



UNIVERSIDAD DE MÁLAGA

Programa de Doctorado en Ingeniería Mecánica y Eficiencia Energética

Escuela de Ingenierías Industriales

Departamento de Ingeniería Eléctrica

Tesis Doctoral

**Localización de faltas en redes eléctricas
mediante transformadas tiempo-frecuencia y
técnicas de inteligencia artificial**

Rafael Arranz Padilla

Director: Dr. Alejandro Rodríguez Gómez

Co-director: Dr. Francisco Jesús Muñoz Gutiérrez

noviembre, 2024



UNIVERSIDAD
DE MÁLAGA

AUTOR: Rafael Arranz Padilla

 <https://orcid.org/0009-0004-9966-4823>

EDITA: Publicaciones y Divulgación Científica. Universidad de Málaga



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional:

<https://creativecommons.org/licenses/by-nc-nd/4.0/legalcode>

Cualquier parte de esta obra se puede reproducir sin autorización pero con el reconocimiento y atribución de los autores.

No se puede hacer uso comercial de la obra y no se puede alterar, transformar o hacer obras derivadas.

Esta Tesis Doctoral está depositada en el Repositorio Institucional de la Universidad de Málaga (RIUMA): riuma.uma.es



Declaración de autoría y originalidad de la tesis presentada para obtener el título de Doctor

D. Rafael Arranz Padilla,

Estudiante del programa de doctorado en Ingeniería Mecánica y Eficiencia Energética de la Universidad de Málaga, autor de la tesis, presentada para la obtención del título de doctor por la Universidad de Málaga, titulada:

Localización de faltas en redes eléctricas mediante transformadas tiempo-frecuencia y técnicas de inteligencia artificial

Realizada bajo la tutorización de Miguel Atencia Ruiz y dirección de Alejandro Rodríguez Gómez y Francisco Jesús Muñoz Gutierrez.

Declaro que:

La tesis presentada es una obra original que no infringe los derechos de propiedad intelectual ni los derechos de propiedad industrial u otros, conforme al ordenamiento jurídico vigente (Real Decreto Legislativo 1/1996, de 12 de abril, por el que se aprueba el texto refundido de la Ley de Propiedad Intelectual, regularizando, aclarando y armonizando las disposiciones legales vigentes sobre la materia), modificado por la Ley 2/2019, de 1 de marzo. Igualmente asumo, ante a la Universidad de Málaga y ante cualquier otra instancia, la responsabilidad que pudiera derivarse en caso de plagio de contenidos en la tesis presentada, conforme al ordenamiento jurídico vigente.

En Málaga, a 08 de Julio de 2024

Fdo:

Fdo:

Fdo:

Rafael Arranz Padilla

Alejandro Rodríguez Gómez

Francisco J. Muñoz Gutiérrez

Doctorando

Director de la Tesis

Director de la Tesis



Autorización de defensa de la tesis doctoral

D. Alejandro Rodríguez Gómez y D. Francisco Jesús Muñoz Gutiérrez, Profesores Titulares del Departamento de Ingeniería Eléctrica de la Universidad de Málaga, en calidad de Directores de la tesis y D. Miguel Alejandro Atencia Ruiz, profesor titular del Departamento de Matemática Aplicada de la Universidad de Málaga, en calidad de tutor.

Certifican que:

D. **Rafael Arranz Padilla**, Ingeniero Industrial por la Universidad de Málaga, ha realizado bajo nuestra dirección la tesis doctoral titulada:

Localización de faltas en redes eléctricas mediante transformadas tiempo-frecuencia y técnicas de inteligencia artificial

Informamos que las publicaciones que avalan esta tesis son aportaciones originales, que han sido desarrolladas como parte de la investigación y que no han sido utilizadas como aval de tesis anteriores.

Autorizamos su presentación para la lectura y defensa de la tesis doctoral ante el tribunal, que ha de juzgar su mérito y calidad científica en la Universidad de Málaga, para que así conste a efectos de lo establecido en el artículo octavo del Real Decreto 99/2011, de 28 de enero, por el que se regula el sistema de doctorado en España.

En Málaga, a 8 de Julio de 2024

Fdo:

Fdo:

Fdo:

Alejandro Rodríguez Gómez

Francisco J. Muñoz Gutierrez

Miguel A. Atencia Ruiz

Director de la Tesis

Director de la Tesis

Tutor de la Tesis



UNIVERSIDAD
DE MÁLAGA

Agradecimientos

A mis padres, Rafael y María del Carmen, no hay palabras suficientes para expresar todo mi agradecimiento y admiración. Gracias por vuestro amor incondicional, por vuestro esfuerzo incansable y por creer siempre en mis sueños. Esta tesis es vuestro logro, fruto de vuestra dedicación y sacrificio, y de todas las oportunidades que me habéis brindado para desarrollarme como persona y como profesional. Y María, querida hermana, gracias por estar siempre a mi lado y por compartir cada triunfo y cada lágrima. Vuestro apoyo ha sido fundamental en este camino.

A María, por ser mucho más de lo que podría imaginar. Gracias por creer en mí y por darme una razón aún más grande para soñar y construir un futuro juntos.

A Alejandro, mi Director de Tesis, no puedo dejar de expresar mi profundo agradecimiento por tu dirección y guía a lo largo de todos estos años. Desde mi primera beca de investigación, que me introdujo en el mundo académico, has sido mi mentor y guía. Esta tesis es el fruto de nuestros años de trabajo conjunto, y es un honor haber compartido este viaje contigo.

A mi codirector de Tesis Paco, a mi compañero de investigación Ángel y al director de departamento Pepe, quiero expresar mi más sincero agradecimiento por vuestra ayuda y dedicación a lo largo de estos años. Gracias por apostar por esta línea de investigación y por brindarme los mejores consejos posibles. Sin vuestro apoyo, este logro no habría sido posible.

A todos mis familiares y amigos que, aunque no estén mencionados en esta tesis, sé que saben quiénes son. Siempre os estaré agradecido por vuestro apoyo y por inspirarme a creer en mí mismo y en mis objetivos. Gracias por alentarme a lo largo de estos años para culminar esta tesis, que sin duda, ha sido un desafío. Os doy las gracias de todo corazón.



UNIVERSIDAD
DE MÁLAGA

Resumen de la Tesis

La presente tesis doctoral se centra en la localización de faltas eléctricas en sistemas de potencia, una tarea crítica para garantizar la confiabilidad y estabilidad de las redes eléctricas. Aunque la tecnología ha avanzado significativamente, aún persisten limitaciones en los equipos de medición utilizados para esta tarea. La investigación presentada propone el uso de la transformada de Stockwell y redes neuronales para mejorar la precisión y eficiencia en la identificación de la ubicación de las faltas.

Las faltas eléctricas, que pueden surgir por factores medioambientales o por operaciones en la red, son responsables de las mayores interrupciones en el sistema eléctrico. Localizarlas con precisión permite a los operadores de red reducir los costos de inspección y reparación, mejorando así la calidad del suministro y evitando cortes no programados.

El proceso de localización de faltas se enfrenta a varias limitaciones: resolución insuficiente de equipos de medición, sensibilidad a interferencias electromagnéticas, dificultades de acceso a ciertas áreas de la red, complejidad del sistema eléctrico y altos costos de equipos especializados. Estas limitaciones subrayan la necesidad de desarrollar tecnologías avanzadas que puedan superar estos desafíos.

Actualmente, existen varios métodos tecnológicos avanzados para la localización de faltas eléctricas. Entre ellos, los métodos basados en la impedancia son ampliamente utilizados debido a su simplicidad y baja complejidad computacional. Estos métodos calculan la impedancia aparente de la línea vista desde uno de sus extremos, utilizando mediciones de tensión e intensidad. Por otro lado, los métodos de onda viajera son muy confiables y se basan en determinar el momento de paso del frente de onda por uno de los extremos de las líneas de transmisión cuando se produce una falta eléctrica. Este método, aunque preciso, requiere sensores sofisticados con una alta frecuencia de muestreo.

La transformada de Stockwell ofrece una mayor precisión en el dominio de la frecuencia comparada con otras transformadas tiempo-frecuencia como la Wavelet. Esta precisión es crucial para identificar las frecuencias asociadas a la tensión de recuperación transitoria (TRV), que aparece cuando un interruptor de potencia interrumpe el flujo de corriente durante una falta. El TRV es una señal de tensión que se define en distintos estándares internacionales y cuyo valor se estudia para conocer los límites de las protecciones y poder dimensionar correctamente las mismas en los sistemas eléctricos de potencia. El TRV contiene información que, al ser analizada mediante la transformada de Stockwell, permite determinar con gran precisión la frecuencia característica del sistema en el momento de la falta y su energía asociada.

Las redes neuronales pueden utilizar esta información para establecer una relación con la distancia de la falta. La tesis propone un sistema que combina la transformada de Stockwell y las redes neuronales para desarrollar un método eficiente y preciso de localización de faltas eléctricas. Este sistema se valida sobre modelos de redes eléctricas reales, demostrando una precisión superior a la de los métodos tradicionales.

La tesis se organiza en cinco capítulos. El primer capítulo introduce la motivación y los objetivos, así como la estructura de la tesis. El segundo capítulo describe los interruptores de potencia y la normativa internacional asociada al TRV. El tercer capítulo presenta técnicas de localización de faltas eléctricas, incluyendo transformadas tiempo-frecuencia y redes neuronales. El cuarto capítulo se dedica a la experimentación y validación del sistema propuesto. El quinto capítulo concluye con los resultados obtenidos y sugiere líneas futuras de investigación.

Las publicaciones derivadas de esta tesis se encuentran recogidas en la revista *Electric Power Systems Research* y en congresos internacionales, las cuales subrayan la relevancia e impacto de este trabajo en el campo de la ingeniería eléctrica.

Índice general

1. Introducción	1
1.1. Resumen del capítulo	1
1.2. Campo de aplicación	1
1.2.1. Contexto Europeo y Español	1
1.2.2. Medida del impacto de las interrupciones en la red	4
1.2.3. Limitaciones actuales en la localización de faltas	4
1.2.4. Evolución de los métodos para la localización de faltas	6
1.3. Motivación y objetivos	11
1.4. Estructura de la tesis	13
1.5. Publicaciones	14
2. Interruptores de potencia y tensión de recuperación transitoria	17
2.1. Resumen del capítulo	17
2.2. Definición de un interruptor de potencia	18
2.3. Historia del interruptor de potencia	19
2.4. Clasificación de interruptores de potencia	21
2.4.1. Clasificación según la potencia	21
2.4.2. Clasificación según el medio de extinción	22
2.5. Normativa para interruptores de potencia	24
2.5.1. Estándares para interruptores de potencia	24
2.5.2. Estándares para interruptores de generación	26
2.6. Características nominales de un interruptor de potencia	27
2.7. Tensión de recuperación transitoria	28
2.7.1. Introducción	28
2.7.2. Factores que afectan al TRV	30



2.7.3.	Tipos de TRV	32
2.7.4.	Procedimientos de prueba para evaluar el TRV	33
2.7.4.1.	IEEE C37.010	33
2.7.4.2.	IEC 62271-100	34
2.8.	Dimensionamiento de interruptores según criterio de TRV	35
2.9.	Técnicas de extinción del arco	36
2.9.1.	Principio de operación de contactos del interruptor	36
2.9.2.	Principales teorías de interrupción del arco eléctrico	38
2.10.	Comportamiento transitorio de la apertura de contacto del interruptor de potencia	42
3.	Técnicas de caracterización y clasificación de señales eléctricas	49
3.1.	Resumen del capítulo	49
3.2.	Transformadas tiempo-frecuencia	50
3.2.1.	Transformada de Fourier	50
3.2.1.1.	Series de Fourier	51
3.2.1.2.	Definición matemática	51
3.2.1.3.	Señales continuas y discretas	52
3.2.1.4.	Transformada de Fourier discreta	53
3.2.1.5.	Teorema de Nyquist	54
3.2.2.	Transformada corta de Fourier	55
3.2.3.	Transformada Wavelet	57
3.2.4.	Transformada de Stockwell	58
3.2.4.1.	Descripción matemática	59
3.2.4.2.	Modelado	62
3.2.4.3.	Teorema de Parseval	65
3.3.	Redes Neuronales	67
3.3.1.	La Neurona Biológica	68
3.3.2.	La Neurona Artificial	69
3.3.3.	Estructura de las Redes Neuronales Artificiales	72



3.3.4.	Modos de operación	73
3.3.5.	Funciones de entrenamiento	74
3.3.6.	Proceso de aprendizaje mediante retropropagación resiliente .	77
3.3.7.	Optimización Bayesiana	78
3.3.7.1.	Proceso Gaussiano como Modelo Sustituto	79
3.3.7.2.	Función de Adquisición	79
3.3.7.3.	Procedimiento de Optimización	80
3.4.	Algoritmo localizador de faltas eléctricas	81
4.	Resultados experimentales	93
4.1.	Resumen del capítulo	93
4.2.	Estudio de la frecuencia característica sobre una línea de transmisión	94
4.2.1.	Metodología	94
4.2.2.	Caso de estudio	97
4.2.2.1.	Efecto de la distancia de falta	100
4.2.2.2.	Efecto del ángulo de incidencia	101
4.2.2.3.	Efecto de la resistencia de falta	105
4.2.2.4.	Efecto del modelo de arco y tecnología de aislamiento del interruptor de potencia	107
4.2.3.	Análisis de sensibilidad de la frecuencia característica y energía asociada a una línea de transmisión	108
4.2.3.1.	Estudio de sensibilidad del ángulo de incidencia . . .	112
4.2.3.2.	Estudio de sensibilidad de la resistencia	112
4.2.3.3.	Estudio de sensibilidad de la capacidad	113
4.2.3.4.	Estudio de sensibilidad de la potencia activa y reactiva	113
4.2.4.	Determinación de la frecuencia característica sobre una línea de transmisión	118
4.2.5.	Determinación de la frecuencia característica sobre una red de líneas de transmisión	126

4.3. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión	128
4.3.1. Metodología	128
4.3.2. Caso de estudio	131
4.3.3. Determinación de la localización de la falta en una red de transmisión	133
4.3.4. Comparación del algoritmo propuesto con otras técnicas basada en análisis frecuencial e inteligencia artificial	139
4.3.4.1. Beneficios del algoritmo propuesto	140
4.3.4.2. Desventajas del algoritmo propuesto	142
5. Conclusiones y líneas futuras de investigación	145
5.1. Introducción	145
5.2. Resumen	145
5.3. Conclusiones experimentales	147
5.3.1. Estudio de la frecuencia característica sobre una línea de transmisión	148
5.3.2. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión	150
5.4. Futuras líneas de investigación	152
Referencias	155

Índice de tablas

3.1. Espacio de búsqueda de la Optimización Bayesiana	86
4.1. Datos del conductor.	98
4.2. Impedancia de las fuentes.	99
4.3. Valor de frecuencia y energía característica, TRV y RRRV máximo a distintas distancias de falta monofásica.	101
4.4. Resultados de la simulación del efecto del ángulo de incidencia para una falta monofásica localizada a una distancia de 100 km.	104
4.5. Resultado de las simulaciones para distintas resistencia de falta.	107
4.6. Valores de los parámetros de los modelos de Cassie y Mayr para un CB.	108
4.7. Valores de los parámetros del modelo Schavmaker para un CB.	108
4.8. Resultados de la simulación empleando distintos modelos de arco simulando faltas eléctricas a 50 y 150 km.	109
4.9. Variables dependientes de estudio.	110
4.10. Datos del conductor y del conductor de tierra.	119
4.11. Impedancias de la fuentes.	119
4.12. Resultados de la simulación para una falta monofásica 50 km en distintos instantes temporales.	123
4.13. Resultados de simulaciones para diferentes resistencias de falta.	124
4.14. Resultados de la simulación utilizando diferentes modelos de arco a 50 km de distancia de la falta	125

4.15. Configuración óptima de hiperparámetros y errores de prueba de la Red neuronal entrenada para cada tipo de falta y su versión puesta a tierra. HLN (Neuronas de la Capa Oculta), EPH (Épocas), ME (Error Medio), STD (Desviación Estándar).	133
4.16. Configuración óptima de hiperparámetros para cada una de las Redes neuronales entrenadas. HLN (Neuronas capa oculta), EPH (Epocas).	136
4.17. Comparación de las técnicas existentes con la técnica propuesta basada en ANN para la localización de faltas.	143



Índice de figuras

2.1. <i>Transient Recovery Voltage</i> (TRV).	29
2.2. TRV exponencial [31].	32
2.3. TRV oscilatorio [31].	33
2.4. TRV línea corta [31].	33
2.5. Envolvente T10 de la curva TRV [31].	36
2.6. Esquema básico de circuito con un interruptor de potencia.	42
3.1. Esquema gráfico de cálculo de la transformada de Stockwell.	63
3.2. Diagrama de bloques de cómputo de la transformada de Stockwell.	64
3.3. Información de frecuencia extraída a partir del análisis ST sobre un TRV.	67
3.4. Esquema gráfico con las diferentes partes de una Neurona Artificial.	70
3.5. Ejemplo representativo de funcionamiento de la BO utilizando GP como modelo sustitutorio de la función real desconocida a priori.	80
3.6. Esquema de la ANN.	82
3.7. Esquema del algoritmo localizador de faltas.	91
4.1. TRVs para faltas a diferentes distancias: (a) 150 km y (b) 50 km.	95
4.2. Esquema del enfoque propuesto.	96
4.3. Análisis de la ST aplicado al TRV. El TRV para faltas monofásicas (a-b), las mallas de la ST (c-d), los contornos de la transformada ST (e-f) y energía de estos contornos (g-h), para 150 km y 50 km, respectivamente.	97
4.4. Modelo esquemático de línea de 132 kV.	98
4.5. Esquema de la torre de la línea aérea utilizada en los casos de estudio.	99



4.6. De izquierda a derecha: TRV, contornos ST y sus energías. De arriba a abajo se indican las distancias de 25 a 175 km en pasos de 25 km.	102
4.7. Frecuencia característica vs distancia.	103
4.8. TRV_{peak} frente a la distancia	103
4.9. TRV, contornos de la ST y energía para diferentes ángulos de incidencia.	105
4.10. TRVs, contornos de la ST y energía para diferentes resistencias de falta.	106
4.11. TRVs, contornos de la ST y energía para modelos de arco con falta eléctrica a 50km.	109
4.12. Estados de referencia para el cálculo de sensibilidad para el ángulo de incidencia (a) ($\alpha = 0^\circ$), resistencia de falta (b) ($R = 0.001\Omega$) y capacitancia equivalente (c) ($C = 0.0095\mu F$).	111
4.13. Sensibilidades en energía y frecuencia con respecto al ángulo de inicio de la falta y a diferentes tipos de faltas: monofásica a tierra (a) y (d), bifásica a tierra, (b) y (e), trifásica a tierra, (c) y (f).	112
4.14. Sensibilidades en energía y frecuencia con respecto la resistencia a tierra considerando todas las faltas.	113
4.15. Sensibilidades en energía y frecuencia con respecto a la capacitancia equivalente y a diferentes tipos de faltas: monofásica a tierra (a) y (d), bifásica a tierra, (b) y (e), trifásica a tierra, (c) y (f).	114
4.16. TRVs, Estado de referencia para potencia activa (P) en el análisis de sensibilidad considerando $P = 10$ MW.	115
4.17. TRVs, Análisis de sensibilidad de la potencia activa consumida por la carga P. Faltas monofásicas (a) y (d), faltas bifásicas (b) y (e), faltas trifásicas (c) y (f).	116
4.18. Estado de referencia para potencia reactiva (Q) en el análisis de sensibilidad considerando $P = 7.5$ MVar.	117
4.19. TRVs, Análisis de sensibilidad de la potencia reactiva consumida por la carga Q. Faltas monofásicas (a) y (d), faltas bifásicas (b) y (e), faltas trifásicas (c) y (f).	117



4.20. Línea de transmisión de 220 kV modelada.	118
4.21. Esquema de la torre de la línea aérea empleada.	120
4.22. De izquierda a derecha: TRV, contornos y energía para cada frecuencia, obtenidos mediante la ST. De arriba abajo, para distancias de 50, 75, 100, 150, 175 y 200 km.	121
4.23. De izquierda a derecha: TRV, contornos y energía para cada frecuencia, obtenidos mediante la ST. De arriba abajo, para distancias de 25, 125 y 225 km.	122
4.24. Frecuencia frente a distancia.	123
4.25. TRV, contornos de la transformada ST y energía-frecuencia para los valores mínimos y máximos de energía debido al ángulo de incidencia.	124
4.26. TRVs, Contornos energía-frecuencia de la transformada ST para diferentes resistencias de falta.	125
4.27. TRVs, contornos de la transformada ST y energía-frecuencia utilizando el modelo de Mayr para el aislamiento de Aire y SF6 para una distancia de falta de 50 km.	126
4.28. Contornos de energía y error típico en la localización de frecuencias para cada distancia.	127
4.29. Red de transmisión IEEE 9.	128
4.30. TRV, contornos de la transformada ST y sistema de energía-frecuencia para distancias de falta de 50, 100 y 150 km.	129
4.31. Contornos de energía y error estándar de frecuencia para cada distancia en el caso IEEE.	129
4.32. Sistema propuesto para localización de faltas.	130
4.33. Esquema del proceso de medida.	132
4.34. Esquema de la red de transmisión IEEE 14.	134
4.35. Espectro de frecuencia ST de la TRV con frecuencia característica (punto rojo) frente a la distancia de falta para diferentes valores del ángulo de incidencia en la línea 7-8.	135



4.36. Efecto de los parámetros de la localización de falta en el sistema localizador.	137
4.37. Diagrama de barras del error medio y la desviación típica de las líneas 1-2 (azul), 3-4 (naranja), 7-8 (amarillo) y 6-13 (morado).	138

Capítulo 1

Introducción

1.1. Resumen del capítulo

En este capítulo se introduce, de forma general, el marco de aplicación de la tesis doctoral y se presentan la motivación y los objetivos que se persiguen con su realización, la estructura de la misma y las publicaciones de calidad que se han originado durante su realización.

1.2. Campo de aplicación

1.2.1. Contexto Europeo y Español

Las redes eléctricas desempeñan un papel fundamental en nuestra sociedad al garantizar la confiabilidad del suministro de energía eléctrica [1]. La seguridad y estabilidad de estas redes son esenciales para el desarrollo socioeconómico, especialmente en el contexto actual, donde Europa y España están experimentando una transformación significativa impulsada por la transición hacia un sistema energético más sostenible y digitalizado. Esta transformación se ha visto impulsada por políticas energéticas que buscan integrar un mayor porcentaje de energías renovables, mejorar la eficiencia energética y reducir las emisiones de gases de efecto invernadero, como se establece en el Plan Nacional Integrado de Energía y Clima

(PNIEC) [2].

En este contexto, uno de los mayores desafíos que enfrenta esta nueva infraestructura es la identificación y localización rápida y precisa de las faltas eléctricas. Estas faltas, que son interrupciones o desviaciones en el flujo de corriente, pueden poner en riesgo la estabilidad de la red, afectando el suministro a los consumidores y generando costos económicos significativos [3]. Para abordar estos desafíos, la innovación en la tecnología de detección y localización de faltas resulta esencial, y su importancia radica en varios aspectos:

- **Incremento de la integración de energías renovables:** La integración de fuentes de energía renovables, como la solar y la eólica, ha aumentado considerablemente en los últimos años. Según la Agencia Europea del Medio Ambiente [4], las energías renovables representaron aproximadamente el 38 % del consumo de electricidad en la Unión Europea en 2020, y este porcentaje sigue creciendo. Esta creciente dependencia de fuentes de energía intermitentes y descentralizadas ha aumentado la complejidad y la vulnerabilidad de las redes eléctricas. Por lo tanto, es fundamental desarrollar métodos de localización de faltas que sean más eficientes y precisos para minimizar las interrupciones en el suministro eléctrico y garantizar una operación estable de la red.
- **Expectativas de calidad del suministro:** Las expectativas de los consumidores en términos de calidad y continuidad del suministro eléctrico han evolucionado. La Comisión Europea ha establecido un marco regulatorio que exige a los operadores de red mantener altos estándares de continuidad y calidad del suministro. De acuerdo con el Informe de la Agencia de Cooperación de los Reguladores de la Energía [5], la calidad del servicio se ha convertido en un factor clave para la aceptación social de las infraestructuras eléctricas y para el desarrollo de un mercado interno de electricidad. Esto implica que los operadores deben invertir en tecnologías avanzadas para localizar y resolver

rápida cualquier interrupción de energía en la red.

- **Aumento de la complejidad de la red:** La proliferación de microrredes y sistemas de almacenamiento de energía ha generado nuevos desafíos para la localización de faltas. Según un estudio de la Universidad Politécnica de Madrid [6], la topología diversa de las redes eléctricas actuales dificulta la identificación rápida y precisa de faltas, lo que puede resultar en largos tiempos de inactividad y elevados costos operativos. Innovar en los métodos de localización de faltas es crucial para adaptarse a estos cambios y mejorar la resiliencia de la red.
- **Impacto económico de las interrupciones:** Las interrupciones en el suministro eléctrico tienen un impacto económico considerable. Según el Informe sobre el Costo de las Interrupciones Eléctricas del Instituto de Estudios Energéticos [7], se estima que las interrupciones pueden costar a la economía española varios miles de millones de euros anuales, afectando tanto a la industria como a los consumidores finales. La implementación de tecnologías avanzadas para la localización de faltas puede ayudar a reducir estos costos, mejorando la eficiencia y minimizando las pérdidas económicas.
- **Normativas y regulaciones:** Las regulaciones en la Unión Europea y España están cada vez más orientadas hacia la mejora de la confiabilidad del suministro eléctrico. La Directiva de Energías Renovables de la UE y el PNIEC [2] establecen metas claras para la reducción de emisiones y el aumento de la eficiencia energética. Esto implica que los operadores de red deben adaptarse y modernizar sus infraestructuras, incluyendo la implementación de tecnologías innovadoras para la localización de faltas.

1.2.2. Medida del impacto de las interrupciones en la red

La magnitud del impacto de estas interrupciones se puede evaluar mediante indicadores de continuidad de servicio, como el Tiempo de Interrupción Equivalente de Potencia Instalada (TIEPI) y el Tiempo de Interrupción No Equivalente de Potencia Instalada (NIEPI) [8]. El TIEPI es un indicador que mide la cantidad total de tiempo que el suministro eléctrico ha estado interrumpido, considerando la potencia instalada en la red. Se calcula sumando la duración de todas las interrupciones y dividiéndola por la potencia instalada en el sistema. Este indicador es útil para evaluar el rendimiento global de la red eléctrica en términos de continuidad de suministro y para comparar el desempeño entre diferentes sistemas. Por otro lado, el NIEPI es un indicador similar al TIEPI, pero no tiene en cuenta la potencia instalada en el sistema. En su lugar, mide la cantidad total de tiempo que el suministro eléctrico ha estado interrumpido, independientemente de la potencia instalada.

Este indicador es útil para evaluar el impacto de las interrupciones en los usuarios finales y en la sociedad en general, sin tener en cuenta las características específicas del sistema eléctrico. Las faltas eléctricas tienen una influencia directa en los valores de TIEPI y NIEPI de un sistema eléctrico. Cuando ocurre una falta eléctrica y se interrumpe el suministro de energía, tanto el TIEPI como el NIEPI aumentan. La magnitud del aumento depende de la duración de la interrupción y de la potencia instalada en el sistema. Por lo tanto, es fundamental gestionar y minimizar el impacto de las faltas eléctricas para mejorar los valores de estos indicadores y garantizar la continuidad del suministro eléctrico [9].

1.2.3. Limitaciones actuales en la localización de faltas

A pesar de los avances significativos en la tecnología de los últimos años, actualmente persisten limitaciones en los equipos utilizados para la localización de

faltas en las redes eléctricas. Estas limitaciones no solo afectan la eficacia de los métodos actuales, sino que también resaltan la urgente necesidad de innovación en este campo:

- **Resolución de los equipos de medición:** Los equipos utilizados para localizar faltas eléctricas pueden tener una resolución limitada, lo que dificulta la detección precisa de variaciones en la señal. Esto puede llevar a errores en la determinación de la ubicación exacta de la falta, especialmente en casos de faltas de baja magnitud o intermitentes [10].
- **Sensibilidad a interferencias electromagnéticas:** Los equipos de localización de faltas pueden ser sensibles a interferencias electromagnéticas externas, como las generadas por equipos de alta potencia o líneas de transmisión cercanas. Estas interferencias afectan la calidad de la señal medida y dificultan la localización precisa de la falta [11].
- **Limitaciones en la accesibilidad:** En algunas situaciones, la ubicación física de la falta puede dificultar el acceso a ciertas áreas para realizar mediciones o pruebas, especialmente en regiones remotas donde la instalación de equipos de medición puede ser limitada o impracticable [12].
- **Complejidad del sistema:** La diversidad de la topología de los sistemas de potencia puede dificultar la interpretación de los datos de medición y la identificación de la ubicación exacta de la falta. La presencia de múltiples nodos de alimentación y conexiones en paralelo complica aún más este proceso [13].
- **Costo de los equipos especializados:** Los equipos diseñados para la localización de faltas pueden tener un costo significativo, limitando su disponibilidad y uso, especialmente para empresas con recursos financieros reducidos [14].

Dadas estas limitaciones, se hace evidente que es imperativo seguir investigando y desarrollando tecnologías avanzadas que superen estos desafíos y mejoren la precisión y eficiencia de los métodos de diagnóstico. La innovación en la localización de faltas es crucial no solo para mantener la integridad de las redes eléctricas, sino también para facilitar la transición hacia un sistema energético más sostenible.

1.2.4. Evolución de los métodos para la localización de faltas

El desarrollo de métodos para la localización de faltas eléctricas se remonta a los primeros días de la industria eléctrica, a finales del siglo XIX. En 1898, Smith introdujo los primeros métodos de localización, que se basaban principalmente en la observación visual y en búsquedas manuales. En este periodo, las tecnologías de medición eran rudimentarias y se limitaban a mediciones de tensión y corriente, lo que resultaba en procesos laboriosos que consumían mucho tiempo. Estos métodos dependían en gran medida de la habilidad y experiencia de los operadores, lo que a menudo provocaba errores y retrasos significativos en la reparación de las faltas [15], [16].

Con el avance de la tecnología, en la década de 1920, comenzaron a surgir métodos más sofisticados. Estos nuevos enfoques fueron posibles gracias al desarrollo de equipos de medición más precisos y confiables. En esta etapa, los métodos comenzaron a clasificarse según el número de terminales de donde se adquiría la información.

Los métodos de un solo terminal, introducidos a partir de 1930, utilizan datos de un solo extremo de la línea. Su simplicidad y menor costo los hicieron populares, aunque su precisión seguía siendo limitada en comparación con otros métodos. Por ejemplo, el método de impedancia, que se basa en calcular la impedancia medida desde el extremo del alimentador hasta la falta, presenta la ventaja de ser fácil de implementar y menos costoso, ideal para sistemas con recursos limitados. Sin embargo, su precisión puede verse comprometida, especialmente en condiciones de

carga variable, y depende de la habilidad del operador, lo que puede llevar a errores en la identificación de la falta [17], [18].

Los métodos de dos terminales surgieron en los años 50 y emplean datos de ambos extremos de la línea, lo que permite una mayor precisión en la localización de las faltas. Una investigación de este tipo de método de dos terminales [19] presenta mejoras notables en la precisión de localización de faltas. Este enfoque permite adaptar mejor la identificación de faltas a diversas condiciones de carga, resultando en un análisis más confiable. Sin embargo, su implementación implica un costo más alto debido a la infraestructura necesaria y a la mayor complejidad en el análisis de datos, lo cual puede ser un reto en sistemas con recursos limitados.

Con el aumento de la complejidad de las redes eléctricas, en las décadas de 1970 y 1980, se desarrollaron métodos de múltiples terminales que recopilan datos de tres o más puntos. Este enfoque proporciona una mayor precisión en condiciones variables y es especialmente útil en sistemas con múltiples alimentaciones [20]. La alta precisión de estos métodos los convierte en una opción confiable para la localización de faltas, pero requieren una inversión significativa en infraestructura y mantenimiento, lo que puede ser un obstáculo en términos de costo y recursos disponibles.

En las décadas de 1990 y 2000, los métodos de impedancia se convirtieron en uno de los enfoques más utilizados debido a su simplicidad y eficiencia computacional. Estos métodos, ampliamente aplicados en sistemas de distribución, son preferidos por su bajo costo y facilidad de implementación [21]. Sin embargo, su precisión puede verse afectada en sistemas con condiciones de carga variable. En contraposición, el método de onda viajera se estableció como uno de los más confiables, basado en la detección del momento de paso del frente de onda a través de la línea en el momento de la falta, proporcionando resultados casi instantáneos con un error de menos del 0.5 % en simulaciones [22]. Sin embargo, este método requiere inversiones en sensores de alta frecuencia y equipos avanzados, lo que puede resultar prohibitivo en términos de costo y complejidad técnica.

A lo largo del tiempo, ha habido un interés creciente en el desarrollo de métodos híbridos que combinan las ventajas de los métodos de impedancia y de onda viajera, lo que resulta en un rendimiento superior mejorando la precisión en la localización de las faltas [23], [24]. Un ejemplo destacado es la transformada Wavelet, que se ha aplicado para mejorar la detección de ondas viajeras, permitiendo una identificación más precisa de eventos transitorios en la red eléctrica [25].

Recientemente, ha habido un aumento en el uso de Redes Neuronales (ANN), del inglés *Artificial Neural Networks* y técnicas de transformadas tiempo-frecuencia en la localización de faltas eléctricas. Las redes neuronales han demostrado ser efectivas en el reconocimiento de patrones complejos y en la mejora de la precisión en la localización de faltas. Estas técnicas permiten el análisis de grandes volúmenes de datos y pueden aprender de ejemplos previos, mejorando su capacidad de diagnóstico en condiciones cambiantes [26], [27].

Los estudios muestran que al implementar ANN en la localización de faltas, la precisión puede aumentar hasta un 98 % en comparación con métodos tradicionales, que típicamente tienen tasas de precisión entre 80 % y 90 %. Por ejemplo, se reportó que el uso de ANN resultó en una mejora de aproximadamente un 15 % en la precisión de localización en comparación con métodos basados en impedancia [27].

Las transformadas tiempo-frecuencia, como la transformada de Fourier de Tiempo Corto y la transformada Wavelet, se utilizan para analizar señales eléctricas y extraer características relevantes en diferentes momentos y frecuencias. Estos enfoques permiten una identificación más precisa de eventos transitorios en la red eléctrica y han mostrado mejoras significativas en la localización de faltas de baja magnitud. Por ejemplo, la aplicación de la transformada Wavelet en combinación con ANN ha permitido aumentar la precisión de localización de faltas en un 20 % [28] destacando la efectividad de esta técnica para identificar eventos en condiciones complejas.

A lo largo de los años, la evolución de los métodos para la localización de

faltas eléctricas ha mostrado un progreso significativo, desde los rudimentarios enfoques de finales del siglo XIX hasta las sofisticadas técnicas actuales que incorporan inteligencia artificial y análisis de señales avanzados. En este contexto, la respuesta natural del sistema eléctrico juega un papel fundamental en la identificación y localización de faltas. Esta respuesta está intrínsecamente vinculada a los parámetros eléctricos de una línea de transmisión, como su topología y características geométricas, incluyendo la longitud de los conductores. La variación en la impedancia de la línea de transmisión impacta directamente en la respuesta del sistema, lo que a su vez afecta la localización de las faltas eléctricas.

Cuando un interruptor de potencia interrumpe el flujo de corriente tras detectar una falta, se genera una tensión de recuperación transitoria (TRV), del inglés *Transient Recovery Voltage*, entre los terminales del interruptor. Este fenómeno es consecuencia del cambio de impedancia originado por el arco eléctrico en la cámara de extinción. El TRV es una señal de tensión definida en varios estándares internacionales y se analiza para conocer los límites de las protecciones, así como para dimensionar adecuadamente los componentes en los sistemas eléctricos de potencia. Esta señal TRV no solo contiene información sobre la magnitud de la tensión, sino que también es rica en contenido frecuencial, que está directamente relacionado con los parámetros de la línea de transmisión. A través de técnicas de análisis como las transformadas tiempo-frecuencia, se puede extraer información valiosa sobre la localización de la falta eléctrica.

Los métodos más recientes se enfocan en la caracterización de la señal a partir del estudio de frecuencias, lo que permite un análisis más profundo y preciso de los fenómenos eléctricos. Dentro de las transformadas tiempo-frecuencia, la transformada Wavelet ofrece información en bandas de frecuencia. El escalado de la función ventana se realiza aplicando un factor constante, lo que significa que cada banda abarca la mitad del espectro restante. Esto condiciona la precisión disponible en frecuencia por el ancho de banda de cada nivel de descomposición. Por otro lado, la transformada de Stockwell permite una mayor precisión en el dominio de

la frecuencia, ya que el escalado de la ventana, que utiliza una función gaussiana, depende de la frecuencia.

Aprovechando estas propiedades, es posible determinar con gran precisión las frecuencias asociadas al TRV durante la ocurrencia de una falta, así como la energía vinculada a cada una de estas frecuencias. Además, mediante un procedimiento sencillo, se pueden especificar las diferentes frecuencias que se presentan en una falta, distinguiendo la frecuencia característica como aquella con el mayor contenido energético. Este enfoque basado en la caracterización de la señal proporciona información crítica que puede ser utilizada por sistemas de inteligencia artificial, como las ANN, para establecer relaciones más precisas entre las características de la señal y la distancia a la que se produjo la falta. Estudios recientes muestran que su integración con ANN puede aumentar aún más la precisión de localización, llegando hasta un 95 % en sistemas complejos [29], [30].

Una de las principales ventajas de las ANN radica en su capacidad para procesar y analizar grandes volúmenes de datos frecuenciales, identificando patrones complejos que pueden ser difíciles de discernir mediante métodos tradicionales. A diferencia de los algoritmos convencionales, que suelen ser más simples y menos adaptables, las ANN pueden aprender de experiencias pasadas, adaptándose a nuevas condiciones y aportando una mayor flexibilidad en el análisis. Esta adaptabilidad no solo mejora la precisión en la detección de faltas, sino que también permite una respuesta más rápida y efectiva ante situaciones críticas en el sistema eléctrico.

Esta tesis se enfocará en la exploración y desarrollo de métodos que integren técnicas de análisis tiempo-frecuencia con modelos de inteligencia artificial, específicamente combinando la transformada de Stockwell con ANN, para identificar la frecuencia característica de la señal TRV y, posteriormente, emplear esta señal para generar ANN que permitan localizar faltas eléctricas en las redes eléctricas. Se espera que esta investigación contribuya a la evolución de los métodos de localización de

faltas, aumentando su precisión y eficiencia, y superando las limitaciones de los enfoques tradicionales mediante una caracterización más detallada de las señales.

1.3. Motivación y objetivos

La eficiencia y fiabilidad del suministro eléctrico es esencial para el correcto funcionamiento de la sociedad moderna. Sin embargo, un suministro eléctrico fiable y seguro no siempre se garantiza, ya que pueden producirse fallos eléctricos en los circuitos que pueden dar lugar a cortes de energía, daños a los equipos y, en casos extremos, incluso riesgos para la seguridad.

La localización de faltas eléctricas en las líneas es una tarea crucial para mantener una buena calidad de servicio eléctrico. Para ello, se deben medir y analizar las señales eléctricas en diferentes puntos de la red eléctrica, con el fin de determinar la ubicación exacta de la falta. Además, estos datos también ayudan a identificar patrones y tendencias de las mismas, lo que puede contribuir a mejorar el diseño y la operación de la red eléctrica.

Esta tesis tiene como propósito presentar unos modelos matemáticos que permitan estimar la ubicación del punto de falta a partir de la frecuencia característica del sistema. Para ello, se utilizarán técnicas avanzadas de procesamiento de señales para identificar patrones y características de la señal eléctrica que relacionan la presencia de un falta y su localización. En la misma, no solo se aborda un desafío técnico crucial en la gestión de sistemas eléctricos, sino que también presenta una contribución valiosa al campo de aplicación mediante la integración de herramientas matemáticas avanzadas y técnicas de procesamiento de señales en un enfoque coherente y aplicable. La investigación realizada ofrece perspectivas prometedoras para el desarrollo de sistemas más robustos y eficientes en la localización de faltas eléctricas fácilmente aplicable a modelos digitales. Por ello, los objetivos propuestos en la presente tesis son:

1. **Evaluar la eficacia de la transformada de Stockwell** para caracterizar señales eléctricas en el dominio tiempo-frecuencia, destacando su capacidad para representar eventos transitorios asociados a faltas con precisión.
2. **Proponer e integrar la transformada de Stockwell y redes neuronales** para desarrollar un sistema eficiente y preciso de localización de faltas eléctricas.
3. **Verificar su precisión y robustez del método** sobre modelos eléctricos que recreen sistemas de transmisión reales.

Para lograr este propósito se presentan dos bloques dependientes. En primer lugar, un enfoque matemático para determinar la frecuencia característica de una línea de transmisión de un sistema eléctrico mediante la aplicación de la transformada tiempo-frecuencia de Stockwell, también denominada S-transform, sobre el TRV que se produce para aislar una falta en el sistema eléctrico. La precisión de este análisis permite identificar, de forma sencilla y robusta, la frecuencia característica de un sistema independientemente de otros parámetros como el instante de inicio de la falta y los ángulos de apertura, la resistencia de la falta, el modelo de arco o el aislamiento del interruptor de potencia.

En segundo lugar, un sistema sencillo que permita la localización de faltas eléctricas mediante el tratamiento de las variables de frecuencia y energía por fase extraídas a partir de la S-transform. Con estas características, el sistema de ANN es capaz de establecer una relación entre estas entradas y la distancia a la que se produce una falta en la línea de transmisión.

Para validar la eficacia del sistema desarrollado, se realizarán distintos casos de uso sobre redes eléctricas reales. Se medirán las señales eléctricas en diferentes puntos de la red y se simularán diversas faltas para evaluar la precisión del sistema. Estos resultados se compararán con los obtenidos por métodos tradicionales de localización de faltas eléctricas para validar la eficacia del sistema.

1.4. Estructura de la tesis

La tesis está organizada en un conjunto de cinco capítulos de la siguiente forma:

En el primer capítulo se define el campo de aplicación de la tesis doctoral, la motivación y los objetivos que se persiguen, así como la estructura de la misma.

En el segundo capítulo se describen los distintos tipos de interruptores de potencia, detalles constructivos y clasificación de los mismos que se pueden encontrar instalados, tanto en sistema de alta como de media tensión así como la normativa internacional asociada al evento de señal del TRV.

En el tercer capítulo se describen algunas de las técnicas empleadas para la localización de faltas eléctricas. Por un lado, se expone de forma concisa las transformadas tiempo-frecuencia centrándose en la transformada Wavelet y la transformada de Stockwell, que se presentan como herramientas para la obtención de características útiles de información en los dominios del tiempo y la frecuencia. Por otro lado, se presentan las técnicas de inteligencia artificial utilizadas con el objetivo de localizar faltas eléctricas a partir de las características obtenidas por las transformadas tiempo-frecuencia. En concreto, se presentan sistemas basados en ANN describiéndose esta técnica para entender con claridad las ventajas que muestran en la clasificación de patrones.

El cuarto capítulo está dedicado a la experimentación. La presentación en este capítulo de cada uno de los apartados presenta una secuencia lógica dividida por distintos experimentos realizados sobre diferentes redes eléctricas.

El capítulo quinto contiene las principales conclusiones derivadas de los resultados experimentales, así como las líneas para futuras investigaciones que han quedado abiertas y representan la posibilidad de continuación del trabajo descrito.

1.5. Publicaciones

Parte del trabajo de investigación desarrollado en esta tesis ha sido difundido en diferentes publicaciones de carácter internacional. Se enumeran a continuación:

A) Artículos en Revistas internacionales asociadas al campo de aplicación de la tesis.

Las dos publicaciones principales de la tesis que se citan a continuación se encuentran publicadas en la revista *Electric Power Systems Research*. Según la *Journal Citation Report (JCR)*, la presente revista se encuentra dentro de la categoría de Ingeniería eléctrica y electrónica en la posiciones 90 y 97 de 276 revistas, según el año de publicación y por tanto, se sitúan en el cuartil Q2. Por otro lado, según las métricas que figuran en Scopus, esta revista en el 2022 se encontraba en la posición 157 de 738 publicaciones y por tanto, según esta referencia, se sitúan en cuartil Q1.

1. R. Arranz, A. Paredes, A. Rodríguez, F. Muñoz (2021). "Fault location in Transmission System based on Transient Recovery Voltage using Stockwell transform and Artificial Neural Networks". In: *Electric Power System Research* 201, p. 107569. ISSN: 0378-7796.

DOI: <https://doi.org/https://doi.org/10.1016/j.epsr.2021.107569>

URL: <https://www.sciencedirect.com/science/article/pii/S0378779621005502>

2. R. Arranz, A. Rodríguez, and F. Muñoz (2020). "Detection of the natural frequency of transmission power lines applying S-transform on Transient recovery Voltage". In: *Electric Power Systems Research* 182, p. 106142. issn: 0378-7796.

DOI: <https://doi.org/https://doi.org/10.1016/j.epsr.2019.106142>

URL: <https://www.sciencedirect.com/science/article/pii/S0378779619304614>

B) Artículo en Congreso Internacional asociado al campo de aplicación

de la tesis.

1. R. A. Padilla, Á. P. Parrilla, A. R. Gómez and F. J. M. Gutiérrez, "Sensitivity Analysis of Dominant Frequency of Transient Recovery Voltage using Stockwell Transform," 2021 IEEE 15th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG), Florence, Italy, 2021, pp. 1-7, doi: 10.1109/CPE-POWERENG50821.2021.9501225.

C) Artículo en Revista Internacional no asociado al campo de aplicación de la tesis.

1. A. Daniel, R. Arranz, and J.A. Aguado (2019). "Sizing and operation of hybrid energy storage systems to perform ramp-rate control in PV power plants". In: International Journal of Electrical Power & Energy Systems 107, pp. 589–596. issn: 0142-0615. doi: <https://doi.org/10.1016/j.ijepes.2018.12.009>. URL: <https://www.sciencedirect.com/science/article/pii/S0142061518311499>.

Capítulo 2

Interruptores de potencia y tensión de recuperación transitoria

2.1. Resumen del capítulo

En el presente capítulo, se aborda la temática del interruptor de potencia, un componente esencial en los sistemas eléctricos para controlar y proteger las redes de distribución eléctrica. Y además, es el elemento a monitorizar la tensión entre sus terminales para la localización de faltas eléctricas objeto de estudio de la presente tesis. Se comienza definiendo qué es un interruptor de potencia, destacando su función principal de interrumpir o restablecer el flujo de corriente eléctrica en una red.

Se presentan diferentes tipos de interruptores, como los interruptores de aire, interruptores de aceite, interruptores de vacío y interruptores de SF₆, cada uno con características particulares que los hacen adecuados para diferentes entornos y niveles de voltaje y además se mencionan los estándares internacionales que definen las especificaciones y requisitos de los interruptores de potencia. Estos estándares garantizan la calidad, seguridad y compatibilidad de los interruptores utilizados en diferentes países y sistemas eléctricos.

Se describen las características nominales de los interruptores de potencia, incluyendo parámetros importantes como son la corriente nominal, la tensión

nominal, la corriente de cortocircuito nominal, la capacidad de interrupción y la capacidad de cierre. Estos parámetros definen el rendimiento y la capacidad de un interruptor y son fundamentales al seleccionar y diseñar un interruptor adecuado.

Otro aspecto clave abordado en este capítulo es el voltaje transitorio de recuperación (TRV), del inglés *Transient Recovery Voltage*, un fenómeno transitorio que ocurre cuando se interrumpe una corriente de cortocircuito en un sistema eléctrico. Se explican los factores que afectan al TRV, como son las características de la red expuesta (impedancia, disposición de las líneas,...) así como las características técnicas del interruptor en cuestión (velocidad de apertura y cierre, resistencia de contacto,...). Estos factores influyen en la magnitud y la duración del TRV y deben ser considerados durante el diseño y la selección de los interruptores de potencia.

Además, se exploran las técnicas de extinción del arco, que son los mecanismos utilizados para apagar el arco eléctrico que se forma durante la apertura del circuito. Se describen métodos como la extinción por separación, extinción por soplado magnético y extinción por soplado de gas, explicando los principios físicos detrás de cada uno y sus ventajas y desventajas así como los principales teorías de extinción del arco.

Finalmente, se explica en detalle el comportamiento transitorio eléctrico de la apertura de los contactos del interruptor de potencia y cuales son las distintas secuencias que describe.

2.2. Definición de un interruptor de potencia

Un interruptor de potencia (CB), del inglés, *Circuit Breaker* es un dispositivo electromecánico utilizado en sistemas eléctricos para controlar y proteger circuitos de potencia. Su función principal es interrumpir o restablecer la corriente eléctrica en condiciones normales o anormales, como cortocircuitos o sobrecargas en el sistema.

En una red eléctrica, los interruptores de potencia son fundamentales debido

a varias razones. En primer lugar, proporcionan protección contra sobrecargas o cortocircuitos. Si la corriente supera un nivel predeterminado, el interruptor abre automáticamente sus contactos para interrumpir la corriente y evitar daños en los equipos o cables conectados a la instalación.

Otra función importante de los interruptores de potencia es permitir el aislamiento de circuitos específicos en la red eléctrica. Esto es especialmente útil durante actividades de mantenimiento o reparación, ya que al abrir el interruptor aísla la conexión de esa sección de la red, permitiendo que los trabajadores realicen sus tareas de manera segura.

Los interruptores de potencia también son utilizados para facilitar la conexión y desconexión de equipos en la red eléctrica. Esto incluye la conexión segura de generadores, transformadores y otros dispositivos a la red, lo que permite un control más preciso y eficiente de la distribución de energía.

Por último, algunos interruptores de potencia cuentan con funciones avanzadas para monitorizar y controlar la calidad de la energía eléctrica. Esto implica la detección de armónicos, fluctuaciones de voltaje y desequilibrios de carga, lo que contribuye a mantener una calidad de red.

2.3. Historia del interruptor de potencia

La historia de los interruptores de potencia se remonta al siglo XIX. En sus inicios, se utilizaban interruptores mecánicos simples para controlar circuitos eléctricos de baja potencia. A medida que las demandas de energía aumentaron, surgió la necesidad de desarrollar interruptores más robustos y capaces de manejar corrientes y tensiones más altas.

En la década de 1920, se introdujo la tecnología de interruptores de aceite. Estos interruptores utilizaban un medio dieléctrico, como el aceite, para extinguir el arco eléctrico formado durante la apertura del circuito. El desarrollo de interruptores

de aceite marcó un hito importante en la protección de sistemas eléctricos de alta potencia.

En la década de 1960, se introdujeron los interruptores de aire comprimido. Estos interruptores utilizan aire comprimido para extinguir el arco eléctrico durante la apertura del circuito. La tecnología de interruptores de aire comprimido ofrecía ventajas significativas, como una mayor velocidad de operación y un mantenimiento más sencillo en comparación con los interruptores de aceite.

Otra tecnología destacada es la de los interruptores de vacío. A finales de la década de 1960 y principios de la década de 1970, se desarrollaron interruptores de vacío que utilizaban como medio dieléctrico el vacío para extinguir el arco eléctrico. Estos interruptores ofrecían una mayor capacidad de interrupción, tiempos de operación más cortos y mayor vida útil en comparación con los interruptores de aire comprimido y de aceite.

En las últimas décadas, la tecnología de los interruptores de gas ha ganado popularidad. Los interruptores de gas, como los basados en SF₆ (hexafluoruro de azufre), son capaces de manejar altas corrientes y tensiones y tienen propiedades dieléctricas excelentes. Estos interruptores de gas son utilizados en subestaciones eléctricas de alta tensión y ofrecen un rendimiento confiable y una vida útil prolongada.

Nuevamente, y debido al alto grado de contaminación de esta última tecnología, los fabricantes están desarrollando interruptores de vacío modernos como alternativa eficiente y respetuosa con el medio ambiente a los interruptores que utilizan hexafluoruro de azufre (SF₆), ya que evitan la emisión de gases de efecto invernadero y reducen el impacto ambiental. Estos interruptores utilizan tecnología de vacío para extinguir el arco eléctrico generado durante la apertura del circuito.

2.4. Clasificación de interruptores de potencia

La clasificación y descripción de los interruptores de potencia se basa en estándares internacionales como IEEE (*Institute of Electrical and Electronics Engineers*) e IEC (*International Electrotechnical Commission*).

2.4.1. Clasificación según la potencia

A continuación se describen las distintas tecnologías de interruptores según su potencia:

1. Interruptores de baja potencia:

- **Electrónica:** Estos interruptores se utilizan en aplicaciones de baja potencia, como dispositivos electrónicos y equipos de bajo voltaje. Su capacidad de interrupción de corriente es relativamente baja debido a las pequeñas corrientes que manejan.
- **Baja tensión:** Estos interruptores se utilizan en aplicaciones residenciales, comerciales e industriales de baja potencia, como paneles de distribución, tableros de control y sistemas de iluminación. Pueden ser de tecnologías como interruptores termomagnéticos, interruptores de circuito residual y contactores.

- #### 2. Interruptores de media potencia.
- Estos interruptores se utilizan en sistemas de distribución de energía de media tensión, generalmente en el rango de 1 kV a 36 kV. Pueden ser de diferentes tecnologías, como interruptores de vacío, interruptores de aire o interruptores de gas (SF₆). Los interruptores de vacío son ampliamente utilizados debido a su alta capacidad de interrupción y baja necesidad de mantenimiento.

3. **Interruptores de alta potencia.** Estos interruptores se utilizan en sistemas de transmisión y distribución de energía de alta tensión, generalmente por encima de 36 kV. Pueden ser de tecnologías como interruptores de vacío, interruptores de aceite o interruptores de gas (SF₆). Los interruptores de gas (SF₆) son comunes en sistemas de alta tensión debido a su alta capacidad de interrupción y excelente capacidad de aislamiento.
4. **Interruptores de potencia para aplicaciones de generación (GCB), del inglés *Generator Circuit Breaker*:**
 - Generación de baja potencia: Estos interruptores se utilizan en generadores de baja potencia, como grupos electrógenos y fuentes de energía renovable a pequeña escala. Pueden ser interruptores de vacío o interruptores de aire dependiendo de las características del generador y los requisitos de interrupción de corriente.
 - Generación de alta potencia: Estos interruptores se utilizan en generadores de alta potencia, como centrales eléctricas y plantas de energía. Pueden ser de diferentes tecnologías, como interruptores de vacío, interruptores de aceite o interruptores de gas (SF₆). La elección de la tecnología depende de la capacidad de interrupción requerida, la tensión del sistema y las consideraciones ambientales.

2.4.2. Clasificación según el medio de extinción

Los medios de extinción utilizados en los interruptores de potencia son:

1. **Vacío.** Los interruptores de potencia de vacío utilizan un contacto móvil y uno fijo dentro de una cámara de vacío. Al abrir el circuito, el vacío asegura que no se produzcan arcos eléctricos. Es una tecnología limpia, libre de gases contaminantes y ofrece una alta capacidad de interrupción.

- Ventajas: Alta capacidad de interrupción, bajo mantenimiento, alta velocidad de operación, buena capacidad de aislamiento, libre de gases contaminantes.
 - Desventajas: Costo inicial más alto que otras tecnologías, limitaciones en aplicaciones de alta tensión y alta corriente.
2. **Aceite.** Los interruptores de potencia de aceite utilizan aceite dieléctrico para extinguir el arco eléctrico. El aceite actúa como aislante y enfriador, y cuando el arco atraviesa el aceite, se genera gas que extingue el arco. Esta tecnología se utiliza principalmente en interruptores de alta tensión.
- Ventajas: Alta capacidad de interrupción, excelente capacidad de aislamiento, ampliamente utilizado en aplicaciones de alta tensión.
 - Desventajas: Requiere mantenimiento regular, mayor tamaño y peso, riesgo de fugas y contaminación ambiental.
3. **Gas.** Los interruptores de potencia de gas utilizan SF₆ como medio de extinción. El SF₆ es un gas inerte con excelentes propiedades de aislamiento y capacidad de extinción de arcos eléctricos. Esta tecnología se utiliza ampliamente en sistemas de alta tensión debido a su alta capacidad de interrupción y excelente capacidad de aislamiento.
- Ventajas: Alta capacidad de interrupción, excelente capacidad de aislamiento, ampliamente utilizado en aplicaciones de alta tensión, menor tamaño y peso que los interruptores de aceite.
 - Desventajas: Contribuye al efecto invernadero, costo inicial más alto, riesgo de fugas y regulaciones ambientales estrictas.

2.5. Normativa para interruptores de potencia

2.5.1. Estándares para interruptores de potencia

Los estándares internacionales más comunes para interruptores de potencia son establecidos por la IEC y la IEEE. Estos abarcan una variedad de normativas técnicas que garantizan la seguridad, confiabilidad y compatibilidad de estos dispositivos. Algunos de los estándares más importantes son:

1. **IEEE C37.04:** Especificaciones generales para interruptores de potencia de alta tensión. Este estándar establece los requisitos generales para el diseño, fabricación, pruebas y rendimiento de los interruptores de potencia de alta tensión. Cubre aspectos como las características eléctricas, mecánicas y ambientales de los interruptores.
2. **IEEE C37.06:** Características y mecanismos de operación de interruptores de potencia. Este estándar proporciona información detallada sobre las características de los interruptores de potencia, incluyendo los tipos de interruptores, los mecanismos de operación, los sistemas de disparo y cierre, y otros aspectos relacionados con su funcionamiento.
3. **IEEE C37.09:** Requisitos de prueba para interruptores de potencia. Este estándar establece los requisitos y procedimientos de prueba para los interruptores de potencia, incluyendo las pruebas de tipo, rutina y especiales. Cubre aspectos como la capacidad de interrupción, la rigidez dieléctrica, la capacidad de cierre, la estabilidad térmica y otras características de rendimiento.
4. **IEEE C37.010:** Pruebas de cortocircuito y requisitos de capacidad de interrupción para interruptores de potencia. Este estándar se centra en las pruebas de cortocircuito y establece los requisitos para la capacidad de interrupción de los interruptores de potencia. Define los procedimientos de

prueba, los parámetros de prueba y los criterios de aceptación para verificar la capacidad de los interruptores para interrumpir corrientes de cortocircuito.

5. **IEEE C37.013:** Directrices para el diseño y prueba de interruptores de potencia con resistencia al arco. Este estándar proporciona directrices para el diseño y la prueba de interruptores de potencia que tienen la capacidad de resistir y extinguir arcos eléctricos. Aborda aspectos como la resistencia al arco, la durabilidad de los contactos y la capacidad de extinción del arco.

6. **IEC 62271-100:** Especificaciones comunes para interruptores de alta tensión y dispositivos de control asociados. Este estándar internacional establece las especificaciones comunes para los interruptores de alta tensión utilizados en sistemas de energía eléctrica. Cubre aspectos como la clasificación, la construcción, la capacidad de interrupción, la rigidez dieléctrica y otros requisitos generales.

7. **IEC 62271-102:** Requisitos específicos para interruptores de alta tensión utilizados en subestaciones de energía. Este estándar se centra en los requisitos específicos para los interruptores de potencia utilizados en subestaciones eléctricas. Aborda aspectos como la clasificación, la capacidad de interrupción, la capacidad de cierre y otros requisitos aplicables a los interruptores utilizados en subestaciones.

8. **IEC 62271-108:** Requisitos específicos para interruptores de potencia utilizados en redes de corriente continua. Este estándar establece los requisitos para los interruptores de potencia utilizados en sistemas de corriente continua. Cubre aspectos como la clasificación, la capacidad de interrupción, la capacidad de cierre y otros requisitos específicos para los interruptores utilizados en sistemas de corriente continua.

2.5.2. Estándares para interruptores de generación

De igual forma, para los interruptores de generación existen normas específicas debido a la aplicación concreta que disponen. Los estándares internacionales más importantes son:

1. **IEC 62271-37-013:** Especificación técnica para interruptores de circuito de generador. Este estándar establece los requisitos técnicos para los interruptores de circuito de generador utilizados en plantas de generación eléctrica. Cubre aspectos como la clasificación, la capacidad de interrupción, la capacidad de cierre y otros requisitos específicos para los GCB.
2. **IEEE C37.013:** Directrices para el diseño y prueba de interruptores de circuito de generador. Este estándar proporciona directrices para el diseño y la prueba de los GCB utilizados para proteger los generadores de potencia en las plantas de generación eléctrica. Aborda aspectos como la capacidad de interrupción, la estabilidad térmica, la capacidad de cierre y otros requisitos relacionados.
3. **IEC 62271-100:** Especificaciones comunes para interruptores de alta tensión y dispositivos de control asociados. Este estándar también es aplicable a los GCB y establece las especificaciones comunes para los interruptores de alta tensión utilizados en sistemas de energía eléctrica. Cubre aspectos como la clasificación, la construcción, la capacidad de interrupción, la rigidez dieléctrica y otros requisitos generales.
4. **IEEE/IEC 62271-37-013:** Conjunto de normas para interruptores de circuito de generador. Esta norma conjunta combina los estándares IEEE y IEC relacionados con los interruptores de circuito de generador. Proporciona una referencia integral para el diseño, prueba y funcionamiento de los GCB en plantas de generación eléctrica.

2.6. Características nominales de un interruptor de potencia

A continuación se definen las principales características técnicas de los interruptores mencionadas por los estándares IEC e IEEE.

1. **Tensión nominal:** La tensión máxima para la cual el interruptor de potencia está diseñado para operar de manera segura y eficiente.
2. **Corriente nominal:** La corriente máxima que el interruptor de potencia puede manejar de manera continua sin sobrecalentamiento.
3. **Capacidad de interrupción:** La capacidad del interruptor de potencia para interrumpir corrientes de cortocircuito sin dañarse. Se especifica en términos de corriente de cortocircuito máxima que el interruptor puede interrumpir de manera segura.
4. **Tiempo de interrupción:** El tiempo máximo que tarda el interruptor de potencia en interrumpir la corriente después de recibir una señal de apertura.
5. **Ciclos de operación:** El número de veces que el interruptor de potencia puede ser operado antes de que se produzcan desgastes o deterioros en sus componentes.
6. **Tensión de Recuperación Transitoria (TRV):** tensión que aparece en los terminales del interruptor después de la interrupción de una corriente de cortocircuito. Se mide y especifica en términos de forma de onda y niveles de tensión.
7. **Tasa de aumento de la tensión de Recuperación (RRRV):** Es el TRV dividido por el tiempo total desde la tensión cero hasta la tensión pico.

8. **Resistencia de contacto:** La resistencia eléctrica de los contactos del interruptor cuando está cerrado. Una baja resistencia de contacto es deseable para minimizar las pérdidas de energía.
9. **Velocidad de apertura y cierre:** La velocidad a la que el interruptor de potencia puede abrir y cerrar sus contactos. Una alta velocidad de operación es importante para una respuesta rápida en caso de faltas en el sistema.
10. **Medio de extinción del arco:** El medio utilizado para extinguir el arco eléctrico formado durante la apertura de los contactos. Puede ser gas (como SF6 o aire), aceite, vacío u otros medios.
11. **Tecnología de interruptor:** La tecnología utilizada en el diseño del interruptor de potencia, como interruptores de aire, interruptores de vacío, interruptores de gas SF6, interruptores de aceite, entre otros.
12. **Ángulo de incidencia:** Se refiere al ángulo con el que la corriente eléctrica impacta sobre los contactos del interruptor. Este ángulo es crucial porque influye en el rendimiento del interruptor y su capacidad para abrir y cerrar circuitos eléctricos de manera efectiva.

2.7. Tensión de recuperación transitoria

2.7.1. Introducción

La Tensión de Recuperación Transitoria (TRV), del inglés *Transient Recovery Voltage* es un fenómeno eléctrico de gran importancia en los sistemas de potencia. Se produce durante la operación de apertura de un interruptor de potencia después de un cortocircuito para aislar el sistema de una falta eléctrica. El TRV es una forma de onda transitoria que representa la recuperación del voltaje en el sistema después

de la interrupción de la corriente de cortocircuito tal y como se muestra en la Figura 2.1.

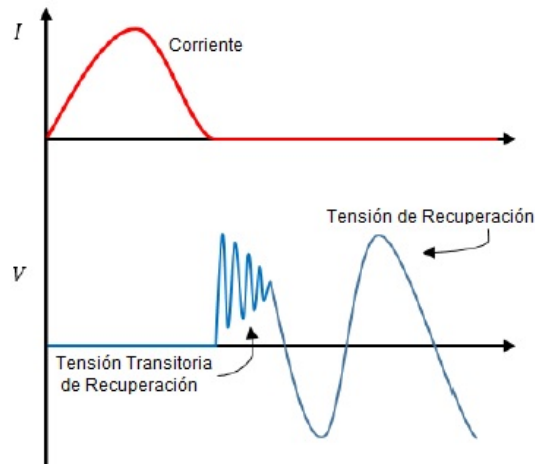


Figura 2.1: *Transient Recovery Voltage (TRV).*

Su medición y comprensión son fundamentales para garantizar el funcionamiento seguro y confiable de los sistemas eléctricos de potencia. La relevancia de este fenómeno se encuentra en que todo el interruptor debe ser capaz de soportar el transitorio electromotriz al que se somete, ya que de lo contrario, el equipo quedará dañado o incluso destruido, sumado a la reactivación del arco eléctrico dentro de la cámara y la imposibilidad de evitar el cortocircuito. Complementariamente al TRV, el interruptor debe evitar la Tasa de aumento de la tensión de Recuperación (RRRV), del inglés *Rate of Rise of Recovery Voltage*.

La medición del TRV se realiza mediante equipos y técnicas especializadas. Los instrumentos de medición capturan la forma de onda del TRV y registran su magnitud, duración y forma. Para medir el TRV, se utilizan sondas de alta tensión y dispositivos de adquisición de datos de alta velocidad. Estos equipos registran los cambios rápidos en el voltaje durante la operación de apertura del interruptor de potencia.

El TRV es una característica eléctrica crítica que debe ser considerada durante el diseño y operación de los sistemas de potencia y que aporta mucha visibilidad sobre

el comportamiento de la red. Su comprensión y gestión adecuada son fundamentales para garantizar la confiabilidad y seguridad del sistema. El TRV puede tener impactos significativos en los equipos eléctricos, como generadores, transformadores y otros dispositivos sensibles, debido a las sobretensiones transitorias que genera.

La gestión adecuada del TRV implica diseñar y seleccionar interruptores de potencia adecuados, considerar la topología de la red eléctrica y las características de los elementos de la red, así como implementar medidas de protección y control adecuadas. Esto ayuda a minimizar los efectos del TRV, como sobretensiones, transitorios y posibles daños en los equipos, asegurando así la estabilidad y confiabilidad del sistema eléctrico.

Para abordar adecuadamente el TRV, los estándares como el IEEE C37.010 e IEC 62271-100 establecen criterios y requisitos para su control. Estos estándares proporcionan pautas sobre los límites aceptables de TRV, los métodos de cálculo, los criterios de aceptación y los procedimientos de prueba. Además, ofrecen directrices sobre el diseño de los interruptores de potencia y las medidas de mitigación necesarias para evitar daños en el sistema debido a sobretensiones transitorias.

2.7.2. Factores que afectan al TRV

La magnitud, forma de onda y duración del TRV dependen de varios factores, como la capacitancia e inductancia del sistema, la velocidad de apertura y cierre del interruptor, la resistencia de contacto y la capacidad de extinción del arco entre otros. Estas características eléctricas del sistema influyen en la cantidad de energía almacenada y liberada durante la interrupción de la corriente de cortocircuito

La corriente de cortocircuito juega un papel fundamental en la generación del TRV. Cuanto mayor sea la corriente de cortocircuito, mayor será la energía almacenada en la inductancia del circuito y, por lo tanto, mayor será la magnitud del TRV. Por esta razón, es importante realizar cálculos precisos de la corriente de

cortocircuito y tener en cuenta los valores esperados en el diseño y selección de los interruptores de potencia.

La impedancia del sistema es un factor crucial que influye en el comportamiento del TRV. Una alta impedancia en el sistema puede provocar que el TRV alcance niveles peligrosos, lo que podría comprometer el aislamiento de los equipos y generar daños en los dispositivos conectados a la red eléctrica. Por otro lado, una baja impedancia del sistema puede resultar en TRV más bajos y de menor duración, lo que reduce los riesgos asociados.

Asimismo, la disposición de las líneas aéreas, como su longitud y configuración (en bucle, radial, anillo, etc.), puede tener un impacto en el TRV. En líneas largas, el TRV tiende a ser más pronunciado debido a la mayor inductancia y capacitancia del sistema. Por otro lado, las líneas en configuraciones de bucle o anillo pueden reducir la magnitud y la duración del TRV debido a la interconexión y a la capacidad de las corrientes de cortocircuito para fluir por diferentes rutas.

Por otro lado, las características del interruptor de potencia también desempeñan un papel esencial en la gestión del TRV. La velocidad de apertura y cierre del interruptor, la resistencia de contacto y la capacidad de extinción del arco son aspectos que deben tenerse en cuenta. Un interruptor de potencia diseñado para un TRV específico debe ser capaz de soportar las tensiones transitorias generadas durante la interrupción y garantizar una operación segura y confiable.

La velocidad de apertura y cierre del interruptor de potencia es un aspecto importante a considerar en relación con el TRV. La velocidad de apertura se refiere al tiempo que tarda el interruptor en abrirse después de que se detecta una condición de cortocircuito, mientras que la velocidad de cierre es el tiempo que tarda en cerrarse después de haberse abierto. Una velocidad de apertura y cierre adecuada es crucial para limitar el TRV y garantizar una operación segura y confiable del sistema. Un cierre demasiado lento puede prolongar la duración del TRV, mientras que un cierre demasiado rápido puede generar transitorios de voltaje no deseados.

La resistencia de contacto del interruptor es otro factor importante que afecta el TRV. Durante la operación del interruptor, puede haber una pequeña resistencia en los contactos, lo que da lugar a una caída de tensión. Esta resistencia de contacto influye en la magnitud y la forma de onda del TRV, ya que puede afectar la transferencia de energía y la aparición de sobretensiones transitorias. Es esencial tener una resistencia de contacto baja para minimizar el impacto del TRV.

La capacidad de extinción del arco también es un aspecto clave a considerar. Cuando el interruptor de potencia se abre, se forma un arco eléctrico entre los contactos. Este arco eléctrico debe ser extinguido rápidamente y de manera confiable para evitar daños en el interruptor y en el sistema eléctrico. Una capacidad de extinción del arco eficiente ayuda a reducir la magnitud y la duración del TRV. Diversas técnicas y tecnologías, como el uso de medios dieléctricos especiales o sistemas de soplado de gas, se emplean para mejorar la capacidad de extinción del arco y mitigar los efectos del TRV.

2.7.3. Tipos de TRV

Todos los tipos de TRV corresponden a una combinación de los siguientes elementos:

1. **TRV Exponencial:** ocurre cuando el interruptor despeja una corriente de cortocircuito dejando en el lado no afectado a transformadores junto a líneas de transmisión. Debido a la existencia de la línea se producen ondas de reflexión.




Figura 2.2: TRV exponencial [31].

2. **TRV oscilatorio:** ocurre cuando el interruptor deja en el lado no afectado solamente un transformador o un equipo de compensación reactiva.




Figura 2.3: TRV oscilatorio [31].

3. **TRV en línea de poca distancia:** posee la particularidad de generar una forma de onda del tipo diente de sierra.




Figura 2.4: TRV línea corta [31].

2.7.4. Procedimientos de prueba para evaluar el TRV

Existen dos normas de referencia para evaluar el TRV sobre los interruptores de potencia.

2.7.4.1. IEEE C37.010

El estándar IEEE C37.010 establece el procedimiento de prueba conocido como "prueba de corriente de recierre" para medir el TRV. A continuación, se detallan los pasos generales de este procedimiento:

1. Se establece un circuito de prueba que representa el sistema eléctrico donde se encuentra el interruptor de potencia.

2. Se aplica una corriente de cortocircuito al circuito de prueba, utilizando una fuente de corriente adecuada.
3. El interruptor de potencia se cierra para permitir el flujo de corriente de cortocircuito.
4. Después de un breve período de tiempo, se abre el interruptor de potencia para interrumpir la corriente de cortocircuito.
5. Se registra la forma de onda de la tensión que se produce después de la apertura del interruptor utilizando equipos de medición, como osciloscopios.
6. Se repite el procedimiento de prueba con diferentes corrientes de cortocircuito para cubrir un rango de condiciones operativas.
7. Los resultados de las pruebas se comparan con los criterios de aceptación establecidos en el estándar para determinar si el TRV está dentro de los límites aceptables.

Es importante tener en cuenta que el estándar IEEE C37.010 proporciona detalles adicionales sobre los requisitos de prueba, los parámetros de medición y los criterios de aceptación específicos.

2.7.4.2. IEC 62271-100

El estándar IEC 62271-100 no especifica un procedimiento de prueba detallado para medir el TRV. Sin embargo, se utilizan métodos similares a los descritos en el IEEE C37.010 para llevar a cabo estas pruebas. Los pasos generales incluirían:

1. Configurar un circuito de prueba representativo del sistema eléctrico.
2. Aplicar una corriente de cortocircuito al circuito de prueba.
3. Cerrar el interruptor de potencia para permitir el flujo de corriente de cortocircuito.

4. Abrir el interruptor de potencia para interrumpir la corriente de cortocircuito.
5. Registrar la forma de onda de la tensión transitoria resultante utilizando equipos de medición adecuados.
6. Repetir el procedimiento de prueba con diferentes corrientes de cortocircuito para cubrir distintas condiciones de operación.
7. Comparar los resultados con los criterios de aceptación establecidos en el estándar para evaluar si el TRV cumple con los límites aceptables.

Es importante tener en cuenta que los procedimientos de prueba específicos pueden variar según los requisitos y recomendaciones establecidos en cada norma. En ambos casos, los procedimientos de prueba para medir el TRV según los estándares IEEE C37.010 e IEC 62271-100 implican la configuración de un circuito de prueba, la aplicación de una corriente de cortocircuito, el cierre y apertura del interruptor de potencia, y la medición de la forma de onda de la tensión transitoria resultante.

2.8. Dimensionamiento de interruptores según criterio de TRV

Las normas IEC 62271-100 e IEEE Std. C37.011, establecen la comparación del valor de TRV de la simulación de transitorios electromagnéticos con las curvas envolventes de los interruptores. Para asegurar que un interruptor esté correctamente dimensionado, la curva de TRV de la simulación de transitorios electromagnéticos no debe cruzar la envolvente de referencia y el RRRV no superar un valor específico asignado en función de la tensión de diseño del interruptor y la curva envolvente de referencia, como se ilustra en la Figura 2.5.

Para determinar la curva envolvente, se compara la corriente máxima que el interruptor debe interrumpir (nivel de cortocircuito) con su capacidad de ruptura.

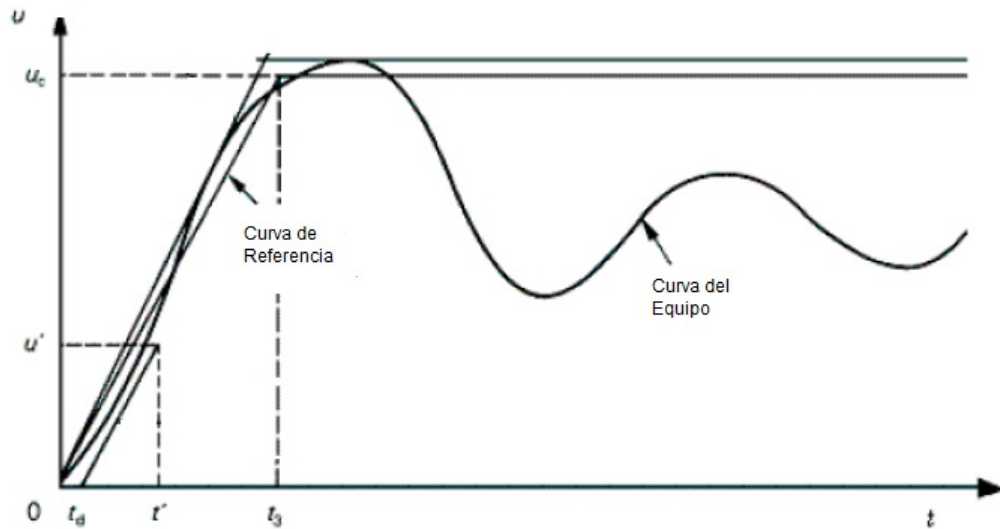


Figura 2.5: Envolvente T10 de la curva TRV [31].

Dependiendo del porcentaje del nivel de cortocircuito respecto a la capacidad de ruptura, se asigna una curva envolvente que va desde T10 hasta T100, donde el número después de la letra T indica el porcentaje del nivel de cortocircuito en relación con la capacidad de ruptura. Además, se considera el factor de primer polo (K_{pp}), proporcionado por el fabricante, que clasifica los límites de TRV y RRRV del interruptor según diferentes tablas estandarizadas. El K_{pp} se refiere al tiempo que tarda el primer polo del interruptor en interrumpir la corriente después de que se haya iniciado el proceso de apertura del interruptor. A medida que sea menor, la eficiencia del interruptor será mayor.

2.9. Técnicas de extinción del arco

2.9.1. Principio de operación de contactos del interruptor

El proceso de separación de los contactos y extinción del arco es fundamental para comprender cómo se interrumpe el suministro eléctrico de manera efectiva y segura. A continuación, se describe en detalle este principio de funcionamiento, destacando

los pasos y mecanismos involucrados:

Cuando se activa la orden de apertura en un interruptor de potencia, se inicia el proceso de interrupción del flujo de corriente eléctrica. La detección de la orden de apertura se realiza a partir de la medida realizada por los transformadores de intensidad y tensión. Estos transformadores monitorean la corriente y la tensión en el sistema eléctrico y envían señales a los dispositivos de control del interruptor de potencia. Cuando se detecta una condición anormal, como una sobrecorriente o una sobretensión, se emite la orden de apertura para interrumpir el suministro eléctrico.

El mecanismo de cierre en un interruptor de potencia se encarga de mantener los contactos en posición cerrada mientras se suministra corriente eléctrica. Para desactivar este mecanismo y permitir la apertura de los contactos, se emplean diferentes métodos según el tipo de interruptor, todos basados en actuaciones electromecánicas controladas a través de sistemas electrónicos.

Al abrir los contactos, en el caso de los interruptores con SF₆, el gas se introduce en alta presión entre los contactos mediante boquillas de sopladors aislando el circuito por lo que la corriente eléctrica intenta mantener su flujo a través del interruptor a medida que la impedancia en la cámara crece, lo que resulta en la formación de un arco eléctrico. El arco eléctrico es una descarga de corriente continua en estado de plasma altamente conductor. La extinción del arco es un proceso crítico para evitar daños a los contactos y asegurar una interrupción segura. Es importante destacar que este proceso de interrupción de la corriente eléctrica ocurre en un tiempo extremadamente breve, normalmente del orden de milisegundos.

La eficacia y confiabilidad del interruptor de potencia para abrir los contactos de manera segura y rápida son de vital importancia en la protección y control de los sistemas eléctricos. Una vez que el arco eléctrico se ha extinguido, los contactos del interruptor permanecen separados y se asegura un aislamiento eléctrico efectivo. Esto evita que la corriente fluya a través del interruptor y garantiza la interrupción del suministro eléctrico.

2.9.2. Principales teorías de interrupción del arco eléctrico

Las teorías de interrupción son enfoques teóricos que buscan explicar los mecanismos físicos y fenomenológicos involucrados en la extinción del arco eléctrico en interruptores de potencia. Estas teorías proporcionan una base teórica para comprender y diseñar interruptores de potencia más eficientes y confiables. A continuación, se describen brevemente las teorías principales que son las de Cassie, Mayr y Schavmaker:

1. La **teoría de Cassie** se utiliza para describir el comportamiento de los arcos eléctricos, enfocándose en la ionización del gas, la resistencia del arco y la transferencia de calor. Esta teoría es fundamental para entender cómo las condiciones ambientales, como la temperatura y la presión, afectan la formación y estabilidad de un arco eléctrico en sistemas eléctricos.
 - Ionización del gas: La corriente eléctrica ioniza el gas en el arco, generando electrones libres e iones. Este proceso permite que el gas actúe como un conductor.
 - Resistencia del arco: La resistencia del arco eléctrico varía con la presión y la temperatura. Una menor resistencia permite un mayor flujo de corriente, lo que resulta en una mayor generación de calor.
 - Transferencia de calor: La energía eléctrica se convierte en calor, el cual se disipa a través de conducción, convección y radiación. El equilibrio entre la generación y la disipación de calor es crucial para la estabilidad del arco.

La ecuación que representa la corriente en un arco eléctrico es la siguiente:

$$I = I_0 \left(\frac{p}{p_0} \right)^{\frac{3}{2}} \cdot \left(\frac{T}{T_0} \right)^{\frac{1}{2}} \cdot \exp \left(-\frac{E_a}{k \cdot T} \right) \quad (2.1)$$

Donde:

- I : Corriente del arco eléctrico.
- I_0 : Corriente de referencia en condiciones estándar.
- p : Presión del gas en el arco.
- p_0 : Presión de referencia.
- T : Temperatura del gas en el arco.
- T_0 : Temperatura de referencia.
- E_a : Energía de activación para la ionización del gas.
- k : Constante de Boltzmann.

2. La **teoría de Mayr** es una de las más utilizadas para modelar el comportamiento de los arcos eléctricos en aplicaciones eléctricas. Esta teoría se centra en la relación entre la corriente del arco, la presión del gas y la energía involucrada en el proceso de ionización, describiendo el comportamiento del arco en función de las condiciones ambientales y las características del medio.

- Ionización del gas: La teoría de Mayr postula que el proceso de ionización en un arco eléctrico es un fenómeno crítico que depende de la energía térmica y del campo eléctrico aplicado. La ionización del gas permite que se forme un canal conductor a través del cual fluye la corriente.
- Relación entre corriente y presión: La corriente del arco eléctrico (I) está relacionada con la presión del gas (p) y la temperatura (T). A medida que la presión del gas aumenta, la cantidad de energía requerida para ionizar el gas también aumenta, lo que influye en la resistencia del arco.
- Transferencia de calor: La generación de calor en el arco eléctrico, como en la teoría de Cassie, también es crucial. La energía eléctrica se convierte en calor, que se disipa a través de conducción, convección y radiación. Esto puede afectar la estabilidad del arco y su duración.

La ecuación que se utiliza comúnmente para describir la corriente en un arco eléctrico, según la teoría de Mayr, es la siguiente:

$$I = K \cdot p^{\frac{3}{2}} \cdot T^{\frac{1}{2}} \cdot e^{\frac{E_a}{k \cdot T}} \quad (2.2)$$

Donde:

- I : Corriente del arco eléctrico.
- K : Constante que depende de las características del sistema.
- p : Presión del gas en el arco.
- T : Temperatura del gas en el arco.
- E_a : Energía de activación para la ionización del gas.
- k : Constante de Boltzmann.

3. La **teoría de Schavmaker** es un enfoque utilizado para describir el comportamiento de arcos eléctricos, enfocándose en la dinámica de los gases ionizados y su interacción con el entorno eléctrico. Esta teoría se centra en varios factores, como la ionización del gas, la resistencia del arco, la generación de calor y la interacción con el medio circundante.

- Ionización del gas: La teoría postula que el arco eléctrico se forma cuando el campo eléctrico aplicado es suficiente para ionizar el gas. Este proceso se ve influenciado por la temperatura, la presión y la energía de ionización del gas.
- Mecanismo de arco: Se considera que el arco eléctrico se forma por un equilibrio entre la generación de electrones libres (ionización) y la recombinación de iones y electrones. Este equilibrio es crucial para la estabilidad del arco.
- Resistencia del arco: La resistencia del arco eléctrico varía con las condiciones del gas, como la presión y la temperatura. En general, un arco más caliente tendrá menor resistencia, lo que permite una mayor corriente.

- Transferencia de calor: La generación de calor en el arco eléctrico es un aspecto clave de la teoría. La energía eléctrica se convierte en calor, que se disipa a través de varios mecanismos: conducción, convección y radiación.

La ecuación que describe la corriente en un arco eléctrico, según la teoría de Schavmaker, es comúnmente representada de la siguiente manera:

$$I = K \cdot p^\alpha \cdot T^\beta \cdot e^{\frac{E_a}{kT}} \quad (2.3)$$

Donde:

- I : Corriente del arco eléctrico.
- K : Constante que depende de las características del sistema.
- p : Presión del gas en el arco.
- T : Temperatura del gas en el arco.
- E_a : Energía de activación para la ionización del gas.
- k : Constante de Boltzmann.
- α : Exponente que representa la dependencia de la corriente respecto a la presión.
- β : Exponente que representa la dependencia de la corriente respecto a la temperatura.

Es importante destacar que las formulaciones matemáticas asociadas a estas teorías son complejas y dependen de diversos parámetros y condiciones específicas del interruptor de potencia. Además, existen otras teorías y enfoques teóricos que también contribuyen a la comprensión de la extinción del arco en interruptores de potencia. Las teorías mencionadas anteriormente son solo algunas de las principales teorías utilizadas en la investigación y el diseño de interruptores de potencia.

2.10. Comportamiento transitorio de la apertura de contacto del interruptor de potencia

El transitorio durante la apertura de un interruptor de potencia es un fenómeno dinámico que implica cambios significativos en las variables eléctricas del sistema. Durante este proceso, se producen eventos clave que afectan a la corriente, a la tensión y a la formación de un arco eléctrico. El análisis del transitorio es esencial para comprender el comportamiento del interruptor y garantizar un diseño eficiente y seguro del sistema eléctrico. De forma general, el circuito básico se puede esquematizar según aparece en la Figura 2.6.




Figura 2.6: Esquema básico de circuito con un interruptor de potencia.

Las fases de la apertura del interruptor de potencia son:

1. Circuito cerrado con intensidad Nominal

En esta fase, el circuito está completamente cerrado y la corriente nominal (I_n) fluye a través de él. La tensión total en el circuito es constante, y no hay interferencia del arco eléctrico.

$$I = I_n \quad (2.4)$$

$$V = I_n \cdot R + V_0 \quad (2.5)$$

Donde:

- V : Tensión total en el circuito.
- I_n : Corriente nominal que circula por el circuito.
- R : Resistencia total del circuito (incluyendo contactos).
- V_0 : Tensión mínima requerida para iniciar el arco.

En esta fase, el TRV no está presente, ya que el circuito está completamente cerrado. Sin embargo, la resistencia y la inductancia del circuito determinarán el comportamiento del sistema cuando se inicie la apertura del interruptor.

2. Principio de apertura del interruptor y tensión de ruptura

Al iniciar el proceso de apertura del interruptor, la tensión comienza a aumentar, acercándose a la tensión de ruptura necesaria para iniciar la ionización del gas.

$$I = I_n \cdot e^{-\frac{t}{\tau}} \quad (2.6)$$

$$V_{ruptura} = V_0 + \frac{I_n}{G} + L \cdot \frac{dI}{dt} \quad (2.7)$$

Donde:

- $V_{ruptura}$: Tensión en el momento en que se inicia la ionización.
- G : Conductancia del arco, que representa la capacidad del arco para conducir corriente.
- I_n : Corriente nominal.
- L : Inductancia del circuito.
- $\frac{dI}{dt}$: Tasa de cambio de la corriente.

La tensión de ruptura es crucial para la formación del arco y puede ser un indicativo del TRV que se generará al abrir el interruptor. A medida que la

corriente comienza a disminuir, el TRV puede aumentar significativamente debido a la energía almacenada en la inductancia.

En este momento, el ángulo de incidencia es clave en la operación. Este ángulo se refiere a la diferencia entre la dirección de la corriente de entrada y la dirección de operación del interruptor cuando se abre o cierra. Este ángulo es crucial porque afecta la dirección y magnitud del flujo de corriente a través del interruptor e influye en la energía que se libera en forma de arco eléctrico. Es decir, si el interruptor se abre en el punto adecuado del ciclo, es decir, cuando coincide el cruce por cero de la intensidad, el arco será más fácil de extinguir.

3. Fase de pre-arco

Esta fase ocurre justo antes de que se establezca el arco. La tensión en el circuito se aproxima a un nivel crítico, y la ionización comienza a facilitar la formación del arco.

$$I = I_n \cdot e^{-\frac{t}{\tau}} \cdot \left(1 - e^{-\frac{t}{t_{ion}}}\right) \quad (2.8)$$

$$V_{pre-arco} = V_0 + R \cdot I_n + L \cdot \frac{dI}{dt} \quad (2.9)$$

Donde:

- $V_{pre-arco}$: Tensión en la fase de pre-arco.
- R : Resistencia del circuito.
- I_n : Corriente nominal.
- L : Inductancia del circuito.

Durante esta fase, el TRV comienza a incrementarse, reflejando cómo la tensión se comportará cuando el interruptor empiece a abrirse. La preparación para la ionización del gas es crucial en esta fase.

4. Fase de establecimiento del arco

El arco eléctrico comienza a formarse, y la corriente a través del arco es más significativa.

$$I = K \cdot p^\alpha \cdot T^\beta \cdot e^{-\frac{E_a}{kT}} \quad (2.10)$$

$$V_{establecimiento} = V_0 + R_{arco} \cdot I + L \cdot \frac{dI}{dt} + \frac{I^2}{G} \quad (2.11)$$

Donde:

- $V_{establecimiento}$: Tensión en el momento de establecimiento del arco.
- R_{arco} : Resistencia del arco en formación.
- I : Corriente a través del arco.
- L : Inductancia del circuito.
- G : Conductancia del arco.

Durante el establecimiento del arco, el TRV puede alcanzar valores máximos debido a la repentina variación de la corriente. Esta fase es crítica porque la energía acumulada en el circuito inductivo afectará a la tensión del sistema.

5. Fase de arco oscilante

Durante esta fase, el arco puede experimentar oscilaciones, y la corriente puede fluctuar.

$$I = I_{max} \cdot \sin(\omega t) \quad (2.12)$$

$$V_{oscilante} = V_0 + R_{arco} \cdot I + L \cdot \frac{dI}{dt} + \Delta V \quad (2.13)$$

Donde:

- $V_{oscilante}$: Tensión durante la fase de arco oscilante.
- ΔV : Tensión adicional generada por las oscilaciones del arco.
- R_{arco} : Resistencia del arco.
- I : Corriente a través del arco.
- L : Inductancia del circuito.

Las oscilaciones en la corriente pueden afectar el TRV, generando picos de tensión que pueden ser peligrosos para los componentes eléctricos.

6. Fase de interrupción del arco

A medida que la corriente comienza a disminuir, la tensión se ajusta a la resistencia residual y a la inductancia del circuito.

$$I = I_{max} \cdot e^{-\frac{t}{\tau}} \quad (2.14)$$

$$V_{interrupción} = V_0 + R_{circuito} \cdot I_{off} + L \cdot \frac{dI_{off}}{dt} \quad (2.15)$$

Donde:

- $V_{interrupción}$: Tensión en la fase de interrupción.
- $R_{circuito}$: Resistencia del circuito en ese momento.
- I_{off} : Corriente residual después de la apertura.
- L : Inductancia del circuito.

Durante la interrupción del arco, el TRV puede experimentar un aumento significativo debido a la rápida caída de la corriente. Este aumento de tensión puede causar sobretensiones en el sistema, lo que es crítico para proteger los componentes eléctricos.

7. Fin del arco

Cuando el arco se apaga, la tensión en el sistema se ajusta a un nivel de recuperación.

$$I = I_{off} \quad (2.16)$$

$$V_{\text{recuperación}} \approx V_0 + I_{off} \cdot R_{\text{circuito}} + L \cdot \frac{dI_{off}}{dt} \quad (2.17)$$

Donde:

- $V_{\text{recuperación}}$: Tensión de recuperación después de que se apaga el arco.
- I_{off} : Corriente residual en el circuito.
- R_{circuito} : Resistencia del circuito.
- L : Inductancia del circuito.

La tensión de recuperación representa el TRV final en el sistema después de que se apaga el arco. Este valor es crítico para evaluar la capacidad del sistema para manejar la energía residual y evitar daños en los componentes eléctricos.

Capítulo 3

Técnicas de caracterización y clasificación de señales eléctricas

3.1. Resumen del capítulo

En el presente capítulo de la tesis, se aborda la caracterización y clasificación de señales, con la descripción de transformadas tiempo-frecuencia y centrándose en la técnica de la transformada de Stockwell. Por otro lado, se presentará el uso de Redes Neuronales, desde la explicación de su base biológica hasta su estructura, modos de operación y procesos de aprendizaje con la Optimización Bayesiana para su uso en la clasificación de señales. Todo ello proporcionará la base científica necesaria para comprender el algoritmo localizar de faltas, que se presenta en la sección final del capítulo.

Las transformadas tiempo-frecuencia son herramientas matemáticas clave para analizar señales no estacionarias, aquellas cuyas propiedades varían en el tiempo, permitiendo representar simultáneamente la señal en los dominios del tiempo y la frecuencia. A diferencia de la transformada de Fourier, que asume que las frecuencias son constantes, las transformadas tiempo-frecuencia capturan la evolución temporal de las frecuencias, lo que las hace indispensables en el análisis de señales con componentes transitorios. Entre ellas, la transformada de Stockwell destaca al combinar lo mejor de la transformada de Fourier y la Wavelet, ofreciendo una

representación detallada de la señal sin sacrificar la localización temporal. Su ventaja radica en que ajusta automáticamente la resolución temporal y frecuencial, proporcionando una localización precisa en el tiempo y caracterizando con exactitud las frecuencias a lo largo del tiempo, lo que la convierte en una herramienta poderosa para el análisis de señales dinámicas.

Por otro lado, las Redes Neuronales son modelos computacionales inspirados en el funcionamiento del cerebro humano. Se componen de unidades interconectadas, llamadas neuronas, que procesan y transmiten información. Las Redes Neuronales tienen una arquitectura organizada en capas, que incluye una capa de entrada, una o varias capas ocultas y una capa de salida. Estas redes pueden aprender de los datos existentes y sus relaciones mediante un proceso de entrenamiento, donde se ajustan los pesos de las conexiones entre las neuronas para optimizar la salida deseada. La Optimización Bayesiana es una técnica utilizada en el proceso de entrenamiento para encontrar los mejores valores de los hiperparámetros que caracterizan el modelo de red neuronal.

3.2. Transformadas tiempo-frecuencia

3.2.1. Transformada de Fourier

La transformada de Fourier (FT), del inglés *Fourier Transform*, es una herramienta matemática fundamental en el análisis de señales y sistemas. Fue desarrollada por el matemático francés Jean-Baptiste Joseph Fourier en el siglo XIX y ha sido de gran aplicación en multitud de áreas, como la ingeniería, la física y la música.

La idea básica detrás de la FT es descomponer una señal en diferentes frecuencias, revelando así su contenido espectral. Esto permite analizar y manipular señales en el dominio de la frecuencia, lo que a menudo resulta más conveniente que trabajar en el dominio del tiempo.

3.2.1.1. Series de Fourier

Las series de Fourier se utilizan para el análisis y la síntesis de señales periódicas, la resolución de ecuaciones diferenciales, el procesamiento de señales, la compresión de datos, entre otros campos.

Una serie de Fourier se define generalmente en términos de una función periódica $f(t)$ con periodo T y se expresa como:

$$f(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} \left\{ a_n \cos\left(\frac{n\omega_0}{T}t\right) + b_n \operatorname{sen}\left(\frac{n\omega_0}{T}t\right) \right\} \quad (3.1)$$

Donde a_0 , a_n y b_n se denominan coeficientes de Fourier de la serie de Fourier de la función $f(t)$ que pueden calcularse como:

$$a_0 = \frac{1}{T} \int_{-T}^T f(t) dt \quad (3.2)$$

$$a_n = \frac{1}{T} \int_0^T f(t) \cos\left(\frac{n\pi}{T}t\right) dt \quad (3.3)$$

$$b_n = \frac{1}{T} \int_0^T f(t) \operatorname{sen}\left(\frac{n\pi}{T}t\right) dt \quad (3.4)$$

De esta forma, cualquier función en un intervalo determinado puede aproximarse a una suma de senos y cosenos de frecuencias enteras múltiplos de la frecuencia fundamental.

3.2.1.2. Definición matemática

Con las series de Fourier se puede expresar cualquier señal periódica como una suma de funciones seno y coseno. El análisis de Fourier se puede hacer extensivo a funciones no periódicas.

La FT es una herramienta matemática que permite descomponer una señal en sus componentes de frecuencia. En otras palabras, permite representar una señal en el dominio del tiempo como una suma de sinusoides de diferentes frecuencias.

La FT de una función continua en el tiempo se define como:

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt \quad (3.5)$$

Donde

- $f(t)$ es la función continua en el tiempo
- $F(\omega)$ es su transformada de Fourier
- j es la unidad imaginaria.

La ecuación muestra la integral de la función $f(t)$ multiplicada por una exponencial compleja. El resultado de esta integral es la FT $F(\omega)$, que es una función de la frecuencia ω .

3.2.1.3. Señales continuas y discretas

Una primera clasificación que se puede hacer de las señales es distinguirlas entre continuas y discretas. Una señal continua es aquella que varía suavemente en el tiempo y en la amplitud, sin saltos ni interrupciones. Puede tomar cualquier valor en cualquier punto del tiempo y se representa por medio de una función continua. Por otro lado, una señal discreta está compuesta por un conjunto finito contable de puntos en el tiempo y la amplitud. La señal solo toma valores en instantes discretos y se representa mediante una secuencia de valores.

3.2.1.4. Transformada de Fourier discreta

La Transformada de Fourier Discreta (DFT), del inglés *Discrete Fourier Transform*, es una versión discreta de la FT, y se utiliza para analizar señales digitales en el dominio de la frecuencia.

La DFT toma una secuencia de puntos discretos en el tiempo y calcula su espectro de frecuencia correspondiente. Es especialmente útil cuando se trabaja con señales que están muestreadas de forma discreta en el tiempo, como señales digitales.

Supóngase que $f(t)$ es una señal periódica de periodo T con periodo de muestreo $\frac{T}{N}$ y frecuencia de muestreo $fm = \frac{N}{T}$. Entonces, si $f(\frac{kT}{N})$ es la k -ésima muestra de $f(t)$ y $F(nWm)$ es la n -ésima muestra de $F(w)$, siendo $Wm = 2fm\pi$, se puede escribir la FT en su forma discreta como:

$$F(n) = \sum_{k=0}^{N-1} f_k e^{-\frac{2ikn\pi}{N}} \quad (3.6)$$

Donde:

$$f_k = f\left(k\frac{T}{N}\right) \quad (3.7)$$

La DFT calcula los coeficientes complejos para cada frecuencia discreta k , que van desde $k = 0$ hasta $k = N-1$. Estos coeficientes representan la contribución de cada frecuencia a la señal original.

La DFT tiene dos componentes principales: la parte real (amplitud) y la parte imaginaria (fase) de los coeficientes complejos. Estas partes se pueden utilizar para analizar la magnitud y la fase de las diferentes componentes de frecuencia presentes en la señal.

3.2.1.5. Teorema de Nyquist

Como ya se ha definido anteriormente, la FT es una herramienta matemática que permite descomponer una señal en diferentes frecuencias y analizar su contenido espectral. Sin embargo, al aplicar la FT a una señal discreta, es decir, una señal que ha sido muestreada en el tiempo, pueden ocurrir problemas si la frecuencia de muestreo no cumple con el criterio del teorema de Nyquist. Por ello, el teorema de Nyquist establece una relación fundamental entre la frecuencia de muestreo y la capacidad de reconstruir correctamente una señal continua a partir de su versión muestreada.

En el contexto de la FT, el teorema de Nyquist establece que para evitar el efecto de aliasing, es necesario muestrear una señal continua a una frecuencia de muestreo que sea al menos el doble de la frecuencia máxima presente en la señal. Si la frecuencia de muestreo es menor que el doble de la frecuencia máxima presente en la señal, pueden aparecer componentes espectrales falsos o distorsiones en el espectro resultante por lo que no se podría recuperar totalmente la señal. Este fenómeno se conoce como aliasing, y ocurre cuando las componentes de alta frecuencia en la señal original se superponen con componentes de baja frecuencia en la versión muestreada.

Si lo expresamos matemáticamente, si la frecuencia más alta contenida en una señal analógica $f(t)$ es $F_{max} = B$ y la señal se muestrea a una tasa $F_s > 2 F_{max} = 2B$, entonces se puede recuperar totalmente a partir de sus muestras mediante la siguiente función:

$$g(t) = \frac{\text{sen}2\pi Bt}{2\pi Bt} \quad (3.8)$$

Así, $f(t)$ se puede expresar como.

$$g(t) = \sum_{n=-\infty}^{\infty} f\left(\frac{n}{F_s}\right) g\left(t - \frac{n}{F_s}\right) \quad (3.9)$$

donde

$$f\left(\frac{n}{F_s}\right) = f(nT) = f_n \quad (3.10)$$

son las muestras de $f(t)$.

Esto es, toda señal $f(t)$ limitada en banda a frecuencia F_{max} , se puede reconstruir a partir de sus muestras $f(n) = \frac{nT}{N}$ siempre que la frecuencia de muestreo $f(m) = \frac{N}{T}$ sea mayor que el doble del ancho de banda $f_m > 2F_{max}$.

Es un error frecuente creer que, una vez satisfecho los criterios del teorema de Nyquist, la calidad de reconstrucción de una señal en toda su banda es función de la tasa de muestreo empleada.

Por otro lado, es un error frecuente confundir muestreo con cuantificación. El muestreo y la cuantificación son dos procesos distintos pero relacionados que se utilizan en el procesamiento de señales para convertir señales analógicas en señales digitales. El muestreo es el proceso mediante el cual se toman mediciones periódicas de una señal analógica en intervalos regulares de tiempo, generando como resultado una secuencia de valores discretos que reflejan las amplitudes de la señal en esos momentos específicos. Por otra parte, la cuantificación consiste en asignar valores numéricos discretos a las amplitudes de la señal previamente muestreada, transformando así cada valor continuo en un nivel discreto.

3.2.2. Transformada corta de Fourier

La FT es una herramienta fundamental en el análisis de señales, pero tiene limitaciones en el análisis de señales no estacionarias debido a su resolución frecuencial fija y la pérdida de información temporal. La Transformada corta de Fourier (STFT), del inglés *Short-time Fourier transform*, supera estas limitaciones al permitir una resolución tiempo-frecuencia variable, lo que proporciona una representación más detallada de la señal en función del tiempo y la frecuencia.

Al dividir la señal en segmentos de tiempo más pequeños y aplicar la FT a cada segmento, la STFT ofrece un análisis localizado en el tiempo, capturando mejor las características temporales y frecuenciales de señales que varían en el tiempo. Además, el uso de ventanas temporales deslizantes en la STFT permite un análisis más preciso de señales no estacionarias, haciendo que sea una herramienta poderosa para el análisis de señales.

Una de las variantes de la STFT es emplearla con la función de Gauss utilizando esta como una función ventana para realizar el análisis espectral de una señal en el dominio tiempo-frecuencia. La ventana de Gauss es una función suave y simétrica que tiene una forma similar a una campana.

La ecuación para calcular la STFT con ventana de Gauss es la siguiente:

$$X(t, \omega) = \int_{-\infty}^{\infty} x(\tau)w(\tau - t)e^{-i\omega\tau} d\tau \quad (3.11)$$

donde:

$X(t, \omega)$ representa la transformada de Fourier del segmento de la señal $x(t)$ en el tiempo t y la frecuencia ω .

Y $w(t)$ es la ventana de Gauss definida como:

$$w(t) = e^{-\frac{t^2}{2\sigma^2}} \quad (3.12)$$

donde σ es un parámetro que controla el ancho de la ventana. Un valor menor de σ produce una ventana más estrecha y mayor resolución en frecuencia, mientras que un valor mayor de σ produce una ventana más amplia y menor resolución en frecuencia.

La ventana de Gauss tiene la propiedad de ser no nula en todo el dominio temporal, pero su amplitud disminuye gradualmente a medida que nos alejamos del punto central. Esto proporciona una suavidad en la transición entre segmentos

y evita discontinuidades abruptas en la STFT.

La STFT con ventana de Gauss se utiliza en aplicaciones donde se requiere una buena resolución tanto en tiempo como en frecuencia, y se prefiere una transición suave entre segmentos. Es especialmente útil en el análisis de señales no estacionarias con cambios espectrales graduales.

3.2.3. Transformada Wavelet

La transformada de Wavelet (WT) es una técnica de análisis de señales que permite estudiar su contenido espectral en diferentes escalas de tiempo y frecuencia. A diferencia de la FT, que ofrece una visión global del espectro de frecuencia de una señal, la WT proporciona información localizada en el tiempo y la frecuencia.

La WT se basa en el uso de funciones Wavelet, que son funciones matemáticas con forma de onda, localizadas en el tiempo y con cierta frecuencia central. Estas funciones son generadas a partir de una función madre (Wavelet madre) mediante dilataciones y desplazamientos.

La WT se puede expresar matemáticamente como sigue:

$$W(a, b) = \int_{-\infty}^{\infty} x(t)\psi^*\left(\frac{t-b}{a}\right)dt \quad (3.13)$$

Donde:

- $W(a, b)$ representa los coeficientes de la WT en la escala a y el desplazamiento b .
- $x(t)$ es la señal de entrada que se desea analizar.
- $\psi(t)$ es la Wavelet madre, que define la forma y las características de las funciones Wavelet utilizadas.

- a es el parámetro de escala, que controla la dilatación o contracción de la Wavelet en el tiempo.
- b es el parámetro de desplazamiento, que determina la posición de la Wavelet en el dominio temporal.

La WT proporciona una representación tiempo-frecuencia de la señal, donde la escala a está relacionada con la frecuencia y el desplazamiento b se refiere a la posición en el tiempo. De esta manera, se pueden identificar componentes de alta frecuencia y de corta duración en escalas pequeñas, así como componentes de baja frecuencia y de larga duración en escalas grandes.

3.2.4. Transformada de Stockwell

La Transformada de Stockwell, también conocida como la transformada S (ST), del inglés *Stockwell Transform* es una técnica de análisis de señales que combina características de la WT y STFT. La idea principal detrás de la ST es obtener una representación en el plano tiempo-frecuencia de una señal que capture tanto las propiedades de frecuencia localizadas en el tiempo como las propiedades de frecuencia global.

Como se ha visto, la WT es una herramienta de análisis de señales que utiliza Wavelet madre como ventanas desplazables y escalables, para analizar diferentes componentes frecuenciales. Proporciona información detallada tanto en el dominio del tiempo como en el dominio de la frecuencia, permitiendo detectar cambios en la frecuencia a lo largo del tiempo.

Por otro lado, la STFT descompone una señal en su representación de frecuencia a lo largo del tiempo, utilizando ventanas de corta duración que se deslizan a lo largo de la señal. La STFT proporciona información sobre las frecuencias presentes en diferentes segmentos de tiempo, pero tiene una resolución frecuencial fija y puede tener dificultades para detectar cambios rápidos en la frecuencia.

La ST combina estas dos técnicas donde utiliza una ventana de corta duración (similar a la STFT) para dividir la señal en segmentos de tiempo y luego aplica un análisis a cada segmento. La ST se adapta a cada frecuencia y escala, permitiendo una representación más precisa de los componentes frecuenciales a lo largo del tiempo.

3.2.4.1. Descripción matemática

La ST emplea la función gaussiana debido a que ofrece una alta localización tanto en el tiempo como en la frecuencia, lo que permite capturar componentes específicos de la señal. Su forma suave y continua evita discontinuidades abruptas, lo que resulta en una representación más suave y fácil de interpretar en el dominio tiempo-frecuencia. Además, tiene una buena capacidad para analizar componentes de frecuencia cercanos y detectar cambios sutiles en el espectro de una señal, lo que es útil para señales no estacionarias.

La función gaussiana se denota como $\Psi(t)$ donde esta ventana divide la señal en segmentos de tiempo más cortos y determina la resolución temporal de la transformada:

$$\Psi(t) = \frac{1}{\sqrt{\sigma}} e^{-\frac{t^2}{2\sigma^2}} \quad (3.14)$$

donde t es la variable de tiempo y σ es un parámetro que controla la amplitud y la localización de la ventana. A medida que σ se hace más pequeño, la ventana gaussiana se vuelve más aguda y se localiza en el tiempo, lo que permite detectar detalles más finos en una señal. Por otro lado, a medida que σ aumenta, la ventana se vuelve más ancha y abarca una mayor cantidad de tiempo, lo que permite capturar características más generales de la señal. La ventana gaussiana tiene propiedades importantes, como la función de escala constante y la función de forma simétrica. Además, su FT es también una función gaussiana en el dominio de la frecuencia.

A continuación, se realiza la convolución entre la señal original y la función ventana escalada en diferentes escalas temporales. Esto se logra desplazando y escalando la misma a lo largo del eje del tiempo y multiplicándola punto a punto con el segmento correspondiente de la señal. La convolución se puede expresar matemáticamente como:

$$x_{\text{conv}}(t, \tau) = x(\tau) * g^*(t - \tau) \quad (3.15)$$

Donde $*$ denota la operación de convolución, $x(t)$ es la señal de entrada y $g^*(t)$ es la función conjugada compleja de la ventana de corta duración.

Por último, se aplica una FT a cada segmento de tiempo convolucionado. Esto proporciona información sobre las frecuencias presentes en cada segmento de tiempo. La FT de cada segmento de tiempo se puede expresar como:

$$X_{\text{STFT}}(t, \omega) = \mathcal{F}[x_{\text{conv}}(t, \tau)] \quad (3.16)$$

Donde $\mathcal{F}[\cdot]$ representa la FT y ω es la frecuencia.

Para adaptar la función ventana gaussiana a diferentes escalas temporales y frecuenciales, se introduce un factor de escala ω_0 y se realiza una dilatación en el dominio de la frecuencia. Esto se logra escalando la variable de frecuencia ω en la función ventana. La función ventana escalada se denota como $\Psi_{\text{scaled}}(\omega)$ y se define como:

$$\Psi_{\text{scaled}}(\omega) = \frac{1}{\sqrt{\sigma}} e^{-\frac{t^2}{2\sigma^2}} e^{i\omega_0 t} \quad (3.17)$$

Donde σ es el parámetro de escala que controla la anchura de la ventana y ω_0 es la frecuencia central. Finalmente, el resultado de la ST se obtiene combinando la FT de la convolución con la función ventana escalada:

$$ST(t, \omega) = X_{\text{STFT}}(t, \omega) \cdot \Psi_{\text{scaled}}(\omega) \quad (3.18)$$

Donde la magnitud cuadrada de $ST(t, \omega)$ se puede utilizar para obtener la densidad espectral de potencia (PSD) en el plano tiempo-frecuencia. La ecuación extendida de la ST sería la siguiente:

$$ST(t, \omega) = \frac{1}{\sqrt{\sigma}} \int_{-\infty}^{\infty} x(\tau) \Psi^* \left(\frac{t - \tau}{\sigma} \right) e^{-i\omega\tau} d\tau \quad (3.19)$$

Donde:

- t es la variable de tiempo en la ST.
- ω es la variable de frecuencia en la ST.
- Ψ^* denota el complejo conjugado de la función ventana.
- El factor $1/\sqrt{\sigma}$ se incluye para asegurar que la transformada sea unitaria.

La ecuación extendida de la ST muestra cómo la señal $x(t)$ se convoluciona con la ventana gaussiana escalada y luego se multiplica por un factor exponencial complejo correspondiente a la frecuencia ω para obtener la representación en el plano tiempo-frecuencia. Esta ecuación permite analizar la distribución espectral de la señal en función del tiempo y la frecuencia.

Asimismo, de forma discreta se puede representar la ST como dada una señal discreta $x[n]$ de longitud N y una ventana gaussiana discreta $\Psi[n]$ con parámetro de escala σ y frecuencia central ω_0 , la ecuación de la ST discreta es:

$$ST[m, k] = \frac{1}{\sqrt{\sigma}} \sum_{n=0}^{N-1} x[n] \Psi^* \left[\frac{m - n}{\sigma} \right] e^{-i\omega_k n} \quad (3.20)$$

Donde:

- m es la variable de tiempo en la ST discreta, con $0 \leq m < N$.
- k es la variable de frecuencia en la ST discreta, con $0 \leq k < K$ (donde K es la cantidad de puntos de frecuencia en la ST).
- $\Psi^*[n]$ denota el conjugado complejo de la ventana gaussiana discreta.
- El factor $1/\sqrt{\sigma}$ se incluye para asegurar que la transformada sea unitaria.

La ecuación de la ST discreta muestra cómo la señal discreta $x[n]$ se convoluciona con la ventana gaussiana discreta escalada y luego se multiplica por un factor exponencial complejo correspondiente a la frecuencia ω_k para obtener la representación en el plano tiempo-frecuencia discreto.

3.2.4.2. Modelado

El proceso desde una perspectiva de alto nivel está representado en la Figura 3.1, mientras que el proceso de computación de la ST se muestra en la Figura 3.2. Como se ilustra en la misma, a partir de una señal cuya magnitud varía en el tiempo se aplica la ST y su salida es una matriz compleja, donde cada fila representa una frecuencia y cada columna el valor en el tiempo. De esta forma, cada columna representa el espectro local para cada punto en el tiempo. A partir de esa matriz se obtienen contornos tiempo-frecuencia con el mismo espectro de amplitud que sirven para detectar y localizar eventos en la señal de tensión, ya que son contornos característicos de cada tipo de perturbación eléctrica. La matriz de salida de la ST puede usarse para formar una malla tridimensional (3D) que permite obtener una gráfica tiempo-frecuencia-amplitud.

Para su cómputo, se utiliza el algoritmo de la Transformada Rápida de Fourier (FFT), del inglés *Fast Fourier Transform* que facilita y agiliza la implementación de la ST, dada la relación existente entre ambas transformadas. De acuerdo con el algoritmo, la FT de cualquier señal de entrada solo requiere ser calculada una vez.

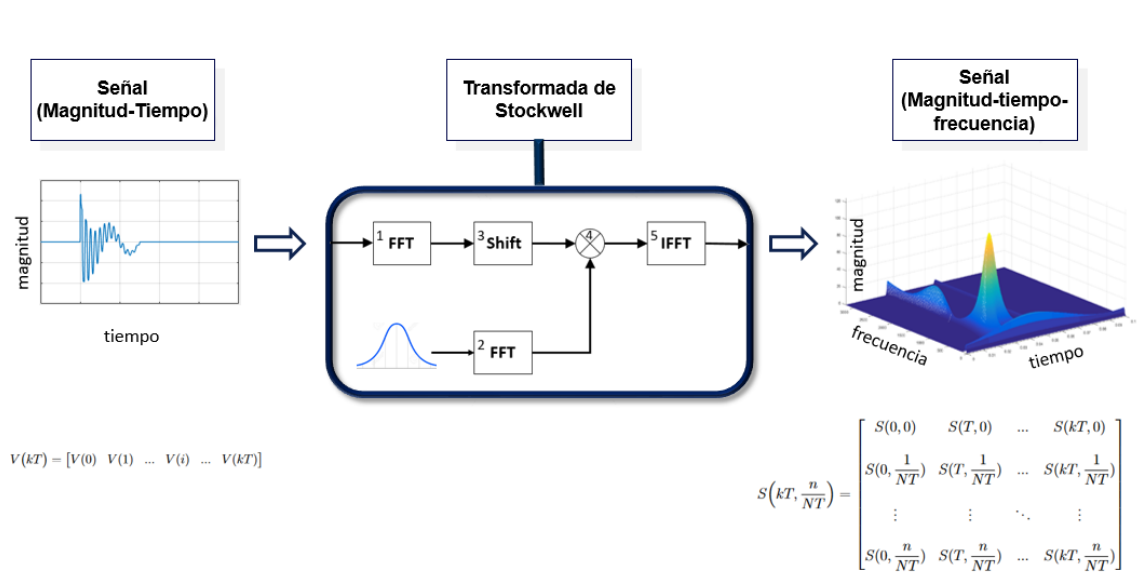


Figura 3.1: Esquema gráfico de cálculo de la transformada de Stockwell.

Así, el procedimiento de cómputo de la ST se puede describir mediante un diagrama de bloques [32] según la Figura 3.2.

El proceso comienza transformando tanto la señal de entrada como la ventana Gaussiana haciendo uso de la FFT. Para cada valor de frecuencia requerida m , el espectro puede ser desplazado hacia la frecuencia por m (corrección de fase).

Se multiplican (convolución) la señal transformada y corregida en fase con la ventana gaussiana, ambas en el dominio de la frecuencia. A este producto se le aplica la Inversa de la Transformada Rápida de Fourier (IFFT), del inglés *Inverse Fast Fourier Transform*, para cada una de las filas que se corresponden con las frecuencias discretas (n/NT) , obteniéndose así el cómputo de la ST que resulta en una matriz compleja en el que cada elemento representa la magnitud de la señal y donde cada columna representa el intervalo de tiempo en función del intervalo de muestreo y las filas representan el espectro de cada frecuencia [33]. La señal de partida es la siguiente:

$$V(kT) = [V(0) \ V(1) \ \dots \ V(i) \ \dots \ V(kT)] \quad (3.21)$$

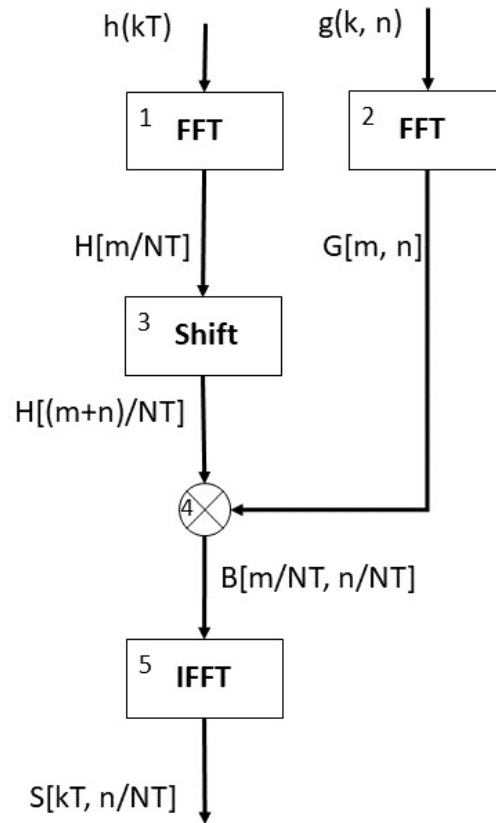


Figura 3.2: Diagrama de bloques de cómputo de la transformada de Stockwell.

Y la salida de la ST es la siguiente:

$$S\left(kT, \frac{n}{NT}\right) = \begin{bmatrix} S(0,0) & S(T,0) & \dots & S(kT,0) \\ S(0, \frac{1}{NT}) & S(T, \frac{1}{NT}) & \dots & S(kT, \frac{1}{NT}) \\ \vdots & \vdots & \ddots & \vdots \\ S(0, \frac{n}{NT}) & S(T, \frac{n}{NT}) & \dots & S(kT, \frac{n}{NT}) \end{bmatrix} \quad (3.22)$$

donde:

- T: periodo de la frecuencia de muestreo

- k : frecuencia de muestreo
- N : longitud de la señal analizada (muestras)
- n : $0, 1, \dots, N-1$

3.2.4.3. Teorema de Parseval

El teorema de Parseval es un principio fundamental en análisis de señales y teoría de la FT. Este teorema establece una relación entre la energía o potencia de una señal en el dominio del tiempo y su representación en el dominio de la frecuencia.

Formalmente, el teorema de Parseval se expresa de la siguiente manera para señales continuas:

$$\int_{-\infty}^{\infty} |x(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{\infty} |X(f)|^2 df \quad (3.23)$$

Donde:

- $x(t)$ es la señal en el dominio del tiempo.
- $X(f)$ es la transformada de Fourier de la señal en el dominio de la frecuencia.
- $|x(t)|^2$ representa el cuadrado de la magnitud de la señal.
- $|X(f)|^2$ representa el cuadrado de la magnitud de la transformada de Fourier de la señal.

Para señales discretas, el teorema de Parseval se expresa como:

$$\sum_{n=-\infty}^{\infty} |x[n]|^2 = \frac{1}{2\pi} \int_{-\pi}^{\pi} |X(e^{j\omega})|^2 d\omega \quad (3.24)$$

Donde:

- $x[n]$ es la señal en el dominio discreto.
- $X(e^{j\omega})$ es la transformada de Fourier discreta de la señal.
- $|x[n]|^2$ representa el cuadrado de la magnitud de la señal en el dominio discreto.
- $|X(e^{j\omega})|^2$ representa el cuadrado de la magnitud de la IFFT de la señal.

Aplicando el teorema de Parseval a la ST se obtiene:

$$\int_{-\infty}^{\infty} |x(t)|^2 dt = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} |ST(t, w)|^2 dt dw \quad (3.25)$$

Esto significa que la energía total de la señal en el dominio del tiempo es igual a la integral doble de la magnitud al cuadrado de su ST en el dominio de la frecuencia y en el dominio de la escala de tiempo.

Para mayor claridad, la Figura 3.3 muestra un ejemplo de análisis ST aplicado a TRV, cuando ocurre una falta monofásica en una red de transmisión. Esta figura presenta el TRV en el dominio del tiempo (a), mallas de magnitud-tiempo-frecuencia 3D obtenidas a partir de la matriz compleja resultante de ST (b), contornos TRV en el dominio tiempo-frecuencia en (c) y la energía obtenida aplicando el teorema de Parseval a estos contornos (d). Tanto las mallas 3D como los contornos tiempo-frecuencia permiten visualizar las principales frecuencias contenidas en el TRV.

Esta señal tiene una longitud de 100 ms muestreada a una frecuencia de 25,6 kHz, la cual permite, de acuerdo a la condición de Nyquist, obtener información de hasta 12,8 kHz.

La aplicación de este teorema sobre la salida de la ST permite analizar cómo se distribuye la energía de la señal a lo largo de diferentes escalas de tiempo y frecuencias, lo que es de mucha utilidad para la detección de eventos transitorios en señales y la caracterización de la energía en señales con contenido de frecuencia variable en el tiempo.

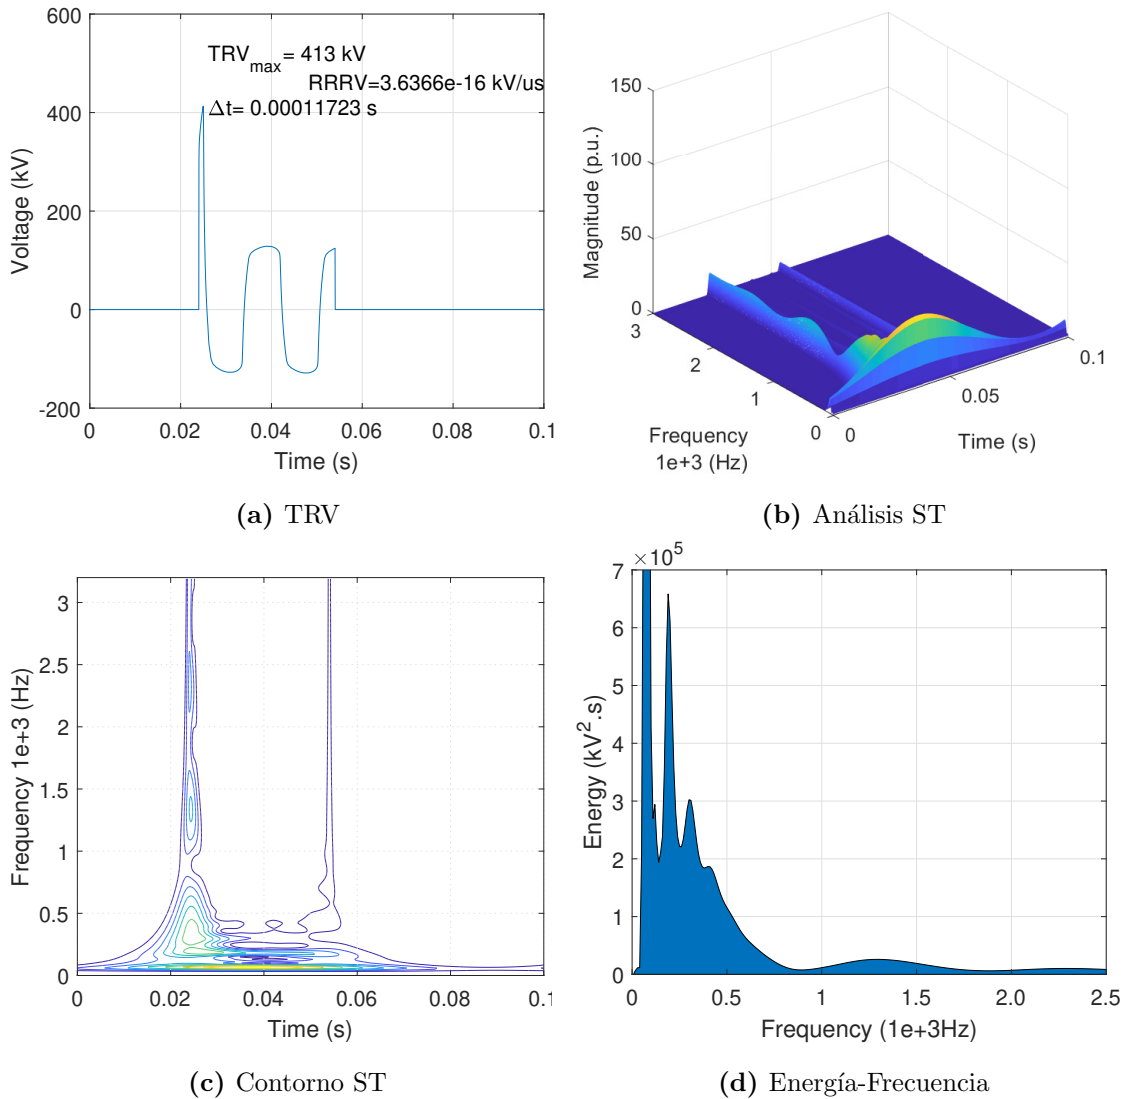


Figura 3.3: Información de frecuencia extraída a partir del análisis ST sobre un TRV.

3.3. Redes Neuronales

Las Redes Neuronales Artificiales, del inglés *Artificial Neural Networks* (ANN) son un modelo computacional inspirado en el funcionamiento del cerebro humano. Están compuestas por unidades básicas llamadas "neuronas artificiales", que están organizadas en capas interconectadas. Cada neurona toma entradas, realiza un cálculo ponderado y produce una salida que puede ser transmitida a otras

neuronas. Las conexiones entre las neuronas tienen pesos asociados que determinan la importancia relativa de las entradas. Durante el entrenamiento, estos pesos se ajustan iterativamente para minimizar una función de error, de modo que la red pueda aprender a realizar tareas específicas, como clasificación, regresión o reconocimiento de patrones. Las ANN se utilizan en una amplia gama de aplicaciones, incluyendo reconocimiento de imágenes, procesamiento de lenguaje natural, conducción autónoma, predicción del mercado financiero y más.

3.3.1. La Neurona Biológica

La neurona biológica es una célula especializada del sistema nervioso que desempeña un papel fundamental en la transmisión y procesamiento de información en el cerebro y el sistema nervioso, permitiendo la comunicación entre diferentes partes del cuerpo y facilitando la realización de las funciones cognitivas y motoras.

La estructura de una neurona biológica consta de tres partes principales: el cuerpo celular o soma, las dendritas y el axón. El cuerpo celular contiene el núcleo de la célula y la maquinaria celular necesaria para su funcionamiento. Las dendritas son extensiones ramificadas que se extienden desde el cuerpo celular y reciben señales de otras neuronas o de células sensoriales externas. El axón, por otro lado, es una prolongación larga y delgada que lleva los impulsos eléctricos generados por la neurona hacia otras células.

La comunicación entre neuronas se lleva a cabo a través de sinapsis, que son conexiones especializadas entre las terminales del axón de una neurona y las dendritas de otra. Cuando una neurona se activa, se genera un impulso eléctrico conocido como potencial de acción, que viaja a lo largo del axón hasta las terminaciones sinápticas. En estas terminaciones, los neurotransmisores, que son sustancias químicas especializadas, son liberados al espacio sináptico, donde se unen a los receptores en las dendritas de las neuronas vecinas. Esta unión entre neurotransmisores y receptores desencadena la generación de un nuevo potencial de

acción en la neurona receptora, y así continúa la transmisión de la señal a lo largo de la red neuronal.

La neurona biológica tiene la capacidad de integrar y procesar información de múltiples fuentes. Las dendritas reciben señales de otras neuronas a través de las sinapsis, y la suma de estas señales determina si la neurona generará un potencial de acción y transmitirá la señal a las neuronas siguientes. Además, las neuronas pueden modificar la fuerza de sus conexiones sinápticas a través de un proceso llamado plasticidad sináptica, lo que les permite adaptarse y aprender de nuevas experiencias.

El cerebro humano está compuesto por miles de millones de neuronas interconectadas, formando una red compleja y altamente organizada. Esta red neuronal permite la realización de una amplia gama de funciones cognitivas y sensoriales, como la percepción, la memoria, el aprendizaje, el razonamiento y el control motor. Cada área del cerebro está especializada en diferentes tipos de procesamiento y las conexiones entre las neuronas determinan la comunicación y la información que fluye en el cerebro.

3.3.2. La Neurona Artificial

Una neurona artificial, en un contexto de ANN, se puede representar como un conjunto de nodos N interconectados. Estos nodos pueden ser vistos como unidades de procesamiento individuales que realizan cálculos y transmiten información a través de conexiones sinápticas.

Una neurona artificial consta de varias partes clave como se puede apreciar en la figura 3.4. La primera es la capa de entrada, que recibe la información o los datos de entrada. Cada dato se representa como un valor numérico y se multiplica por un peso correspondiente a la importancia relativa del dato en la tarea que se está realizando. La suma ponderada de estos productos se pasa a través de una función

de activación, que determina si la neurona se activa o no.

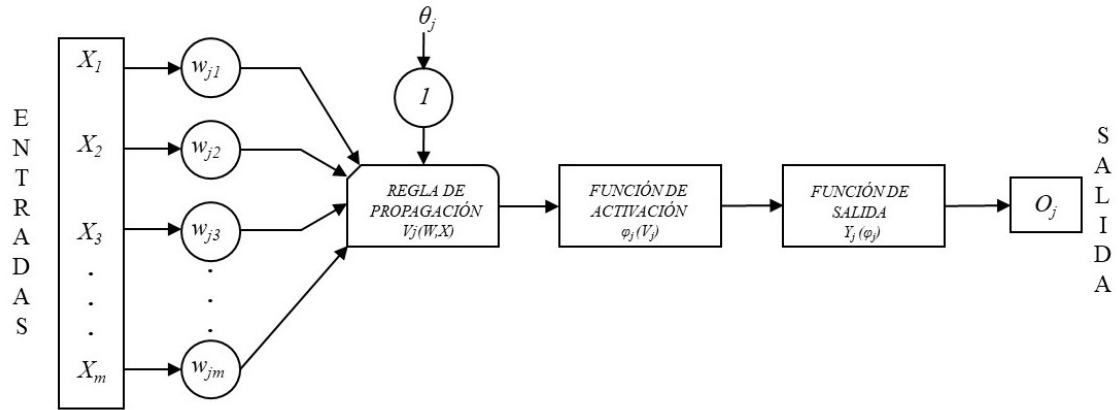


Figura 3.4: Esquema gráfico con las diferentes partes de una Neurona Artificial.

Las funciones de activación son elementos clave en las ANN, ya que introducen no linealidad en el modelo y determinan si una neurona se activa o no en función de la entrada recibida. Existen diversas funciones de activación comúnmente utilizadas en las ANN. A continuación, se presentan algunas de las funciones de activación más utilizadas:

- Función Sigmoide:** también conocida como función logística, tiene una forma de S y mapea los valores de entrada a un rango entre 0 y 1. La fórmula matemática de la función sigmoide es:

$$f(x) = 1/(1 + e^{-x}) \quad (3.26)$$

Esta función es ampliamente utilizada en ANN, especialmente en problemas de clasificación binaria, donde se requiere una salida que represente una probabilidad.

- Función ReLU (Rectified Linear Unit):** es una función no lineal que devuelve el valor de entrada si es positivo y cero en caso contrario. Matemáticamente, se define como:

$$f(x) = \max(0, x) \quad (3.27)$$

La función ReLU es popular en ANN debido a su simplicidad de cálculo y su capacidad para manejar eficazmente el problema del desvanecimiento del gradiente en el entrenamiento.

- **Función Tangente Hiperbólica (Tanh):** es una función similar a la sigmoideal, pero su rango se extiende entre -1 y 1. Matemáticamente, se define como:

$$f(x) = \frac{e^x - e^{1-x}}{e^x + e^{1-x}} \quad (3.28)$$

Esta función se utiliza comúnmente en ANN, especialmente en problemas de clasificación y regresión.

- **Función Lineal:** esta función simplemente devuelve el valor de entrada sin realizar ninguna transformación. Matemáticamente, se define como:

$$f(x) = x \quad (3.29)$$

Esta función se utiliza en capas de salida cuando se requiere una salida lineal, como en problemas de regresión.

Estas son solo algunas de las funciones de activación más comunes en las ANN [34]. Cada una tiene sus propias características y se selecciona según el tipo de problema y los requisitos específicos de la ANN. Es importante elegir cuidadosamente la función de activación adecuada para lograr un rendimiento óptimo en el modelo.

Una vez que se ha calculado la salida de la neurona, se compara con un umbral o valor límite. Si la salida supera el umbral, se considera que la neurona está activada y envía una señal de salida. De lo contrario, si la salida está por debajo del umbral, la neurona permanece inactiva y no emite ninguna señal.

Las funciones de activación más empleadas en la construcción de ANN son las sigmoides, entre las que se encuentran la función logística o tangente hiperbólica. Resulta evidente a partir de las ecuaciones de la función sigmoideal logística y tangente hiperbólica que una puede ser expresada en función de la otra.

3.3.3. Estructura de las Redes Neuronales Artificiales

La estructura de las ANN Artificiales se refiere a cómo se organizan y conectan las neuronas artificiales dentro de la red. Existen diferentes tipos de estructuras utilizadas en las ANN, donde la elección de esta estructura depende del tipo de problema y de los datos con los que se está trabajando. A continuación, se presentan algunas de las estructuras más comunes:

- **Redes Feedforward:** Esta es la estructura más básica de una ANN. Las neuronas están organizadas en capas, donde cada capa se conecta solo con la capa siguiente. La información fluye en una dirección, desde la capa de entrada, a través de las capas ocultas, hasta la capa de salida. Este tipo de red se llama "feedforward" porque la información se mueve hacia adelante sin bucles o retroalimentación.
- **Redes Recurrentes:** A diferencia de las redes feedforward, las redes recurrentes tienen conexiones que forman bucles, permitiendo la retroalimentación de información. Esto significa que las salidas anteriores de la red pueden alimentarse nuevamente como entradas, lo que permite el procesamiento de secuencias y la captura de dependencias temporales. Las redes recurrentes son especialmente útiles en tareas como el procesamiento del lenguaje natural y las series temporales.
- **Redes Convolucionales:** Estas redes se utilizan comúnmente en tareas de visión por computadora y reconocimiento de imágenes. Se basan en la idea

de aplicar operaciones de convolución a los datos de entrada para extraer características relevantes.

- **Redes Modulares:** Las redes modulares se componen de múltiples subredes o módulos interconectados. Cada módulo es responsable de realizar una tarea específica, y la información se transmite entre los módulos para realizar el procesamiento conjunto. Esta estructura modular permite una mayor modularidad y flexibilidad en el diseño de ANN complejas.

Además de estas estructuras básicas, existen otras variantes y combinaciones de ellas. Por ejemplo, es posible combinar redes recurrentes y convolucionales en una sola arquitectura, conocida como ANN convolucionales recurrentes. También se utilizan técnicas como la conexión residual, donde las salidas de capas anteriores se suman a las salidas de capas posteriores para mejorar el flujo de información y el entrenamiento de la red.

La elección de la estructura de la ANN depende del tipo de problema, los datos disponibles y los objetivos de rendimiento. Diseñar una estructura adecuada y eficiente es un aspecto crítico en el desarrollo de ANN efectivas y potentes para una amplia gama de aplicaciones en el campo de la inteligencia artificial y el aprendizaje automático.

3.3.4. Modos de operación

Las ANN pueden operar en diferentes modos, lo que se refiere a cómo se utilizan y aplican para resolver problemas específicos. A continuación, se describen algunos de los modos de operación más comunes en las ANN:

- **Aprendizaje:** El modo de aprendizaje es fundamental en las ANN. Durante esta fase, la ANN ajusta los pesos sinápticos para aprender a partir de los datos de entrenamiento. Durante el entrenamiento, los pesos de la red se actualizan

iterativamente utilizando el algoritmo de retropropagación u otros métodos de optimización para minimizar el error entre las salidas predichas por la red y las salidas reales proporcionadas en los datos de entrenamiento. El objetivo es que la red aprenda patrones y relaciones en los datos para realizar predicciones precisas en datos futuros.

- **Inferencia o predicción:** Una vez que la ANN ha sido entrenada, se puede utilizar en el modo de inferencia o evaluación. Durante la inferencia, la red toma nuevas entradas y genera salidas basadas en los pesos sinápticos ajustados durante el aprendizaje. Este modo se utiliza para hacer predicciones o clasificar nuevos datos en función del conocimiento adquirido durante el entrenamiento.
- **Transferencia de aprendizaje:** en este modo, se aprovecha el conocimiento adquirido por una ANN previamente entrenada en una tarea específica y se transfieren sus pesos y estructura a una tarea relacionada. Esto puede ser útil cuando se dispone de pocos datos para entrenar una nueva red desde cero, ya que el conocimiento previo de la red preentrenada puede ayudar a acelerar el proceso de entrenamiento y mejorar el rendimiento en la nueva tarea.

Es importante destacar que estos modos de operación no son mutuamente excluyentes y pueden combinarse en diferentes etapas o contextos. Por ejemplo, una ANN puede operar en el modo de aprendizaje durante la fase de entrenamiento, y luego cambiar al modo de inferencia para hacer predicciones en nuevos datos. La elección del modo de operación depende del problema en cuestión y los objetivos específicos que se buscan lograr con la ANN.

3.3.5. Funciones de entrenamiento

Una función de entrenamiento de una ANN es un algoritmo o método que se utiliza para ajustar los parámetros de la ANN durante el proceso de aprendizaje,

con el objetivo de minimizar alguna medida de error entre las salidas predichas por la red y las salidas deseadas para un conjunto de datos de entrenamiento. Estas funciones de entrenamiento son esenciales para permitir que la ANN aprenda de los datos y mejore su capacidad para realizar predicciones precisas. Las principales funciones de entrenamiento, respetando su nomenclatura en inglés, son:

1. **Levenberg-Marquardt:** Es un algoritmo de optimización que se utiliza comúnmente en la minimización de funciones no lineales, como la función de error de una ANN. Combina la idea del método de Gauss-Newton y el método del gradiente descendente para ajustar los parámetros de la red de manera eficiente.
2. **Bayesian Regularization:** Este método utiliza técnicas bayesianas para regularizar los pesos de la ANN durante el entrenamiento. Se basa en la adición de términos de penalización a la función de error, lo que ayuda a evitar el sobreajuste al ajustar los pesos hacia valores más pequeños.
3. **BFGS Quasi-Newton:** Es un algoritmo de optimización numérica que se utiliza para encontrar el mínimo de una función. BFGS es una aproximación de la matriz Hessiana inversa y se puede utilizar para ajustar los pesos de la ANN durante el entrenamiento.
4. **Resilient Backpropagation:** Es un algoritmo de entrenamiento que ajusta las tasas de aprendizaje de manera adaptativa para cada peso en función de la dirección del gradiente en iteraciones anteriores. Destaca por su eficiencia y capacidad para converger hacia soluciones óptimas en comparación con otros métodos de entrenamiento.
5. **Scaled Conjugate Gradient:** Es una variante del algoritmo de gradiente conjugado que utiliza una estrategia de aprendizaje adaptable para cada peso de la ANN. Se basa en el método de gradiente conjugado para encontrar los mínimos locales de la función de error.

6. **Conjugate Gradient with Powell/Beale Restarts:** Es un algoritmo de optimización que combina el método de gradiente conjugado con la estrategia de reinicio de *Powell/Beale* para encontrar el mínimo de la función de error de la ANN.
7. **Fletcher-Powell Conjugate Gradient:** Es una variante del algoritmo de gradiente conjugado que utiliza la dirección de búsqueda de *Fletcher-Powell* para ajustar los pesos de la ANN durante el entrenamiento.
8. **Polak-Ribière Conjugate Gradient:** Es otra variante del algoritmo de gradiente conjugado que utiliza la dirección de búsqueda de Polak-Ribière para ajustar los pesos de la ANN durante el entrenamiento.
9. **One Step Secant:** Es un algoritmo de optimización que utiliza una aproximación secante de la matriz Hessiana para encontrar el mínimo de la función de error de la ANN.
10. **Variable Learning Rate Gradient Descent:** Es una variante del algoritmo de gradiente descendente que ajusta la tasa de aprendizaje de manera adaptativa durante el entrenamiento de la ANN.
11. **Gradient Descent with Momentum:** Es una variante del algoritmo de gradiente descendente que utiliza un término de momento para acelerar el proceso de entrenamiento y evitar mínimos locales.
12. **Gradient Descent:** Es el algoritmo de entrenamiento más básico y común para ANN. Utiliza el gradiente descendente para ajustar los pesos y sesgos de la red en la dirección que minimiza el error de predicción.

Cada función de entrenamiento tiene sus propias características y puede ser más adecuada para diferentes tipos de problemas o conjuntos de datos. La elección de la función de entrenamiento adecuada puede tener un impacto significativo en el rendimiento y la convergencia de la ANN.

3.3.6. Proceso de aprendizaje mediante retropropagación resiliente

El algoritmo de entrenamiento mediante retropropagación resiliente, del inglés *resilient backpropagation*, es uno de los métodos habituales utilizados para entrenar ANN en problemas de aprendizaje supervisado. El proceso de aprendizaje implica ajustar los pesos sinápticos para que la red pueda aprender a partir de los datos de entrenamiento y mejorar su rendimiento en la tarea específica que se le ha asignado. El proceso de aprendizaje en las ANN se puede dividir en las siguientes etapas:

1. **Inicialización de pesos:** En esta etapa, los pesos se inicializan con valores aleatorios o predefinidos. Una inicialización adecuada de los pesos puede ser importante para evitar problemas de convergencia y ayudar a la red a comenzar el proceso de aprendizaje de manera efectiva.
2. **Propagación hacia adelante:** Durante la propagación hacia adelante, los datos de entrenamiento se introducen en la ANN y se propagan a través de las capas de neuronas. La entrada se multiplica por los pesos sinápticos y se aplica una función de activación en cada neurona para producir una salida. Este proceso se repite capa por capa hasta llegar a la capa de salida, que produce la salida final de la red.
3. **Cálculo del error:** Después de la propagación hacia adelante, se calcula el error o la discrepancia entre la salida de la red y el valor esperado. Este error se utiliza para evaluar el rendimiento de la red y medir qué tan bien está realizando la tarea.
4. **Retropropagación del error (*Backpropagation*):** La retropropagación del error es una etapa clave en el proceso de aprendizaje de las ANN. Se utiliza para calcular las contribuciones de cada peso sináptico al error total de la red.

5. **Actualización de pesos:** Una vez que se han calculado las contribuciones de los pesos al error, se actualizan los pesos sinápticos calculándose el gradiente de la función de pérdida. Esto se repite durante múltiples iteraciones hasta que se alcance un criterio de convergencia, como una disminución en el error o el número máximo de iteraciones sin incurrir en un sobreajuste. El sobreajuste ocurre cuando el modelo se ajusta demasiado a unas características muy específicas de los datos de entrenamiento y no consigue generalizar adecuadamente la función objetivo.
6. **Repetición del proceso:** Los pasos 2 a 5 se repiten para cada época de entrenamiento, donde una época completa consiste en pasar por todo el conjunto de entrenamiento una vez. Por lo tanto, el número de épocas define la cantidad de veces que el algoritmo de aprendizaje trabaja a través de todo el conjunto de datos de entrenamiento. El número de épocas generalmente se establece para permitir que el algoritmo de aprendizaje opere hasta que el error esté suficientemente minimizado, pudiendo variar entre cientos o miles, lo que lo convierte en un parámetro susceptible de optimización.

3.3.7. Optimización Bayesiana

La Optimización Bayesiana (BO), del inglés *Bayesian Optimization* es un enfoque probabilístico que se utiliza para ajustar los hiperparámetros de las ANN. A diferencia de otros métodos de optimización, la BO considera los hiperparámetros como variables aleatorias y emplea un modelo probabilístico para explorar el espacio de parámetros, buscando iterativamente la configuración óptima.

Sea $f : \mathcal{X} \rightarrow \mathbb{R}$ la función objetivo a optimizar, donde \mathcal{X} es el espacio de hiperparámetros. En la BO, un modelo sustitutorio probabilístico $p(f|D)$, como el Proceso Gaussiano (GP), se ajusta a las observaciones de la función objetivo, en este caso la función de pérdida de la ANN durante el entrenamiento, en los puntos de datos $D = \{(x_i, y_i) \mid y_i = f(x_i) + \epsilon\}$, donde y_i es el valor observado y ϵ representa el

ruido. Estos puntos representan el conjunto de hiperparámetros de la ANN, mientras que el GP modela el comportamiento de la función objetivo de la ANN dada una configuración de hiperparámetros. A partir de este modelo, se calcula la distribución posterior de f y se utiliza para guiar la selección de los puntos de evaluación futuros mediante una función de adquisición $\alpha(x; p(f|D))$.

3.3.7.1. Proceso Gaussiano como Modelo Sustituto

Un Proceso Gaussiano (GP) es un modelo no paramétrico que define una distribución sobre funciones. En este caso, se asume que $f(x)$ es una realización de un GP con una media $\mu(x)$ y una covarianza $k(x, x')$ entre puntos x y x' . Así, para cada nuevo punto x , la predicción sigue una distribución normal:

$$f(x) \sim \mathcal{N}(\mu(x), \sigma^2(x)) \quad (3.30)$$

donde $\mu(x)$ es la media posterior y $\sigma^2(x)$ es la varianza posterior que se obtiene actualizando el GP con las observaciones en D .

La función de covarianza o kernel $k(x, x')$ define la relación entre puntos en \mathcal{X} . Un kernel comúnmente utilizado es la función de base radial (RBF), del inglés Radial Basis Function, dado por:

$$k(x, x') = \sigma_f^2 \exp\left(-\frac{\|x - x'\|^2}{2\ell^2}\right) \quad (3.31)$$

donde σ_f^2 controla la varianza y ℓ es el parámetro de longitud de escala que regula la correlación entre puntos cercanos.

3.3.7.2. Función de Adquisición

La función de adquisición $\alpha(x; p(f|D))$ determina cómo seleccionar el próximo punto x a evaluar, ha de equilibrar la cantidad de exploración versus explotación

del conocimiento adquirido. Una función de adquisición común es el *Expected Improvement* (EI), que busca maximizar la ganancia esperada respecto al mejor valor observado \hat{y} hasta el momento en D :

$$\alpha(x) = \mathbb{E} [\text{máx}(0, f(x) - \hat{y})] \quad (3.32)$$

La EI toma en cuenta tanto la media $\mu(x)$ como la incertidumbre $\sigma(x)$ del modelo GP, incentivando la exploración en regiones con alta incertidumbre y la explotación




Figura 3.5: Ejemplo representativo de funcionamiento de la BO utilizando GP como modelo sustitutorio de la función real desconocida a priori.

3.3.7.3. Procedimiento de Optimización

El proceso de BO sigue los siguientes pasos:

1. Construir un modelo sustituto probabilístico (p. ej., GP) de la función objetivo.
2. Seleccionar el próximo punto a evaluar x_{next} que maximice la función de adquisición $\alpha(x)$.
3. Evaluar la función objetivo en x_{next} y actualizar el conjunto de datos D con el nuevo resultado.

4. Repetir los pasos 2-3 hasta alcanzar un criterio de parada, como el máximo número de iteraciones o una ganancia mínima en el valor de $f(x)$.

La BO es especialmente efectiva cuando el coste de evaluación de la función objetivo es alto, ya que minimiza el número de evaluaciones necesarias para encontrar una configuración de hiperparámetros óptima (localmente). Sin embargo, dado que el modelo sustituto se construye y se actualiza de forma secuencial, la paralelización es limitada, especialmente en el caso de los Procesos Gaussianos, que tienen una complejidad computacional de $\mathcal{O}(n^3)$ en tiempo y $\mathcal{O}(n^2)$ en espacio, donde n es el número de muestras observadas.

3.4. Algoritmo localizador de faltas eléctricas

Para desarrollar un algoritmo capaz de relacionar la distancia a la que ocurre una falta, es necesario implementar un modelo de aprendizaje automático utilizando un conjunto de datos previamente recopilado. Este modelo buscará establecer la relación entre las variables de entrada y la variable de salida. Una de las hipótesis fundamentales de este estudio es que la frecuencia característica y su energía asociada, determinadas mediante la ST y el teorema de Parseval, son lo suficientemente distintivas como para no requerir un algoritmo complejo o específico. Por lo tanto, la ANN se perfila como una técnica robusta y ampliamente aplicable, especialmente en procesos de clasificación y reconocimiento de patrones.

El esquema de la ANN empleada como algoritmo de localizador de faltas se muestra en la Figura 3.6, con 6 variables de entrada y n neuronas en la capa oculta, junto con sus funciones de ponderación y activación, y una única neurona en la capa de salida, con sus respectivas funciones. Las funciones de activación utilizadas son la tangosigmoidal (F^1) para la capa oculta y lineal (F^2) para la capa de salida [35]. La determinación del número de neuronas en la capa oculta es un aspecto crucial, generalmente definido en función del número de entradas [36], pero también puede

variar según la naturaleza del problema, lo que lo convierte en un parámetro sujeto a determinación.

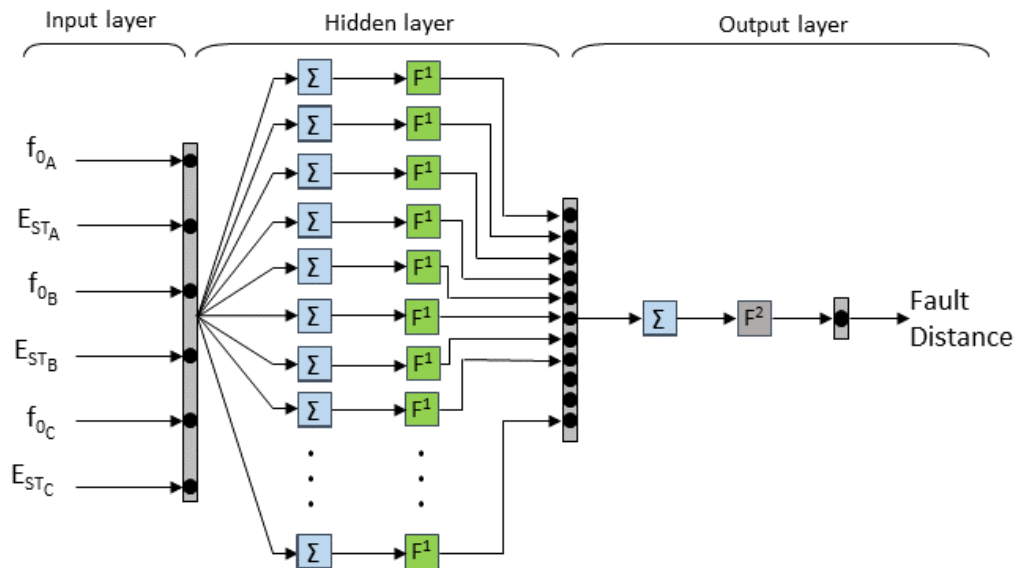


Figura 3.6: Esquema de la ANN.

A continuación, se describe las diferentes etapas realizadas para desarrollar el algoritmo localizador de faltas:

1. Capa de entrada

La capa de entrada recibe información externa, la cual se representa mediante un conjunto de neuronas correspondientes a las entradas de datos *data* (f_0^A , f_0^B , f_0^C , E_{ST}^A , E_{ST}^B , E_{ST}^C). Las capas ocultas sirven como transición entre la entrada y la salida, con una única capa oculta establecida como una estructura de aproximación universal [37]. La capa de salida presenta el resultado estimado de la ANN, en este caso, la distancia de la falta L . Es decir, la matriz de entrada *data* tiene la siguiente estructura, donde cada fila representa una muestra diferente:

$$\text{data} = \begin{bmatrix} f_0^{A_1} & f_0^{B_1} & f_0^{C_1} & E_{ST}^{A_1} & E_{ST}^{B_1} & E_{ST}^{C_1} \\ f_0^{A_2} & f_0^{B_2} & f_0^{C_2} & E_{ST}^{A_2} & E_{ST}^{B_2} & E_{ST}^{C_2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ f_0^{A_n} & f_0^{B_n} & f_0^{C_n} & E_{ST}^{A_n} & E_{ST}^{B_n} & E_{ST}^{C_n} \end{bmatrix} \quad (3.33)$$

El vector de salida L contiene las distancias de falta correspondientes a cada conjunto de datos:

$$L = \begin{bmatrix} L_1 \\ L_2 \\ \vdots \\ L_n \end{bmatrix} \quad (3.34)$$

2. Normalización

Una vez obtenidas las entradas de datos $data$ (frecuencias características y energías de cada fase) así como su vector salida correspondiente a la distancia a la que se produce la falta L , es fundamental normalizar su magnitud. Esto es crucial ya que garantiza que cada característica tenga una escala similar, evitando que las magnitudes más elevadas dominen el aprendizaje.

a) El cálculo de la normalización de las entradas de datos $data$ se realizaría de la siguiente forma:

1) En primer lugar se calcula la norma euclidiana:

$$\text{norm}(data) = \sqrt{\sum_{i=1}^n \sum_{j=1}^m data_{i,j}^2} \quad (3.35)$$

donde n es el número de muestras y m es el número de datos de entrada, frecuencia característica y energías.

2) La normalización de las características de entrada se puede realizar dividiendo cada característica por su norma:

$$data_normalized = \frac{data}{\text{norm}(data)} \quad (3.36)$$

b) La normalización de la distancia a la que se produce la falta L se realizaría de la siguiente forma:

1) Se calcula la norma a la que se produce la falta:

$$\text{norm}(L) = \sqrt{\sum_{i=1}^n L_i^2} \quad (3.37)$$

2) Se normaliza la distancia de salida:

$$L_{\text{normalized}} = \frac{L}{\text{norm}(L)} \quad (3.38)$$

3. División de los datos en conjuntos de entrenamiento y test

La división adecuada de los datos es crucial para evaluar el rendimiento de la ANN. Generalmente, se sigue un enfoque de 80-20 o 90-10, donde se asigna la mayor parte de los datos al conjunto de entrenamiento para maximizar el aprendizaje y se reserva una pequeña porción para la validación del modelo. En esta tesis, se opta por una proporción del 90 % para el conjunto de entrenamiento y el 10 % para el conjunto de test. Esto se justifica considerando la necesidad de proporcionar al modelo una cantidad suficiente de datos para aprender patrones significativos, mientras que se mantiene un conjunto de test adecuado para evaluar su capacidad de generalización. La división de los datos en conjuntos de entrenamiento y test se puede representar matemáticamente de la siguiente manera, los cuales se escogen de forma aleatoria para cada conjunto:

a) Para el conjunto de entrenamiento:

$$\text{Entrenamiento} = 0,9 \times \text{data_normalized} \quad (3.39)$$

b) Para el conjunto de test:

$$\text{Test} = 0,1 \times \text{data_normalized} \quad (3.40)$$

Donde:

- `data_normalized` es el conjunto de datos que ha sido normalizado previamente.
- Entrenamiento es el subconjunto que se utilizará para entrenar la red neuronal.
- Test es el subconjunto reservado para evaluar el rendimiento del modelo.

4. Optimización bayesiana de hiperparámetros

La selección adecuada de la configuración de hiperparámetros durante el entrenamiento de un modelo de aprendizaje automático tiene un impacto significativo en su rendimiento. Estos algoritmos se seleccionan debido a su naturaleza genérica y su capacidad para adaptarse a una amplia gama de conjuntos de datos [38]. Por ello, la BO se destaca como una técnica general de optimización de hiperparámetros, ya que considera resultados anteriores para mejorar la eficiencia, funcionando bien para problemas de optimización complejos [39].

En este algoritmo de localización de faltas, se han considerado tres parámetros clave de la ANN cuya correcta determinación puede influir significativamente en su rendimiento: la función de entrenamiento, el número de épocas y la cantidad de neuronas en la capa oculta. El objetivo es lograr un rendimiento óptimo sin incurrir en sobreajuste, es decir, evitando que el algoritmo de aprendizaje se ajuste demasiado a características específicas de los datos de entrenamiento, lo que podría distorsionar la relación causal con la función objetivo [40].

- **Número de neuronas de la capa oculta:** La cantidad de neuronas en la capa oculta puede influir significativamente en la capacidad del modelo para aprender patrones complejos. Un número muy bajo de neuronas puede llevar a un modelo subajustado, mientras que un número muy alto puede resultar en un sobreajuste. Este valor se establece entre 1 y 4096 neuronas.

- **Número de épocas de la función entrenamiento:** Este es el número total de iteraciones que la red neuronal pasará sobre el conjunto de entrenamiento. Un número insuficiente de épocas puede resultar en un aprendizaje inadecuado, mientras que un número excesivo puede causar sobreajuste. Este valor se establece entre 1000 y 200000.
- **Función de Entrenamiento:** Se evalúan diferentes algoritmos de entrenamiento, que son responsables de actualizar los pesos de la red neuronal durante el proceso de entrenamiento. Entre las funciones comunes se incluyen algunas como *Levenberg-Marquardt*, *Resilient Backpropagation* y *Conjugate Gradient with Fletcher-Reeves*.

Por ello, las ANN que se emplean en la presente tesis se ajustan al espacio de búsqueda que se indica en la tabla 3.1 según la experimentación de cada caso.

Parámetro de entrada	Espacio de búsqueda
Número de neuronas de la capa oculta	1 a 4096
Número de épocas de la función de entrenamiento	1000 a 200000
Función de entrenamiento	<i>Levenberg-Marquardt, Bayesian Regularization, BFGS Quasi-Newton, Resilient Backpropagation, Scaled Conjugate Gradient, Conjugate Gradient with Powell/Beale Restarts, Fletcher-Powell Conjugate Gradient, Polak-Ribière Conjugate Gradient, One Step Secant, Variable Learning Rate Gradient Descent, Gradient Descent with Momentum, Gradient Descent</i>

Tabla 3.1: Espacio de búsqueda de la Optimización Bayesiana

En todas las ANN desarrolladas en la tesis, se encontró que la función de entrenamiento de Retropropagación Resiliente, del inglés *Resilient Backpropagation*

fue la más efectiva para el algoritmo de localización de faltas propuesto. Es importante destacar que durante el proceso de BO, se observaron variaciones en el número de neuronas en la capa oculta y en el número de épocas necesarias para el entrenamiento en las diferentes ANN.

5. Construcción de la ANN

La construcción de la ANN se realiza una vez que se han identificado los mejores hiperparámetros a través del proceso de optimización anterior. Por ello, una vez identificados, se genera una ANN prealimentada a partir de la función `feedforwardnet` de Matlab:

$$\text{ANN} = \text{feedforwardnet}(\text{Neuronas}, \text{Función de entrenamiento}) \quad (3.41)$$

En esta función, Neuronas representa el número de neuronas en la capa oculta de la red y Función de entrenamiento es el algoritmo de entrenamiento seleccionado, en este caso, la retropropagación resiliente.

Además de la definición de la red, se configuran otros parámetros relevantes. Esto incluye el número máximo de épocas, que es el límite de iteraciones que la red llevará a cabo durante el entrenamiento, y las condiciones de entrenamiento, como el número de fallos permitidos antes de que se detenga el proceso de entrenamiento.

6. Entrenamiento de la ANN

El entrenamiento ajusta los pesos de la red para minimizar el error en las predicciones del conjunto de entrenamiento. Para mejorar la eficiencia del proceso de entrenamiento, se emplean técnicas como el ajuste dinámico de la tasa de aprendizaje. Estas técnicas ayudan a prevenir problemas comunes como el sobreajuste y la convergencia lenta, asegurando que el modelo no solo aprenda patrones de los datos de entrenamiento, sino que también generalice bien a datos no vistos.

Por ello, la ANN se entrena a partir de la función `train` de Matlab. Para ello, se utiliza el conjunto de entrenamiento, que consiste en los datos normalizados y las correspondientes distancias de falta:

$$\text{net} = \text{train}(\text{net}, X'_{\text{train}}, L'_{\text{train}}) \quad (3.42)$$

En esta función, X'_{train} son los datos de entrada (frecuencias y energías asociadas) y L'_{train} son las salidas correspondientes, en este caso, la distancia a la que se produce la falta.

El entrenamiento de la ANN es un paso crucial que implica ajustar los pesos internos de la red para minimizar el error en las predicciones. Para ello, se emplea el algoritmo de retropropagación donde se parte del Error Cuadrático Medio MSE :

$$MSE = \frac{1}{N} \sum_{i=1}^N (L_{\text{true},i} - L_{\text{pred},i})^2 \quad (3.43)$$

donde:

- N es el número total de muestras en el conjunto de datos.
- L_{true} son los valores reales observados de la distancia a la que se produce la falta.
- L_{pred} son las predicciones realizadas por el modelo.

Este error se utiliza como retroalimentación para ajustar los pesos de la red en cada iteración. El ajuste de pesos se realiza mediante el algoritmo de retropropagación, que se basa en la regla delta:

$$\alpha \Delta = -\frac{1}{2} \nabla \text{MSE} \quad (3.44)$$

donde:

- α es el factor de amortiguamiento.
- ∇MSE es el gradiente del MSE, que indica la dirección y la tasa de cambio del error respecto a los pesos de la red.

Este enfoque adaptativo en el ajuste de pesos, junto con la construcción cuidadosa de la red, garantiza que la retropropagación resiliente sea robusta frente a desafíos como los mínimos locales y el ruido en los datos de entrada, haciendo que la ANN sea efectiva.

7. Evaluación de la ANN

La evaluación del modelo es un paso crucial en el proceso de aprendizaje automático, ya que permite determinar la efectividad de la ANN en la predicción de la distancia de falta. Este proceso ayuda a identificar cómo se desempeña el modelo en datos no vistos y si es capaz de generalizar adecuadamente.

Para evaluar el modelo, se utilizan los datos de prueba X_{test} para realizar predicciones. Las salidas generadas por la ANN se comparan con los valores reales de las distancias de falta. El proceso de predicción se puede formalizar como:

$$L_{\text{pred}} = f(X_{\text{test}}) \quad (3.45)$$

donde f es la función de activación de la red, que transforma las entradas en salidas.

Proceso resumido de algoritmo para la localización de faltas

La ANN de localización de faltas con el ajuste de hiperparámetros se presenta de forma esquemática en el Algoritmo 1, y gráfica, en la Figura 3.7. Primero, se cargan los mejores resultados previos de Error Cuadrático Medio MSE (`best_mse`) para iniciar la optimización, o se establece un valor inicial si no existen resultados

previos. Luego, se seleccionan y normalizan los datos de entrada y la distancia de falta (L) para dividirlos en conjuntos de entrenamiento y test. La BO se lleva a cabo para cada tipo de falta, donde se evalúan diferentes combinaciones de hiperparámetros en un espacio de búsqueda que abarca el número de neuronas ($[1, 4096]$), el número de épocas ($[1000, 200000]$) y la función de entrenamiento (entre otras `trainlm`, `trainrp`, `traincgf`). En cada iteración, se elige un conjunto de hiperparámetros según la función de adquisición, se entrena la ANN y se calcula el MSE normalizado. Si el MSE resultante mejora los mejores resultados anteriores, se actualizan los valores óptimos y la configuración de la ANN. Este proceso se repite hasta alcanzar el máximo de iteraciones, logrando la configuración óptima de la red para cada tipo de falta.

Algorithm 1 Estimador de distancia de faltas

```
1: Cargar mejores resultados previos si existen. Si no, establecer best_mse = 3000
2: Seleccionar variables data e información de distancias de falta L
3: Normalizar datos:  $\text{data} = \frac{\text{data}}{\text{norm}(\text{data})}$  y  $L = \frac{L}{\text{norm}(L)}$ 
4: Dividir datos en conjuntos de entrenamiento y prueba:  $\{X_{\text{train}}, L_{\text{train}}, X_{\text{test}}, L_{\text{test}}\}$ 
5: Definir espacio de búsqueda para la BO.
6: for cada tipo de falta ft do
7:   while  $N_{\text{iter}} < 200$  do
8:     Inferir hiperparámetros  $x$  utilizando la función de adquisición.
9:     Definir ANN net con número de neuronas  $x.nn$  y función de entrenamiento  $x.trfnc$ 
       a partir de la función feedforwardnet
10:     Entrenar la red net con  $\{X_{\text{train}}, L_{\text{train}}\}$ 
11:     Generar predicciones L_pred con datos de prueba  $X_{\text{test}}$ 
12:     Calcular  $MSE$  para cada muestra
13:     Normalizar  $MSE$  en función de la distancia de falta  $L_{\text{norm}}$ 
14:     Calcular  $MSE$  total
15:     if  $MSE < \text{best\_mse}$  then
16:       Guardar nuevos resultados: best_mse, x_best, ANN_best
17:     end if
18:   end while
19:   ANN optimizada: best_mse, x_best, ANN_best
20: end for
```

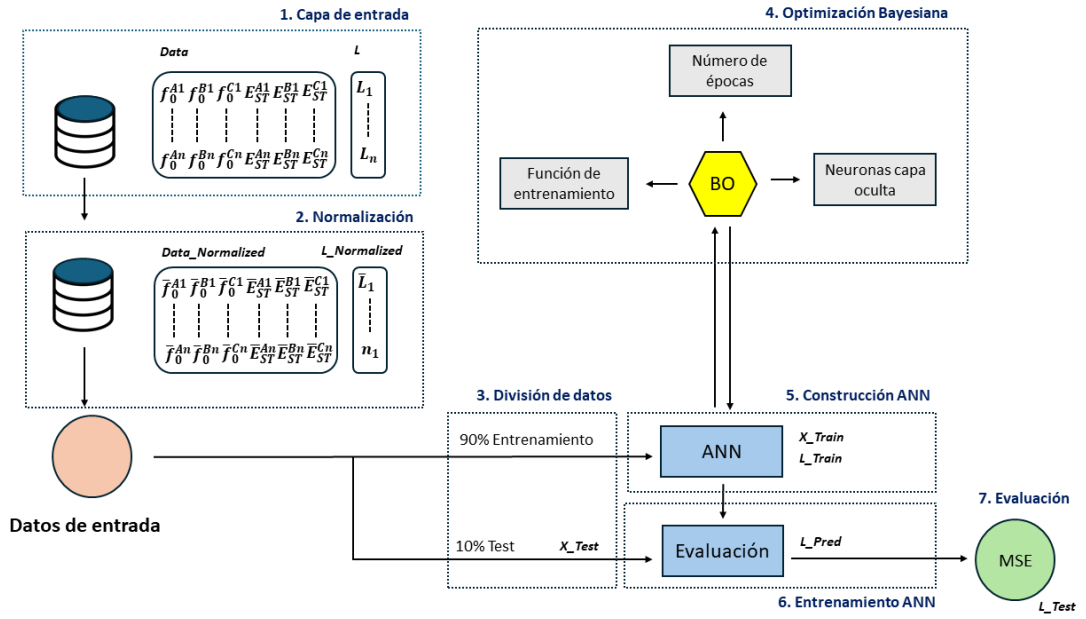


Figura 3.7: Esquema del algoritmo localizador de faltas.

Capítulo 4

Resultados experimentales

4.1. Resumen del capítulo

En el presente capítulo, se presentan los resultados experimentales obtenidos de las diferentes simulaciones realizadas en las distintas redes de transmisión, presentadas para identificar la frecuencia característica cuando se produce una falta eléctrica en la red.

El principal objetivo es presentar los resultados experimentales de los distintos estudios que abordan la detección de la frecuencia característica, así como justificar su robustez a partir de los distintos análisis de sensibilidad realizados.

El capítulo comienza con un análisis de la frecuencia característica a partir de la transformada de Stockwell en una línea de transmisión. Se examinan los efectos de la distancia de falta, el ángulo de incidencia, la resistencia de falta y las características de los interruptores de potencia en detección de la frecuencia característica. Se llevan a cabo experimentos que permiten obtener resultados cuantitativos y establecer conclusiones sobre cómo estos factores influyen en la frecuencia característica.

Posteriormente, se extiende el estudio a una línea de transmisión de una compañía eléctrica y a una red de líneas de transmisión. Se determina la frecuencia característica en ambos casos lo que permite evaluar cómo se comporta la frecuencia característica en diferentes configuraciones de sistemas de transmisión eléctrica.

Finalmente, en la última sección se aplica el algoritmo de localización de

faltas basado de la transformada de Stockwell y redes neuronales a una red de líneas de transmisión. Se detallan el diseño y desarrollo del sistema, junto con los resultados obtenidos en las pruebas realizadas. Dichos resultados demuestran la eficacia del enfoque propuesto para la detección y localización de faltas en sistemas de transmisión eléctrica, y se realiza una comparación final de sus ventajas y desventajas respecto a otros enfoques actuales.

4.2. Estudio de la frecuencia característica sobre una línea de transmisión

4.2.1. Metodología

La metodología del estudio de la frecuencia característica del sistema permite disponer de un procedimiento automatizado sencillo de forma que sea aplicable a cualquier red de transmisión. Este método nos permite establecer de forma sencilla esta frecuencia aplicando transformadas tiempo frecuencia sobre una señal conocida como es el TRV.

Como se trató en capítulos anteriores, el TRV se produce cuando los contactos de un interruptor de potencia (CB), del inglés *Circuit Breaker* abren para extinguir una falta en el sistema eléctrico de potencia apareciendo un arco entre los polos mientras que el RRRV es la tasa de aumento que se produce de este transitorio. La corriente fluye continuamente entre los contactos en un nuevo medio gaseoso ionizado hasta su instante de paso por cero. En consecuencia, entre los dos polos de un CB se producirán diferentes tensiones, así como componentes de alta frecuencia después de la interrupción [41]. La Figura 4.1 ilustra el TRV que aparece en los terminales de un CB cuando se produce una falta monofásica en una línea de transmisión de 220 kV a 150 km (a) y a 50 km (b).

En Figura 4.1 se ilustra claramente la diferencia de magnitudes de frecuencia




Figura 4.1: TRVs para faltas a diferentes distancias: (a) 150 km y (b) 50 km.

entre ambas señales, la cual está asociada directamente a la impedancia del sistema, como son la capacitancia, inductancia y resistencia de la red.

Estos parámetros son, desde un punto de vista computacional, medidos directamente (selección) sobre la señal. Sin embargo, el TRV contiene información en frecuencia que, debidamente analizada (extracción) en este dominio, puede proporcionar información característica sobre el sistema equivalente cuando se produce la falta. La Figura 4.2 muestra a grandes rasgos un esquema del enfoque propuesto.

El resultado del análisis de la ST es una matriz de elementos complejos cuyas columnas representan el espectro local en el tiempo y cuyas filas representan la frecuencia. La representación de estos elementos en el plano tiempo-frecuencia permite obtener los contornos con el mismo espectro de amplitud [42].

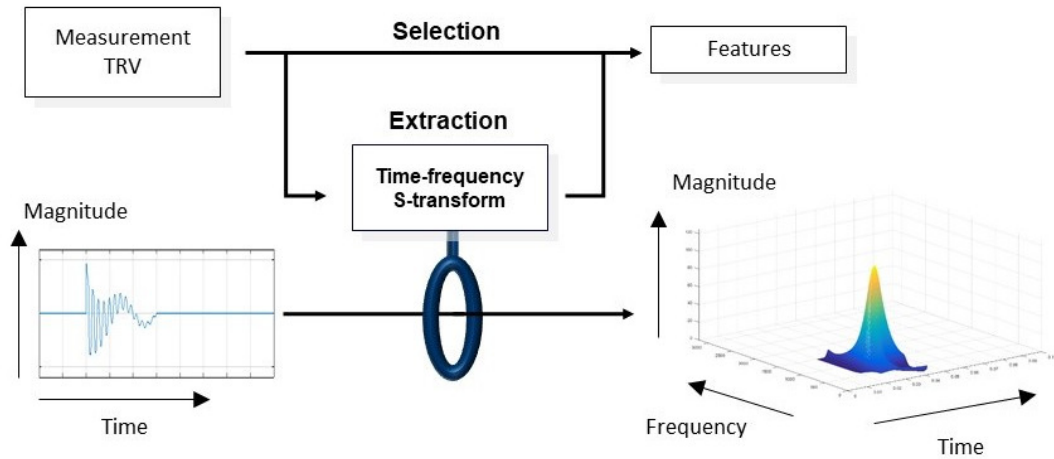


Figura 4.2: Esquema del enfoque propuesto.

A partir de esta matriz es posible calcular el contenido energético de la señal, basándonos en el teorema de Parseval, calculando el contenido energético en los contornos tiempo-frecuencia [43].

La Figura 4.3 muestra un ejemplo de análisis de la transformada ST para los dos TRV anteriores, cuando se produce una falta monofásica a 150 y 50 km en diferentes instantes de tiempo y ángulos de inicio. Estos TRVs se representan en el dominio del tiempo, (a) y (b), respectivamente. Las mallas tridimensionales de amplitud, tiempo y frecuencia de la matriz compleja obtenida por ST se representan en (c) y (d). Los contornos de TRV en el dominio tiempo-frecuencia se representan en (e) y (f). Tanto las mallas 3D como los contornos de tiempo-frecuencia permiten localizar la frecuencia de las TRV. Finalmente, los valores de la energía contenida en cada frecuencia, mostrados en (g) y (h), permiten determinar con precisión la frecuencia característica donde se alcanza el punto de máxima energía. Este punto se ha marcado indicando el valor de esta frecuencia, f_0 . Esta es la frecuencia del sistema que depende de las características del circuito y que, en el caso de una falta, están asociadas principalmente a la tipología de la línea y a la distancia de falta. Para los casos mostrados en la Figura 4.3, estas frecuencias son 440 y 1190 Hz para

una distancia de falta de 150 y 50 km, respectivamente.

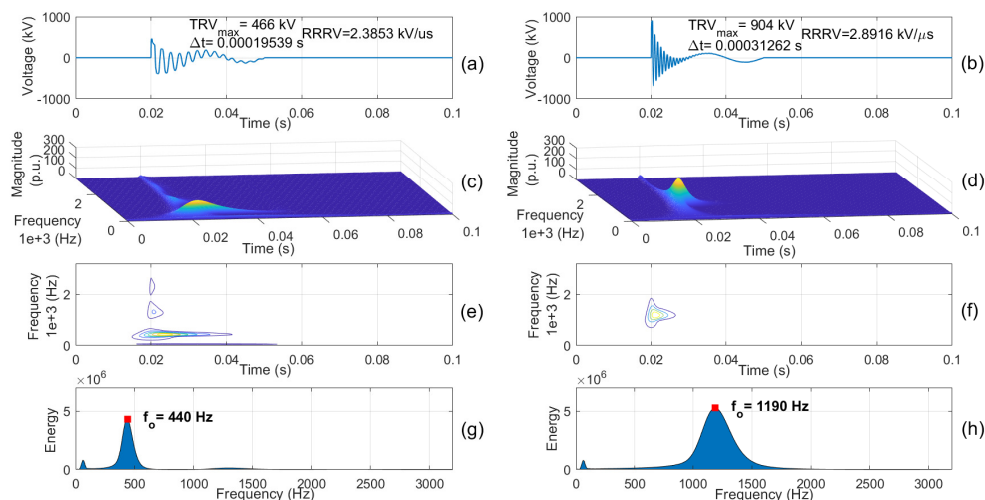


Figura 4.3: Análisis de la ST aplicado al TRV. El TRV para faltas monofásicas (a-b), las mallas de la ST (c-d), los contornos de la transformada ST (e-f) y energía de estos contornos (g-h), para 150 km y 50 km, respectivamente.

4.2.2. Caso de estudio

Para determinar la frecuencia asociada [44], [45] a la distancia a la que se produce una falta eléctrica es necesario emplear el modelo de línea que represente su comportamiento en un amplio rango de frecuencias teniendo en cuenta los distintos fenómenos electromagnéticos que pueden influir, por ejemplo la interacción entre líneas paralelas.

A modo de caso de estudio, se presenta una línea de transmisión que permite evaluar como influyen distintas variables eléctricas sobre el sistema propuesto para la localización de la frecuencia característica cuando se produce una falta eléctrica.

Por ello, se presenta una línea de transmisión de 132 kV con frecuencia nominal de 50 Hz y de una longitud total de 200 km conectada en ambos extremos por una subestación, considerando parámetros geométricos en formación *3LConc*. En

la Figura 4.4 se representa el esquema eléctrico correspondiente. Todos los datos eléctricos que componen la línea de transmisión son obtenidos de estándares de compañías eléctricas. En concreto, todos los datos se representan en las tablas 4.1 y 4.2 mientras que la Figura 4.5 muestra el esquema geométrico de las torres de alta tensión empleadas, donde la flecha de los conductores se considera de 10 m. La resistividad a tierra considerada es de $10^{-3} [\Omega.m]$. Para el análisis, el modelo es desarrollado y simulado en PSCAD-EMTDC^R [46].




Figura 4.4: Modelo esquemático de línea de 132 kV.

Dato del conductor						Conductor de tierra	
Radio Exterior	Estilo Conductor	Alambres	Alambres Exteriores	Radio Alambre	Resistencia CC	Exterior Radio	Resistencia CC
10.9 $10^{-3}[m]$	Trenzado	33	26	0.003 [m]	0.196 [Ω/km]	5.325 $10^{-3}[m]$	0.277 [Ω/km]

Tabla 4.1: Datos del conductor.

Según el estado del arte, la falta eléctrica que con más frecuencia se produce es la monofásica a tierra [47], [48]. Por ello, en este caso de estudio se escoge este fenómeno para caracterizar el efecto que tiene sobre la línea de transmisión presente.

Para ello, se analizan la variación de las siguientes variables con el objetivo de

	Secuencia Positiva		Secuencia Cero	
	Impedancia [Ω]	Fase [deg]	Impedancia [Ω]	Fase [deg]
ZA	20.46	89.04	40.19	85.97
ZB	6.724	82.04	12.54	88.97

Tabla 4.2: Impedancia de las fuentes.




Figura 4.5: Esquema de la torre de la línea aérea utilizada en los casos de estudio.

analizar la robustez de la ST: se consideran cuatro valores de resistencia de falta distintos, desde $0,001 \Omega$ a 100Ω , tres modelos de arco y la apertura del CB en distintas ángulos de incidencia variando la posición desde donde se produce la falta eléctrica en el sistema.

Las faltas serán simuladas en PSCAD desde donde se obtienen las señales de TRV. Esta señal tiene una longitud de 100 ms muestreada a una frecuencia de 25,6 kHz, la cual permite, de acuerdo a la condición de Nyquist, obtener información de hasta 12,8 kHz.

4.2.2.1. Efecto de la distancia de falta

Cuando se produce una falta eléctrica y un CB abre sus contactos para aislar la misma, aparece una señal TRV con una alta sobretensión transitoria debido a las oscilaciones de energía acumulada por la capacitancia e inductancia equivalentes del circuito cuando este abierto. Esta impedancia equivalente está asociada con los elementos característicos que representan el sistema eléctrico. Por ello, el valor de la impedancia característica del sistema varía acorde a la localización donde se produce la falta.

En la Tabla 4.3 se representan 16 faltas monofásicas a distintas distancias, incluyendo la frecuencia alcanzada a la máxima energía así como su energía, TRV y RRRV. Parte de estos resultados son representados gráficamente en la Figura 4.6, desde 25 a 175 km en pasos de 25 km. Adicionalmente, la Figura 4.6 muestra de izquierda a derecha, el TRV, los contornos tiempo-frecuencia del análisis de la ST y la energía en dichos contornos. Los resultados evidencian que la frecuencia varía inversamente con la distancia.

La Figura 4.7 muestra gráficamente la frecuencia característica frente a la distancia de los datos en la Tabla 4.3. Se observa que una interpolación lineal facilitaría los valores de las distancias de falta mediante el cálculo de la frecuencia característica por el método propuesto, por ello, en la Figura 4.7, los datos de distancias intermedias se han representado fuera de la línea para comprobar esta posible aproximación donde se observa que la variación de la frecuencia con la distancia es más abrupta para distancias inferiores a 50 km.

Destaca la robustez de la aproximación propuesta en la determinación de la frecuencia característica, principalmente asociada a la distancia de la falta, independientemente de la localización en la que se produzca la misma. La Figura 4.8 muestra el TRV máximo frente a la distancia, donde se puede comprobar que la relación es inversamente proporcional desde los 25 km donde se produce el máximo. Este resultado es similar al que se presenta en [49] donde se muestra

Distancia [km]	f_o [Hz]	Energía _{ST} $10^6 \cdot [kV^2 \cdot s]$	TRV _{Max} [kV]	RRRV [kV/ μ s]
10	3750	0.716	1100.70	14.08
20	2500	1.299	1140.00	9.72
25	2130	2.234	1166.98	7.47
40	1420	3.311	1003.51	4.28
50	1190	5.246	903.96	2.89
60	1020	5.308	820.45	2.99
75	810	4.025	721.08	2.64
80	760	4.578	693.73	2.53
100	630	5.039	603.69	2.57
110	570	4.957	567.90	2.42
125	510	4.598	522.63	2.23
130	490	4.607	509.74	2.61
150	440	4.281	466.06	2.39
160	400	3.982	448.28	2.29
175	380	3.873	427.16	2.19
190	350	3.982	412.12	2.11

Tabla 4.3: Valor de frecuencia y energía característica, TRV y RRRV máximo a distintas distancias de falta monofásica.

el RRRV vs la distancia. La Figura 4.8 pone de manifiesto que el cálculo de los valores intermedios por interpolación permite disponer de valores muy próximos a los resultados experimentales.

4.2.2.2. Efecto del ángulo de incidencia

El método propuesto se prueba ahora para distintos ángulos de incidencia, el cual tiene relación con el instante en el que se produce el paso por cero de la tensión dentro del CB. A medida que el ángulo de incidencia es mayor, la tensión en la que se produce la apertura de los contactos es mayor.

Por ello, se realizaron 64 simulaciones para ilustrar como varia el TRV según el

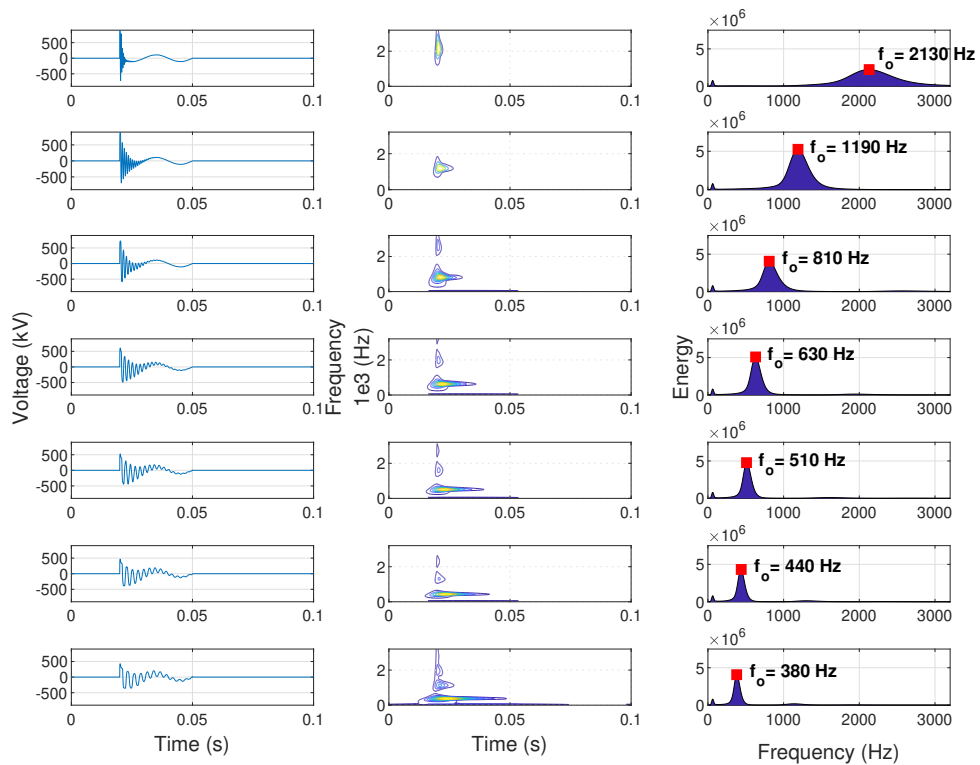


Figura 4.6: De izquierda a derecha: TRV, contornos ST y sus energías. De arriba a abajo se indican las distancias de 25 a 175 km en pasos de 25 km.

ángulo de apertura del CB. Para cada simulación, donde la localización de la falta se mantiene fija a 100 km, el ángulo de apertura aumenta en pasos de $0,3125$ ms ($5,625^\circ$), cubriendo un ciclo completo.

La Tabla 4.4 muestra sólo los resultados obtenidos para un intervalo de tiempo de 5 ms (un cuarto de ciclo), empezando por el que presenta el valor mínimo de energía. En ella se muestra el instante de tiempo en el que se produce la apertura, la frecuencia del sistema determinada a partir de la energía máxima obtenida de los contornos del análisis ST, la energía, el valor pico del TRV, el RRRV y el intervalo de tiempo para alcanzar el TRV. Como se observa la misma, a medida que la tensión es mayor, la energía y TRV aumentan.

La Figura 4.9 muestra, de izquierda a derecha, un resumen de los resultados en




Figura 4.7: Frecuencia característica vs distancia.




Figura 4.8: TRV_{peak} frente a la distancia

distintos instantes, a la izquierda el valor con mínima energía (404.0625 ms), a la derecha el valor de máxima energía (409.0625 ms) y en el centro el valor intermedio de ambas (406.5625 ms). De arriba abajo, el TRV (a-b-c), los contornos obtenidos

Ángulo CB [°]	Tiempo [ms]	f_0 [Hz]	Energía $10^6 \cdot [kV^2 \cdot s]$	TRV _{Max} [kV]	RRRV [kV/ μ s]	Δt [ms]
0.000	404.0625	630	0.642	171.16	0.24	0.703400
5.625	404.375	630	0.154	220.64	0.33	0.664320
11.250	404.6875	630	0.343	272.27	0.41	0.664320
16.875	405	630	0.627	321.21	0.48	0.664320
22.500	405.3125	630	0.986	367.38	0.59	0.625240
28.125	405.625	630	1.404	412.66	0.66	0.625240
33.750	405.9375	630	1.891	454.78	0.73	0.625240
39.375	406.25	630	2.419	493.06	0.79	0.625240
45.000	406.5625	630	2.961	527.21	0.84	0.625240
50.625	406.875	630	3.509	557.24	0.89	0.625240
56.250	407.1875	630	3.999	582.99	0.93	0.625240
61.875	407.5	630	4.486	603.87	0.97	0.625240
67.500	407.8125	630	4.912	619.28	0.99	0.625240
73.125	407.125	630	5.247	625.38	1.00	0.625240
78.750	408.4375	630	5.429	628.10	1.24	0.508010
84.375	408.75	630	5.534	628.48	1.46	0.429860
90.000	409.0625	630	5.592	626.98	1.60	0.390780

Tabla 4.4: Resultados de la simulación del efecto del ángulo de incidencia para una falta monofásica localizada a una distancia de 100 km.

a partir del análisis tiempo-frecuencia ST (d-e-f) y la energía frente a la frecuencia de estos contornos (g-h-i). En las Figuras superiores se representan los valores de TRV, intervalo de tiempo y RRRV, y en las inferiores la frecuencia característica del sistema. Se puede comprobar que la amplitud de la energía cambia en función del ángulo de incidencia, pero la frecuencia a la que se alcanza este valor se determina con precisión, independientemente de este ángulo. Hay que tener en cuenta que para el ángulo de incidencia que produce el valor mínimo de TRV, la energía a la frecuencia característica que depende de la distancia de falta no alcanza el valor máximo absoluto porque esta energía puede ser menor que la energía a la frecuencia fundamental (50 Hz), como se puede comprobar en la Figura 4.9 (g). Por lo tanto, el

valor máximo relativo debe determinarse a una frecuencia distinta de la fundamental. Para el resto de instantes, el valor de la energía en la frecuencia característica se convierte en un máximo absoluto, como puede comprobarse en la Figura 4.9 (h e i). Es necesario destacar que el método propuesto determina, de forma robusta, la frecuencia característica, f_o , independientemente del ángulo de incidencia a la que abre los contactos el interruptor de potencia. Además, el método propuesto facilita la energía en cada punto y permite determinar experimentalmente el cruce por cero y 90° .

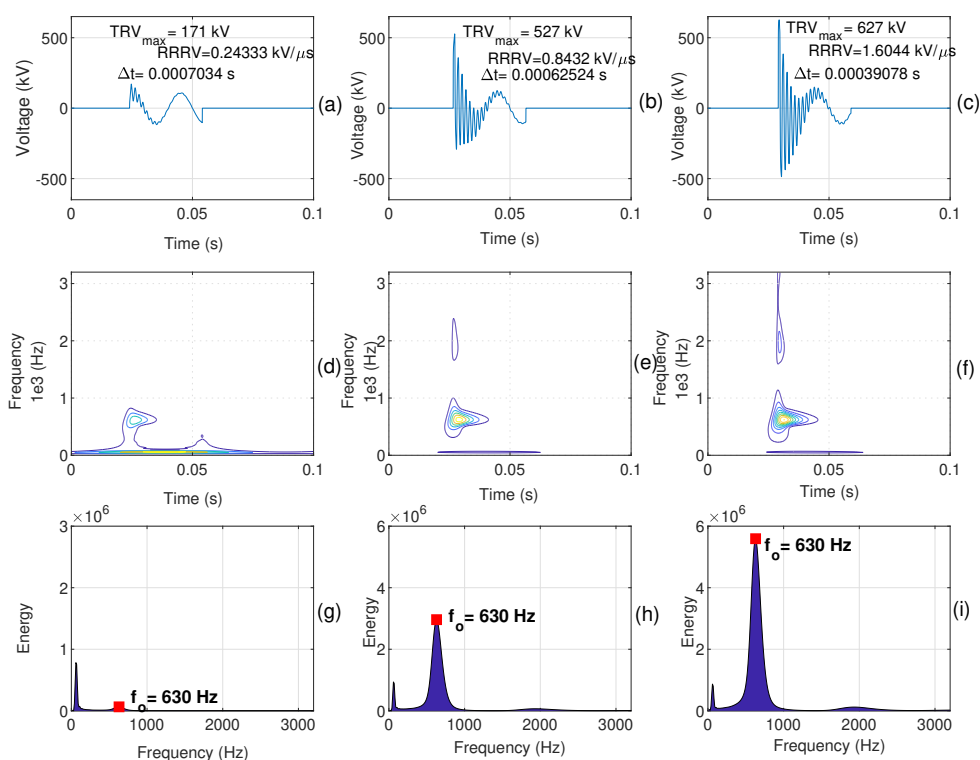


Figura 4.9: TRV, contornos de la ST y energía para diferentes ángulos de incidencia.

4.2.2.3. Efecto de la resistencia de falta

El modelo propuesto se comprobó para diferentes resistencias de falta. Para ello, se fijó la distancia de falta a 100 km y se realizaron distintas simulaciones en las

que la resistencia a tierra varía de $0,001 \Omega$ a 100Ω . En la Tabla 4.5 se muestran los valores obtenidos para diferentes valores de resistencia de falta y para un ángulo de incidencia de 0° y 90° . La Figura 4.10 muestra (de arriba abajo y de izquierda a derecha,) los TRV para valores de resistencia de $1 \text{ m}\Omega$, $100 \text{ m}\Omega$, 10Ω , y 100Ω ; los contornos obtenidos al aplicar la ST, y las energías de los contornos. Se puede comprobar que sólo para un valor de falta muy elevado (100Ω), se produce una pequeña desviación en la determinación de la frecuencia. Este valor es inusual para faltas monofásicas a tierra.

De nuevo, cabe destacar que el método propuesto sigue siendo muy robusto en la determinación de la frecuencia característica del sistema siendo independiente de la resistencia de falta.

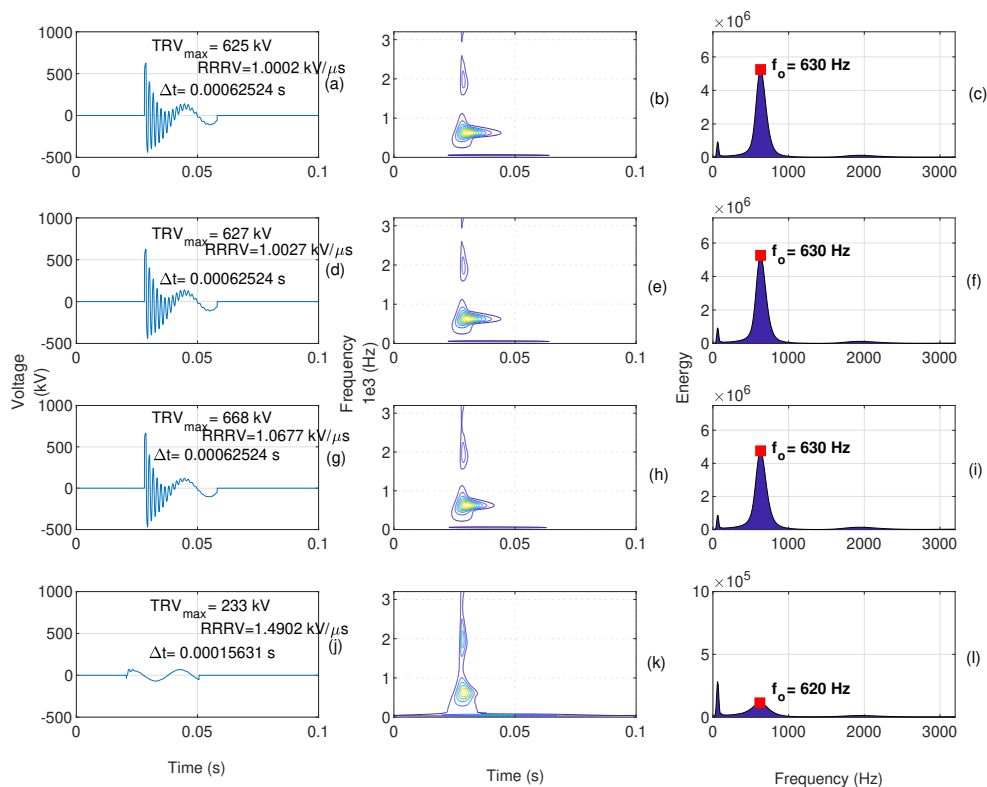


Figura 4.10: TRVs, contornos de la ST y energía para diferentes resistencias de falta.

R_G [Ω]	Ángulo CB [$^\circ$]	f_o [Hz]	Energía $10^6 \cdot [kV^2 \cdot s]$	TRV_{Max} [kV]	RRRV [kV/ μs]	Δt [ms]
0.001	0	630	5.247	625.380	1.000	0.62524
0.1	0	630	5.261	626.941	1.002	0.62524
10	0	630	4.759	667.551	1.067	0.62524
100	0	620	0.114	232.939	1.490	0.15631
0.001	90	630	5.245	625.398	1.000	0.62524
0.1	90	630	5.261	626.960	1.002	0.62524
10	90	630	0.475	667.569	1.067	0.62524
100	90	620	1.140	232.938	1.490	0.15631

Tabla 4.5: Resultado de las simulaciones para distintas resistencia de falta.

4.2.2.4. Efecto del modelo de arco y tecnología de aislamiento del interruptor de potencia

Para comprobar la precisión del sistema propuesto, se realizará un análisis de varios modelos matemáticos que describen el comportamiento del arco eléctrico durante la operación de apertura de los polos en los interruptores de potencia. Estos modelos ilustran el comportamiento no lineal del arco eléctrico del CB, así como la interacción entre el proceso de conmutación y los componentes del sistema [50].

Estos modelos, desarrollados por Cassie [51], Mayr [52] y Schavmaker [53], se presentan como ecuaciones diferenciales que describen la conductancia del arco durante el proceso de interrupción de la corriente, incluyendo el cálculo de la conductancia del arco eléctrico en el dominio del tiempo basado en parámetros que caracterizan un tipo de CB y un aislamiento dados. Las Tablas 4.6 y 4.7 presentan los valores de los parámetros en los modelos de ecuaciones para interruptores de potencia por vacío y SF6 [54].

Los resultados para diferentes modelos de arco y tipo de aislamiento se muestran en la Tabla 4.8, para distancias de falta de 50 km y 150 km. La Figura 4.11 muestra los correspondientes a 50 km de distancia de falta y aislamiento SF6. En la Figura

Modelo Arco	Parámetro	Unidad	Tecnología	
			Aire	SF6
Cassie	Constante de tiempo	[μ s]	0.8	0.8
	Tensión de Arco	[kV]	2.6	2.35
Mayr	Constante de tiempo	[μ s]	0.124	0.22
	Potencia de enfriamiento por arco	[kW]	3.45	8.8

Tabla 4.6: Valores de los parámetros de los modelos de Cassie y Mayr para un CB.

Modelo Arco	Parámetro	Unidad	Tecnología	
			Aire	SF6
Schavmaker	Constante de tiempo de arco	[μ s]	6	1.5
	Potencia de enfriamiento por arco	[MW]	16	4
	Coefficiente de potencia de enfriamiento	[p.u.]	0.5	0.68

Tabla 4.7: Valores de los parámetros del modelo Schavmaker para un CB.

4.11 se muestran los correspondientes a 50 km de distancia de falta y aislamiento en SF6. Se puede comprobar la robustez del método, para ambas distancias 50 y 150 km, donde la frecuencia característica determina con precisión, 1190 y 440 Hz, respectivamente, independientemente del modelo de arco y del tipo de CB utilizado.

4.2.3. Análisis de sensibilidad de la frecuencia característica y energía asociada a una línea de transmisión

Un análisis de sensibilidad refleja la influencia del cambio de los parámetros característicos estudiados anteriormente en los resultados del método propuesto [55] donde en este caso, se estudiará su efecto sobre la curva de energía-frecuencia obtenida del análisis de ST. Es decir, si hay un ligero cambio en uno de los parámetros de entrada y las curvas de energía-frecuencia varía en gran medida, daría lugar a un parámetro de alta sensibilidad. Para disponer de un método robusto donde las características de energía-frecuencia puedan ser variables representativas del sistema, es muy importante entrenarlo sólo con parámetros de alta sensibilidad ya que de lo

4.2. Estudio de la frecuencia característica sobre una línea de transmisión

Modelo	Tecnología	Distancia [km]	f_o [Hz]	Energía $10^6 \cdot [kV^2 \cdot s]$	TRV_{Max} [kV]	RRRV [kV/ μs]
Mayr	Aire	50	1190	1.248	528.423	1.6903
Cassie	Aire	50	1190	1.321	528.614	1.6909
Schavmaker	Aire	50	1190	1.330	528.614	1.6909
Mayr	SF6	50	1190	1.248	528.423	1.6903
Cassie	SF6	50	1190	1.319	528.586	1.6908
Schavmaker	SF6	50	1190	1.183	528.421	1.6903
Mayr	Aire	150	440	1.410	355.498	1.6903
Cassie	Aire	150	440	1.411	355.502	1.6909
Schavmaker	Aire	150	440	1.573	364.594	1.3009
Mayr	SF6	150	440	1.410	355.498	1.6903
Cassie	SF6	150	440	1.410	355.499	1.6908
Schavmaker	SF6	150	440	1.400	355.266	1.6903

Tabla 4.8: Resultados de la simulación empleando distintos modelos de arco simulando faltas eléctricas a 50 y 150 km.

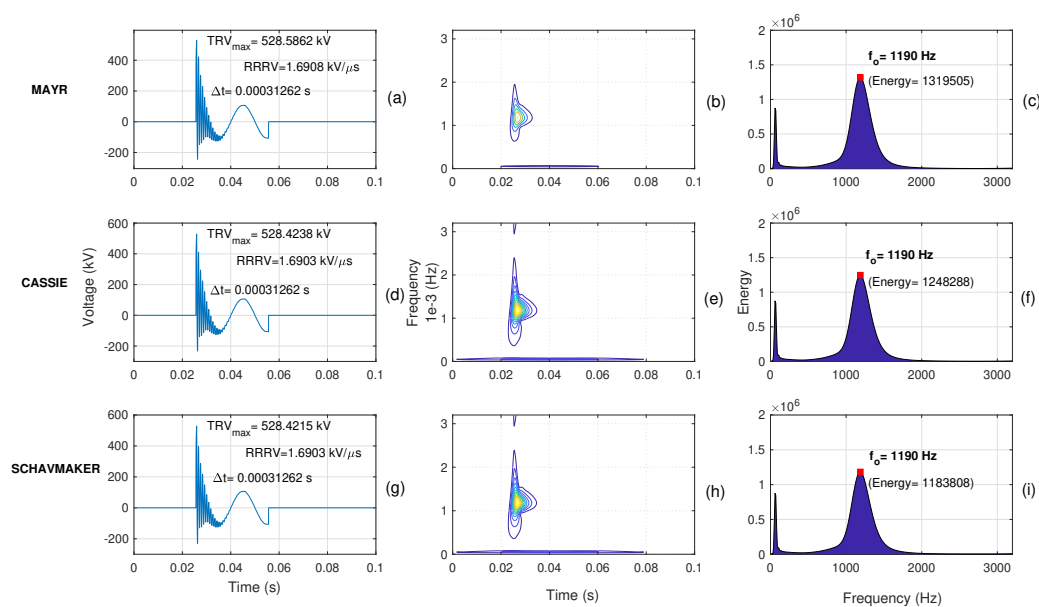


Figura 4.11: TRVs, contornos de la ST y energía para modelos de arco con falta eléctrica a 50km.

contrario, se producirá un ajuste excesivo. Por lo tanto, el análisis de sensibilidad evalúa la solidez de las características propuestas para este enfoque.

Utilizando la línea de transmisión presentada en la sección anterior, es posible realizar simulaciones variando los valores de los diferentes parámetros mostrados en la Tabla 4.9. Por ello, utilizando PSCAD-EMTDC^R, se ejecutaron 51205 simulaciones diferentes con el objetivo de tener un amplio análisis de los parámetros sensibles del sistema. Tras este proceso, se realiza un análisis frecuencial de las señales TRV mediante ST con el fin de obtener la frecuencia característica y su valor energético asociado para cualquier combinación dada de los parámetros de entrada de la línea de transmisión.

Variable	Valores
Resistencia de falta (R_{fault})	0.001, 0.01, 0.1, 1, 10, 100, 1000 Ω
Ángulo de incidencia (α)	0° a 90° en pasos de 15°
Distancia de la falta (L)	10 a 190 km en pasos de 5 km
Capacitancia equiv. (C)	0.0095, 0.00975, 0.01, 0.01025, 0.0105 μF
Tipo de falta	A-G, B-G, C-G, AB, AB-G, AC, AC-G, BC, BC-G, ABC, ABC-G
Variación de P	7.5 MW, 15 MW, 22.5 MW, 30 MW
Variación de Q	7.5 MVar, 15 MVar, 22.5 MVar, 30 MVar

Tabla 4.9: Variables dependientes de estudio.

Todos los parámetros son muy importantes para determinar la distancia de falta, ya que están correlacionados de forma no lineal con el método. Para realizar un análisis de sensibilidad de parámetros sobre los parámetros de entrada de la línea de transmisión, se calculan las sensibilidades de cada parámetro. Las sensibilidades de energía cuantificarán como la variación de energía relativa a cada parámetro, mientras que las sensibilidades de frecuencia permitirán estudiar la estabilidad de la frecuencia característica con respecto a los parámetros de entrada del modelo. Para cada tipo de falta y para cada parámetro (ángulo de incidencia, capacitancia

4.2. Estudio de la frecuencia característica sobre una línea de transmisión

equivalente y resistencia de falta), las sensibilidades de energía y frecuencia se obtienen considerando las siguientes ecuaciones 4.1 y 4.2.

$$ES_{\alpha} = \frac{E}{E^*} \Bigg|_{L=L_i}^{\alpha=\alpha_i} \quad ES_R = \frac{E}{E^*} \Bigg|_{L=L_i}^{R=R_i} \quad ES_C = \frac{E}{E^*} \Bigg|_{L=L_i}^{C=C_i} \quad (4.1)$$

$$FS_{\alpha} = \frac{f_0}{f_0^*} \Bigg|_{L=L_i}^{\alpha=\alpha_i} \quad FS_R = \frac{f_0}{f_0^*} \Bigg|_{L=L_i}^{R=R_i} \quad FS_C = \frac{f_0}{f_0^*} \Bigg|_{L=L_i}^{C=C_i} \quad (4.2)$$

Para el cálculo de sensibilidades es necesario disponer un estado de referencia como se muestra en las ecuaciones 4.1 y 4.2. En la Figura 4.12 se grafican los estados de referencia para el ángulo de incidencia, la resistencia de falta y de capacitancia equivalente. Aunque cambie el tipo de falta, la frecuencia característica y su energía asociada no varían para la misma resistencia de falta. Por otra parte, la frecuencia característica presenta valores similares con la misma tendencia entre los distintos tipos de falta. La energía asociada en los estados de referencia para la capacitancia equivalente y el ángulo de incidencia varía de la misma forma para los diferentes tipos de falta.

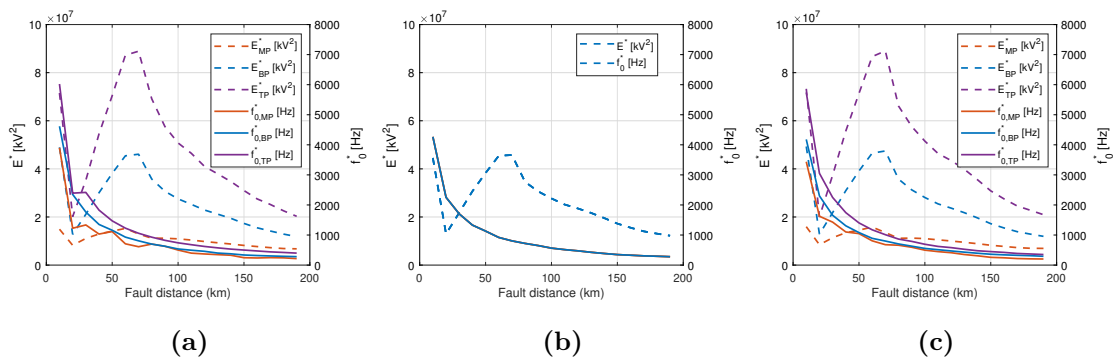


Figura 4.12: Estados de referencia para el cálculo de sensibilidad para el ángulo de incidencia (a) ($\alpha = 0^\circ$), resistencia de falta (b) ($R = 0.001\Omega$) y capacitancia equivalente (c) ($C = 0.0095\mu F$).

4.2.3.1. Estudio de sensibilidad del ángulo de incidencia

La Figura 4.13 muestra la influencia del ángulo de incidencia en la frecuencia característica y las sensibilidades energéticas donde se representan los valores medios de las sensibilidades para cada distancia de falta. Como se muestra, la frecuencia característica y su energía asociada varían enormemente con el cambio del ángulo de incidencia. Se muestra hasta un 60% de cambio en el caso de la frecuencia característica y un 50% de cambio en el caso de la energía. Como resultado, este parámetro se considera un parámetro sensible.

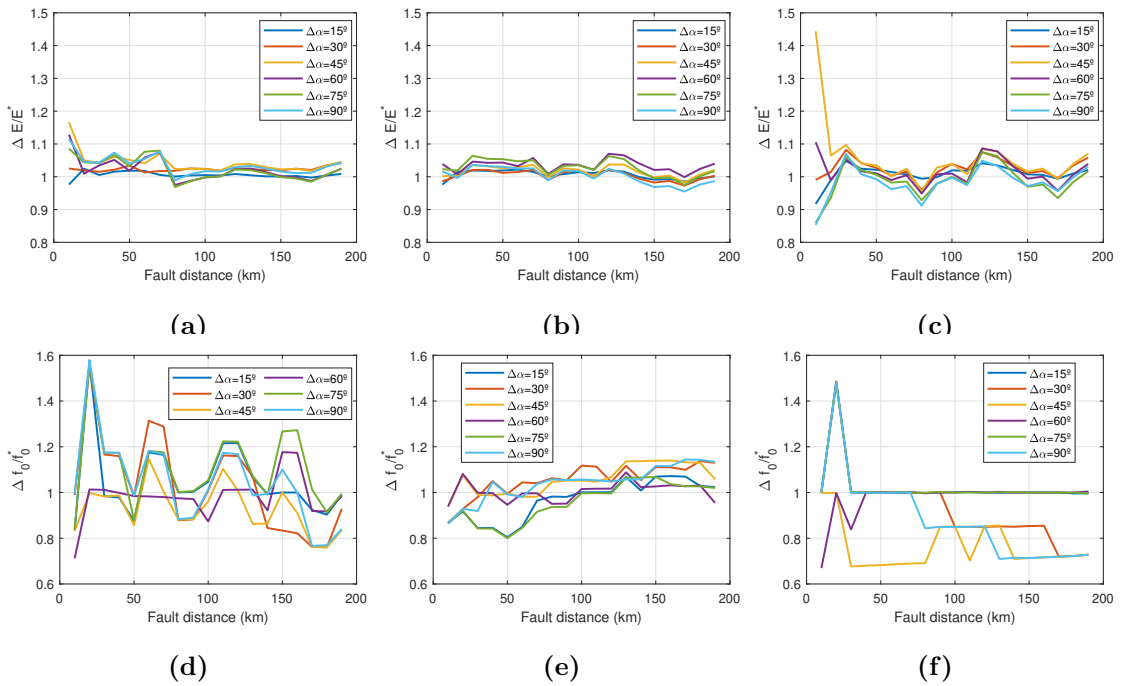


Figura 4.13: Sensibilidades en energía y frecuencia con respecto al ángulo de inicio de la falta y a diferentes tipos de faltas: monofásica a tierra (a) y (d), bifásica a tierra, (b) y (e), trifásica a tierra, (c) y (f).

4.2.3.2. Estudio de sensibilidad de la resistencia

La Figura 4.14 muestra la influencia de la resistencia de falta en las sensibilidades de frecuencia característica y energía. De la misma, se puede concluir que la

resistencia de falta no tiene influencia ni en la frecuencia característica ni en su valor de energía asociado. Como resultado, no se considera un parámetro sensible.

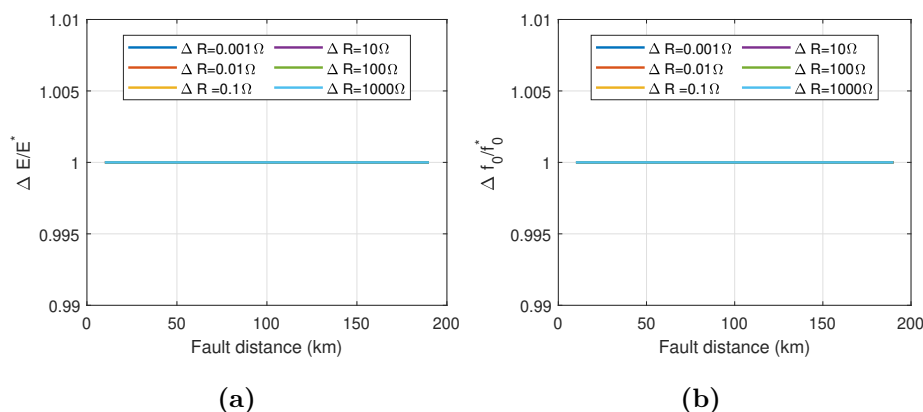


Figura 4.14: Sensibilidades en energía y frecuencia con respecto la resistencia a tierra considerando todas las faltas.

4.2.3.3. Estudio de sensibilidad de la capacidad

La Figura 4.15 muestra las sensibilidades de energía y frecuencia con respecto a la capacitancia equivalente del sistema de potencia considerado. Como se ha indicado anteriormente, se espera que la capacitancia varíe poco, ya que si, debido a una falta, es necesario sustituir un componente, la capacitancia del componente de repuesto será similar. No obstante, se considera un 10 % de cambio, y el efecto es inferior al 2%. Por ello, este parámetro también se considera no sensible y constante.

4.2.3.4. Estudio de sensibilidad de la potencia activa y reactiva

En el análisis de sensibilidad también es crucial analizar como el cambio de la capacidad nodal de la red se relacionan con la energía de la TRV y su frecuencia característica.

En esta sección, se analizará como afecta la variación de potencia activa y reactiva sobre la línea dependiendo del tipo de falta (monofásica, bifásica y trifásica). Cada

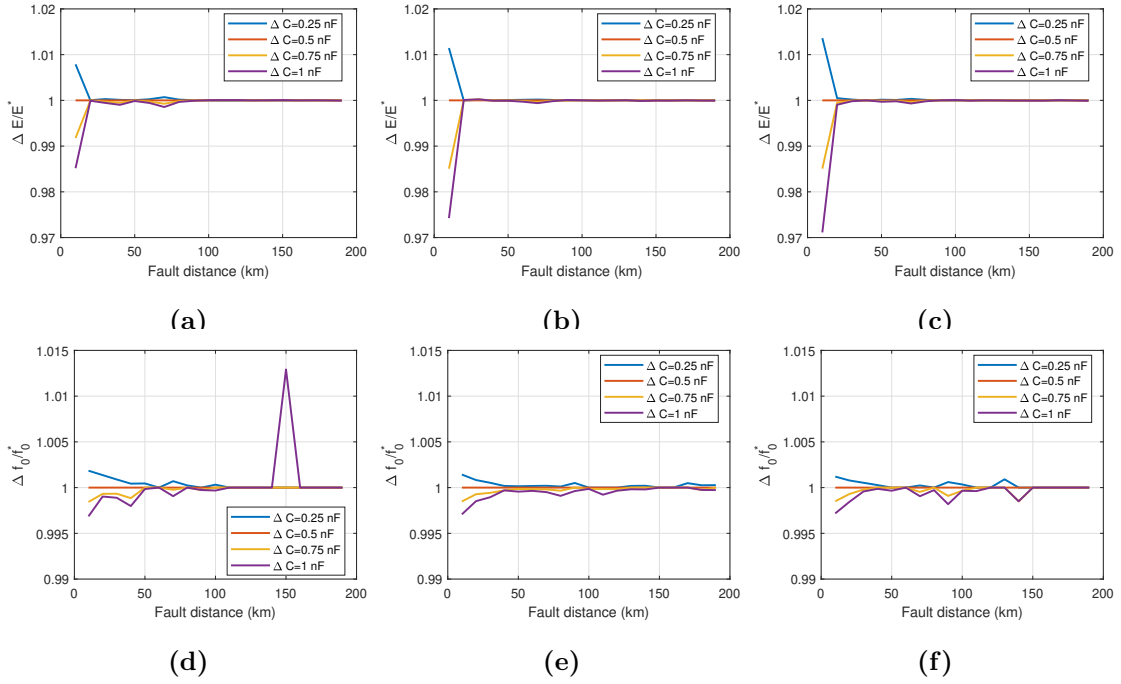


Figura 4.15: Sensibilidades en energía y frecuencia con respecto a la capacitancia equivalente y a diferentes tipos de faltas: monofásica a tierra (a) y (d), bifásica a tierra, (b) y (e), trifásica a tierra, (c) y (f).

estudio proporcionará información sobre la importancia relativa de estos parámetros en las curvas energía-distancia y frecuencia-distancia de la falta donde su análisis de sensibilidad permitirá conocer cómo la variación de los parámetros de entrada del modelo afectan a sus características. En cualquier caso, y sobre una red de transmisión, las variaciones de potencia activa y reactiva están acotadas por nodo.

Matemáticamente, las sensibilidades se definen mediante derivadas parciales, pero, en este estudio, se selecciona un caso de referencia o base (señalado con * asterisco), y se considera el estudio incremental, ecuaciones 4.3 y 4.4. Las sensibilidades energéticas cuantificarán la variación de energía respecto a cada parámetro, mientras que las sensibilidades frecuenciales permiten estudiar la estabilidad de la frecuencia característica respecto a los parámetros en estudio.

$$ES_P = \frac{E}{E^*} \Big|_{L=L_i}^{P=P_i} \quad ES_Q = \frac{E}{E^*} \Big|_{L=L_i}^{Q=Q_i} \quad (4.3)$$

$$FS_P = \frac{f_0}{f_0^*} \Big|_{L=L_i}^{P=P_i} \quad FS_Q = \frac{f_0}{f_0^*} \Big|_{L=L_i}^{Q=Q_i} \quad (4.4)$$

Los estados de referencia en el caso de variación de potencia activa se muestran en la Figura 4.16 teniendo en cuenta las faltas monofásicas (LG), bifásicas (LL) y trifásicas (LLL). La frecuencia características disminuye directamente con la distancia de la falta, al igual que su contenido energético asociado. Las faltas trifásicas son las que tienen mayor cantidad de energía. Las faltas de corta distancia concentran mayores energías y frecuencias, como se ha demostrado. La Figura 4.17 muestra la variación de las sensibilidades relativas a la distancia de falta y al tipo de falta para la energía y la frecuencia característica, considerando una variación de la potencia activa consumida por la carga PQ de 10 MW, 20 MW, 30 MW y 40 MW, respectivamente. Se considera como caso de referencia aquel con 10 MW de potencia activa consumida.




Figura 4.16: TRVs, Estado de referencia para potencia activa (P) en el análisis de sensibilidad considerando $P = 10$ MW.

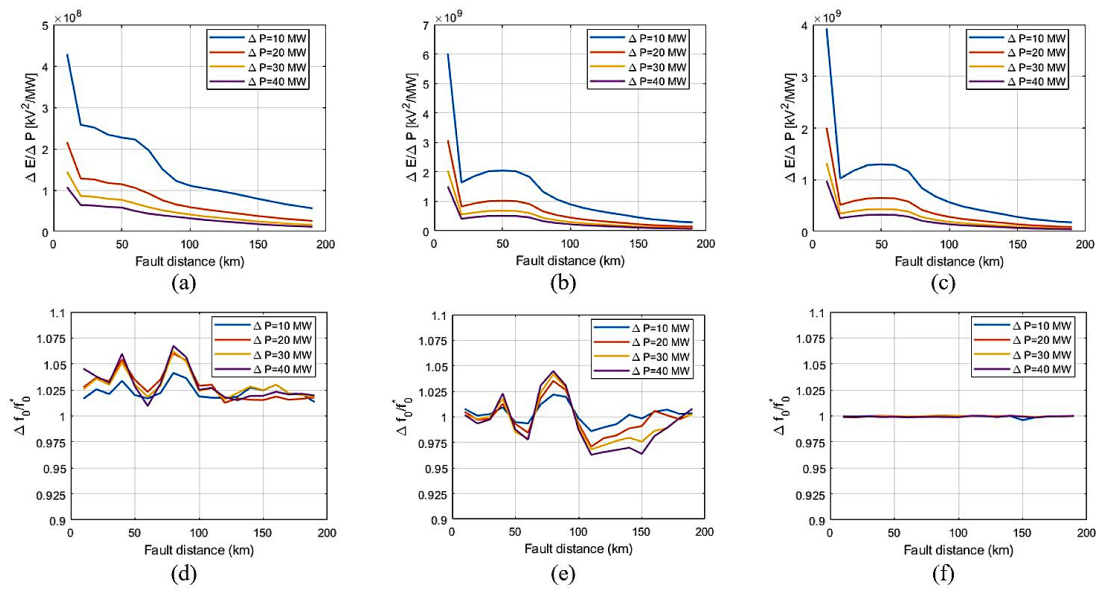


Figura 4.17: TRVs, Análisis de sensibilidad de la potencia activa consumida por la carga P. Faltas monofásicas (a) y (d), faltas bifásicas (b) y (e), faltas trifásicas (c) y (f).

En este caso, la frecuencia característica está contenida en una banda del 7,5 % en el caso de falta monofásica, inferior al 10 % en el caso bifásico y cercana al 1 % en el caso trifásico. Considerando la energía asociada a la frecuencia característica, ésta varía en mayor medida con respecto a los incrementos de potencia activa consumida, estabilizándose en valores inferiores cuando aumenta la carga. El contenido energético es especialmente elevado tanto en las faltas bifásicas como en las trifásicas.

En la Figura 4.18 se muestran los estados de referencia con variación de potencia reactiva considerando las faltas monofásicas (LG), bifásicas (LLG) y trifásicas (LLL). La frecuencia característica muestra una disminución monótona con la distancia de la falta. La energía asociada también disminuye con la distancia de la falta, pero no de forma monótona, exhibiendo un máximo local en un cuarto de la longitud de la línea. Las faltas trifásicas son las que presentan un mayor contenido energético, seis veces más que las monofásicas y dos veces más que las bifásicas.

La Figura 4.19 muestra la variación de las sensibilidades con respecto a la

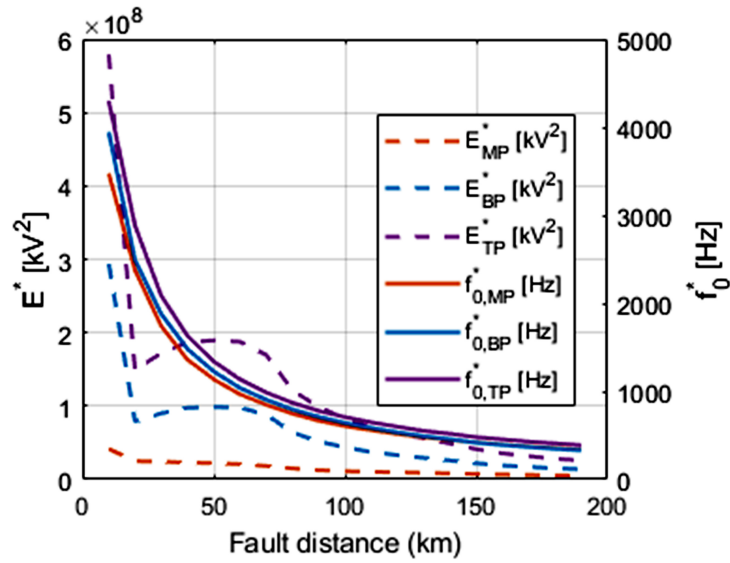


Figura 4.18: Estado de referencia para potencia reactiva (Q) en el análisis de sensibilidad considerando $P = 7.5$ MVar.

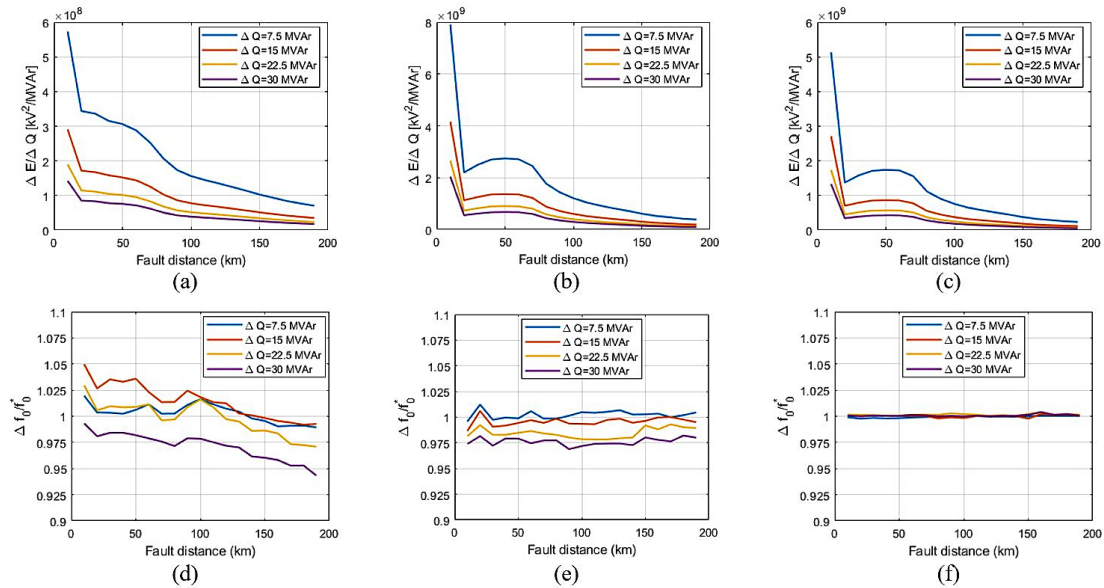


Figura 4.19: TRVs, Análisis de sensibilidad de la potencia reactiva consumida por la carga Q . Faltas monofásicas (a) y (d), faltas bifásicas (b) y (e), faltas trifásicas (c) y (f).

distancia de falta y al tipo de la misma para la energía y la frecuencia característica, considerando un cambio en la potencia reactiva consumida por la carga PQ de 7.5 MVar, 15 MVar, 22.5 MVar y 30 MVar. Se considera como caso de referencia el de

menor consumo (7.5 MVar) de la carga. La frecuencia característica está contenida en una banda ancha del 10 % para monofásicas, del 5 % para las bifásicas y de menos del 1 % para las trifásicas. Por otra parte, la energía asociada a frecuencia característica varía de la misma forma que el caso de la potencia activa. La energía contenida en TRV es mayor para valores pequeños de potencia reactiva consumida, y comienza a estabilizarse bajo demanda elevada, en valores inferiores.

En vista a los resultados de variaciones de flujo de potencia activa y reactiva, se comprueba como la variación de frecuencia característica es mínima y, por lo tanto, no se consideran como variables sensibles.

4.2.4. Determinación de la frecuencia característica sobre una línea de transmisión

Para demostrar la robustez del enfoque propuesto, se realizará el mismo ensayo sobre una nueva línea de transmisión diferente. Esta línea tiene una longitud de 250 km y una tensión nominal de 220 kV y conecta dos subestaciones. La Figura 4.20 muestra un diagrama esquemático del modelo de la línea.




Figura 4.20: Línea de transmisión de 220 kV modelada.

En este caso, la línea de transmisión comprende un doble circuito de 220 kV,

dispuesto en formación *H-Frame-3H4* tal y como se muestra en la Tabla 4.10. Los datos de conductores y parámetros geométricos de la línea se han obtenido a partir de una línea real y de normativa de compañías eléctricas. Los datos de la línea se presentan en la Figura 4.21, así como los parámetros de impedancia de las fuentes en la Tabla 4.11. La flecha de los conductores se consideró de 10 m y la resistividad del terreno se tomó como 100 Ω . Se utilizaron cuatro valores de resistencia de falta, desde una falta con 0.001 hasta 100 Ω . Las faltas se simularon con diferentes instantes de tiempo y ángulos de incidencia. Para obtener resultados comparables, todas las simulaciones tuvieron una duración de dos ciclos completos.

Dato del conductor						Cable de tierra	
Radio exterior	Estilo Conductor	Alambres	Alambres exteriores	Radio alambre	Resistencia CC.	Radio exterior	Resistencia CC
13.85 10^{-3} [m]	Trenzado	61	54	0.003 [m]	0.0719 [Ω /km]	5.325 10^{-3} [m]	0.277 [Ω /km]

Tabla 4.10: Datos del conductor y del conductor de tierra.

	Secuencia Positiva		Secuencia Cero	
	Impedancia	Fase	Impedancia	Fase
	[Ω]	[deg]	[Ω]	[deg]
Z_1	51.53	82.50	44.15	82.62
Z_2	7.124	88.49	7.54	88.11
Z_3	55.75	88.97	15.37	87.42
Z_4	17.67	85.19	17.12	86.79

Tabla 4.11: Impedancias de la fuentes.

Se simularon nueve faltas eléctricas en el sistema cambiando la localización de la misma, como se muestra en las Figuras 4.22 y 4.23. La Figura 4.22 muestra los resultados (de arriba a abajo) para distancias de falta de 50, 75, 100, 150, 175 y 200 km. También muestra (de izquierda a derecha) el TRV, los contornos de frecuencia del análisis de la ST en cada valor del TRV y las energías de cada frecuencia,




Figura 4.21: Esquema de la torre de la línea aérea empleada.

respectivamente. Las gráficas de energía frente a frecuencia de la izquierda indican la frecuencia en el punto en que se alcanza el valor máximo de energía. La Figura 4.24 muestra los resultados para distancias de falta a 25, 125, y 225 km con el fin de mejorar la apreciación de los detalles. Todos estos resultados se obtuvieron para cada distancia de falta simulando en el mismo instante de tiempo.

La Figura 4.24 muestra un gráfico de la frecuencia en función de la distancia. El resultado es similar al observado en el caso de estudio. La frecuencia cambia más bruscamente para distancias cercanas a la localización de la falta. En cualquier caso, la relación entre la frecuencia característica del sistema y el TRV permite corroborar que técnicamente sea posible realizar un localizador de faltas.

Al igual que en el caso de estudio, se han realizado simulaciones en las que se ha modificado el inicio de la falta. En la Tabla 4.12 se muestran los resultados de cada simulación: instante de tiempo en el que se produce la falta, frecuencia característica determinada a partir del máximo relativo de energía obtenido de los contornos del análisis ST, energía, valor máximo de la TRV, RRRV, e intervalo de tiempo necesario para alcanzar el valor máximo de la TRV. Es necesario destacar

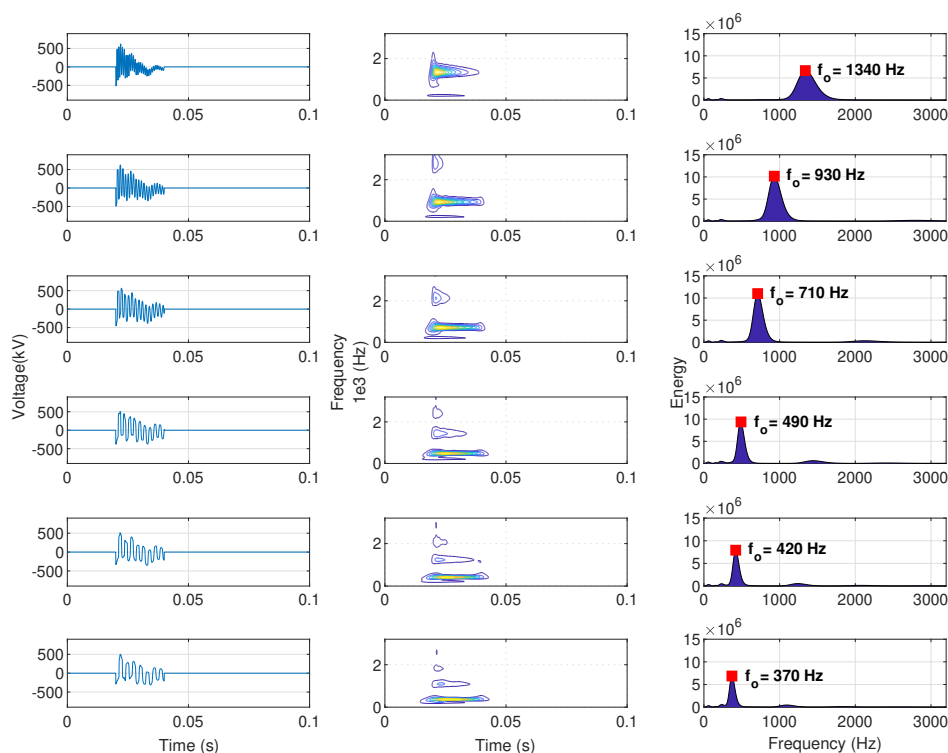


Figura 4.22: De izquierda a derecha: TRV, contornos y energía para cada frecuencia, obtenidos mediante la ST. De arriba abajo, para distancias de 50, 75, 100, 150, 175 y 200 km.

que el método propuesto determina la frecuencia del sistema, f_o , de forma robusta independientemente del ángulo de apertura de los contactos del interruptor de potencia.

La Figura 4.25 muestra (de arriba a abajo) el TRV, el contorno obtenido a partir del análisis ST y la energía frente a la frecuencia para dos ángulos de inicio diferentes cuando se alcanza el valor mínimo (izquierda) y máximo (derecha) de energía. En las subFiguras superiores se representan el pico de TRV, el intervalo de tiempo y el RRRV, así como el valor de la frecuencia del sistema en las inferiores.

El modelo se simuló para diferentes resistencias de falta que oscilaban entre 0.001 Ω y 100 Ω para una distancia de falta de 125 km y ángulos de incidencia entre 0° y

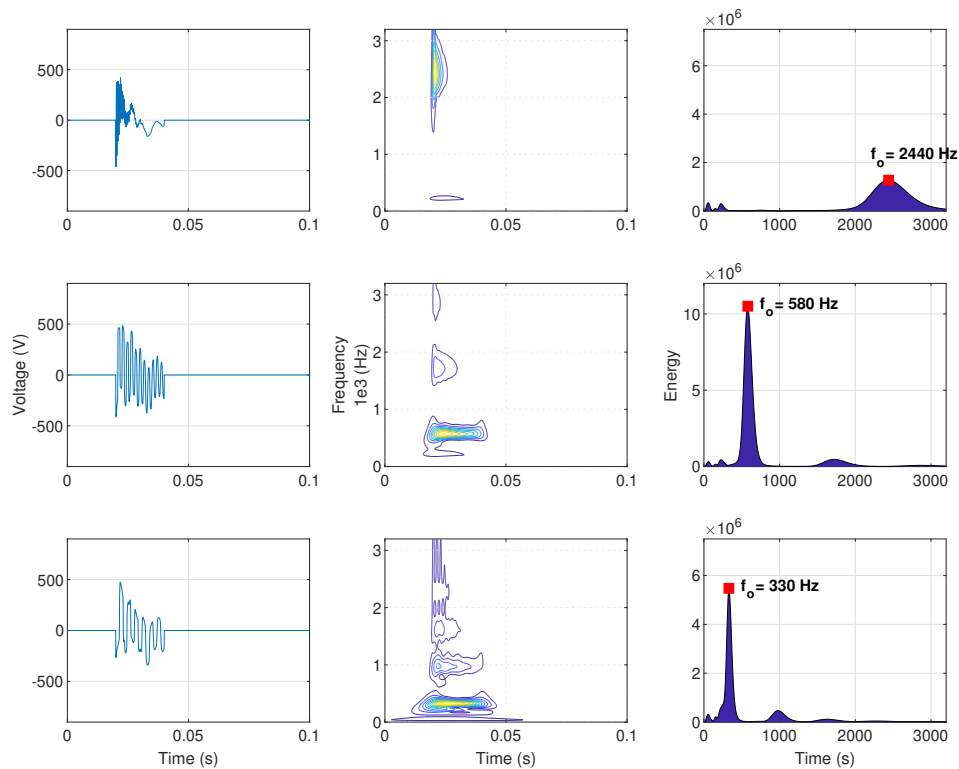


Figura 4.23: De izquierda a derecha: TRV, contornos y energía para cada frecuencia, obtenidos mediante la ST. De arriba abajo, para distancias de 25, 125 y 225 km.

90°. En la Tabla 4.13 se muestran los valores obtenidos para diferentes valores. De igual forma, la Figura 4.26 muestra, de arriba abajo y de izquierda a derecha, los TRVs para valores de resistencia de 1 m Ω , 100 m Ω , 10 Ω , y 100 Ω ; los contornos obtenidos al aplicar la ST y sus energías. Una vez más, hay que señalar que el método propuesto es muy robusto en la determinación de la frecuencia asociada a la distancia de falta.

La Tabla 4.14 muestra los resultados obtenidos para una distancia de falta de 50 km utilizando diferentes modelos de arco y la Figura 4.27 muestra los resultados utilizando el modelo de Mayr y aislamiento SF₆. Hay que destacar que existen diferencias importantes en el valor de pico TRV y en el valor de la energía pero el procedimiento es invariable en la determinación de la frecuencia característica

4.2. Estudio de la frecuencia característica sobre una línea de transmisión




Figura 4.24: Frecuencia frente a distancia.

Ángulo CB [°]	Tiempo [ms]	f_0 [Hz]	Energía _{ST} $10^6 \cdot [kV^2 \cdot s]$	TRV _{Max} [kV]	RRRV [kV/ μ s]	Δt [ms]
39.375	402.1875	1340	0.358	217.523	0.521	0.39078
45.000	402.5	1340	0.319	289.173	0.925	0.31262
50.625	402.8125	1340	1.023	370.124	1.184	0.31262
56.250	403.125	1340	2.018	436.963	1.398	0.31262
61.875	403.4375	1340	3.336	499.018	1.596	0.31262
67.500	403.75	1340	4.940	559.858	1.791	0.31262
73.125	404.0625	1340	6.482	613.666	1.963	0.31262
78.750	404.375	1340	8.726	669.689	2.142	0.31262
84.375	404.6875	1340	1.073	725.659	2.321	0.31262

Tabla 4.12: Resultados de la simulación para una falta monofásica 50 km en distintos instantes temporales.

asociada a la línea de transmisión.

Para el análisis de la precisión, se han realizado 180 simulaciones, 20 simulaciones para distancias de 25 a 225 km, cada 25 km, en las que se ha cambiado el inicio

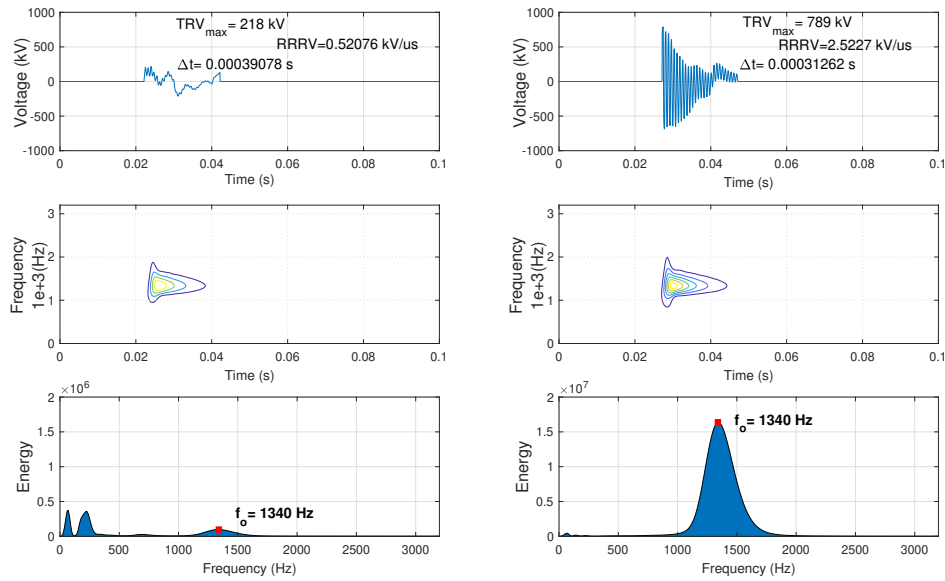


Figura 4.25: TRV, contornos de la transformada ST y energía-frecuencia para los valores mínimos y máximos de energía debido al ángulo de incidencia.

R_G [Ω]	Ángulo CB [$^\circ$]	f_o [Hz]	Energía _{ST} $10^6 \cdot [kV^2 \cdot s]$	TRV _{Max} [kV]	RRRV [kV/ μ s]
0.001	90	580	1.238	335.155	2.07500
0.1	90	580	1.239	335.394	2.08872
10	90	580	0.730	319.338	1.91685
100	90	580	0.328	343.215	0.43914
0.001	90	580	14.735	508.265	0.58731
0.1	90	580	14.844	509.876	0.59003
10	90	580	17.900	590.831	0.88937
100	90	580	0.459	330.014	2.41011

Tabla 4.13: Resultados de simulaciones para diferentes resistencias de falta.

de la falta. Hay una diferencia de 1 ms entre cada dos simulaciones. Todas estas simulaciones se muestran en la Figura 4.28, en una representación 3D, donde cada simulación realizada para cada distancia está representada por su contorno de energía ST. Además, para cada contorno, se representa el valor máximo de energía

4.2. Estudio de la frecuencia característica sobre una línea de transmisión

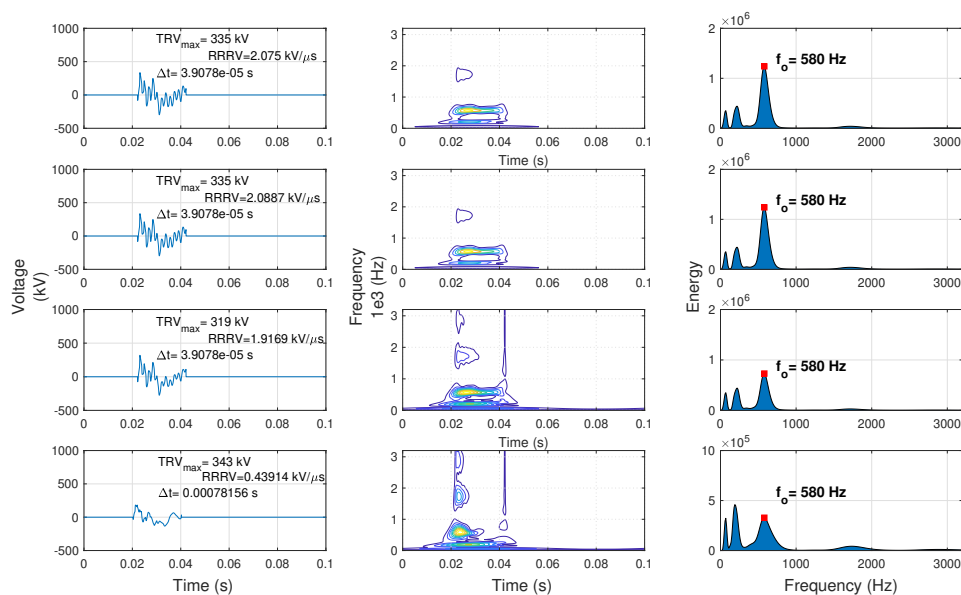


Figura 4.26: TRVs, Contornos energía-frecuencia de la transformada ST para diferentes resistencias de falta.

Modelo	Tecnología	Distancia [km]	f_o [Hz]	Energía _{ST} $10^6 \cdot [kV^2 \cdot s]$	TRV _{Max} [kV]	RRRV [kV/ μ s]
Mayr	Aire	50	580	1.237	335.036	2.075
Cassie	Aire	50	580	1.238	335.155	2.075
Schavmaker	Aire	50	580	0.841	311.301	0.314
Mayr	SF6	50	580	1.237	335.036	2.075
Cassie	SF6	50	580	1.237	335.036	2.075
Schavmaker	SF6	50	580	1.232	330.970	2.075

Tabla 4.14: Resultados de la simulación utilizando diferentes modelos de arco a 50 km de distancia de la falta

alcanzado que localiza la frecuencia característica cuando se produce la falta. Para cada distancia se ha calculado y representado el valor del Error Medio Estándar (SEM). Los valores del SEM son inferiores a 1 en la mayoría de los casos. En este caso, el SEM presenta valores superiores al modelo de comprobación pero, en cuanto a los valores de frecuencia, siguen siendo reducidos y, por tanto, incluso en esta red

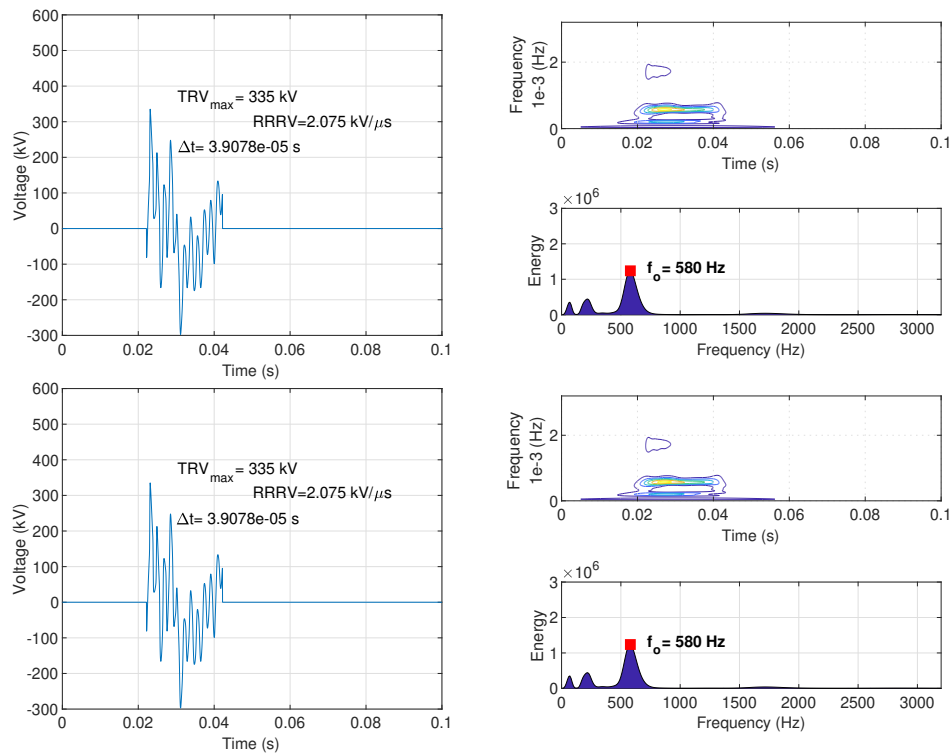


Figura 4.27: TRVs, contornos de la transformada ST y energía-frecuencia utilizando el modelo de Mayr para el aislamiento de Aire y SF6 para una distancia de falta de 50 km.

eléctrica, supone una precisión adecuada en la localización de la frecuencia.

4.2.5. Determinación de la frecuencia característica sobre una red de líneas de transmisión

Se presenta un caso adicional para verificar el rendimiento del planteamiento en redes de transmisión eléctricas. Para ello, se simula el método sobre modelo IEEE de 9 buses, utilizado por los investigadores para desarrollar y probar nuevas ideas y conceptos. El sistema consta de cargas, líneas de transmisión y generadores. Los modelos y parámetros de todos estos elementos se describen por completo en la documentación facilitada por IEEE.




Figura 4.28: Contornos de energía y error típico en la localización de frecuencias para cada distancia.

El esquema del modelo IEEE 9 se muestra en la Figura 4.29, donde se simulan distintas faltas eléctricas en la línea de transmisión entre los buses 7 y 8. En este caso se han realizado 120 simulaciones, 20 simulaciones para distancias de 25 a 150 km, cada 25 km, donde se ha cambiado el inicio de la falta, con una diferencia de 1 ms entre ellas.

La Figura 4.30 muestra, de izquierda a derecha, los resultados resumidos de tres distancias diferentes: 50, 100 y 150 km, respectivamente. De arriba a abajo, el TRV (a-b-c), los contornos de tiempo-frecuencia obtenidos a partir del análisis de ST (d-e-f) y la energía frente a la frecuencia de estos contornos (g-h-i). En estas últimas Figuras, los contornos se han trazado a partir de 250 Hz evitando la energía alrededor de la frecuencia fundamental y mejorando así la representación.

En las Figuras superiores se representan los valores de TRV y el intervalo de tiempo, y en las inferiores, la frecuencia característica del sistema. La frecuencia característica se reduce en función de la distancia.

Todas estas simulaciones, para cada distancia, se representan por su contorno

de energía ST en la Figura 4.31. Para cada contorno, el sistema de frecuencia se localiza por un máximo local, que están marcados en la figura junto con el valor SEM para cada distancia. En este caso, el SEM presenta valores superiores al modelo de comprobación pero, en cuanto a los valores de frecuencia, siguen siendo reducidos y, por tanto, incluso en esta red eléctrica, supone una precisión adecuada en la localización de la frecuencia.

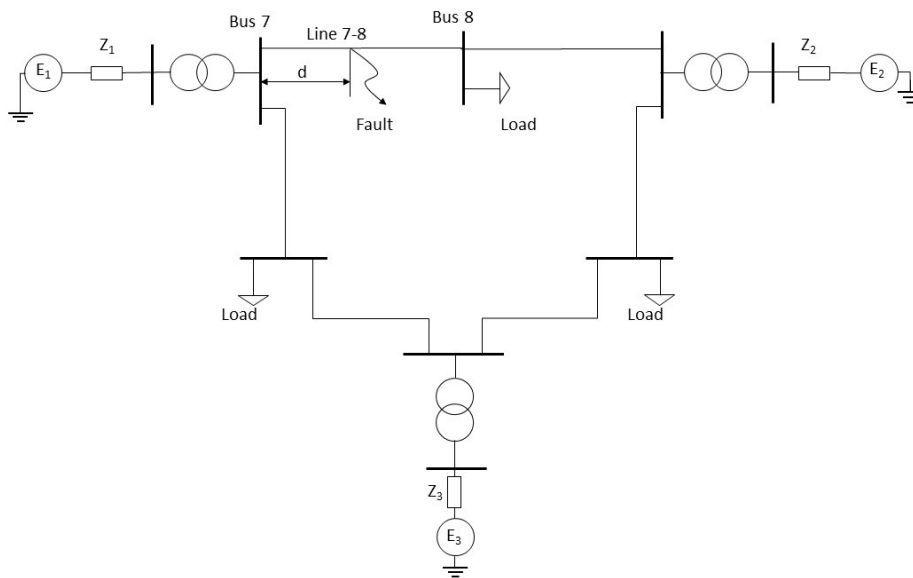


Figura 4.29: Red de transmisión IEEE 9.

4.3. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión

4.3.1. Metodología

La técnica de localización de faltas propuesta se presenta en la Figura 4.32. En primer lugar, se registran las señales TRV de las faltas producidas en las líneas

4.3. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión

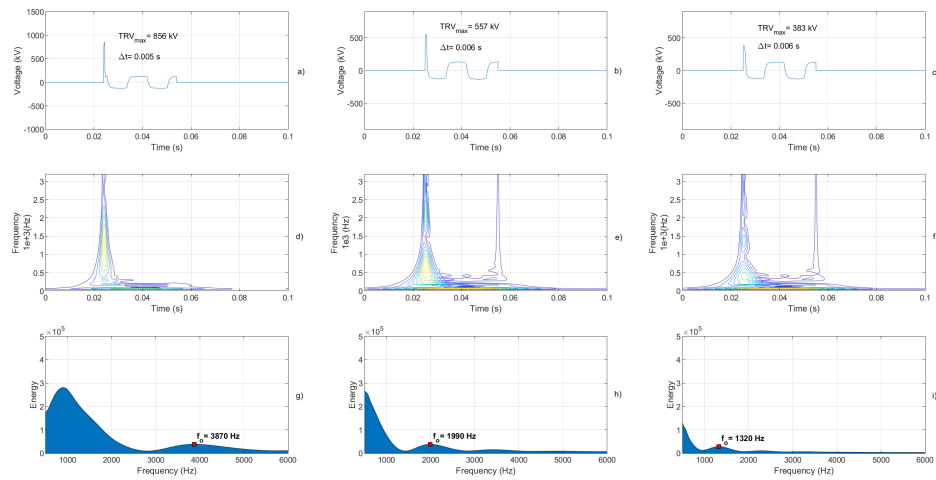


Figura 4.30: TRV, contornos de la transformada ST y sistema de energía-frecuencia para distancias de falta de 50, 100 y 150 km.




Figura 4.31: Contornos de energía y error estándar de frecuencia para cada distancia en el caso IEEE.

de transmisión. Para ello, se variarán los parámetros de entrada analizados en los estudios de sensibilidad como son el ángulo de incidencia, la resistencia de falta, la capacitancia equivalente y el tipo de falta y con ello, se obtiene un banco de señales necesario para generar el modelo de localización de falta. Cada señal obtenida tiene

una longitud de 30 ms muestreada a una frecuencia de 25.6 kHz.

Una vez obtenido el conjunto de señales de TRV se aplica el análisis de la transformada ST. La frecuencia de muestreo permite, según la condición de Nyquist, obtener información de la banda hasta 12,8 kHz. El resultado del análisis de la transformada ST es una matriz de elementos complejos cuyas columnas representan el espectro local en el tiempo y cuyas filas representan la frecuencia. A partir de esta matriz es posible calcular el contenido energético de la señal (E_{ST}) basándose en el teorema de Parseval. La frecuencia característica (f_0) se obtiene a partir de la función de energía calculada como aquella con mayor componente energético.

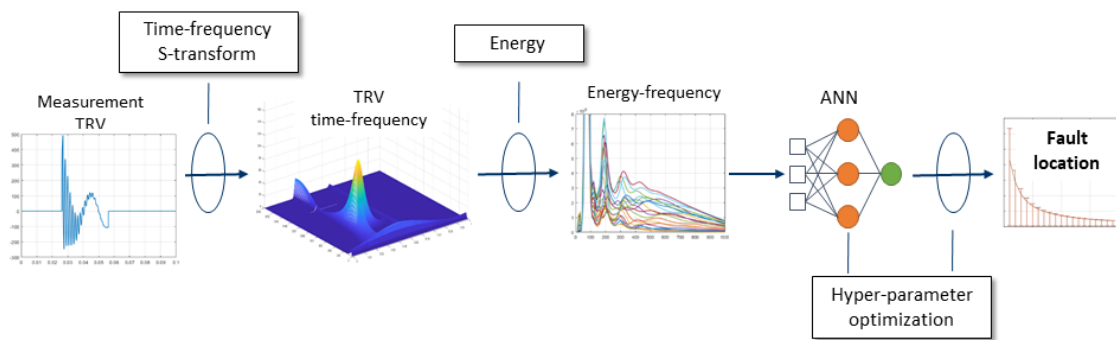


Figura 4.32: Sistema propuesto para localización de faltas.

Por último, estos seis parámetros obtenidos del análisis de la ST, frecuencias características de cada una de las fases (f_0^R, f_0^S, f_0^T) así como su contenido energético obtenido a partir del teorema de Parseval (E_0^R, E_0^S, E_0^T) se introducen en una ANN que estimará la distancia de la falta. La configuración de este algoritmo de localización de faltas requiere dividir el banco de señales creado en conjuntos de datos de entrenamiento y de prueba. El primero permitirá a la ANN aprender la relación no lineal que se presenta para cada tipo de falta, para lo que se utilizará el 90% del banco de señales. Tras este proceso, el segundo analizará la eficacia del método, midiendo el error entre la distancia real y la estimada de la falta. Los hiperparámetros de la ANN se seleccionan utilizando BO. Para el análisis de la

ST así como el entrenamiento y prueba de la técnica de la ANN se ha utilizado MATLAB^R 2020b.

El método de localización de faltas se calculó en un PC con una CPU Intel Core i5-7400 a 3,00 GHz y 12 GB de memoria RAM. El tiempo de ejecución una vez obtenido la ANN es de 958 ms. Este periodo de tiempo refleja el tiempo de preparación (54 ms), el cálculo ST (579 ms) y la localización ANN (323 ms).

4.3.2. Caso de estudio

Para el este caso de estudio se emplea la misma línea de transmisión usada para la determinación de la frecuencia característica.

Para ello, las variables de sensibilidad empleadas en el estudio son la resistencia de falta (R_{falta}); ángulo de incidencia (α), capacitancia equivalente del CB y de la subestación (C) y distancia de falta (L) que se presentan en la Tabla 4.9. La capacitancia equivalente de la subestación y del CB no puede variar considerablemente, dado que la paramenta de conexión y los auxiliares eléctricos se reemplazan por modelos similares en caso de avería. Sin embargo, en este estudio se considera una desviación del 10% de este parámetro y se abordarán sus consecuencias. De igual forma, se procede con la variación de potencia activa y reactiva.

Este modelo se configura para producir un banco de señales TRV lo suficientemente amplio para obtener información para el entrenamiento de la red neuronal. Debido a que el software PSCAD-EMTDC^R permite ejecutar modelos de parámetros dependientes, se utiliza la simulación por lotes. Para generar el banco de señales TRV, se realiza el siguiente proceso: en primer lugar, teniendo en cuenta el ángulo de inicio (α), se produce una falta en un momento preciso; a continuación, se abre el CB 0.01 segundos más tarde; se produce el arco y se mide y registra el TRV; transcurridos 0.03 segundos, se extingue la falta y se vuelve a cerrar el interruptor de potencia. Un esquema del proceso se muestra en la Figura 4.33. Aunque solo

se consideran los primeros 10 ms después del inicio de la falta para cerrar el CB, este intervalo es suficiente para obtener información precisa en el dominio de la frecuencia, dado que la respuesta del TRV ocurre en cuestión de microsegundos. Esta consideración acelera las simulaciones y reduce el costo computacional.

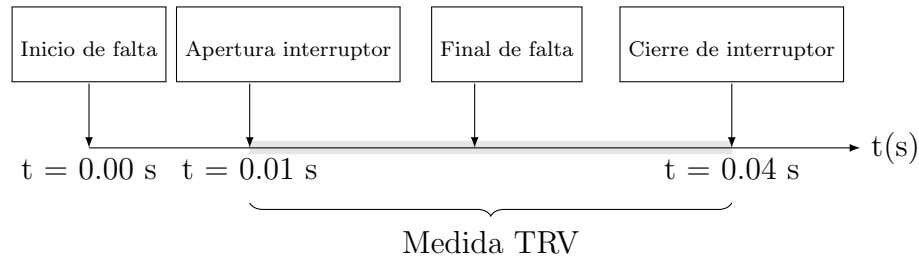


Figura 4.33: Esquema del proceso de medida.

La frecuencia característica y su valor de energía asociada varían significativamente entre los diferentes tipos de falta, debido a las distintas topologías presentes en cada caso. Dado este aspecto heterogéneo de los distintos tipos de faltas, se requiere una herramienta de predicción individualizada para cada tipo y su variante a tierra correspondiente. Por consiguiente, se ha generado un conjunto de datos de entrenamiento específico para cada ANN, que luego se somete a pruebas utilizando diferentes ángulos de incidencia y distancias de aplicación de las faltas, como resultado de un análisis de sensibilidad previo. Además, la BO identificará los valores óptimos de los hiperparámetros para cada ANN entrenada.

Los hiperparámetros óptimos de la ANN se determinan cuando la BO converge. Estos valores se detallan en la Tabla 4.15. Se encontró que la retropropagación resiliente es la estrategia de entrenamiento más eficaz para cualquier ANN específica, aunque el número de épocas y neuronas en la capa oculta varía. El error medio de entrenamiento de todas las Redes Neuronales es del 2.41 %, con una desviación estándar del 1.01 %.

Además, en la Tabla 4.15 se presentan el error medio y la desviación estándar de los casos de prueba de cada ANN entrenada. Se observa que el error medio máximo es inferior al 4 % en una línea de 200 km, con una desviación estándar relativa

4.3. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión

menor al 5%. Los errores de entrenamiento y prueba son similares, lo que indica un rendimiento óptimo del localizador de faltas basado en ANN.

Tipos de falta	HLN	EPH	ME(%)	STD(%)
A-G	64	64000	2.59	2.07
B-G	8	71000	1.46	0.91
C-G	32	162000	2.15	1.22
AB & AB-G	256	172000	3.09	2.67
AC & AC-G	4096	93000	2.28	2.15
BC & BC-G	4096	100000	3.91	4.29
ABC & ABC-G	1024	8000	1.46	1.41

Tabla 4.15: Configuración óptima de hiperparámetros y errores de prueba de la Red neuronal entrenada para cada tipo de falta y su versión puesta a tierra. HLN (Neuronas de la Capa Oculta), EPH (Épocas), ME (Error Medio), STD (Desviación Estándar).

4.3.3. Determinación de la localización de la falta en una red de transmisión

Se ha considerado como caso de estudio el sistema estándar IEEE 14, presentado en la Figura 4.34, conocido por la comunidad de investigadores y cuyos datos son publicados en artículos de referencia. Las simulaciones se realizaron en PSCAD-EMTDC^R utilizando el modelo de arco de Mayr para la implementación de TRV.

El sistema consta de cinco generadores síncronos, de los cuales tres son compensadores síncronos, tres transformadores, 12 cargas, 14 buses y 17 líneas de transmisión de potencia de diferente longitud (de 16 km a 133 km) y diferentes tipos de configuraciones de torres de líneas aéreas. Las referencias del sistema eran: tensión de 138 kV, potencia de 100 MVA y frecuencia de 50 Hz.

Para validar el método propuesto, se seleccionaron cuatro líneas con característi-

cas distintas, considerando los resultados del flujo de potencia del sistema de 14 nudos IEEE, con el fin de evaluar la precisión del localizador de faltas en diversas condiciones. La línea 1-2 se eligió por su mayor capacidad de transporte de potencia activa, la línea 7-8 por su mayor capacidad de transporte de potencia reactiva o mayor magnitud de tensión, la línea 3-4 por tener la menor magnitud de tensión, y la línea 6-13 por tener el mayor número de conexiones en el nodo emisor. La medición de TRV se llevó a cabo únicamente en uno de los nodos de cada línea (nodo 1, nodo 7, nodo 3 y nodo 6, respectivamente).

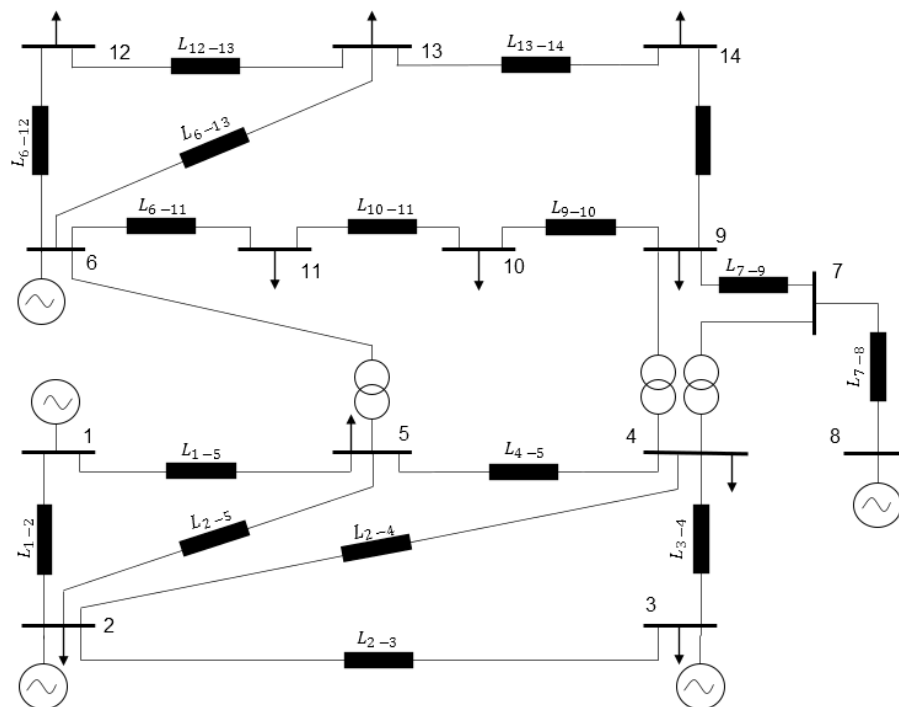


Figura 4.34: Esquema de la red de transmisión IEEE 14.

Para cada línea seleccionada, se evalúa el método propuesto al variar la distancia de la falta, el ángulo de incidencia y el tipo de falta, manteniendo constante la capacitancia equivalente y la resistencia de la falta según el análisis de sensibilidad realizado. A continuación, se aplica la transformada ST y se calcula la frecuencia característica junto con sus correspondientes valores de energía. La Figura 4.35 muestra tres ejemplos del espectro de energía del TRV para diferentes tipos de faltas. Estos espectros se agrupan según la distancia de la falta. Como se puede apreciar,

4.3. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión

la frecuencia característica del espectro de energía (destacada en rojo) disminuye conforme aumenta la distancia de la falta. Esta característica, junto con su respectivo valor de energía, será utilizada por la ANN para determinar la ubicación de la falta.


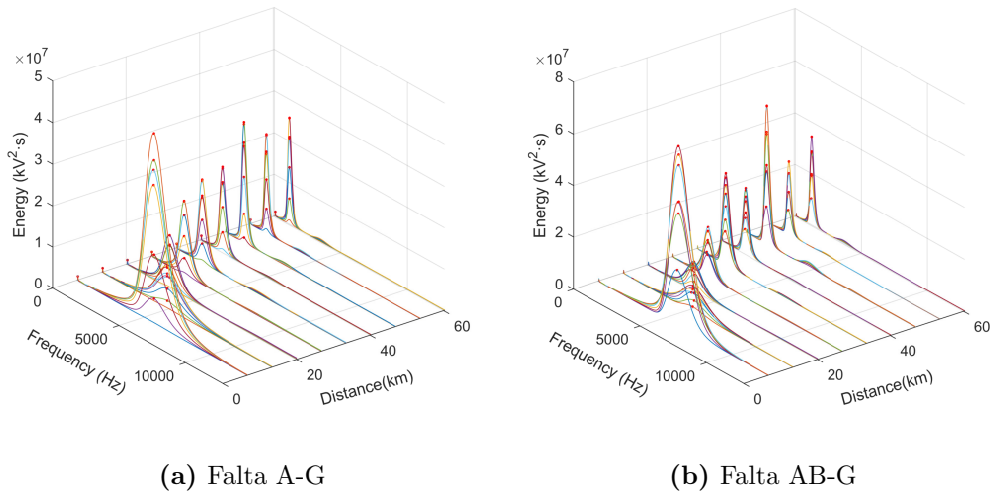


Figura 4.35: Espectro de frecuencia ST de la TRV con frecuencia característica (punto rojo) frente a la distancia de falta para diferentes valores del ángulo de incidencia en la línea 7-8.

Los datos se dividen en conjuntos de entrenamiento y prueba para cada línea, permitiendo así que la ANN aprenda utilizando el conjunto de entrenamiento. Después de este proceso, se evalúa el rendimiento del localizador de faltas utilizando los datos de prueba. Para optimizar los hiperparámetros de la ANN, se emplea

BO en cada una de las ANN definidas. Esta técnica busca optimizar el número de neuronas, las épocas y la función de entrenamiento para minimizar el error MSE de la salida. De manera similar al caso de estudio, se entrena y prueba una ANN para cada tipo de falta.

A continuación, se exponen y analizan los resultados de las pruebas de localización de faltas en las líneas seleccionadas de la red IEEE 14 para el caso de estudio, presentando los hiperparámetros óptimos obtenidos tras la convergencia del BO. La Tabla 4.16 detalla los resultados del BO para cada una de las ANN definidas. Se destaca que la función de entrenamiento óptima para todas ellas es la retropropagación resiliente.

Tipos de falta	Línea 1-2		Línea 3-4		Línea 7-8		Línea 6-13	
	HLN	EPH	HLN	EPH	HLN	EPH	HLN	EPH
A-G	128	9,000	128	10000	256	8000	128	2000
B-G	16	1000	16	5000	128	6000	16	9000
C-G	1028	1000	128	2000	16	6000	256	2000
AB & AB-G	16	8000	16	10000	256	10000	64	6000
AC & AC-G	16	6000	256	10000	256	9000	256	3000
BC & BC-G	32	10000	64	9000	128	10000	64	6000
ABC & ABC-G	16	3000	16	3000	16	10000	64	2000

Tabla 4.16: Configuración óptima de hiperparámetros para cada una de las Redes neuronales entrenadas. HLN (Neuronas capa oculta), EPH (Épocas).

La Figura 4.36a muestra la influencia de la longitud de la línea en el error obtenido por la metodología presentada. En cualquier caso, el error se mantiene por debajo de 4 km en el caso más desfavorable (línea 3-4). De hecho, los resultados indican que el error no se ve afectado por la longitud de la línea estudiada, ya que todos los resultados están contenidos en una banda de 2 km.

La Figura 4.36b representa la influencia de la variación del ángulo de incidencia en el error obtenido por la metodología propuesta. Aunque se obtienen algunas variaciones menores al aumentar el ángulo de incidencia, especialmente con $\alpha =$

4.3. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión

0°, el error permanece estable e inferior a 2.5 km. Analizando las Figuras 4.36b y 4.36a es posible afirmar que la metodología puede adaptarse en gran medida a las diferentes frecuencias características y energías impuestas por la variación del ángulo de incidencia con poco impacto en el resultado final.

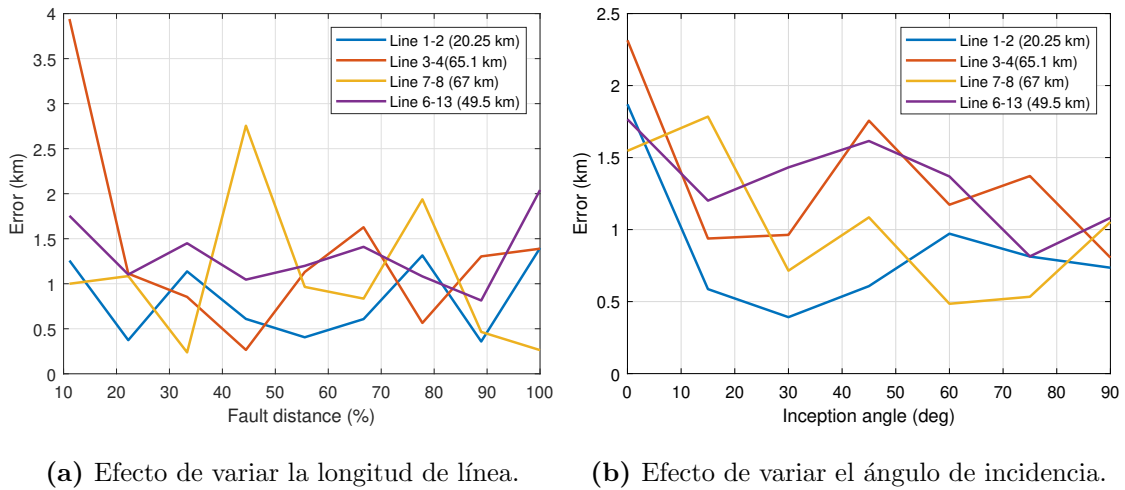


Figura 4.36: Efecto de los parámetros de la localización de falta en el sistema localizador.

Además, en la Figura 4.37 muestra tanto el error medio como la desviación estándar para cada tipo de falta considerado. En todos los casos, el error medio se sitúa por debajo del 6 %, con una desviación estándar inferior al 8 %. Sin embargo, es importante notar que los resultados pueden variar incluso para el mismo tipo de fase. Por ejemplo, los resultados para las faltas monofásicas muestran variaciones dependiendo de la fase. Esta variabilidad se atribuye a la metodología heurística empleada en la selección de hiperparámetros y a la aleatoriedad en la selección del conjunto de entrenamiento. A pesar de ello, se observa coherencia en los resultados entre las diferentes fases, lo que contribuye a mejorar la calidad global de los resultados.

Las líneas de transmisión 1-2, 3-4, 7-8 y 6-13 tienen longitudes de 20, 25 km, 65.1 km, 67 km y 49.5 km, respectivamente. Los errores medios obtenidos al testear cada una de las ANN para cada línea y tipo de falta muestran un error medio máximo del 6.02 % para la línea 1-2, 4.02 % para la línea 3-4, 3.24 % para la línea

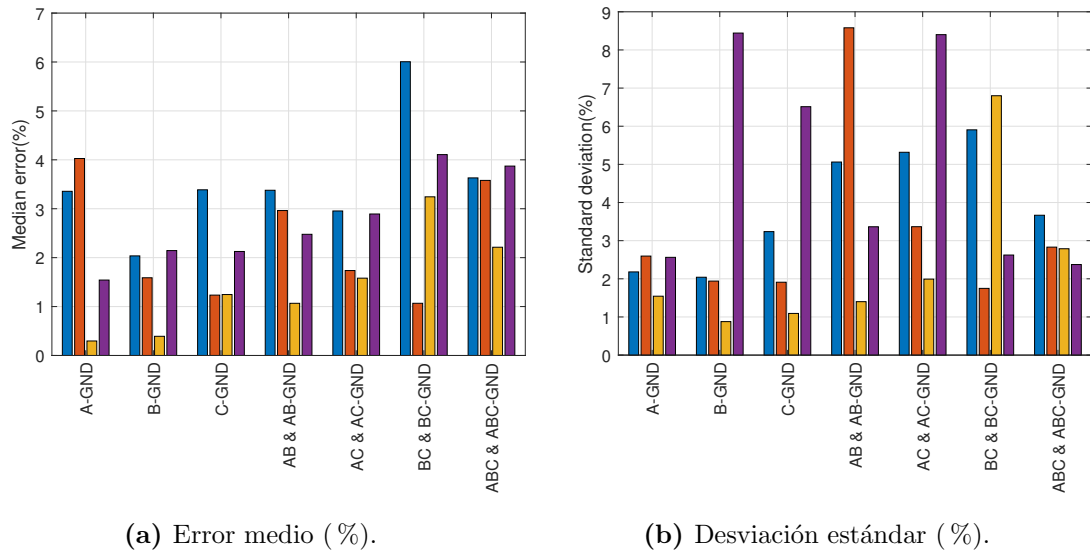


Figura 4.37: Diagrama de barras del error medio y la desviación típica de las líneas 1-2 (azul), 3-4 (naranja), 7-8 (amarillo) y 6-13 (morado).

7-8 y 4.10 % para la línea 6-13. La desviación típica arroja resultados máximos de 5.88 % para la línea 1-2, 8.57 % para la línea 3-4, 6.79 % para la línea 7-8 y 8.38 % para la línea 6-14. Es importante señalar que la desviación estándar puede ser mayor en algunos casos que la mediana del error, lo cual puede atribuirse a la naturaleza heurística de la metodología de la ANN y la adaptabilidad aumentada mediante la BO.

Sin embargo, a pesar de esta variabilidad, la precisión global de la metodología garantiza una respuesta rápida en caso de faltas en la línea, lo que mejora la seguridad de la red. Además, los valores máximos de error medio y desviación estándar durante el entrenamiento son 5.73 % y 2.77 % para la línea 1-2, 2.26 % y 0.86 % para la línea 3-4, 1.72 % y 0.51 % para la línea 7-8 y 3.67 % y 1.2 % para la línea 6-13, respectivamente, todos ellos valores en términos relativos. Esta similitud entre los errores de entrenamiento y prueba indica un rendimiento óptimo del localizador de faltas mediante ANN.

4.3.4. Comparación del algoritmo propuesto con otras técnicas basada en análisis frecuencial e inteligencia artificial

El estudio inicial consideró un total de 204820 casos. Sin embargo, tras el análisis de sensibilidad realizado sobre este primer caso de estudio, se determinó que era posible reducir este número a 29260 casos, empleando un enfoque más compacto sobre las redes de transmisión IEEE-14. Este proceso fue clave para evitar problemas de sobreajuste en la técnica de ANN empleada, lo que garantiza que el modelo no se ajuste demasiado a los datos específicos, permitiendo una mejor generalización. Un aspecto innovador del enfoque propuesto radica en el uso del TRV como parámetro de medida, una diferencia significativa con respecto a gran parte de la literatura existente, que generalmente toma las mediciones de corriente y tensión en el nodo de envío. Al utilizar el TRV, se pretende mejorar la sensibilidad del sistema en diferentes condiciones operacionales, proporcionando así un análisis más preciso y confiable.

Además, mientras que muchos estudios previos se centran en escenarios de falta simplificados, comúnmente abordando solo un extremo de las líneas de transmisión, este tesis propone abarcar una mayor complejidad al considerar una amplia variedad de líneas y trabajar bajo diferentes condiciones de operación. Este enfoque multivariable no solo expande la aplicabilidad del método en entornos reales, sino que también refuerza su capacidad para manejar situaciones más complejas [17].

El método propuesto para la localización de faltas se compara, además, con varias técnicas del estado del arte, poniendo de relieve aspectos clave como el algoritmo implementado, los modelos de referencia utilizados para la validación y los distintos tipos de faltas que se han contemplado. También se toma en cuenta si estas técnicas incluyen o no un análisis de sensibilidad respecto a los parámetros de entrada. En cada comparación, se examinan detalles importantes como el número de casos de

prueba considerados y el porcentaje de error obtenido, siendo todas las evaluaciones resumidas en la Tabla 4.17. A continuación, se presenta un análisis detallado de esta comparativa resaltando tanto las fortalezas como las debilidades del algoritmo propuesto.

4.3.4.1. Beneficios del algoritmo propuesto

- **Resolución superior en frecuencias.** La ST utilizada en el algoritmo propuesto proporciona una resolución superior en comparación con otras técnicas como la WT o la DFT. Esta capacidad es fundamental para captar transitorios en sistemas eléctricos, lo que permite una localización más precisa de faltas.

En el estudio realizado por [56], la aplicación de WT para clasificar faltas en un sistema de transmisión logró errores mínimos de hasta -0.0007% . Sin embargo, el enfoque enfrenta limitaciones en la adaptabilidad, ya que la WT, al descomponer la señal en bandas de frecuencia fijas, no puede ajustar la resolución de la frecuencia característica según las características del transitorio, limitando su capacidad en situaciones donde los eventos transitorios son breves y de alta frecuencia.

De igual forma, el método [57] que combina la WT con ANN y la transformada de Clarke, consigue un error absoluto de 0.119% , siendo muy preciso en escenarios controlados. No obstante, la técnica presenta limitaciones en términos de resolución de frecuencias debido a la WT como se indica anteriormente.

- **Adaptabilidad a variaciones en los parámetros del sistema.** La capacidad del algoritmo basado en ANN para adaptarse a variaciones en los parámetros del sistema, como la impedancia de la red, es notable. Esta capacidad de generalización es crucial en redes eléctricas complejas, donde las condiciones operativas pueden variar significativamente.

El método [58] combina la DFT y ANN y es efectivo en sistemas controlados, pero presenta limitaciones en entornos dinámicos debido a la rigidez inherente de la DFT, que solo proporciona un análisis global de las frecuencias y no captura adecuadamente los transitorios rápidos que ocurren durante faltas eléctricas. Aunque la ANN puede generalizar, su capacidad de adaptación está restringida por la falta de información temporal precisa de la DFT, lo que dificulta su aplicación en redes con condiciones operativas cambiantes.

Por otro lado, el método [59] utiliza mediciones híbridas dispersas de voltaje y corriente, presentando una precisión alta, con un error máximo de 0.7%. Sin embargo, este enfoque se enfoca principalmente en la resistencia de falta como factor de variación, lo que limita su flexibilidad ante las fluctuaciones de otros parámetros del sistema eléctrico, como la impedancia de las líneas o las cargas no constantes. Además, el análisis de sensibilidad es más limitado, ya que el método solo contempla 25 casos de prueba, lo que puede afectar su habilidad para generalizar y adaptarse en condiciones dinámicas o más complejas.

- **Exhaustividad en el análisis de sensibilidad.** El análisis de sensibilidad exhaustivo realizado en el enfoque propuesto permite optimizar mejor los hiperparámetros del modelo, garantizando que sea robusto frente a un rango amplio de condiciones operativas.

El algoritmo propuesta realiza un análisis exhaustivo de sensibilidad, entrenándose en más de 200000 simulaciones iniciales para garantizar un rendimiento robusto frente a diversas condiciones operacionales. Por contraste, en el método [60] solo hicieron uso de aproximadamente 3520 casos de prueba, lo que podría resultar en una menor efectividad al cubrir diferentes escenarios operativos en comparación con el enfoque propuesto, que abarca un mayor rango de variaciones.

- **Uso innovador del TRV como parámetro principal de localización.** La implementación del TRV es una innovación clave en el algoritmo propuesto.

Este método permite obtener una mayor precisión en la captura de los transitorios, en comparación con enfoques más tradicionales que se basan únicamente en las mediciones de corriente y voltaje en el nodo de envío.

El método [61] utiliza la Transformada Híbrida (HS) combinada con ANN para la detección de faltas, logrando un error máximo del 1.89% , lo que indica un enfoque bastante preciso. Sin embargo, una de las principales limitaciones de esta combinación radica en su capacidad para identificar con precisión transitorios rápidos. La HS se basa en una mezcla de metodologías de descomposición que, aunque eficaces en condiciones generales, pueden ofrecer una resolución temporal limitada cuando se trata de capturar perturbaciones eléctricas que ocurren en cortos intervalos de tiempo como ocurre con el TRV.

4.3.4.2. Desventajas del algoritmo propuesto

- **Alta complejidad computacional.** La utilización de ANN junto con la ST y el análisis de sensibilidad incrementa considerablemente la complejidad computacional del algoritmo.

La investigación de [56] logra una menor demanda computacional con su enfoque basado en WT y ANN, lo que permite una implementación más rápida. Sin embargo, esto se traduce en una menor precisión en escenarios operativos variados, lo que limita su utilidad en condiciones cambiantes.

- **Dependencia de datos extensos para entrenamiento.** El algoritmo basado en ANN y ST requiere grandes conjuntos de datos para garantizar un rendimiento óptimo. Si no se cuenta con datos representativos y de alta calidad, el rendimiento del algoritmo puede degradarse considerablemente.

En el método [58], lograron una menor tasa de error con su enfoque de DFT y ANN, pero utilizando una cantidad significativamente menor de datos. Aunque esto reduce la necesidad de procesamiento, también reduce la capacidad del

4.3. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión

método para adaptarse a una gran variedad de escenarios o condiciones del sistema eléctrico.

- Limitaciones en la implementación en tiempo real.** Los algoritmos basados en ST y ANN requieren un procesamiento intensivo que puede dificultar su implementación en tiempo real, especialmente en sistemas que requieren respuestas ultrarrápidas. Aunque los métodos más tradicionales, como los discutidos en otros trabajos, usan enfoques simplificados como la DFT o WT, su capacidad para ofrecer un rendimiento superior en tiempo real es comprometedor, ya que son menos precisos en la detección y localización de faltas complejas o transitorios rápidos.

Autor	Algoritmo	Modelo base	Modelo de validación	Tipo de falta	Análisis de sensibilidad	Test de uso	Error
Yadav y Swetapadma [56]	Combinación de DWT y ANN	-	4 Bus, 3 TL, 2 gen	LG, LL, LLL	Sí	10,000	Min. error -0.0007 % Max. error 0.6665 %
Abdollahi et al. [58]	Combinación de DFT y ANN	2 Bus, 1 TL, 2 gen	-	LG, LL, LLL	Solo resistencia de falta	242	Min. error 0.01 % Max. error 4.73 %
Samantaray et al [61]	Combinación de transformada HS y ANN	2 Bus, 1 TL, 2 gen	-	LG, LLG, LL, LLL, LLLG	Sí	3,000	Min. error 0.89 % Max. error 1.89 %
Asuhaimi et al [57]	Combinación de DWT con BPNN y transformada de Clarke	2 Bus, 1 TL, 2 gen	-	LG, LLG, LL, LLL, LLLG	Sí	-	Error absoluto 0.119 %
Khan et al [59]	Mediciones híbridas dispersas de voltaje y corriente	4 Bus, 3 TL, 2 gen	IEEE 14	LG, LLG, LL, LLL, LLLG	Solo resistencia de falta	25	Max. 0.7 %
Valsan et al. [60]	DWT	-	4 Bus, 4 TL, 4 gen	LG, LLG, LL, LLL	Sí	3,520	Error medio 0.217 % Max. error 3.6 %
	Método propuesto en TRV	2 Bus, 1 TL, 2 gen	IEEE 14	LG, LLG, LL, LLL, LLLG	Sí	29,260	Max. error 5,73 %

Tabla 4.17: Comparación de las técnicas existentes con la técnica propuesta basada en ANN para la localización de faltas.

Capítulo 5

Conclusiones y líneas futuras de investigación

5.1. Introducción

La presente tesis se ha centrado en la innovadora combinación de la transformada de Stockwell como técnica de transformada tiempo-frecuencia, junto con el poder de las redes neuronales, para abordar de manera precisa la localización de faltas en redes eléctricas. En un contexto donde la confiabilidad y eficiencia de los sistemas eléctricos son fundamentales, esta metodología se presenta como una contribución significativa para mejorar la gestión y la respuesta ante este tipo de eventos.

5.2. Resumen

En una era en la que la sociedad moderna depende de manera crítica de un suministro eléctrico ininterrumpido y seguro, la eficiencia y fiabilidad de la infraestructura eléctrica se erigen como pilares fundamentales para el desarrollo y funcionamiento de diversas actividades cotidianas. Sin embargo, la realidad nos muestra que los fallos eléctricos pueden representar una amenaza constante, con el potencial de generar cortes de energía, daños a equipos y, en situaciones extremas, poner en riesgo la seguridad de las personas y las instalaciones.

En este contexto, la tesis doctoral propone abordar una de las cuestiones más críticas en la gestión de sistemas eléctricos: la localización de faltas en las líneas de transmisión. Reconociendo la importancia de un enfoque integral, se presenta un modelo matemático que utiliza técnicas avanzadas de procesamiento de señales para estimar con precisión la ubicación de puntos de falta en la red eléctrica a partir de los transitorios de tensión producidos en los interruptores de potencia. La innovación central radica en la aplicación de la transformada tiempo-frecuencia de Stockwell, una herramienta que permite analizar de manera detallada las señales eléctricas y extraer información valiosa para identificar patrones, tendencias y que combinada con técnicas de inteligencia artificial tiene el poder de determinar la ubicación exacta de un falta.

En el primer bloque de la tesis se aborda la importancia del interruptor de potencia en sistemas eléctricos. Se definen tipos de interruptores, como los de aire, aceite, vacío y SF₆, destacando sus características específicas para diferentes entornos y niveles de tensión. Se mencionan estándares internacionales que garantizan la calidad y seguridad y se detallan las características esenciales, como corriente y tensión nominal, corriente de cortocircuito, capacidad de interrupción y cierre. Además, se explora el fenómeno de Tensión Transitoria de Recuperación (TRV), del inglés Transient Recovery Voltage y sus factores de influencia, así como las técnicas de extinción del arco.

El segundo bloque de la tesis se dedica a la formulación de un enfoque matemático para determinar la frecuencia característica de una línea de transmisión. Este enfoque, basado en la transformada de Stockwell, demuestra una notable precisión al identificar la frecuencia característica del sistema, incluso en condiciones desafiantes donde otros parámetros, como el instante de inicio de la falta, los ángulos de incidencia, la resistencia de la falta, el modelo de arco o el aislamiento del interruptor de potencia, pueden variar.

En el tercer bloque, la tesis propone un sistema basado en redes neuronales

que utiliza las variables de frecuencia y energía por fase obtenidas a través de la transformada de Stockwell. Este sistema presenta una solución eficaz para la localización de faltas eléctricas al establecer relaciones significativas entre estas variables y la distancia a la que se produce una falta en la línea de transmisión. Este enfoque permite identificar la ubicación de faltas de manera rápida y precisa, contribuyendo así a una respuesta más eficiente ante eventos adversos en la red eléctrica.

Para validar la eficacia del modelo propuesto, la tesis propone una fase de experimentación en la que se aplican distintos casos de uso en redes eléctricas reales. Se llevan a cabo mediciones de señales eléctricas en diversos puntos de la red y se simulan faltas eléctricas para evaluar la precisión del sistema desarrollado. La comparación de los resultados con métodos tradicionales de localización de faltas eléctricas permite establecer la eficacia y la contribución significativa de este enfoque innovador en la mejora de la confiabilidad y eficiencia del suministro eléctrico.

5.3. Conclusiones experimentales

A través de una fase de experimentación meticulosa, este trabajo ha validado la eficacia y relevancia del modelo propuesto al demostrar su capacidad para mejorar tanto la confiabilidad como la eficiencia del suministro eléctrico en entornos reales, a través de la precisa localización de faltas eléctricas.

Inicialmente, se estableció un método robusto para identificar la frecuencia característica del sistema, manteniendo su efectividad incluso ante la variabilidad de ciertos parámetros eléctricos. Este enfoque fue sometido a rigurosos análisis de sensibilidad, evidenciando su robustez incluso en redes de transmisión reales.

Una vez confirmada la eficacia del primer método, se procedió al diseño y prueba de un algoritmo innovador basado en redes neuronales para determinar la distancia a la que ocurre una falta, utilizando la frecuencia característica del sistema como

parámetro clave. Este método fue validado en redes de transmisión reales, obteniendo niveles de precisión que se compararon favorablemente con otros métodos del estado del arte.

Los resultados obtenidos destacan la efectividad y el potencial de las técnicas propuestas para mejorar la gestión y operación de redes eléctricas, abriendo nuevas posibilidades para la detección y localización precisa de faltas.

5.3.1. Estudio de la frecuencia característica sobre una línea de transmisión

La metodología para estudiar la frecuencia característica del sistema proporciona un procedimiento automatizado simple que puede aplicarse a cualquier red de transmisión. Este método nos permite determinar fácilmente esta frecuencia utilizando transformadas tiempo-frecuencia sobre la señal TRV.

La propuesta se basa en el interruptor de circuito, que desempeña un papel fundamental en la interrupción del flujo de corriente en el sistema eléctrico. Durante una interrupción, se forma un arco entre sus polos, generando una corriente que fluye en un nuevo medio gaseoso ionizado hasta que se alcanza el instante de cruce por cero, momento en el que se produce el TRV, una señal con componentes de alta frecuencia. El TRV puede ser exponencial y oscilatorio, dependiendo de la respuesta del sistema eléctrico. Estos parámetros dependen directamente de la impedancia de la línea. Por ello, el método propuesto reside en el análisis del TRV en el dominio de la frecuencia a través de la transformada de Stockwell con el objetivo de extraer información valiosa sobre la frecuencia característica del sistema.

Para verificar la robustez del método, se utilizaron dos modelos distintos con este fin: uno basado en una línea de transmisión real y otro en el modelo IEEE 9, un estándar comúnmente utilizado en la investigación en este campo.

En primer lugar, se realizaron simulaciones detalladas en la línea de transmisión

real, abarcando diversas condiciones de falta, incluyendo diferentes distancias, ángulos de incidencia y resistencias de falta. El objetivo fue evaluar la capacidad del método para adaptarse a las variaciones operativas y geométricas inherentes a las redes eléctricas.

Las simulaciones cubrieron una gama de distancias de falta, desde 25 km hasta 225 km, revelando que la frecuencia del sistema experimenta cambios más significativos para distancias de falta más cercanas. Este hallazgo sugiere una relación entre la frecuencia característica del sistema y la proximidad a la ubicación de la falta.

Además, se variaron los ángulos de apertura del interruptor de circuito, desde 0° hasta 90° , observando que el método propuesto determina la frecuencia del sistema de manera consistente e independiente del ángulo de operación del interruptor. Esto subraya la fiabilidad del enfoque ante diferentes condiciones de operación.

Asimismo, se simuló una falta a tierra a 125 km de distancia con resistencias variables, desde 0.001Ω hasta 100Ω . Los resultados demostraron que el método propuesto es capaz de determinar la frecuencia del sistema de manera robusta, independientemente de la resistencia de la falta. Esta capacidad es esencial para evaluar la respuesta del sistema ante diversos tipos de faltas y condiciones de carga.

Se compararon los resultados utilizando diferentes modelos de arco y tecnologías de aislamiento, como el modelo de Mayr y el modelo de Cassie, junto con aisladores de aire y SF₆. Aunque se observaron diferencias significativas en el valor pico del TRV y en la energía disipada, se destacó la capacidad del método para determinar con precisión la frecuencia característica del sistema, lo que indica su utilidad en la evaluación de diferentes configuraciones de equipos de conmutación.

Además, se exploró la variación de la potencia activa y reactiva en un 10 % sobre la línea de transmisión, observando mínimos cambios en la frecuencia característica del sistema. Esto asegura que la precisión del enfoque propuesto sea independiente al flujo de potencia de la red.

Finalmente, se realizaron 180 simulaciones aleatorias adicionales para diferentes distancias y ángulos de inicio de falta, demostrando que el método propuesto proporciona una precisión adecuada en la localización de la frecuencia del sistema, con valores de métrica de error generalmente inferiores a 1.

Además, se repitió el análisis utilizando el modelo IEEE 9, donde se observaron errores medios ligeramente más altos en comparación con el modelo de verificación inicial. Sin embargo, los valores de frecuencia siguieron siendo precisos, lo que confirma la utilidad del enfoque propuesto incluso en redes eléctricas más complejas.

5.3.2. Localización de una falta en base a la frecuencia característica sobre una red de líneas de transmisión

La metodología propuesta para la localización de faltas se detalla en el capítulo tercero de la tesis y aplicado sobre redes de transmisión en el capítulo cuarto. La propuesta es un enfoque integral que utiliza señales TRV registradas durante la ocurrencia de falta en líneas de transmisión con el objetivo de identificar la distancia a la que se producen a partir del análisis de la transformada de Stockwell de estas señales.

El análisis de la transformada de Stockwell produce una matriz de elementos complejos, donde las columnas representan el espectro local en el tiempo y las filas representan la frecuencia. Utilizando el teorema de Parseval, se calcula el contenido energético (E_{ST}) de cada señal, así como la frecuencia característica (f_0), definida como aquella con la mayor componente energética. Estos parámetros proporcionan información crucial para identificar y caracterizar la falta.

La etapa final del proceso implica la introducción de los parámetros obtenidos del análisis de la transformada de stockwell en una red neuronal artificial diseñada para estimar la distancia de la falta. Esta red neuronal se entrena y prueba utilizando conjuntos de datos separados, con el 90 % de las señales utilizadas para

entrenamiento y el restante 10% para pruebas. Se utilizan técnicas avanzadas de optimización, como la optimización bayesiana, para seleccionar los hiperparámetros óptimos de la red neuronal.

Se utilizaron dos modelos distintos con este fin: uno basado en una línea de transmisión real y otro en el modelo IEEE 14, un estándar comúnmente utilizado en la investigación en este campo.

En la línea de transmisión real, el análisis reveló una variabilidad significativa en la frecuencia característica y los valores de energía asociados entre diferentes tipos de faltas. Esta variabilidad se deriva de las diversas topologías asociadas con cada tipo de falta. Debido a la naturaleza distinta de cada tipo de falta, es imperativo desarrollar predictores dedicados para cada tipo, incluidas las de tierra. Para entrenar y probar las Redes Neuronales Artificiales, se crearon conjuntos de datos induciendo faltas con ángulos de inicio y distancias de falta variables para cada tipo de falta, guiados por un análisis de sensibilidad. Los hiperparámetros óptimos para cada red neuronal se determinaron mediante Optimización Bayesiana, lo que resultó en un mejor rendimiento durante el entrenamiento. La retropropagación resiliente se determinó como la función de entrenamiento más efectiva para las redes neuronales en todos los tipos de faltas. La mediana del error de todas las redes neuronales entrenadas se encontró en 2.41%, con una desviación estándar de 1.01%. Es importante destacar que el error medio máximo observado fue inferior al 4% para una línea de 200 km, con una desviación estándar de menos del 5%. La similitud entre los errores de entrenamiento y pruebas indica el rendimiento óptimo del localizador de faltas en diferentes escenarios.

En el caso de la red de transmisión IEEE 14, se observó que el error se mantiene por debajo de 4 km en el peor de los casos y que no queda afectado por la longitud de la línea estudiada, ya que todos los resultados están contenidos en una banda de 2 km. Además, al variar el ángulo de inicio, el error permanece estable y por debajo de 2.5 km, con algunas variaciones menores.

Se presentaron tanto el error medio como la desviación estándar del error para cada tipo de falta considerada. En todos los casos, el error medio se encuentra por debajo del 6% y la desviación estándar por debajo del 8%. Aunque los resultados pueden variar entre el mismo tipo de falta debido a la metodología utilizada para la selección de hiperparámetros y la selección aleatoria del conjunto de entrenamiento, se determinó que la función de entrenamiento óptima para todas las redes neuronales entrenadas es la retropropagación resiliente. Sin embargo, los resultados son consistentes entre las fases, lo que mejora los resultados generales al procesar los parámetros de entrada de manera más especializada.

Además, se comparó el esquema propuesto para la localización de faltas con algunas de las técnicas existentes, resaltando que proporciona la colección más extensa de casos de prueba de los revisados y utiliza el TRV como parámetro de medición. Este enfoque propuesto presenta una visión holística al considerar una amplia variedad de líneas y trabajar bajo diferentes condiciones.

5.4. Futuras líneas de investigación

Los resultados obtenidos en la tesis no buscan cerrar ninguna línea de trabajo, sino más bien abrir nuevas perspectivas en la comprensión del problema. Deben ser vistos como un punto de partida que fomente la exploración de futuros desarrollos y avances en el campo de la clasificación de la localización de faltas mediante transformadas tiempo-frecuencia e inteligencia artificial. A partir de los descubrimientos realizados en la tesis, surgen diversas direcciones prometedoras para investigaciones futuras:

1. La presente tesis se ha desarrollado para la localización de faltas eléctricas basado en en la transformada de Stockwell y redes neuronales, con unos mejores resultados en comparación con otros sistemas, que además se comporta de forma robusta y con capacidad de localizar las faltas de forma precisa sobre

redes eléctricas reales y complejas. Se hace necesario aplicar este enfoque de forma práctica e implementar el sistema de forma real. Una primera aproximación podría ser implementar el localizador de faltas eléctricas sobre gemelos digitales para que pueda trabajar con medidas eléctricas en tiempo real.

2. Añadir a la localización de faltas eléctricas la identificación del tipo de falta eléctrica asociada a la misma. Esto permitiría dar más precisión al tipo de problema asociado a la hora de localizar las faltas en los trabajos de operación y mantenimiento. Además, podría implementarse una estructura modular que en base a esta identificación pudieran mejorarse los resultados de localización
3. Detectar y localizar faltas de alta impedancia. Estas son particularmente difíciles de detectar debido a que su corriente asociada es baja y pueden persistir en la red sin que produzcan un salto de las protecciones.
4. Combinar la transformada de Stockwell con otras técnicas de transformadas tiempo-frecuencia que maximice la precisión en la caracterización de las señales y energías asociadas. Asimismo, la combinación de la transformada de Stockwell con otras técnicas de inteligencia artificial, como árboles de decisión u otras variantes de redes neuronales para el diseño del sistema en localización de faltas. Todas estas técnicas deben tener como finalidad mejorar la precisión en la localización o que puedan reducir el coste y tiempo computacional obtenido en el sistema presentado en esta tesis.

Referencias

- [1] P. Kundur, «Power System Stability and Control,» *IEEE Transactions on Power Systems*, vol. 38, n.º 1, págs. 1-10, 2023. DOI: 10.1109/TPWRS.2022.3210067.
- [2] G. de España, «Plan Nacional Integrado de Energía y Clima 2021-2030,» Ministerio para la Transición Ecológica y el Reto Demográfico, inf. téc., 2021. dirección: <https://www.miteco.gob.es/es/ministerio/temas/energia/PNIEC.aspx>.
- [3] A. Zidan, M. Khairalla, A. M. Abdrabou et al., «Fault Detection, Isolation, and Service Restoration in Distribution Systems: State-of-the-Art and Future Trends,» *IEEE Transactions on Smart Grid*, vol. 8, n.º 5, págs. 2170-2185, 2017. DOI: 10.1109/TSG.2016.2517620.
- [4] A. E. del Medio Ambiente, «Informe sobre Energías Renovables en Europa,» 2021. dirección: <https://www.eea.europa.eu/publications/european-environment-agency-report-2021>.
- [5] ACER, «Informe de la Agencia de Cooperación de los Reguladores de la Energía 2021,» 2021. dirección: https://www.acer.europa.eu/official_documents/acer_annual_report_2021.pdf.
- [6] U. P. de Madrid, «Estudio sobre la Complejidad de las Redes Eléctricas,» 2021. dirección: <https://www.upm.es/estudios/estudio-complejidad-redes-2021.pdf>.
- [7] I. de Estudios Energéticos, «Informe sobre el Costo de las Interrupciones Eléctricas,» 2022. dirección: <https://www.iee.org/informe-costos-interrupciones-2022.pdf>.

- [8] D. Gao et al., «Evaluating Power System Interruptions Using TIEPI and NIEPI,» *IEEE Access*, vol. 11, págs. 23 456-23 467, 2023. DOI: 10 . 1109 / ACCESS . 2023 . 3270452.
- [9] J. Machowski, «Power System Dynamics and Stability: A Review,» *Journal of Modern Power Systems and Clean Energy*, vol. 10, n.º 3, págs. 675-686, 2022. DOI: 10 . 35833 / MPCE . 2022 . 000032.
- [10] J. Wang, «Measurement Resolution in Fault Location: Challenges and Solutions,» *IEEE Transactions on Instrumentation and Measurement*, vol. 71, págs. 1-9, 2022.
- [11] M. Liu, «Electromagnetic Interference in Power Systems: Mitigation Techniques,» *Electric Power Systems Research*, vol. 198, pág. 107 286, 2022.
- [12] W. Chen, «Accessibility Challenges in Fault Detection in Medium Voltage Systems,» *IEEE Access*, vol. 11, págs. 30 957-30 967, 2023.
- [13] Z. Guo et al., «Complexity and Fault Location in Power Networks,» *International Journal of Electrical Power & Energy Systems*, vol. 142, pág. 108 192, 2023.
- [14] H. Tang, «Economic Aspects of Specialized Fault Detection Equipment,» *Journal of Modern Power Systems and Clean Energy*, vol. 11, n.º 1, págs. 123-134, 2023.
- [15] A. Smith, «Early Methods of Electrical Fault Localization,» *Journal of Electrical Engineering*, vol. 4, n.º 2, págs. 78-85, 1898.
- [16] B. Jones, «Manual Search Techniques for Fault Localization in Early Power Systems,» *Transactions on Electrical Engineering*, vol. 10, n.º 3, págs. 201-210, 1905.
- [17] S. Didehvar y R. Mohammadi Chabanloo, «Accurate estimating remote end equivalent impedance for adaptive one-ended fault location,» *Electric Power Systems Research*, vol. 170, págs. 194-204, 2019, ISSN: 0378-7796. DOI: 10 . 1016 / j . epsr . 2019 . 01 . 011.

-
- [18] J. Zhao, H. Xie e Y. Zhou, «Single-ended traveling wave-based fault location method using wavelet packet decomposition,» *Electric Power Systems Research*, vol. 174, pág. 105 877, 2019. DOI: 10.1016/j.epsr.2019.105877.
- [19] S. G. Di Santo y C. E. de Moraes Pereira, «Fault location method applied to transmission lines of general configuration,» *International Journal of Electrical Power & Energy Systems*, vol. 69, págs. 287-294, 2015, ISSN: 0142-0615. DOI: 10.1016/j.ijepes.2015.01.014.
- [20] A. Javadian y M. S. Mirhosseini, «Accurate fault location algorithm for two-terminal transmission lines based on phasor measurement units,» *IEEE Transactions on Power Delivery*, vol. 34, n.º 4, págs. 1413-1421, 2019. DOI: 10.1109/TPWRD.2019.2902965.
- [21] H. A. Jimenez, D. Guillen, R. Tapia-Olvera, G. Escobar y F. Beltran-Carbajal, «An improved algorithm for fault detection and location in multi-terminal transmission lines based on wavelet correlation modes,» *Electric Power Systems Research*, vol. 192, pág. 106 953, 2021, ISSN: 0378-7796. DOI: 10.1016/j.epsr.2020.106953.
- [22] J. Carvalho, A. da Silva y F. Bezerra, «Fault location in power distribution systems using the traveling wave method,» *Electric Power Systems Research*, vol. 183, pág. 106 278, 2020. DOI: 10.1016/j.epsr.2020.106278.
- [23] D. C. M. da Silva M. Oleskovicz, «A hybrid fault locator for three-terminal lines based on wavelet transforms,» *Electric Power Systems Research*, vol. 78, n.º 11, págs. 1980-1988, 2008. DOI: 10.1016/j.epsr.2008.03.027.
- [24] D. Gazzana, G. Ferreira, A. Bretas et al., «An integrated technique for fault location and section identification in distribution systems,» *Electric Power Systems Research*, vol. 115, págs. 65-73, oct. de 2014. DOI: 10.1016/J.EPSR.2014.02.002.

- [25] A. Borghetti, M. Bosetti, M. Di Silvestro, C. A. Nucci y M. Paolone, «Continuous-wavelet transform for fault location in distribution power networks: Definition of mother wavelets inferred from fault originated transients,» *IEEE Transactions on Power Systems*, vol. 23, n.º 2, págs. 380-388, mayo de 2008, ISSN: 08858950. DOI: 10.1109/TPWRS.2008.919249.
- [26] A. Palazoglu et al., «Neural network applications in fault detection for electric power systems,» *International Journal of Electrical Power & Energy Systems*, vol. 32, n.º 7, págs. 620-628, 2010. DOI: 10.1016/j.ijepes.2010.01.004.
- [27] A. Mahmood et al., «Deep neural network approach for fault detection and location in electrical power systems,» *IEEE Transactions on Power Systems*, vol. 34, n.º 6, págs. 4900-4909, 2019. DOI: 10.1109/TPWRS.2019.2906884.
- [28] J. He et al., «Application of wavelet transform in power system fault location,» *Electric Power Systems Research*, vol. 123, págs. 192-199, 2015. DOI: 10.1016/j.epsr.2015.01.015.
- [29] Z. Song et al., «Smart fault detection and location using deep learning in power systems,» *Journal of Modern Power Systems and Clean Energy*, vol. 8, n.º 5, págs. 957-966, 2020. DOI: 10.35833/MPCE.2020.000377.
- [30] I. D. Thilakarathne et al., «Application of deep learning techniques in power system fault detection and classification,» *IEEE Access*, vol. 8, págs. 160 656-160 665, 2020. DOI: 10.1109/ACCESS.2020.3010747.
- [31] G. I. Escudero Chamber, «Análisis del TRV en el SEN y proposición de técnicas de mitigación,» Tesis doct., Universidad de Chile, 2022.
- [32] C. Beuter y M. Oleskovicz, «S-transform: from main concepts to some power quality applications,» *IET Signal Processing*, vol. 14, n.º 3, págs. 115-123, 2020.
- [33] A. Rodríguez Gómez, «Clasificación de perturbaciones eléctricas mediante la transformada de Stockwell,» Tesis doct., Universidad de Málaga, 2011.

- [34] F. J. Muñoz Gutiérrez, «Nuevas técnicas para la estimación del campo magnético generado por líneas eléctricas aéreas de alta tensión,» Tesis doct., Universidad de Málaga, 2010.
- [35] G. Cybenko, «Approximation by superpositions of a sigmoidal function,» *Mathematics of Control, Signals and Systems*, vol. 2, n.º 4, págs. 303-314, 1989. DOI: 10.1007/BF02551274.
- [36] G. P. Zhang, «Neural networks for classification: a survey,» *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 30, n.º 4, págs. 451-462, nov. de 2000, ISSN: 1558-2442. DOI: 10.1109/5326.897072.
- [37] Hecht-Nielsen, «Theory of the backpropagation neural network,» en *International 1989 Joint Conference on Neural Networks*, IEEE, 1989, 593-605 vol.1. DOI: 10.1109/IJCNN.1989.118638.
- [38] M. Zöllner y M. F. Huber, «Benchmark and Survey of Automated Machine Learning Frameworks,» *CoRR*, vol. abs/1904.12054, 2019. arXiv: 1904.12054. dirección: <http://arxiv.org/abs/1904.12054>.
- [39] L. Yang y A. Shami, «On hyperparameter optimization of machine learning algorithms: Theory and practice,» *Neurocomputing*, vol. 415, págs. 295-316, nov. de 2020, ISSN: 18728286. DOI: 10.1016/j.neucom.2020.07.061. arXiv: 2007.15745.
- [40] G. I. Diaz, A. Fokoue, G. Nannicini y H. Samulowitz, «An effective algorithm for hyperparameter optimization of neural networks,» *CoRR*, vol. abs/1705.08520, 2017. arXiv: 1705.08520. dirección: <http://arxiv.org/abs/1705.08520>.
- [41] D. Dufournet y J. Hu, «Revision of IEEE C37.011 Guide for the Application of Transient Recovery Voltages for AC High-Voltage Circuit Breakers,» *IEEE Transactions on Power Delivery*, vol. 27, n.º 2, págs. 1018-1022, abr. de 2012, ISSN: 0885-8977. DOI: 10.1109/TPWRD.2011.2182621.

- [42] A. Rodríguez, J. Aguado, F. Martín, J. López, F. Muñoz y J. Ruiz, «Rule-based classification of power quality disturbances using S-transform,» *Electric Power Systems Research*, vol. 86, págs. 113-121, 2012. DOI: 10.1016/j.epsr.2011.12.009.
- [43] P. K. Ray, N. Kishor y S. R. Mohanty, «Islanding and Power Quality Disturbance Detection in Grid-Connected Hybrid Power System Using Wavelet and S-Transform,» *IEEE Transactions on Smart Grid*, vol. 3, n.º 3, págs. 1082-1094, 2012. DOI: 10.1109/TSG.2012.2197642.
- [44] A. Morched, B. Gustavsen y M. Tartibi, «A universal model for accurate calculation of electromagnetic transients on overhead lines and underground cables,» *IEEE Transactions on Power Delivery*, vol. 14, n.º 3, págs. 1032-1038, 1999. DOI: 10.1109/61.772350.
- [45] B. Gustavsen, «Transmission line models for the simulation of interaction phenomena between parallel AC and DC overhead lines,» *IPST'99, Budapest*, 1999.
- [46] H. Manitoba, «Research centre,» *PSCAD/EMTDC: Electromagnetic transients program including dc systems*, 1994.
- [47] M. Moschakis y N. Hatziargyriou, «Analytical calculation and stochastic assessment of voltage sags,» *IEEE Transactions on Power Delivery*, vol. 21, n.º 3, págs. 1727-1734, 2006. DOI: 10.1109/TPWRD.2006.874108.
- [48] B. Ravindranath y M. Chander, *Power system protection and switchgear*. New Age International, 1977.
- [49] B. Filipović-Grčić, D. Filipović-Grčić e I. Uglešić, «Analysis of transient recovery voltage in 400 kV SF6 circuit breaker due to transmission line faults,» *International Review of Electrical Engineering (IREE)*, vol. 6, n.º 5-Part B, págs. 2652-2658, 2011.

- [50] P. Oramus, T. Chmielewski, T. Kuczek, W. Piasecki y M. Szewczyk, «Transient recovery voltage analysis for various current breaking mathematical models: shunt reactor and capacitor bank de-energization study,» *Archives of Electrical Engineering*, vol. 64, n.º 3, págs. 441-458, 2015. DOI: 10.2478/ae-2015-0034.
- [51] A. Cassie, «Theorie Nouvelle des Arcs de Rupture et de la Rigidité des Circuits,» *Cigre Report*, vol. 102, págs. 588-608, 1939.
- [52] O. Mayr, «Beiträge zur Theorie des statischen und des dynamischen Lichtbogens,» *Archiv für Elektrotechnik*, vol. 37, n.º 12, págs. 588-608, 1943. DOI: 10.1007/BF02084317.
- [53] P. H. Schavemaker y L. Van der Slui, «An improved Mayr-type arc model based on current-zero measurements [circuit breakers],» *IEEE Transactions on Power delivery*, vol. 15, n.º 2, págs. 580-584, 2000. DOI: 10.1109/61.852988.
- [54] U. Habedank, «Application of a new arc model for the evaluation of short-circuit breaking tests,» *IEEE transactions on power delivery*, vol. 8, n.º 4, págs. 1921-1925, 1993. DOI: 10.1109/61.248303.
- [55] F. Ni, M. Nijhuis, P. H. Nguyen y J. F. G. Cobben, «Variance-Based Global Sensitivity Analysis for Power Systems,» *IEEE Transactions on Power Systems*, vol. 33, n.º 2, págs. 1670-1682, mar. de 2018, ISSN: 1558-0679. DOI: 10.1109/TPWRS.2017.2719046.
- [56] A. Yadav y A. Swetapadma, «A single ended directional fault section identifier and fault locator for double circuit transmission lines using combined wavelet and ANN approach,» *International Journal of Electrical Power & Energy Systems*, vol. 69, págs. 27-33, 2015, ISSN: 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2014.12.079>.
- [57] A. Asuhaimi Mohd Zin, M. Saini, M. W. Mustafa, A. R. Sultan y Rahimuddin, «New algorithm for detection and fault classification on parallel transmission line using DWT and BPNN based on Clarke's transformation,» *Neurocompu-*

- ting, vol. 168, págs. 983-993, 2015, ISSN: 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2015.05.026>.
- [58] A. Abdollahi y S. Seyedtabaii, «Transmission line fault location estimation by Fourier wavelet transforms using ANN,» en *2010 4th International Power Engineering and Optimization Conference (PEOCO)*, jun. de 2010, págs. 573-578. DOI: 10.1109/PEOCO.2010.5559253.
- [59] A. Khan, A. Q. Khan, M. Sarwar, M. Abubakar y N. Iqbal, *An Accurate Fault Location Algorithm for Meshed Power Networks Utilizing Hybrid Sparse Voltage and Current Measurements*, 2019. arXiv: 1906.12113 [eess.SP].
- [60] S. P. Valsan y K. Swarup, «Wavelet transform based digital protection for transmission lines,» *International Journal of Electrical Power & Energy Systems*, vol. 31, n.º 7, págs. 379-388, 2009, ISSN: 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2009.03.024>.
- [61] S. Samantaray, P. Dash y G. Panda, «Fault classification and location using HS-transform and radial basis function neural network,» *Electric Power Systems Research*, vol. 76, n.º 9, págs. 897-905, 2006, ISSN: 0378-7796. DOI: <https://doi.org/10.1016/j.epsr.2005.11.003>.