Name_bdd*) y de operación (*Name_op*). A partir de esta clasificación, se consignan los valores de despacho activo expresados en megavatios (MW), diferenciados según la naturaleza de la fuente o estrategia de control considerada. En particular, se distinguen el despacho total de energías renovables variables (*Dispatch_ERV*), de generación sincrónica (*Dispatch_GS*), así como los despachos provenientes de convertidores bajo esquemas de control GFL (*Dispatch_GFL*) y GFM (*Dispatch_GFM*). Este bloque de información permite cuantificar la participación relativa de cada familia tecnológica y constituye una entrada operativa global utilizada posteriormente en el vector de características de los modelos de IA.

Tabla 4: Base de datos de despachos energéticos por tipo de controlador y escenario operativo.

Id_op	Name_bdd	Name_op	Dispatch_ERV	Dispatch_GS	Dispatch_GFL	Dispatch_GFM
PF_0001	name_bdd_1	name_op_1	4300,71	4008,83	4300,7	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
PF_nnnn	name_bdd_z	name_op_x	13423,0	4279,4	12920,5	511,5

3.4.2. Contingencias y fallas simuladas

Una vez definidos los escenarios operacionales, la base de datos incorpora un segundo bloque destinado a describir de forma estructurada las contingencias aplicadas en cada simulación. Este bloque permite caracterizar las perturbaciones que originan la respuesta dinámica de tensión y asegurar la trazabilidad entre escenario, falla y resultados dinámicos.

La Tabla 5 presenta la estructura de la base de datos correspondientes a fallas simuladas en cada escenario operativo definido previamente. Esta información constituye un insumo esencial para el análisis dinámico, ya que permite representar de forma sistemática las perturbaciones a las que se somete el sistema eléctrico. Cada registro de la tabla corresponde a una simulación particular de falla, identificada mediante un código único (*Id_sim*) y asociada a un escenario operativo a través de identificador común (*Id_op*). La descripción de las columnas incluye, entre otros, el identificador interno de falla (*Fault_id*), el tipo de elemento en que se aplica (*Fault_type*) y el nombre del elemento afectado (*Faulted_element*). Además, se consignan parámetros técnicos relevantes como la distancia de aplicación (*Distance_to_fault*), la reactancia de falla (*X_fault*), la tensión nominal del punto de estudio (*Voltage*), así como los instantes de ocurrencia (*Time_fault*) y despeje (*Time_clearance*). Esta organización permite reproducir de forma consistente las condiciones de simulación y proporciona atributos explícitos de la contingencia que pueden incorporarse como variables adicionales en los modelos de IA.

Tabla 5: Base de datos de fallas simuladas por escenario operativo.

Id_op	Id_sim	Fault_id	Fault_type	Faulted_element	Distance_to_fault	X_fault	Voltage	Time_fault	Time_clearance
PF_0001	PF_0001_0001	i_shc_0	busbar	name_busbar	0	0	220	1	1,12
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	PF_0001_mmmm	i_shc_1	busbar	name_busbar	0	5	500	1	1,12
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
PF_nnnn	PF_nnnn_0001	i_shc_0	busbar	name_busbar	0	0	220	0,5	0,62
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	PF_nnnn_mmmm	i_shc_0	busbar	name_busbar	0	10	220	1	1,12

3.4.3. Curvas temporales de tensión

El núcleo temporal de la base de datos está constituido por las curvas de tensión obtenidas a partir de las simulaciones RMS. Estas curvas representan la respuesta dinámica completa del sistema ante cada contingencia y constituyen la referencia física frente a la cual se evalúa el desempeño de los modelos predictivos.

La Tabla 6 presenta la estructura de la base de datos que contiene la evolución de la tensión durante la falla. Cada registro corresponde a un instante de tiempo dentro de una simulación específica, identificada por *Id_sim* y asociada a su escenario operacional mediante *Id_op*. Las columnas incluyen el tiempo de simulación y el valor de la tensión en la barra de interés, expresado en kV, para todo el horizonte temporal considerado. Tal como se indicó en la sección anterior, estas trayectorias temporales se utilizan exclusivamente como salida objetivo de los modelos de inteligencia artificial, permitiendo evaluar su capacidad para reconstruir la evolución dinámica de la tensión.

Tabla 6: Base de datos de curvas de tensión por simulación.

Id_op	Id_sim	Time [s]	Voltage [kV]
PF_0001	PF_0001_0001	0,000	220,8
		0,001	220,8
		⋮	⋮
		5,000	220,6
⋮	⋮	⋮	⋮
PF_nnnn	PF_nnnn_mmmm	0,000	220,1
		0,001	220,1
		⋮	⋮
		5,000	220,3

3.4.4. Parámetros eléctricos e índices derivados

La base de datos incorpora un bloque destinado a almacenar parámetros eléctricos e indicadores derivados de cada simulación. Estos indicadores permiten caracterizar la fortaleza eléctrica del sistema y el entorno local de cada barra bajo el escenario y contingencia considerados.

La Tabla 7 presenta la estructura de la base de datos de parámetros e indicadores de desempeño. Cada registro se asocia a una simulación específica mediante los identificadores *Id_op* e *Id_sim*, e incluye los distintos parámetros calculados a partir del estado pre-falla, de equivalentes eléctricos locales y de magnitudes derivadas de la simulación. Estos indicadores se emplean como variables explicativas auxiliares o como herramientas de análisis e interpretación de resultados, pero no constituyen la variable objetivo del problema de predicción, la cual corresponde a la reconstrucción de la curva completa de tensión en el dominio del tiempo.

Tabla 7: Base de datos con parámetros e indicadores de desempeño por simulación.

Id_op	Id_sim	Index_1	Index_2	...	Index_n
PF_0001	PF_0001_0001	976,54	10,30	...	16,53
	⋮	⋮	⋮	⋮	⋮
	PF_0001_mmmm	1043,51	15,33	...	0,65
⋮	⋮	⋮	⋮	⋮	⋮
PF_nnnn	PF_nnnn_0001	489,06	75,89	...	0,23
	⋮	⋮	⋮	⋮	⋮
	PF_nnnn_mmmm	727,48	19,56	...	16,97

3.5. Entrenamiento y predicción mediante modelos de IA

A partir de la base de datos descrita en la sección 3.4, se construye el conjunto de muestras utilizado para entrenar los modelos de IA. Cada muestra se identifica mediante un identificador de la simulación correspondiente (Id_{sim}) y se vincula con el escenario operacional respectivo mediante el identificador (Id_{op}). Asimismo, cada muestra se representa mediante un vector de características construido a partir de magnitudes del estado estacionario pre-falla, parámetros equivalentes locales por barra (incluyendo aquellos derivados de la distancia eléctrica) y, cuando corresponde, atributos asociados a la contingencia. Todas las variables de entrada se someten a un preprocesamiento uniforme para todas las arquitecturas, que incluye depuración básica de registros, con el fin de asegurar coherencia entre muestras y comparabilidad entre modelos.

El conjunto completo de muestras se particiona en subconjuntos de entrenamiento, validación y prueba utilizando una proporción 75%, 10% y 15%, respectivamente. Esta partición se realiza al comienzo y es única para todos los modelos (RF, ET, MLP, RNN, LSTM y Transformer). El conjunto de entrenamiento y validación se utilizan para ir ajustando los hiperparámetros de cada modelo, incluyendo un proceso de control de sobreajuste. El conjunto de prueba se reserva exclusivamente para la evaluación final del desempeño de cada modelo. Cabe destacar que en el caso de modelos neuronales, los hiperparámetros se ajustan en función del desempeño sobre el conjunto de validación, incorporando mecanismos de regularización cuando corresponde y controlando el sobreajuste mediante criterios como la parada temprana.

Finalmente, el rendimiento de los modelos de IA se evalúa en dos dimensiones: i) tiempos de entrenamiento (tiempo total de ajuste del modelo, incluyendo épocas en redes neuronales o construcción del ensamble en modelos basados en árboles) e inferencia (tiempo requerido para generar la predicción por muestra o por lote, según corresponda) y ii) calidad de las predicciones. En cuanto a la calidad de las predicciones, esta se cuantifica mediante métricas estándar de regresión (MAE y RMSE).

Capítulo 4

Caso de estudio y resultados

En este capítulo se presenta el caso de estudio y los resultados obtenidos. El caso de estudio considerado en este trabajo se construye a partir de un modelo dinámico detallado del SEN, sobre el cual se definen escenarios de operación representativos y se ejecutan simulaciones dinámicas ante contingencias de cortocircuito. El objetivo es disponer de un conjunto de curvas de tensión que permita evaluar la capacidad de distintos modelos de IA para reconstruir la respuesta dinámica de la tensión bajo condiciones operativas realistas. Todos los modelos se implementaron en Python y se entrenaron en un equipo con procesador AMD Ryzen 7 4800H con gráficos Radeon. Adicionalmente, los modelos se entrenaron y validaron utilizando la infraestructura del Laboratorio Nacional de Computación de Alto Rendimiento (NLHPC), para comparar el beneficio de utilizar esta infraestructura, frente al uso de un computador personal.

4.1. Caso de estudio

4.1.1. Escenarios de operación

El punto de partida del caso de estudio corresponde al modelo dinámico del SEN descrito en el capítulo anterior. Sobre este modelo se definió un conjunto de quince escenarios de operación, cada uno de los cuales representa un punto de operación distinto del sistema eléctrico, caracterizado por una combinación específica de GS, ERV y recursos basados en convertidores. Estos escenarios fueron definidos de manera de cubrir condiciones operativas coherentes con la operación real del sistema, permitiendo analizar la respuesta dinámica de la tensión bajo distintos niveles de penetración tecnológica.

Cada escenario se caracteriza por los despachos de potencia activa asociados a cuatro tipos de recursos: GS, ERV y generación basada en inversores que operan en modo GFL y GFM. La Tabla 8 presenta los valores de despacho correspondientes a cada escenario, expresados en MW. En ella, la variable Dispatch_ERV representa la potencia renovable total, mientras que Dispatch_GFL y Dispatch_GFM permiten desagregar dicha potencia según el modo de control de los inversores, cumpliéndose en todos los casos que la potencia renovable total corresponde a la suma de ambas contribuciones.

Tabla 8: Escenarios de operación considerados en el estudio, con los respectivos despachos de potencia activa por tipo de tecnología.

Escenario	Dispatch_ERV	Dispatch_GS	Dispatch_GFL	Dispatch_GFM
1	4300,71	4008,83	4300,71	0
2	824,47	8466,64	824,47	0
3	4289,14	4635,72	4289,14	0
4	13220,54	4492,71	12920,54	300
5	13432,04	4279,40	12920,54	511,5
6	1634,56	6040,51	1634,56	0
7	1634,56	6033,93	1634,56	0
8	5456,48	4252,83	5456,48	0
9	1778,79	6772,51	1778,79	0
10	750,85	6734,68	750,85	0

11	1299,29	6610,29	1299,29	0
12	1389,50	8068,44	1389,50	0
13	5640,00	3963,85	5640,00	0
14	4925,98	4991,08	4925,98	0
15	4904,92	4363,16	4904,92	0

En conjunto, los escenarios considerados abarcan desde estados de operación dominados por generación síncrona, con mayor aporte inercial y de cortocircuito, hasta configuraciones con alta penetración de ERV, en las cuales el comportamiento dinámico del sistema depende en mayor medida de las estrategias de control de los convertidores. Adicionalmente, algunos escenarios incorporan una participación no nula de recursos operando en modo GFM, lo que permite analizar dentro del mismo caso de estudio el efecto de este tipo de control sobre la respuesta dinámica de la tensión. Sobre este conjunto acotado pero representativo de puntos de operación se aplican, de manera sistemática, las contingencias dinámicas descritas en la sección siguiente.

4.1.2. Contingencias analizadas

Las simulaciones dinámicas del caso de estudio se ejecutaron sobre el modelo del SEN bajo los escenarios de operación definidos en la sección anterior, aplicando contingencias de cortocircuito trifásico en un conjunto de 342 barras de subestación de 220 kV distribuidas a lo largo del sistema, abarcando zonas norte, centro y sur. En todos los casos se consideró una falla trifásica aplicada directamente en la barra bajo análisis en $t = 1$ s y un despeje 120 ms después. La ventana de simulación del evento fue de 5 s, con una resolución de 1 ms para el registro de la salida. Este horizonte permite capturar en una misma corrida el estado estacionario previo a la contingencia, la evolución de la tensión durante la falla y su recuperación dinámica posterior, en el marco temporal de interés para la estabilidad de tensión de corto plazo.

Tal como se indicó en la metodología, previo a la aplicación de la contingencia, cada punto de operación fue ajustado de forma tal de que las variables cumplieran con lo especificado por la NTSyCS y que la simulación dinámica sin falla fuera estable. Esto asegura que las trayectorias registradas representen una respuesta dinámica atribuible a la falla y no a problemas de inicialización del sistema. Este criterio asegura consistencia en el conjunto de curvas de tensión empleadas como salida objetivo del caso de estudio.

Las contingencias se aplicaron de forma sistemática sobre los 15 escenarios de operación, manteniendo constantes el tipo de falla y los instantes de aplicación y despeje, de modo que las diferencias observadas en la respuesta dinámica de la tensión se atribuyan al punto de operación y al entorno eléctrico de la barra analizada. En total, el caso de estudio considera 1952 simulaciones dinámicas, obtenidas a partir de la aplicación de contingencias sobre las barras seleccionadas para cada escenario. Esta cantidad no corresponde a una combinación uniforme entre los 15 escenarios y las 342 barras identificadas, debido a que no todas las fallas lograron converger. La Figura 15; **Error! No se encuentra el origen de la referencia.** resume la composición del conjunto de datos en función de la presencia o ausencia de recursos operando en modo GFM, evidenciando que ambos grupos aportan una fracción comparable del total de simulaciones.

A partir de estas 1952 simulaciones dinámicas que conforman la base de datos global, se realizó la partición de datos para el proceso de aprendizaje de los modelos IA. Específicamente, el 75% (1464 simulaciones) se destinó al conjunto de entrenamiento (*training set*) para el ajuste de los parámetros internos de los modelos; el 10% (195 simulaciones) se utilizó como conjunto de validación (*validation set*) para la sintonización de hiperparámetros y la prevención de sobreajuste; y el 15% restante (293

simulaciones) se reservó exclusivamente como conjunto de prueba (*test set*) para evaluar la capacidad de generalización de las técnicas ante escenarios completamente no vistos durante la etapa de entrenamiento.

Porcentaje de datos




Figura 15: Distribución de datos con y sin presencia de GFM.

En conjunto, los escenarios operacionales y las contingencias dinámicas descritas en esta sección definen un caso de estudio amplio y estructurado, diseñado para capturar la diversidad operativa y eléctrica del SEN y para proporcionar una base consistente sobre la cual evaluar la capacidad de los modelos de inteligencia artificial para reconstruir la respuesta dinámica completa de la tensión ante perturbaciones severas.

4.2. Configuración de los modelos de IA

Tal como se indicó en el Capítulo 3, en el marco de esta tesis se implementaron distintos modelos de IA. En esta sección se presenta la configuración de cada uno de los modelos implementados.

4.2.1. Extra Trees

El modelo Extra Trees (ET) se emplea como un método de ensamble basado en árboles de decisión para estimar la trayectoria temporal completa de la tensión. Esta técnica se caracteriza por introducir aleatoriedad tanto en la selección de variables como en los puntos de corte, lo que contribuye a reducir la varianza del modelo y mejorar su robustez frente a perturbaciones en los datos. La configuración adoptada consideró un ensamble de 100 árboles ($n_{\text{estimators}} = 100$) sin restricción explícita de profundidad ($max_depth = None$), permitiendo capturar relaciones altamente no lineales entre las variables de entrada y la respuesta dinámica del sistema, mientras que en cada partición se selecciona un subconjunto aleatorio de atributos definido por $max_features = "sqrt"$. El entrenamiento se realizó sin remuestreo bootstrap ($bootstrap = False$), utilizando el conjunto completo de datos en cada árbol, y se asegura la reproducibilidad mediante la fijación de una semilla ($random_state = 123$). El resto de los hiperparámetros se mantuvo en sus valores por defecto del framework utilizado (véase Anexo 6.1).

4.2.2. Random Forest

El modelo RF se utiliza como un método de ensamble basado en árboles de decisión, cuya predicción se obtiene mediante el promedio de múltiples árboles entrenados con aleatoriedad controlada, permitiendo capturar relaciones no lineales complejas presentes en los datos. En este caso de estudio, el modelo se

configuró con 100 árboles ($n_{\text{estimators}} = 100$) y sin restricción de profundidad ($\text{max_depth} = \text{None}$), mientras que la diversidad entre árboles se aseguró mediante la selección aleatoria de un subconjunto de variables en cada partición, definido por $\text{max_features} = \text{"sqrt"}$. A diferencia de la formulación clásica del método, el entrenamiento se realizó sin muestreo bootstrap ($\text{bootstrap} = \text{False}$), de modo que cada árbol se ajustó utilizando el conjunto completo de entrenamiento, concentrando la aleatoriedad principalmente en la selección de atributos y permitiendo una comparación más consistente con el modelo ET bajo condiciones equivalentes. La reproducibilidad se asegura mediante $\text{random_state} = 123$, manteniéndose el resto de los parámetros en sus valores por defecto del framework (véase Anexo 6.1).

4.2.3. MLP

El modelo MLP se emplea como un enfoque de aprendizaje profundo orientado a reconstruir directamente la trayectoria temporal completa de la tensión a partir de variables disponibles en estado estacionario pre-falla y parámetros equivalentes locales. El problema se formuló como una regresión multisalida donde se predice simultáneamente la serie temporal $\hat{v}(t)$ en el horizonte de análisis (0–5 s), con pasos de 1 ms. La arquitectura implementada se muestra en la Figura 16 y corresponde a una red feed-forward con tres capas ocultas totalmente conectadas de 256, 128 y 64 neuronas, respectivamente, utilizando funciones de activación ReLU para modelar relaciones no lineales entre las variables de entrada y la dinámica de tensión, lo que permite capturar interacciones complejas propias del fenómeno de estabilidad de tensión de corto plazo. Con el objetivo de mejorar la capacidad de generalización y mitigar el sobreajuste, se incorporó regularización mediante dropout, con tasas de 0,2 en las dos primeras capas y 0,1 en la tercera, introduciendo ruido controlado durante el entrenamiento y favoreciendo la robustez del modelo frente a nuevas condiciones operativas. El proceso de entrenamiento se ejecutó con un máximo de 500 épocas e incluyó un criterio de parada temprana (*early stopping*) con una paciencia de 20 épocas, evitando el sobreentrenamiento y reduciendo el costo computacional asociado. El resto de los parámetros se mantuvieron a los valores por defecto, cuyos valores se encuentran disponible en el Anexo 6.2.1.




Figura 16: Arquitectura del modelo MLP utilizado para la reconstrucción de la curva de tensión.

Adicionalmente, bajo la configuración de entrenamiento descrita previamente, se obtuvo la curva de pérdida del modelo MLP para los conjuntos de entrenamiento y validación, la cual se presenta en la Figura 17.




Figura 17: Curva de pérdida de entrenamiento y validación del modelo MLP.

4.2.4. RNN

El modelo RNN se implementó mediante una red recurrente simple (SimpleRNN) orientada a modelar de forma no lineal la relación entre el vector de entrada $\vec{x}$ y la trayectoria temporal de tensión $\hat{v}(t)$, formulando el problema como una regresión multisalida donde se reconstruye la serie completa en el horizonte de análisis, con pasos de 1 ms. La arquitectura utilizada, ilustrada en la Figura 18, considera dos capas recurrentes apiladas: una primera capa de 128 unidades con *dropout* = 0,1 y *return_sequences* = *True*, la cual genera una representación secuencial intermedia preservando la dependencia temporal, seguida de una segunda capa de 64 unidades con *dropout* = 0,1 y *return_sequences* = *False*, que condensa dicha información en un estado oculto final que captura las principales características dinámicas de la respuesta de tensión.

Posteriormente, una capa densa proyecta este estado latente a un vector de dimensión N_t , correspondiente al número de muestras discretas del horizonte temporal considerado, el cual es reordenado mediante una operación de *reshape* para obtener directamente la serie predicha $\hat{v}(t)$ en el intervalo $t \in [0,5]$ s, con una resolución de 1 ms. El entrenamiento se ejecutó con un máximo de 500 épocas e incorporó un criterio de parada temprana (*early stopping*) con una paciencia de 100 épocas, lo que permite evitar el sobreentrenamiento y estabilizar el proceso de ajuste. El resto de los hiperparámetros se mantuvo en sus valores por defecto y se muestran en el Anexo 6.2.273.




Figura 18: Arquitectura del modelo RNN utilizado para la reconstrucción de la curva de tensión.

Adicionalmente, bajo la configuración de entrenamiento descrita previamente, se obtuvo la curva de pérdida del modelo RNN para los conjuntos de entrenamiento y validación, la cual se presenta en la Figura 19.




Figura 19: Curva de pérdida de entrenamiento y validación del modelo RNN.

4.2.5. LSTM

El modelo LSTM se implementó mediante una red recurrente de tipo *Long Short-Term Memory*, diseñada para capturar dependencias temporales de mayor alcance y mitigar problemas asociados a gradientes desvanecidos o explosivos, lo que resulta particularmente relevante en la modelación de la dinámica de tensión post-falla. Al igual que en el caso anterior, el problema se formuló como una regresión multisalida que permite reconstruir directamente la trayectoria $\hat{v}(t)$ en el horizonte de análisis a partir del vector de entrada $\vec{x}$, con una resolución de 10 ms. La arquitectura adoptada, mostrada en la Figura 20, considera dos capas LSTM apiladas: una primera capa de 256 unidades con *dropout* = 0,2 y *return_sequences* = *True*, encargada de generar una representación secuencial enriquecida de la dinámica del sistema, seguida por una segunda capa de 128 unidades con *dropout* = 0,15 y *return_sequences* = *False*, que resume dicha información en un estado oculto final de mayor capacidad representativa en comparación con la RNN simple.




Figura 20: Arquitectura del modelo LSTM utilizado para la reconstrucción de la curva de tensión.

A continuación, una capa densa proyecta este estado a un vector de dimensión N_t , el cual se reordena mediante una operación de *reshape* para obtener la serie predicha $\hat{v}(t)$ en el intervalo $t \in [0, 5]$ s, con resolución de 1 ms, manteniendo consistencia con la formulación adoptada para los demás modelos. El

entrenamiento se realiza con un máximo de 500 épocas e incluye un criterio de parada temprana con una paciencia de 100 épocas, empleando el optimizador Adam con una tasa de aprendizaje de 10^{-3} , lo que permite un equilibrio adecuado entre velocidad de convergencia y estabilidad numérica. El resto de los hiperparámetros se mantuvo en sus valores por defecto del framework utilizado y se presentan en el Anexo 6.2.3. A continuación, bajo la configuración de entrenamiento descrita previamente, se obtuvo la curva de pérdida del modelo LSTM para los conjuntos de entrenamiento y validación, la cual se presenta en la Figura 21.




Figura 21: Curva de pérdida de entrenamiento y validación del modelo LSTM.

4.2.6. Transformer

El modelo Transformer se implementó bajo una configuración *encoder-only*, orientada a mapear el vector de características del estado pre-falla hacia la reconstrucción completa de la trayectoria temporal de tensión $\hat{v}(t)$, formulando el problema como una regresión multisalida en el dominio temporal. La entrada del modelo corresponde a un tensor de dimensión $(1 \cdot n_{in})$, donde n_{in} representa el número de variables de entrada, el cual es proyectado a un espacio latente de dimensión $d_{model} = 128$ mediante una capa de *embedding* para variables continuas (*RegEmbedding*), incorporando adicionalmente codificación posicional con el objetivo de preservar la estructura interna de la representación.

Sobre esta representación se apilan múltiples capas de encoder ($num_{layers} = 4$), cada una compuesta por un bloque de autoatención multi-cabeza (*Multi-Head Attention*) con $num_{heads} = 4$, seguido de una red *feed-forward* de dimensión $d_{ff} = 128$, incorporando conexiones residuales, normalización y regularización mediante *dropout* con tasa $dropout_{rate} = 0,1$, lo que permite capturar dependencias globales entre las variables de entrada y mejorar la capacidad de representación del modelo frente a relaciones complejas no locales.

La salida del encoder es posteriormente aplanada (*Flatten*) y proyectada mediante una capa densa a un vector de dimensión $N_t \cdot n_{out}$, donde N_t corresponde al número de pasos temporales a predecir y n_{out} al número de variables objetivo; dicho vector es reordenado mediante una operación de *reshape* para obtener la salida $\hat{V}(t) \in \mathbb{R}^{N_t \times n_{out}}$, correspondiente a la trayectoria temporal estimada en el horizonte de análisis. El entrenamiento se realizó utilizando el optimizador Adam con una tasa de aprendizaje de 10^{-4} , considerando un máximo de 500 épocas e incorporando un criterio de parada temprana (*early stopping*) con una paciencia de 100 épocas, manteniéndose el resto de los hiperparámetros en sus valores por defecto del framework utilizado (véase Anexo 6.2.4). A continuación, bajo la configuración de entrenamiento descrita previamente, se obtuvo la curva de pérdida del modelo Transformer para los conjuntos de entrenamiento y validación, la cual se presenta en la Figura 22.




Figura 22: Curva de pérdida de entrenamiento y validación del modelo Transformer.

4.3. Resultados de predicción y desempeño global de los modelos

La Tabla 9 presenta los valores de MAE y RMSE obtenidos para cada modelo, segmentados en los intervalos *pre-fault*, *fault-on* y *post-fault*, además del horizonte completo de 5 s (5001 muestras temporales). Estas métricas fueron evaluadas sobre el conjunto de prueba, correspondiente al 15% de las 1952 simulaciones RMS consideradas en este estudio, las cuales representan escenarios operacionales heterogéneos del Sistema Eléctrico Nacional. Esta desagregación temporal permite analizar el desempeño de los modelos bajo distintos regímenes dinámicos, diferenciando entre condiciones cercanas al equilibrio previo a la contingencia, la transición abrupta durante la falla y la fase de recuperación posterior, lo que resulta clave para evaluar su capacidad de representar fenómenos de estabilidad de tensión de corto plazo.

Tabla 9: Desempeño de los modelos en términos de MAE y RMSE para la reconstrucción de la trayectoria temporal de tensión, evaluado en distintos regímenes dinámicos (*pre-fault*, *fault-on* y *post-fault*) y en el horizonte completo de 5 s, sobre el conjunto de prueba (15% de las simulaciones), correspondiente a escenarios no utilizados durante el entrenamiento.

Modelo	MAE				RMSE			
	Pre-fault	Fault-on	Post-fault	Total	Pre-fault	Fault-on	Post-fault	Total
ET	0,35	9,47	0,86	0,97	0,74	15,98	2,10	3,10
RF	0,34	7,59	0,81	0,88	0,78	14,81	1,94	2,88
MLP	0,62	7,31	1,45	1,42	0,92	17,05	3,18	3,87
RNN	0,55	7,67	1,48	1,44	0,87	16,17	3,16	3,76
LSTM	0,40	7,94	1,51	1,44	0,79	18,86	3,53	4,28
Transformer	0,78	5,56	1,01	1,07	1,08	19,44	2,18	3,60

En términos globales, el modelo Random Forest presenta el mejor desempeño promedio en la reconstrucción de la trayectoria completa de tensión, alcanzando el menor MAE total (0,88 kV) y también el menor RMSE total (2,88 kV). Le sigue el modelo Extra Trees, con valores de 0,97 kV y 3,10 kV, respectivamente, mientras que el Transformer se posiciona como la mejor arquitectura neuronal en términos agregados, con un MAE total de 1,07 kV y un RMSE total de 3,60 kV. En contraste, los modelos MLP, RNN y LSTM exhiben errores globales más elevados, particularmente en RMSE, lo que sugiere una menor robustez frente a desviaciones de mayor magnitud. En conjunto, estos resultados indican que los métodos basados en ensamblajes de árboles logran capturar de forma más efectiva la relación no lineal entre los descriptores pre-contingencia y la evolución temporal de la tensión, aun sin incorporar explícitamente una estructura secuencial en la entrada.

El análisis por intervalos revela un comportamiento consistente con la naturaleza física del fenómeno. En el régimen *pre-fault*, todos los modelos presentan errores reducidos, con valores de MAE inferiores a 0,8 kV y RMSE cercanos o inferiores a 1,1 kV, lo que confirma una adecuada reconstrucción de condiciones próximas al equilibrio previo a la contingencia. En contraste, el intervalo *fault-on* concentra los mayores errores en todas las arquitecturas, reflejando la mayor dificultad para representar la caída abrupta de tensión durante la falla. En esta etapa, el Transformer alcanza el menor MAE (5,56 kV), lo que sugiere una buena capacidad para aproximar la profundidad media de la caída de tensión. Sin embargo, el menor RMSE en este mismo intervalo corresponde a Random Forest (14,81 kV), indicando un mejor control de errores de mayor magnitud. Este resultado sugiere que, aunque el Transformer logra una representación promedio más ajustada del evento transitorio, Random Forest mantiene una respuesta más robusta frente a casos más severos o de mayor dispersión.

En el régimen *post-fault*, los errores disminuyen de forma importante respecto del intervalo de falla, lo que indica que los modelos son capaces de reproducir de manera razonable la dinámica de recuperación. En esta etapa, Random Forest vuelve a destacar con el menor MAE (0,81 kV) y RMSE (1,94 kV), seguido de cerca por Extra Trees. Por el contrario, LSTM presenta el peor desempeño en este intervalo, con un MAE de 1,51 kV y un RMSE de 3,53 kV, lo que sugiere mayores dificultades para reproducir con precisión la trayectoria posterior al despeje de la falla. En términos generales, los resultados muestran que la mayor complejidad del problema se concentra en la etapa *fault-on*, mientras que tanto el estado previo como la recuperación posterior son representados con menor error por la mayoría de las arquitecturas.

Finalmente, la comparación conjunta entre MAE y RMSE muestra una tendencia coherente a lo largo de los distintos intervalos, confirmando que los modelos con mejor desempeño promedio también tienden a mantener un mejor control sobre errores de mayor magnitud. En particular, Random Forest exhibe el comportamiento más equilibrado y robusto entre todos los regímenes dinámicos analizados, lo que lo posiciona como la alternativa más consistente para la reconstrucción global de trayectorias temporales de tensión. En conjunto, estos resultados respaldan la validez de la formulación de regresión multisalida adoptada y muestran que la calidad informativa de los descriptores pre-falla permite reconstruir con adecuada precisión tanto la caída inicial como la evolución posterior de la tensión, aun frente a escenarios operacionales heterogéneos del SEN.

4.4. Análisis cualitativo de la reconstrucción de la señal

Con el fin de complementar el análisis cuantitativo, en esta subsección se comparan trayectorias de tensión reales y predichas para un caso representativo del conjunto de prueba.

La siguiente figura muestra los resultados de predicción de RF para tres casos: la mejor predicción (menor error), una predicción con un error promedio y la peor predicción.






Figura 23: Reconstrucción de la trayectoria de tensión con RF para tres casos: el caso con el menor error (arriba), el caso con un error promedio (al centro) y el caso con el peor error (abajo).

Como se puede ver de la figura anterior, RF logra predecir con bastante precisión la evolución de la tensión durante falla, incluso en los peores casos. Cabe destacar que el peor caso es bastante similar al caso promedio. La principal diferencia es que el modelo no logra predecir con exactitud el valor final de la tensión, lo que repercute negativamente en los valores estadísticos. Los valores MAE/RMSE de la mejor

predicción, la predicción con un error promedio y la peor predicción fueron (todos los valores en kV): 0,003/0,007 (mejor predicción), 0,98/1,14 (caso promedio) y 2,32/2,95 (peor caso), respectivamente.

A modo ilustrativo, a continuación se muestran los resultados obtenidos por LSTM, también para tres casos: la mejor predicción, una predicción con un error promedio y la peor predicción. Como se puede ver de las figuras, al igual que con RF, LSTM mostró un buen desempeño en reconstruir la tensión durante la falla. El peor caso en cuanto a exactitud en la predicción fue porque el modelo no logró reproducir las oscilaciones del sistema una vez despejada la falla. Sin embargo, el modelo logró predecir con bastante exactitud el valor de la tensión inmediatamente después de despejada la falla. Los valores MAE/RMSE de la mejor predicción, la predicción con un error promedio y la peor predicción fueron (todos los valores en kV): 0,213/0,459 (mejor predicción), 1,41/2,11 (caso promedio) y 3,65/4,74 (peor caso), respectivamente.






Figura 24: Reconstrucción de la trayectoria de tensión con LSTM para tres casos: el caso con el menor error (arriba), el caso con un error promedio (al centro) y el caso con el peor error (abajo).

La Figura 25 muestra la predicción de la tensión en el horizonte completo de 5 s por Transformer, LSTM y RF, para un caso con el error promedio. La Figura 26 muestra un acercamiento del intervalo transitorio comprendido entre la ocurrencia de la falla y la recuperación inicial posterior a su despeje. Esta comparación permite evaluar no solo la precisión global de los modelos, sino también su capacidad para representar fenómenos dinámicos rápidos asociados a la caída de tensión y a la transición post-falla.




Figura 25: Reconstrucción de la trayectoria de tensión para un caso representativo, comparando la señal real con las predicciones de los modelos RF, LSTM y Transformer en el horizonte completo de análisis.

A nivel global, se observa que los tres modelos reproducen adecuadamente la estructura general del evento, identificando correctamente tanto el régimen previo a la contingencia como la ocurrencia de la falla, el despeje y la posterior convergencia hacia un nuevo estado de operación. En particular, fuera del intervalo transitorio más severo, las predicciones presentan una alta cercanía con la señal real, lo que indica que las arquitecturas evaluadas logran capturar de forma satisfactoria la evolución general de la trayectoria de tensión. No obstante, también se aprecia que las mayores discrepancias se concentran en las inmediaciones del evento dinámico, especialmente en la profundidad de la caída, la magnitud del

sobreimpulso posterior y la forma de la recuperación temprana. Esto es consistente con lo observado en el análisis cuantitativo, donde el intervalo *fault-on* concentra los mayores errores.




Figura 26: Acercamiento de la reconstrucción en el intervalo transitorio, destacando diferencias en la representación de la caída de tensión, el sobreimpulso posterior al despeje de la falla y la recuperación inicial.

Desde una perspectiva cualitativa, las figuras muestran que la dificultad principal del problema no radica en reproducir estados cuasi estacionarios, sino en representar con precisión la dinámica rápida inducida por la contingencia. En este contexto, el Transformer destaca por su mayor sensibilidad frente a variaciones abruptas de la señal, lo que le permite aproximar mejor la profundidad de la caída y el sobreimpulso posterior. No obstante, esta mayor capacidad de ajuste local puede venir acompañada de una respuesta algo menos amortiguada en la etapa inmediata de recuperación. Por su parte, RF exhibe una reconstrucción más regular y estable del tramo posterior al despeje, aunque a costa de suavizar parte de la severidad del transitorio. El comportamiento de LSTM sigue una tendencia similar, aunque con una aproximación intermedia entre ambos extremos. Así, el análisis visual confirma que las fortalezas relativas de cada modelo dependen del régimen dinámico considerado, lo que refuerza la conveniencia de complementar las métricas agregadas con una inspección cualitativa de trayectorias representativas.

4.5. Eficiencia computacional

La Tabla 10 presenta los tiempos de entrenamiento e inferencia obtenidos para los modelos evaluados, permitiendo cuantificar el costo computacional asociado a cada arquitectura tanto en la etapa offline de ajuste como en la etapa de predicción. Esta comparación resulta relevante para evaluar la viabilidad operativa del enfoque propuesto, particularmente en aplicaciones que requieren el análisis masivo de contingencias bajo restricciones de tiempo.

Tabla 10: Tiempos de entrenamiento e inferencia de distintos modelos.

Modelo	Tiempo de entrenamiento [s]	Tiempo de inferencia [ms]
Extra Trees	30,10	0,041
Random Forest	60,94	0,055
MLP	221,07	1,111
RNN	315,18	1,029
LSTM	366,94	1,072
Transformer	2451,24	1,289

En términos de entrenamiento, se observan diferencias significativas entre las arquitecturas evaluadas. El modelo Transformer presenta el mayor costo computacional, con un tiempo de entrenamiento de 2451,24 s, superando ampliamente al resto de los enfoques. Este valor es aproximadamente un orden de magnitud superior al de los modelos recurrentes y muy superior al de los métodos basados en ensamblajes de árboles, cuyos tiempos de entrenamiento corresponden a 30,10 s para Extra Trees y 60,94 s para Random Forest. No obstante, este costo se asocia a una etapa de ajuste realizada offline, por lo que no compromete directamente la factibilidad operativa del enfoque en fase de aplicación. En contraste, los tiempos de inferencia son muy reducidos para todos los modelos, manteniéndose en el orden de los milisegundos o incluso fracciones de milisegundo. En particular, Extra Trees y Random Forest presentan los menores tiempos de predicción, con 0,041 ms y 0,055 ms, respectivamente, mientras que las arquitecturas neuronales registran valores entre 1,029 ms y 1,289 ms. Estos resultados muestran que, aunque existen diferencias importantes en el costo de entrenamiento, la etapa de inferencia resulta extremadamente rápida en todos los casos.

Al comparar estos tiempos con una simulación RMS convencional en PFD, cuyo tiempo de ejecución es del orden de 300 s por contingencia, se evidencia una reducción muy significativa del costo computacional. Considerando, por ejemplo, el modelo Extra Trees, el factor de aceleración respecto de la simulación convencional es del orden de varios millones, lo que pone de manifiesto la magnitud de la mejora alcanzada en términos de rapidez de evaluación. En conjunto, estos resultados confirman que la reconstrucción de trayectorias de tensión mediante modelos de aprendizaje automático permite disminuir drásticamente los tiempos de cálculo, manteniendo al mismo tiempo niveles de error competitivos. En este sentido, el enfoque propuesto resulta especialmente atractivo para aplicaciones que requieren el análisis masivo de contingencias o esquemas de apoyo a la operación en escenarios donde la rapidez de respuesta constituye un requisito fundamental.

4.6. Discusión técnica

Los resultados obtenidos evidencian que el desempeño de los modelos no depende exclusivamente de la complejidad de la arquitectura, sino en gran medida de la capacidad de los descriptores de entrada para capturar información físicamente relevante del sistema previo a la contingencia. En particular, los modelos basados en ensamblajes de árboles, y especialmente RF, alcanzan el mejor desempeño global en términos de MAE y RMSE, lo que sugiere que las relaciones no lineales entre las variables pre-falla y la trayectoria temporal de tensión pueden ser representadas eficazmente mediante particiones del espacio de características, sin requerir una modelación explícita de dependencias secuenciales. Este comportamiento resulta consistente con la naturaleza estructural del problema, donde indicadores como la fortaleza eléctrica local, la condición operativa y el acoplamiento eléctrico aportan información suficiente para anticipar, al menos en buena medida, la respuesta dinámica posterior del sistema.

Por otra parte, las arquitecturas neuronales más complejas no muestran una ventaja global sistemática frente a los métodos basados en árboles, aunque sí exhiben fortalezas específicas en ciertos regímenes dinámicos. En particular, el Transformer presenta una mejor capacidad para reproducir la severidad del transitorio durante el intervalo *fault-on*, capturando con mayor fidelidad la profundidad de la caída y la transición abrupta asociada al despeje de la falla. Sin embargo, esta mejora local no se traduce en un mejor desempeño agregado sobre el horizonte completo, donde RF mantiene un comportamiento más equilibrado y robusto. Esto sugiere la existencia de un compromiso entre precisión local del transitorio y estabilidad global de la reconstrucción, en el cual arquitecturas más expresivas pueden representar mejor los eventos dinámicos rápidos, pero no necesariamente optimizan el error total de la trayectoria.

Desde el punto de vista computacional, esta conclusión adquiere aún mayor relevancia. Los modelos basados en árboles no solo presentan los mejores resultados globales de reconstrucción, sino también los menores tiempos de entrenamiento e inferencia, lo que los posiciona como la alternativa más conveniente para esquemas de análisis masivo de contingencias. En este contexto, la formulación del problema como una regresión multisalida a partir de variables exclusivamente pre-falla demuestra ser un enfoque robusto, eficiente y escalable, capaz de reconstruir con adecuada precisión la dinámica de tensión de corto plazo y, al mismo tiempo, reducir drásticamente el costo computacional respecto de la simulación RMS convencional.

Capítulo 5

Conclusiones

Los resultados obtenidos a lo largo de este capítulo permiten establecer que la reconstrucción de la trayectoria temporal completa de la tensión a partir de variables pre-falla y descriptores eléctricos locales constituye un problema abordable con un alto nivel de precisión mediante modelos de aprendizaje automático. En particular, las métricas obtenidas muestran que la información contenida en dichos descriptores resulta suficiente para capturar no solo la magnitud de la caída de tensión asociado a la contingencia, sino también la evolución dinámica posterior de la señal. Esto respalda la hipótesis central del trabajo, según la cual variables de estado previas al evento, junto con indicadores de robustez eléctrica local, contienen información predictiva relevante sobre la respuesta transitoria del sistema.

En términos de desempeño global, el modelo Random Forest alcanza los mejores resultados tanto en MAE como en RMSE sobre el horizonte completo de análisis, lo que evidencia una alta capacidad para reconstruir la trayectoria de tensión de forma precisa y robusta. Le siguen Extra Trees y, entre las arquitecturas neuronales, el Transformer, mientras que modelos como MLP, RNN y LSTM presentan errores globales mayores. Estos resultados sugieren que, para el problema abordado, la relación entre las variables de entrada y la respuesta dinámica del sistema puede representarse eficazmente mediante modelos basados en particiones no lineales del espacio de características, sin requerir explícitamente una estructura secuencial en la entrada. En este sentido, la buena respuesta alcanzada por los métodos basados en árboles refuerza la idea de que los indicadores de robustez y acoplamiento eléctrico utilizados logran encapsular una fracción importante de la dinámica subyacente del sistema.

No obstante, el análisis cualitativo mostró que las fortalezas de los modelos no son uniformes en todos los regímenes dinámicos. En particular, el Transformer presenta una mejor capacidad para capturar la severidad del transitorio en el intervalo *fault-on*, reproduciendo con mayor fidelidad la profundidad de la caída y la transición abrupta asociada al despeje de la falla. Sin embargo, esta ventaja local no se traduce en un mejor desempeño global, ya que Random Forest mantiene un comportamiento más equilibrado y robusto a lo largo del horizonte completo, especialmente en la etapa *post-fault*. Esto evidencia la existencia de un compromiso entre precisión local del transitorio y estabilidad global de la reconstrucción, sugiriendo que distintas arquitecturas pueden presentar ventajas relativas según el régimen dinámico analizado.

Desde el punto de vista computacional, los resultados muestran una reducción drástica en los tiempos de cálculo respecto de la simulación RMS convencional. Mientras una simulación detallada puede requerir del orden de cientos de segundos por contingencia, los modelos entrenados permiten obtener predicciones en tiempos del orden de milisegundos o incluso fracciones de milisegundo, lo que implica factores de aceleración extremadamente altos. Esta diferencia transforma de manera significativa la factibilidad del análisis masivo de contingencias, abriendo la posibilidad de utilizar este tipo de aproximaciones en aplicaciones de apoyo operativo, análisis rápido de seguridad dinámica o esquemas cuasi en línea. En este contexto, los modelos basados en árboles no solo destacan por su precisión global, sino también por su bajo costo computacional, consolidándose como la alternativa más conveniente dentro del conjunto evaluado.

En conjunto, los resultados obtenidos validan la efectividad del enfoque propuesto tanto desde el punto de vista predictivo como computacional. La formulación del problema como una regresión multisalida sobre la trayectoria temporal completa demuestra ser capaz de reproducir adecuadamente la dinámica de tensión de corto plazo en escenarios operacionales heterogéneos del Sistema Eléctrico Nacional. Así, este trabajo aporta evidencia de que es posible complementar los métodos tradicionales de simulación con herramientas de aprendizaje automático más escalables y eficientes, con potencial para apoyar futuros esquemas de evaluación rápida de estabilidad de tensión en sistemas eléctricos modernos con alta penetración de electrónica de potencia.

5.1. Trabajos futuros

Como línea de trabajo futuro, resulta natural profundizar en la incorporación de información temporal en las variables de entrada, considerando secuencias previas a la contingencia en lugar de un único estado pre-falla. Esto permitiría evaluar en qué medida la inclusión de dinámica previa mejora la representación de transitorios severos, particularmente en el intervalo *fault-on*, donde se concentran las mayores no linealidades y diferencias entre modelos. Asimismo, esta extensión permitiría analizar con mayor justicia el potencial de arquitecturas secuenciales y basadas en atención cuando disponen de entradas coherentes con su estructura.

Adicionalmente, se propone evaluar de manera más sistemática la capacidad de generalización del enfoque frente a escenarios no utilizados durante el entrenamiento, tales como cambios topológicos, variaciones más extremas en la composición de generación, modificaciones en los niveles de cortocircuito o condiciones operativas de mayor severidad. Este análisis permitiría delimitar con mayor claridad el rango de validez del modelo y comprender sus limitaciones en contextos fuera de distribución.

Finalmente, una línea especialmente relevante consiste en extender el enfoque hacia aplicaciones más cercanas al ámbito operativo, por ejemplo mediante esquemas de clasificación rápida de contingencias críticas, estimación de índices de severidad o integración con herramientas de apoyo a la toma de decisiones en seguridad dinámica. En conjunto, estas proyecciones permitirían avanzar desde una prueba de concepto centrada en la reconstrucción de trayectorias hacia una herramienta más robusta, generalizable y útil para estudios operacionales en sistemas eléctricos de gran escala.

Bibliografía

- [1] I. R. E. A. (IRENA), «World Energy Transitions Outlook 2023,» IRENA, 2023.
- [2] IRENA, «Renewable Capacity Highlights 2025,» Abu Dhabi, 2025.
- [3] Coordinador Eléctrico Nacional, «Reporte Energético SEN – Julio 2025,» 2025.
- [4] M. d. E. (Chile), «Plan de Descarbonización: habilitantes para prescindir del carbón en el Sistema Eléctrico Nacional,» 2024.
- [5] P. Kundur, *Power System Stability and Control*, New York: McGraw-Hill Education, 1994.
- [6] C. W. Taylor y J. A. Diaz de Leon II, «Understanding and Solving Short-Term Voltage Stability Problems,» de *IEEE Power Engineering Society Summer Meeting*, Chicago, IL, 2002.
- [7] S. Rizvi, S. Sadanandan y A. Srivastava, «Data-driven short-term voltage stability assessment using convolutional neural networks considering data anomalies and localization,» *IEEE Access*, vol. 9, 2021.
- [8] High Share of Inverter-Based Generation Task Force, «Grid-Forming Technology in Energy Systems Integration,» Energy Systems Integration Group, Reston, VA, 2022.
- [9] R. Hassani, J. Mahseredjian, T. Tshibungu y U. Karaagac, «Evaluation of time-domain and phasor-domain methods for power system transient,» *Electric Power Systems Research*, vol. 212, p. 108335, 2022.
- [10] J. Guest, I. Commerford, N. Modi, S. Saadati, J. C. Alonso y T. Kahingala, «Speeding Up Electromagnetic Transient Simulations for Inverter-Based Resources: Australian experience,» *IEEE Electrification Magazine*, vol. 11, nº 3, pp. 72-80, 2023.
- [11] J. Stiasny y S. Chatzivasileiadis, «Physics-informed neural networks for time-domain simulations: Accuracy, computational cost, and flexibility,» *Electric Power Systems Research*, vol. 224, 2023.
- [12] Z. Y. Dong, Y. Xu, P. Zhang y K. P. Wong, «Using IS to assess an electric power system's real-time stability,» *IEEE Intelligent Systems*, vol. 28, nº 4, pp. 60-66, 2013.

- [13] H. Yang, W. Zhang, J. Chen y L. Wang, «PMU-based voltage stability prediction using least square support vector machine with online learning,» *Electric Power Systems Research*, vol. 160, pp. 234-242, 2018.
- [14] J. Xie y W. Sun, «A Transfer and Deep Learning-Based Method for Online Frequency Stability Assessment and Control,» *IEEE Access*, vol. 9, pp. 75712-75721, 2021.
- [15] Y. Zhang, Z. Y. Dong, R. Zhang y Y. Xu, «A Noise-Tolerant Temporal-Adaptive Approach for Short-Term Voltage Stability Assessment of Power Systems,» de *IEEE Innovative Smart Grid Technologies - Asia*, Singapore, 2018.
- [16] Business Insider España, «How AI can help power grids survive the data center boom,» 2025. [En línea]. Available: <https://www.businessinsider.com/sc/how-ai-enhances-power-grid-resilience-during-data-center-surge>.
- [17] Reuters, «Eletrobras partners with C3 AI to modernize Brazil's power grid,» Reuters Business & Energy, 2025. [En línea]. Available: www.reuters.com/business/energy/eletrobras-partners-with-c3-ai-modernize-brazils-power-grid-2025-08-18/.
- [18] Global Neighbours, «How AI is solving problems in China's energy industry,» Global Neighbours, 2024. [En línea]. Available: www.globalneighbours.org/how-ai-is-solving-problems-in-chinas-energy-industry/.
- [19] Australian Energy Market Operator (AEMO), «2024 System Strength Report,» Australian Energy Market Operator, Australia, 2025.
- [20] T. Lund, H. Wu, H. Soltani, J. G. Nielsen, G. K. Andersen y X. Wang, «Operating Wind Power Plants Under Weak Grid Conditions Considering Voltage Stability Constraints,» *IEEE Transactions on Power Electronics*, 2022.
- [21] National Grid Electricity System Operator (ESO), «Provision of Short Circuit Level Data: A System Operability Framework Document,» Warwick, 2022.
- [22] T. Van C. y C. Vournas, *Voltage Stability of Electric Power Systems*, Boston: Springer, 1998.
- [23] I. Dobson, T. Van Cutsem, C. Vournas y C. L. Demarco, «Voltage Stability Assessment: Concepts, Practices and Tools,» vol. 11, 2002.
- [24] R. Álvarez, C. Rahmann y F. Riveros, «Propuesta normativa para incluir aspectos de fortaleza de red en la NTSyCS,» Universidad de Chile, Santiago, 2025.
- [25] Verband der Netzbetreiber (VDN) e.V. beim VDEW, «TransmissionCode 2007: Network and System Rules of the German Transmission System Operators,» Berlin, 2007.

- [26] N. Hatziargyriou, J. V. Milanović, C. Rahmann, V. Ajjarapu, C. Canizares, I. Erlich, D. Hill, I. Hiskens, I. Kamwa, B. Pal, P. Pourbeik, J. Sanchez- Gasca, A. Stankovi, T. Van Cutsem, V. Vittal y C. Vournas, «Stability Definitions and Characterization of Dynamic Behavior in Systems with High Penetration of Power Electronic Interfaced Technologies,» *IEEE Power & Energy Society Technical Report*, 2020.
- [27] NERC, «Integrating Inverter-Based Resources into Low Short-Circuit Strength Systems,» Atlanta, GA, USA, 2017.
- [28] M. H. Nawir, *Integration of Wind Farms into Weak AC Grids*, Cardiff University: Cardiff, United Kingdom, 2017.
- [29] Y. Zhang, S. Huang, J. Schmall, J. Conto, J. Billo y E. Rehman, «Evaluating System Strength for Large-Scale Wind Plant Integration,» de *IEEE PES General Meeting*, National Harbor, MD, USA, 2014.
- [30] B. Bahrani, M. H. Ravanji, B. Kroposki, D. Ramasubramanian, X. Guillaud, T. Prevost y N. Cutululis, «Grid-Forming Inverter-Based Resource Research Landscape: Understanding the Key Assets for Renewable-Rich Power Systems,» *IEEE Power and Energy Magazine*, vol. 22, nº 2, pp. 18-29, 2024.
- [31] T. Cutsem y C. Vournas, *Voltage Stability of Electric Power Systems*, Springer New York, NY, 1998.
- [32] F. Milano, F. Dörfler, G. Hug, D. Hill y G. Verbič, «Foundations and Challenges of Low-Inertia Systems,» de *Power Systems Computation Conference*, Dublin, Ireland, 2018.
- [33] F. Riveros, R. Álvarez, C. Rahmann y R. Moreno, «Optimal sizing and allocation of Battery Energy Storage for improving voltage robustness,» de *IEEE International Conference on Automation*, Santiago, 2024.
- [34] F. Riveros, «Localización óptima de baterías en sistemas con alta penetración de energías renovables considerando criterios de robustez,» Universidad Técnica Federico Santa María, Valparaíso, Chile, 2024.
- [35] F. Li, B. Chen, Z. Wang y X. Zhang, «Power System Strength Assessment with High Penetration of Inverter-Based Resources,» *Energies*, vol. 12, nº 8, 2019.
- [36] J. Modarresi, E. Gholipour y A. Khodabakhshian, «A comprehensive review of the voltage stability indices,» *Renewable and Sustainable Energy Reviews*, vol. 63, 2016.
- [37] C. Reis y F. P. M. Barbosa, «A Comparison of Voltage Stability Indices,» de *IEEE Mediterranean Electrotechnical Conference*, 2006.

- [38] M. S. S. Danish, T. Senjyu, N. R. Sabory, N. K. y P. Mandal, «A Recap of Voltage Stability Indices in the Past Three Decades,» *Energies*, vol. 12, n° 8, 2019.
- [39] A. Boričić, J. L. Rueda Torres y M. Popov, «Comprehensive Review of Short-Term Voltage Stability Evaluation Methods in Modern Power Systems,» *Energies*, vol. 14, 2021.
- [40] M. H. J. Bollen y S. K. Rönnerberg, «A Weak System Indicator for Power Systems with Power Electronic Converters,» de *IEEE Power Systems Conference and Exposition (PSCE)*, New York, USA, 2004.
- [41] Y. Zhang, Y. Xu, Y. Dong y R. Zhang, «A Hierarchical Self-Adaptive Data-Analytics Method for Real-Time Power System Short-Term Voltage Stability Assessment,» *IEEE Transactions on Industrial Informatics*, vol. 15, n° 1, pp. 74-84, Enero 2019.
- [42] M. Maharjan, A. Ekic, M. Beedle, J. Tan y D. Wu, «Evaluating grid strength under uncertain renewable generation,» *International Journal of Electrical Power & Energy Systems*, 2023.
- [43] H. S. Salama y I. Vokony, «Voltage stability indices—A comparison and a review,» *Computers & Electrical Engineering*, 2022.
- [44] M. Aslanian, M. E. Hamedani-Golshan, H. Haes Alhelou y P. Siano, «Analyzing Six Indices for Online Short-Term Voltage Stability Monitoring in Power Systems,» *Applied Sciences*, 2020.
- [45] L. Liyanarachchi, N. Hosseinzadeh, A. Gargoom y E. M. Farahani, «A new index for the assessment of power system strength considering reactive power injection and interaction of inverter based resources,» *Sustainable Energy Technologies and Assessments*, 2023.
- [46] R. Rosso, X. Wang, M. Liserre, X. Lu y S. Engelken, «Grid-Forming Converters: Control Approaches, Grid Synchronization and Future Trends — A Review,» *Electric Power Systems Research*, vol. 209, 2022.
- [47] J. Matevosyan, B. Badrzadeh, T. Prevost, E. Quitmann, D. Ramasubramanian y H. Urdal, «Grid-Forming Inverters: Are They the Key for High Renewable Penetration?,» *Power and Energy Magazine*, vol. 17, pp. 89-98, 2019.
- [48] ENTSO-E, «High Penetration of Power Electronic Interfaced Power Sources and the Potential Contribution of Grid Forming Converters,» European Network of Transmission System Operators for Electricity, 2020.
- [49] IEEE Power & Energy Society, «Impact of Inverter Based Generation on Bulk Power System Dynamics and Short-Circuit Performance,» IEEE / NERC Task Force, 2018.

- [50] P. Tielens y D. V. Hertem, «The relevance of inertia in power systems,» *Renewable and Sustainable Energy Reviews*, vol. 55, p. 999–1009, 2016.
- [51] P. Cuffe y A. Keane, «Visualizing the Electrical Structure of Power Systems,» *IEEE Transactions on Power Systems*, vol. 32, nº 3, 2017.
- [52] Australian Energy Market Operator, «System Strength in the NEM Explained,» Melbourne, 2020.
- [53] O. Damanik, O. C. Sakinci, G. Grdenic y J. Beerten, «Evaluation of the use of short-circuit ratio as a system strength indicator in converter-dominated power systems,» 2022.
- [54] Y. Xu, R. Zhang, J. Zhao, Z. Y. Dong, D. Wang, H. Yang y K. P. Wong, «Assessing Short-Term Voltage Stability of Electric Power Systems by a Hierarchical Intelligent System,» *IEEE Transactions on Neural Networks and Learning Systems*, vol. 27, nº 8, pp. 1686-1695, 2016.
- [55] A. C. Adewole y R. Tzoneva, «Surrogate-splits ensembles for real-time voltage stability assessment in the presence of missing synchrophasor measurements,» *IET Science, Measurement & Technology*, vol. 11, nº 5, pp. 545-552, 2017.
- [56] L. Breiman, «Random Forests,» *Machine Learning*, vol. 45, 2001.
- [57] P. Geurts, D. Ernst y L. Wehenkel, «Extremely randomized trees,» *Machine Learning*, vol. 63, 2006.
- [58] K. Hornik, M. Stinchcombe y H. White, «Multilayer feedforward networks are universal approximators,» *Neural Networks*, 1989.
- [59] Y. Zhang, Z. Wang, H. Li y J. Chen, «Deep Learning for Short-Term Voltage Stability Assessment of Power Systems,» *Electric Power Systems Research*, vol. 190, pp. 29711 - 29718, 2021.
- [60] Y. Li, J. Cao, Y. Xu, L. Zhu y Z. Y. Dong, «Deep learning based on Transformer architecture for power system short-term voltage stability assessment with class imbalance,» *Renewable and Sustainable Energy Reviews*, 2024.
- [61] M. T. Mossie, T. T. Yetayew, G. T. Bitew, M. G. Yenealem y T. M. Beza, «Machine learning algorithms for voltage stability assessment in electrical distribution systems,» *Scientific Reports*, 2025.
- [62] O. B. Adewuyi, K. A. Folly, D. T. O. Oyedokun y E. I. Ogunwole, «Power System Voltage Stability Margin Estimation Using Adaptive Neuro-Fuzzy Inference System Enhanced with Particle Swarm Optimization,» *Sustainability*, 2022.

- [63] S. Gu, J. Qiao, W. Shi, F. Yang, X. Zhou y Z. Zhao, «Multi-task transient stability assessment of power system based on graph neural network with interpretable attribution analysis,» *Energy Reports*, vol. 9, 2023.
- [64] Z. Wang, G. Li, Y. Xu y M. Zhou, «A short-term voltage stability online prediction method based on graph convolutional networks and long short-term memory networks,» *International Journal of Electrical Power & Energy Systems*, vol. 127, 2021.
- [65] G. Cai, B. Liu, X. Wang, Y. Sun y J. Wang, «Online assessment of short-term voltage stability based on hybrid model-driven and data-driven method,» *International Journal of Electrical Power & Energy Systems*, 2024.
- [66] D. Pinzón y D. G. Colomé, «Real-time multi-state classification of short-term voltage stability based on multivariate time series machine learning,» *International Journal of Electrical Power & Energy Systems*, vol. 108, pp. 402-414, 2019.
- [67] A. H. Babaali y M. T. Ameli, «Weighted ensemble learning for real-time short-term voltage stability assessment with phasor measurements data,» *IET Generation, Transmission & Distribution*, vol. 17, nº 10, 2023.
- [68] Y. Zhang, Y. Xu, R. Zhang y Z. Y. Dong, «A Missing-Data Tolerant Method for Data-Driven Short-Term Voltage Stability Assessment of Power Systems,» *IEEE Transactions on Smart Grid*, vol. 10, nº 5, pp. 5663-5673, 2019.
- [69] M. Shahriyari, A. Safari, A. Quteishat y H. Afsharirad, «A short-term voltage stability online assessment based on multi-layer perceptron learning,» *Electric Power Systems Research*, vol. 223, 2023.
- [70] L. Zhu, J. Zhang y S. Zhao, «Intelligent Short-Term Voltage Stability Assessment via Spatial Attention Rectified RNN Learning,» *IEEE Transactions on Industrial Informatics*, vol. 17, nº 10, 2021.
- [71] T. Luo y X. Jiang, «A Novel Multi-Task Learning Method for Evaluating Short-Term Voltage Stability with Incomplete PMU Measurements,» *Complex & Intelligent Systems*, vol. 9, 2023.
- [72] H. Li, K. Zhang, Y. Zhao y Y. Liu, «Real-Time Short-Term Voltage Stability Assessment using Temporal Convolutional Neural Network,» *Applied Sciences*, vol. 12, 2022.
- [73] J. Fang, C. Liu, L. Zheng y C. Su, «A data-driven method for online transient stability monitoring with vision-transformer networks,» *International Journal of Electrical Power and Energy Systems*, 2023.
- [74] P. Liu, S. Han, N. Rong y J. Fan, «Frequency Stability Prediction of Power Systems Using Vision Transformer and Copula Entropy,» *Entropy*, 2022.

- [75] N. Ahmad, Y. Ghadi, M. Adnan y M. Ali, «Load Forecasting Techniques for Power System: Research Challenges and Survey,» *IEEE Access*, vol. 10, 2022.
- [76] J. Jing, H. Di, T. Wang, N. Jiang y Z. Xiang, «Optimization of power system load forecasting and scheduling based on artificial neural networks,» *Energy Informatics*, vol. 8, 2025.
- [77] M. Murugan, S. Sridhar, R. Lenus, M. Sushith, S. Srithar y R. Sundar, «Random Forest Algorithm based on Life Assessment and Reliability Test Procedures for Relays used in Circuit Breaker Operating Mechanisms,» *International Journal of Electrical and Electronics Research*, vol. 13, nº 3, 2025.
- [78] J. Liu, X. He, K. Li y W. Xue, «A Review of State-of-the-Art AI and Data-Driven Techniques for Load Forecasting,» *Energies*, vol. 18, 2025.
- [79] H. Qin, S. Li, J. Zhang, Z. Rao, C. He, Z. Chen y B. Li, «Online Prediction and Correction of Static Voltage Stability Index Based on Extreme Gradient Boosting Algorithm,» *Energies*, vol. 17, 2024.
- [80] Comisión Nacional de Energía, «Norma Técnica de Seguridad y Calidad de Servicio,» Santiago de Chile, 2025.
- [81] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot y E. Duchesnay, «Scikit-learn: Machine Learning in Python,» *Journal of Machine Learning Research*, vol. 12, 2011.
- [82] scikit-learn developers, «scikit-learn,» [En línea]. Available: <https://scikit-learn.org>.
- [83] Keras, «Dense layer,» [En línea]. Available: https://keras.io/api/layers/core_layers/dense/.
- [84] Keras, «Adam,» [En línea]. Available: <https://keras.io/api/optimizers/adam/>.
- [85] Keras, «Dropout layer,» [En línea]. Available: https://keras.io/api/layers/regularization_layers/dropout/.
- [86] Keras, «SimpleRNN layer,» [En línea]. Available: https://keras.io/api/layers/recurrent_layers/simple_rnn/.
- [87] Keras, «LSTM layer,» [En línea]. Available: https://keras.io/api/layers/recurrent_layers/lstm/.
- [88] Keras, «MultiHeadAttention layer,» [En línea]. Available: https://keras.io/api/layers/attention_layers/multi_head_attention/.

- [89] Keras, «LayerNormalization layer,» [En línea]. Available: https://keras.io/api/layers/normalization_layers/layer_normalization/.
- [90] M. Cuevas, R. Álvarez, C. Rahmann, D. Ortiz, J. Peña y R. Rozas, «Artificial intelligence techniques for dynamic security assessments – a survey,» *Artificial Intelligence Review*, vol. 57, nº 340, 2024.
- [91] S. Adhikari, M. F. Shaaban, A. Gaouda y M. M. A. Salama, «Real-Time Short-Term Voltage Stability Assessment Using a Hybrid Temporal Convolutional Network–Long Short-Term Memory Model,» *Applied Sciences*, 2022.
- [92] M. J. Abbass, R. Lis y W. Rebizant, «Advanced Voltage Stability Assessment in Renewable-Powered Islanded Microgrids Using Machine Learning Models,» *Energies*, 2025.
- [93] J. Cao, M. Zhang y Y. Li, «A review of data-driven short-term voltage stability assessment of power systems: Concept, principle, and challenges,» Jilin, China, 2021.
- [94] P. Duraipandy y D. Devaraj, «On-Line Voltage Stability Assessment using Least Squares Support Vector Machine with Reduced Input Features,» Kanyakumari, India, 2014.
- [95] J. Machowski, J. Bialek y J. Bumby, «Power System Dynamics: Stability and Control,» 2011.
- [96] S. Adhikari, J. Schoene, N. Gurung y A. Mogilevsky, «Fault Induced Delayed Voltage Recovery (FIDVR): Modeling and Guidelines,» de *IEEE Power & Energy Society*, Atlanta, GA, USA, 2020.
- [97] Y. Liu, Y. Lu, H. Wu, R. Guo y D. Gan, «Preventive Control of Transient Voltage Stability Based on Polynomial Approximation of Transient Voltage Stability Index,» de *Power Science and Technology*, Dali, China, 2024.
- [98] European Network of Transmission System Operators for Electricity, «High Penetration of Power Electronic Interfaced Power Sources and the Potential Contribution of Grid Forming Converters,» Brussels, 2020.
- [99] F. Milano, F. Dörfler, G. Hug, D. J. Hill y G. Verbič, «Foundations and Challenges of Low-Inertia Systems,» *IEEE Power and Energy Magazine*, vol. 16, nº 6, 2018.
- [100] North American Electric Reliability Corporation (NERC), «Integrating Inverter-Based Resources into Low Short Circuit Strength Systems,» Atlanta, GA, 2017.
- [101] Keras, «Layer weight initializers,» [En línea]. Available: <https://keras.io/api/layers/initializers/>.

- [102] J. Cao, M. Zhang y Y. Li, «A Review of Data-Driven Short-Term Voltage Stability Assessment of Power Systems: Concept, Principle, and Challenges,» *Mathematical Problems in Engineering*, 2021.

Anexos

6. Configuración de modelos

6.1. Modelos basados en árboles

Los modelos ET y RF, implementados en la librería *scikit-learn* [81], corresponden a métodos de ensamble basados en múltiples árboles de decisión que difieren principalmente en el nivel de aleatoriedad incorporado durante la construcción de los árboles; en este trabajo se emplean los hiperparámetros por defecto definidos en *scikit-learn* [81], los cuales constituyen una configuración estándar ampliamente utilizada como línea base para obtener resultados robustos sin necesidad de ajuste fino inicial, cuyos valores se presentan en la Tabla 11.

Tabla 11: Hiperparámetros por defecto en modelo de árboles (*scikit-learn*) [82].

Hiperparámetro	Extra Trees	Random Forest
n_estimators	100	100
criterion	squared_error	squared_error
max_depth	None	None
min_samples_split	2	2
min_samples_leaf	1	1
min_weight_fraction_leaf	0,0	0,0
max_features	1,0	1,0
max_leaf_nodes	None	None
min_impurity_decrease	0,0	0,0
bootstrap	False	True
oob_score	False	False
n_jobs	None	None
random_state	None	None
verbose	0	0
warm_start	False	False
ccp_alpha	0,0	0,0
max_samples	None	None

6.2. Modelo de redes neuronales

Las redes neuronales artificiales constituyen una familia de modelos de aprendizaje automático diseñados para representar relaciones complejas entre conjuntos de variables a través de estructuras compuestas por múltiples capas y operaciones encadenadas. La forma en que estas capas se organizan da origen a distintas arquitecturas, cada una con capacidades particulares para abordar problemas de aproximación funcional, reconocimiento de patrones, procesamiento secuencial o modelación de dependencias de largo alcance. Entre los elementos estructurales más comunes en este tipo de modelos se encuentran las capas densas, las capas recurrentes, los mecanismos de atención, las operaciones de normalización, las técnicas de regularización y los optimizadores utilizados durante el entrenamiento. A continuación, se presentan configuraciones de referencia para distintas arquitecturas de redes neuronales ampliamente reportadas en la literatura y en la documentación oficial de sus bibliotecas de implementación.

6.2.1. Modelo Multi-Layer Perceptron

La implementación del modelo MLP se realizó mediante TensorFlow/Keras. A diferencia de otras bibliotecas, esta librería no define un conjunto único de hiperparámetros por defecto para una red MLP completa, sino configuraciones predeterminadas a nivel de sus componentes. La capa Dense, por ejemplo, utiliza por defecto activación lineal (`activation=None`), sesgo habilitado (`use_bias=True`), inicialización de pesos *glorot_uniform* e inicialización de sesgo en cero [83]. Por su parte, el optimizador Adam emplea una tasa de aprendizaje de 0,001, con $\beta_1 = 0,9$, $\beta_2 = 0,999$, $\epsilon = 10^{-7}$ y `amsgrad=False` [84]. En el caso de la capa *Dropout*, la tasa de descarte debe ser definida explícitamente por el usuario [85].

Tabla 12: Parámetros predeterminados de los componentes utilizados en el modelo MLP implementado en TensorFlow/Keras.

Hiperparámetro	Multi-Layer Perceptron
Tipo de capa	Dense
Activation	None
use_bias	True
kernel_initializer	glorot_uniform
bias_initializer	Zeros
kernel_regularizer	None
bias_regularizer	None
activity_regularizer	None
kernel_constraint	None
bias_constraint	None
optimizador	Adam
learning_rate	0,001
beta_1	0,9
beta_2	0,999
epsilon	1e-7
amsgrad	False
weight_decay	None
clipnorm	None
clipvalue	None
global_clipnorm	None

6.2.2. Modelo Recurrent Neural Network

La implementación del modelo RNN se realizó mediante TensorFlow/Keras, utilizando como componente recurrente principal la capa SimpleRNN. A diferencia de una configuración cerrada para toda la arquitectura, Keras define parámetros predeterminados a nivel de cada capa y componente de entrenamiento. En particular, la capa SimpleRNN emplea por defecto activación tanh, activación recurrente lineal, uso de sesgo habilitado (`use_bias=True`), inicialización de la matriz de entrada mediante *glorot_uniform*, inicialización recurrente orthogonal e inicialización de sesgo en cero. Además, sus argumentos `dropout` y `recurrent_dropout` toman por defecto el valor 0, mientras que `return_sequences`, `return_state`, `go_backwards`, `stateful` y `unroll` se definen por defecto como `False` [86]. Por su parte, cuando el entrenamiento se realiza con el optimizador Adam, éste considera como valores predeterminados una tasa de aprendizaje de 0,001, con $\beta_1 = 0,9$, $\beta_2 = 0,999$, $\epsilon = 10^{-7}$ y `amsgrad=False` [84]. Estos parámetros de referencia se resumen en la Tabla 13.

Tabla 13: Parámetros predeterminados de la capa SimpleRNN y del optimizador utilizados como referencia para la implementación del modelo RNN en TensorFlow/Keras.

Hiperparámetro	Recurrent Neural Network
Capa recurrente	SimpleRNN
Activation	tanh
recurrent activation	Lineal
use_bias	True
kernel_initializer	glorot_uniform
recurrent_initializer	orthogonal
bias_initializer	zeros
dropout	0,0
recurrent_dropout	0,0
return_sequences	False
return_state	False
go_backwards	False
stateful	False
unroll	False
Optimizador	Adam
learning_rate	0,001
beta_1	0,9
beta_2	0,999
epsilon	1e-7
amsgrad	False

6.2.3. Modelo Long Short-Term Memory

La implementación del modelo LSTM se realizó mediante TensorFlow/Keras, utilizando como componente recurrente principal la capa LSTM. Al igual que en otros modelos neuronales implementados en esta biblioteca, Keras no define una configuración única para toda la arquitectura, sino parámetros predeterminados a nivel de cada capa y componente de entrenamiento. En particular, la capa LSTM emplea por defecto activación tanh, activación recurrente sigmoid, uso de sesgo habilitado (use_bias=True), inicialización de la matriz de entrada mediante glorot_uniform, inicialización recurrente orthogonal e inicialización de sesgo en cero. Además, sus argumentos unit_forget_bias, return_sequences, return_state, go_backwards, stateful y unroll toman por defecto los valores True, False, False, False, False y False, respectivamente, mientras que dropout y recurrent_dropout se fijan por defecto en 0.0 [87]. Por su parte, cuando el entrenamiento se realiza con el optimizador Adam, éste considera como valores predeterminados una tasa de aprendizaje de 0.001, con $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 10^{-7}$ y amsgrad=False [84]. Estos parámetros de referencia se resumen en la Tabla 14.

Tabla 14: Parámetros predeterminados reportados por la documentación oficial de TensorFlow/Keras para los componentes utilizados como base en la implementación del modelo LSTM.

Hiperparámetro	Long Short-Term Memory
Capa recurrente	LSTM
Activation	Tanh
recurrent activation	Sigmoid
use_bias	True
kernel_initializer	glorot_uniform
recurrent_initializer	orthogonal
bias_initializer	zeros
dropout	0,0
recurrent_dropout	0,0
return_sequences	False
return_state	False
go_backwards	False
stateful	False
unroll	False
Optimizador	Adam
learning_rate	0,001
beta_1	0,9
beta_2	0,999

epsilon	1e-7
amsgrad	False

6.2.4. Modelo Transformer

La implementación del modelo Transformer se realizó mediante TensorFlow/Keras, utilizando una arquitectura tipo encoder compuesta por mecanismos de atención multi-cabeza, capas densas, conexiones residuales, normalización y regularización por *dropout*. Dado que TensorFlow/Keras no define una configuración predeterminada única para una arquitectura Transformer completa, los parámetros por defecto se establecen a nivel de los componentes individuales que conforman el modelo. En particular, la capa `MultiHeadAttention` define por defecto `dropout=0.0`, `use_bias=True`, `output_shape=None`, `attention_axes=None`, `flash_attention=None`, e inicializadores `glorot_uniform` para los kernels y `zeros` para los sesgos [88]. La capa `LayerNormalization` utiliza por defecto `axis=-1`, `epsilon=0.001`, `center=True`, `scale=True`, con `beta_initializer="zeros"` y `gamma_initializer="ones"` [89]. Por su parte, la capa `Dropout` requiere que la tasa de descarte `rate` sea especificada explícitamente por el usuario [85]. Finalmente, cuando el entrenamiento se realiza con el optimizador Adam, éste considera como valores predeterminados una tasa de aprendizaje de 0,001, con $\beta_1 = 0,9$, $\beta_2 = 0,999$, $\epsilon = 10^{-7}$ y `amsgrad=False` [84]. Estos parámetros de referencia se resumen en la Tabla 15.

Tabla 15: Parámetros predeterminados reportados por la documentación oficial de TensorFlow/Keras para los principales componentes utilizados como base en la implementación del modelo Transformer.

Hiperparámetro	Transformer
Capa de atención	<code>MultiHeadAttention</code>
<code>dropout</code>	0,0
<code>use_bias</code>	True
<code>Output_shape</code>	None
<code>Attention_axes</code>	None
<code>kernel_initializer</code>	<code>Glorot_uniform</code>
<code>bias_initializer</code>	<code>Zeros</code>
Capa de normalización	<code>LayerNormalization</code>
<code>axis</code>	-1
<code>epsilon</code>	0,001
<code>center</code>	True
<code>scale</code>	True
<code>beta_initializer</code>	<code>Zeros</code>
<code>gamma_initializer</code>	<code>Ones</code>
Capa de regularización	<code>Dropout</code>
Optimizador	Adam
<code>learning_rate</code>	0,001
<code>beta_1</code>	0,9
<code>beta_2</code>	0,999
<code>epsilon</code>	1e-7
<code>amsgrad</code>	False