



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

PLANIFICACIÓN CUASI-ÓPTIMA DE EQUIPOS DE COMPENSACIÓN REACTIVA
PARA REDES RESILIENTES ANTE EVENTOS SÍSMICOS

TESIS PARA OPTAR AL GRADO DE
MAGÍSTER EN CIENCIAS DE LA INGENIERÍA, MENCIÓN ELÉCTRICA

ALEX FERNANDO VILLAMARÍN JÁCOME

PROFESOR GUÍA:
RODRIGO MORENO VIEYRA

MIEMBROS DE LA COMISIÓN:
FERNANDO ORDOÑEZ PIZARRO
PATRICIO MENDOZA ARAYA

Este trabajo ha sido parcialmente financiado por la Agencia Nacional de Investigación y
Desarrollo ANID mediante programa FONDECYT 1181928

SANTIAGO DE CHILE

2020

RESUMEN DE LA TESIS PARA OPTAR
AL GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA, MENCIÓN ELÉCTRICA
POR: ALEX FERNANDO VILLAMARÍN JÁCOME
FECHA: 2020
PROF. GUÍA: RODRIGO MORENO VIEYRA

PLANIFICACIÓN CUASI-ÓPTIMA DE EQUIPOS DE COMPENSACIÓN REACTIVA PARA REDES RESILIENTES ANTE EVENTOS SÍSMICOS

Los sistemas eléctricos son susceptibles a daños tras la ocurrencia de terremotos. Dado que originalmente la planificación de redes eléctricas no considera el riesgo que ocurran estos eventos, su impacto puede provocar interrupciones severas en el suministro eléctrico. Por consiguiente, se propone un modelo de optimización vía simulación para determinar la inversión cuasi-óptima en equipos de compensación reactiva, con el fin de mitigar los efectos adversos de eventos naturales en el suministro eléctrico y así mejorar la resiliencia de la red. Mientras el optimizador toma decisiones de inversión en equipos de compensación reactiva en distintos puntos de la red, el simulador evalúa las mejoras en resiliencia mediante simulaciones de Monte Carlo con dos niveles de incertidumbre: realización del terremoto y las consecuentes fallas de la red. Además, el simulador tiene una modelación granular de subestaciones eléctricas a nivel de paños. Para hacer la búsqueda de la solución cuasi-óptima más robusta se utiliza un método de aproximación por promedio muestral. Los análisis demuestran que el modelo propuesto es efectivamente más robusto en la búsqueda de la solución cuasi-óptima con respecto al método convencional de optimización. Adicionalmente, se demuestra que la capacidad de transporte post-contingencia aumenta significativamente con los equipos de compensación instalados, disminuyendo, en el caso particular de nuestros experimentos, la energía no suministrada esperada en condiciones adversas en un 10 %.

En memoria de Rodrigo Sarabia †

Gabriela Jácome †

María Olga Carrera de Jácome †

Manuel Villamarín †

Agradecimientos

En primer lugar, me gustaría agradecer todo el apoyo, paciencia y gran amor de la persona que me ha enseñado lo que en realidad es “Resiliencia”, mi amada esposa Evelyn Sarabia. Juntos seguimos cumpliendo sueños. Te amo!

Mis agradecimientos y aprecio al Profesor Rodrigo Moreno por su guía, apoyo y discusiones que han contribuido en gran parte al desarrollo de este trabajo. Además, por el estímulo que brinda con sus conversaciones y metas inspiradoras de tratar de resolver problemas del sector eléctrico desde los aportes de la academia.

Además, quisiera agradecer al Profesor Diego Ortiz de la Universidad de las Fuerzas Armadas - ESPE, por la confianza, amistad y todas las discusiones fructíferas que ayudaron a sobrellevar mi etapa en el Magíster. Gracias Profe!

Quisiera agradecer a los Profesores Patricio Mendoza y Fernando Ordóñez de la Universidad de Chile, por los comentarios realizados a este trabajo.

También, a mis buenos amigos y compatriotas Danny, Andrés y Ricardo les agradezco por compartir gratos momentos de alegría y ayudar a desconectarme de Beauchef. Además, a todos mis amigos y compañeros que he tenido el gusto de conocer en la Universidad de Chile.

A mis amigos/hermanos Cristian, Juan y Henry por su amistad de siempre y por alegrarme con videollamadas en los momentos difíciles.

Este trabajo y todo lo que soy es dedicado para mis padres Virginia y Marco, quienes siempre me han brindado su amor, respeto y apoyo. Por siempre creer en mí y sobre todo por no poner límites a mis sueños, sin ellos nada sería igual. A mis hermanos Geovanny y Bryan, por su amor y alegría, no estar junto a ustedes ha sido lo más difícil, pero ustedes son la motivación para seguir luchando por mis sueños.

Finalmente y no menos importante, a la Virgencita de Baños de Agua Santa y a nuestro Señor Jesucristo.

Tabla de Contenido

1. Introducción	1
1.1. Motivación	1
1.2. Hipótesis propuesta	3
1.3. Objetivo	3
1.3.1. Objetivo general	3
1.3.2. Objetivos específicos	3
1.4. Contribuciones	4
1.5. Estructura del documento	4
2. Estado del arte	5
2.1. Resiliencia en redes eléctricas	5
2.2. Planificación de redes eléctricas resilientes	6
2.3. Optimización estocástica aplicada a resiliencia de sistemas eléctricos	7
2.3.1. Optimización vía simulación	8
2.3.2. Métodos de aproximación por promedio muestral	9
3. Metodología	10
3.1. Descripción general del modelo	11
3.2. Simulador	12
3.2.1. Modelación de terremotos	12
3.2.2. Vulnerabilidad sísmica de componentes	13
3.2.3. Operación del sistema	15
3.2.4. Métricas de resiliencia	20
3.3. Optimizador	21
3.3.1. Aproximación por promedio muestral	23
4. Casos de estudio y resultados	27
4.1. Descripción de los datos de entrada	29
4.2. Descripción de los casos de estudio	29
4.2.1. Caso base	29
4.2.2. Cuantificación del riesgo	31
4.2.3. Impacto en variables eléctricas	31
4.2.4. Coberturas al riesgo mediante equipos de compensación reactiva	32
4.3. Resultados	34
4.3.1. Cuantificación del riesgo	34
4.3.2. Impacto en variables eléctricas	38

4.3.3. Coberturas al riesgo mediante equipos de compensación reactiva . . .	40
5. Conclusiones y trabajo futuro	48
5.1. Conclusiones	48
5.2. Trabajo futuro	49
Bibliografía	55
6. Apéndice	56
6.1. Parámetros del caso de estudio IEEE RTS 24-Barras	56
6.2. Curvas de fragilidad	58
6.3. Datos de los terremotos	60
6.4. Resultados de la optimización	60
6.4.1. Presupuesto igual a 2	60
6.4.2. Presupuesto igual a 3	63
6.4.3. Presupuesto igual a 4	65
6.5. Esquema de la función ga (Genetic Algorithm)	67

Índice de Tablas

1.1. Efectos del terremoto 27F: Impacto en el sistema de transmisión	2
4.1. Resultados del análisis de vulnerabilidad de los componentes	38
4.2. Resultados del método de ranking	41
4.3. Resultados del método OvS-FU	42
4.4. Resultados del método OvS-SAA	43
4.5. Ranking de soluciones de 10 optimizaciones del método OvS-FU, e intervalo de confianza para cada solución.	43
4.6. Ranking de soluciones de 10 optimizaciones del método OvS-SAA, e intervalo de confianza para cada solución.	44
4.7. Resultados de los métodos OvS-SAA y OvS-FU para todos los presupuestos, esta tabla resume los resultados del Apéndice 6.5 a 6.16.	45
4.8. Robustez y tiempos de simulación.	46
6.1. Demanda máxima y capacidad de Generación localizada en cada barra	56
6.2. Localización de los Generadores	57
6.3. Localización de las barras	57
6.4. Localización de los terremotos	60
6.5. Resultados de 10 optimizaciones de OvS-FU	61
6.6. Resultados de 10 optimizaciones de OvS-SAA	61
6.7. Ranking de soluciones de 10 optimizaciones de OvS-FU, e intervalo de confianza para cada solución.	62
6.8. Ranking de soluciones de 10 optimizaciones de OvS-SAA, e intervalo de confianza para cada solución.	62
6.9. Resultados de 10 optimizaciones de OvS-FU	63
6.10. Resultados de 10 optimizaciones de OvS-SAA	63
6.11. Ranking de soluciones de 10 optimizaciones de OvS-FU, e intervalo de confianza para cada solución.	64
6.12. Ranking de soluciones de 10 optimizaciones de OvS-SAA, e intervalo de confianza para cada solución.	64
6.13. Resultados de 10 optimizaciones de OvS-FU	65
6.14. Resultados de 10 optimizaciones de OvS-SAA	65
6.15. Ranking de soluciones de 10 optimizaciones de OvS-FU, e intervalo de confianza para cada solución.	66
6.16. Ranking de soluciones de 10 optimizaciones de OvS-SAA, e intervalo de confianza para cada solución.	66

Índice de Figuras

3.1. Metodología	12
3.2. Dada la PGA en el eje x, la probabilidad de estar en un determinado estado es la diferencia entre la curva y la curva que está debajo de esta. También existe un estado sin daños, cuya probabilidad es la diferencia entre 1 y la curva por encima de todas las demás (curva de estado leve)	14
3.3. Métricas de Resiliencia [1]	20
3.4. Triángulo de Resiliencia	21
3.5. Marco de total incertidumbre: árbol de escenarios	26
3.6. SAA: árbol de escenarios	26
4.1. Configuración espacial de la red y atenuación logarítmica de la PGA para un terremoto ilustrativo con un epicentro en (0,0) km. Los valores de PGA (es decir, contornos) se muestran en [g].	28
4.2. Sistema de prueba IEEE-RTS de 24 barras	30
4.3. Localización de los terremotos en el plano	33
4.4. Histograma de la ENS	35
4.5. Mapa de riesgo de la ENS	36
4.6. Mapa de Vulnerabilidad de la red de transmisión	37
4.7. Voltajes en las barras	39
4.8. Cargabilidad de las líneas de transmisión	39
4.9. Esperanza condicional de la ENS en función del presupuesto	47
6.1. Curvas de fragilidad para instalaciones de pequeña generación con componentes anclados	58
6.2. Curvas de fragilidad para instalaciones de mediana/grande generación con componentes anclados	58
6.3. Curvas de fragilidad para subestaciones de medio voltaje con componentes sísmicos	59
6.4. Curva de fragilidad para torres de transmisión	59

Capítulo 1

Introducción

1.1. Motivación

La demanda de energía es cada vez mayor con una población mundial en aumento y una sociedad que depende cada vez más de la electricidad, esta dependencia ha llevado a numerosas dificultades tras la ocurrencia de interrupciones o apagones eléctricos. Históricamente, las redes eléctricas han sido diseñadas, construidas y operadas bajo criterios de seguridad que consideran la ocurrencia de eventos creíbles, generalmente basado en criterios N-1 o N-2. Sin embargo, pueden verse afectados por eventos menos comunes (llamados eventos HILP - del inglés High Impact Low Probability), pero que presentan un impacto importante en el suministro eléctrico y en el bienestar de la población. Estos eventos HILP (tales como eventos climáticos extremos, desastres naturales y ataques provocados por el hombre) pueden causar daños severos o incluso irreparables a la infraestructura eléctrica, lo que resulta en interrupciones del suministro de electricidad a un gran número de clientes. Esto a su vez podría representar un gran costo social y económico, considerando que los sistemas eléctricos son base de otros tipos de sistemas como telecomunicaciones, transporte, alimentación, entre otros.

Entre los diferentes desastres naturales, los terremotos son los más impredecibles y desastrosos [3], que afectan a una gran cantidad de países y que pueden producir efectos devastadores en las redes eléctricas. Así, por ejemplo, el terremoto de Wenchuan en 2008 causó grandes daños a los sistemas de transmisión y distribución de energía eléctrica en la provincia de Sichuan, China, donde se dañaron aproximadamente 900 subestaciones y 270 líneas de transmisión de la red eléctrica estatal. Se ha estimado que al menos el 90% del daño podría haberse evitado adoptando nuevas pautas para el diseño, planificación y adaptación sísmica [8]. Aproximadamente el 90% de los chilenos no tenían electricidad inmediatamente después del terremoto de 8.8 Mw¹ el 27 de febrero de 2010. El evento causó que la compañía de transmisión de energía más grande de Chile tuviera pérdidas directas de aproximadamente 6500 millones de dólares [9]. El devastador terremoto de Tohoku Chiho Taiheiyo-Oki el 11 de marzo de 2011 y sus réplicas dañaron 14 plantas de energía, 70 transformadores y 42 torres de transmisión, entre otras fallas. La interrupción del servicio afectó a 4.6 millones de

¹Escala sismológica de magnitud de momento

residentes y la réplica del 7 de abril afectó a 4 millones adicionales [10]. El terremoto de 7.8 Mw que sufrió Ecuador en abril de 2016 causó una pérdida económica de aproximadamente 103 millones de dólares para la reconstrucción integral de la infraestructura eléctrica de distribución en las zonas afectadas. El 30 de noviembre de 2018, un terremoto de 7 Mw sacudió el sur de Alaska y provocó daños en la infraestructura de transmisión [11].

Evidentemente, los diversos eventos ocurridos demuestran las crecientes dificultades que se enfrentan los sistemas eléctricos tradicionales en el desarrollo de una infraestructura eléctrica más resiliente ante los efectos adversos de los desastres naturales. Particularmente los sistemas de transmisión, construidos con el propósito de transportar la energía eléctrica desde grandes unidades generadoras hasta los centros de consumo, a través de líneas y torres que atraviesan cientos de kilómetros de distancia, son los más expuestos a diferentes amenazas. Tomando como ejemplo las lecciones del terremoto de Chile en 2010 y su impacto en el suministro de electricidad [2], los componentes del sistema de transmisión (subestaciones y líneas) fueron los componentes más afectados, tal como se muestra en la tabla 1.1. Por las razones mencionadas, es relevante considerar un mayor nivel de detalle en la evaluación de vulnerabilidad de los componentes del sistema de transmisión que permita representar un comportamiento más realista de las subestaciones frente a la ocurrencia de terremotos.

Por otra parte, a medida que la frecuencia de las interrupciones causadas por eventos extremos en la red eléctrica ha aumentado significativamente en los últimos años, también ha incrementado la necesidad de incorporar una planificación de redes eléctricas con un enfoque resiliente, que vaya más allá de la planificación tradicional que busca aumentar los niveles de redundancia en la capacidad de la red de transmisión [3]. Para esto, una estrategia para mitigar los efectos adversos de los terremotos en el suministro eléctrico es mediante una inversión adecuada de nuevos activos en la red que permitan mejorar la resiliencia de las redes eléctricas. Por lo tanto, la inversión adecuada de equipos de compensación de potencia reactiva podría convertirse en una alternativa que permita aprovechar al máximo la capacidad de transporte de las redes de transmisión que queden disponibles después de un evento sísmico de gran magnitud.

Total de instalaciones	Total	Con daños	(%)
Subestaciones	50	12	24
Líneas de transmisión (km)	8239	1.6	0.02
Detalle en la zona afectada (66 a 500kV)	Total	Con daños	(%)
Interruptores	294	9	3
Bushings ATR y reactores	265	12	5
Pararrayos	265	10	4
Transformadores de medida	706	20	3
Desconectores	882	21	2
Estructuras alta tensión	9475	3	0.03

Tabla 1.1: Efectos del terremoto 27F: Impacto en el sistema de transmisión

1.2. Hipótesis propuesta

En este trabajo se busca demostrar que, mediante una planificación adecuada de equipos de compensación de potencia reactiva, es posible mitigar los efectos de terremotos en el suministro eléctrico. Particularmente, mediante una localización cuasi-óptima (cuasi²) de equipos de compensación reactiva, es posible aprovechar al máximo la capacidad de transporte de las redes de transmisión que quedan disponibles después de un evento exógeno de gran magnitud. Esta alternativa podría, eventualmente, sustituir los enfoques tradicionales que buscan aumentar los niveles de redundancia en la capacidad de la red de transmisión.

1.3. Objetivo

1.3.1. Objetivo general

El objetivo general de esta tesis es desarrollar un modelo de simulación y optimización que sea capaz de determinar la inversión eficiente en equipos de compensación de potencia reactiva para mejorar la resiliencia de las redes eléctricas frente a eventos sísmicos. En la etapa de simulación se evalúa la naturaleza estocástica del terremoto y el posterior daño en los componentes de la red dentro de un marco de simulación de Monte Carlo. Y en la etapa de optimización se propone un algoritmo de optimización vía simulación (OvS) eficiente para encontrar la solución de inversión cuasi-óptima.

1.3.2. Objetivos específicos

- Diseñar un modelo para generar simulaciones que permitan evaluar el impacto de los eventos sísmicos en los componentes de la red eléctrica mediante un AC-OPF (del inglés Alternating Current Optimal Power Flow), necesario como herramienta para cuantificar la resiliencia a través de distintas métricas.
- Diseñar un algoritmo de optimización vía simulación que, mediante la aplicación del método de aproximación por promedio muestral (SAA - del inglés Sample Average Approximation), sea capaz de evaluar el desempeño de las estrategias de mejora de planificación de redes eléctricas considerando la inversión cuasi-óptima en equipos de compensación reactiva desde un enfoque de resiliencia frente a eventos sísmicos.
- Desarrollar un modelo detallado de vulnerabilidad de subestaciones a nivel de paños³ basado en curvas de fragilidad, con el fin de obtener una representación más realista del comportamiento de una subestación frente a la ocurrencia de terremotos porque influye en los resultados finales de la energía no suministrada (ENS).
- Determinar la cantidad y ubicación cuasi-óptima de equipos de compensación de potencia reactiva que permiten mejorar la resiliencia de la red eléctrica frente a la ocurrencia

²Nos referimos al término “cuasi-óptimo” a lo largo de este documento, ya que la optimización se lleva a cabo mediante simulaciones y no hay garantía de la optimización global. Sin embargo, como se demostrará más adelante en el capítulo 4, para el caso particular de nuestros experimentos los resultados son óptimos.

³Un paño es una parte de la subestación que contiene interruptores, desconectores, pararrayos, transformadores de potencia y corriente, el sistema de barras, etc.

de eventos sísmicos.

1.4. Contribuciones

- Desarrollar a través de un enfoque probabilístico un modelo de vulnerabilidad de la subestación a nivel de paños basado en curvas de fragilidad, que proporciona una representación más realista del comportamiento de una subestación frente a la ocurrencia de eventos sísmicos.
- Desarrollar un algoritmo de optimización para identificar la inversión cuasi-óptima en equipos de compensación reactiva para mejorar la resiliencia de las redes eléctricas. Dicha optimización se resuelve utilizando los métodos de total incertidumbre (FU del inglés Full Uncertainty) y SAA para demostrar la robustez de las soluciones y los tiempos de ejecución empleados.
- Demostrar que la inversión en equipos de compensación de potencia reactiva representa una estrategia efectiva para mejorar la resiliencia de la red eléctrica frente a la ocurrencia de eventos sísmicos.

1.5. Estructura del documento

Este documento está estructurado en cinco capítulos de la siguiente forma: En el capítulo 1 se presenta la motivación e introducción del trabajo de investigación. En el capítulo 2 se presenta el estado del arte de los avances en la resiliencia de los sistemas eléctricos y las técnicas de optimización para resolver el problema de planificación de redes eléctricas resilientes. En el capítulo 3 se presenta la metodología propuesta para implementar el modelo de simulación y optimización. En el capítulo 4 se presentan los casos de estudio y resultados. Finalmente, en el capítulo 5 se presentan las principales conclusiones y se propone posibles trabajos a futuro.

Capítulo 2

Estado del arte

2.1. Resiliencia en redes eléctricas

La resiliencia se puede definir como la capacidad que posee el sistema eléctrico para resistir eventos extremos (alto impacto, pero baja probabilidad), recuperarse rápidamente de tales eventos disruptivos y adaptar su operación e infraestructura para prevenir o mitigar el impacto de eventos similares en el futuro [4], [5]. Recientemente, el grupo de trabajo IEEE Task Force on Definition and Quantification of Resilience [6] ha proporcionado la siguiente definición de resiliencia: “La capacidad de resistir y reducir la magnitud y/o duración de los eventos disruptivos, que incluye la capacidad de anticipar, absorber, adaptarse y/o recuperarse rápidamente de dicho evento”.

En el contexto de definiciones y marcos generales, en [7] y [8] se presenta y discute un marco conceptual de resiliencia en sistemas eléctricos junto con las medidas clave que se pueden tomar para mejorar la resiliencia de la red. En [9] se introducen cuatro índices para medir la resiliencia de la red desde diferentes perspectivas, incluida la fragilidad, la supervivencia y la restauración. En [10] se propone el concepto de trapecioide de resiliencia multifase, que presenta un conjunto de métricas para cuantificar la resiliencia en cada etapa del proceso de recuperación del colapso. Además, en [1] se propone un marco de aversión al riesgo que puede usarse para operar y diseñar redes eléctricas de manera más resiliente, reduciendo la exposición a condiciones climáticas adversas y desastres naturales extremos.

En el contexto de evaluación de resiliencia, en [11] se proponen cuatro fases para evaluar la resiliencia del sistema eléctrico: caracterización de amenazas, evaluación de vulnerabilidad de los componentes del sistema, respuesta del sistema y restauración del sistema. Del mismo modo, en [12] se propone un método de evaluación de resiliencia dividido en tres etapas, de acuerdo con el proceso de evolución de los desastres: dureza antes de los desastres, resistencia durante los desastres y capacidad de restauración posterior a los desastres. En [13] se desarrolla un modelo de fragilidad del sistema de transmisión que presenta una metodología probabilística multitemporal y multirregional de evaluación de la resiliencia. Por otra parte, existen enfoques que proponen métodos de evaluación de la resiliencia divididos principalmente en tres categorías [14]: el método basado en la simulación (combina fácilmente con escenarios de desastre y calcula la consecuencia del desastre), el método analítico (aprovecha

la probabilidad de falla del sistema en una situación determinada) y el análisis estadístico (utiliza registros históricos de interrupción y restauración para el análisis de datos).

En el contexto de mejorar la resiliencia del sistema, en la literatura previa (como [4], [7], [1], [15–20]) se han propuesto varios métodos basados en la planificación y en la operación. Los métodos basados en la planificación se centran en establecer planes de expansión de la red para fortalecer los sistemas de transmisión y distribución frente a eventos extremos futuros, mientras que los métodos basados en la operación desarrollan estrategias fundamentadas en la optimización para utilizar los activos disponibles contra fallas y eventos extremos. Es importante destacar que en la actualidad, el desarrollo de estrategias para mejorar la resiliencia de redes eléctricas mediante técnicas que utilicen potencia reactiva tiene un alcance limitado, con algunos trabajos centrados en mejorar la resiliencia ante tormentas de hielo mediante técnicas que utilizan potencia reactiva para generar calor y derretir el hielo cubierto en las líneas de transmisión [21] y la asignación de equipos de compensación de potencia reactiva como esquema para mejorar la resiliencia frente a eventos disruptivos que provocan múltiples interrupciones de las líneas de transmisión y que puede resultar en la violación del voltaje en barras o la pérdida de carga [22].

En relación a los estudios en la literatura que se han centrado en el impacto de los eventos sísmicos en los sistemas eléctricos, en [23] se describe un marco para evaluar la resiliencia frente a eventos sísmicos junto con la evaluación de varias estrategias de inversión para mitigar el impacto de dichos eventos. Asimismo, en [24] se propone una metodología probabilística para generar escenarios de terremotos y calcular el riesgo del sistema utilizando su respuesta a todos los escenarios. Ambos trabajos fueron aplicados en una red eléctrica real en Chile. En [25] se propone un marco para evaluar el impacto de los terremotos en el sistema eléctrico y estrategias correctivas de mitigación a través del control de topología para mejorar la resiliencia. En [26] se propone un marco para la evaluación de riesgos y resiliencia mediante un ranking de criticidad de los componentes de sistemas eléctricos sujetos a terremotos.

2.2. Planificación de redes eléctricas resilientes

La planificación de la transmisión es muy desafiante debido a diversas fuentes de incertidumbre que los planificadores deben considerar. Además de las fuentes de incertidumbre, como las variaciones de la demanda y las energías renovables intermitentes que enfrentan los operadores de las redes eléctricas en la programación a corto plazo [27], los planificadores también deben considerar la incertidumbre de los cambios en las políticas, los avances tecnológicos y los desastres naturales [1], [28].

En la actualidad, la investigación sobre planificación de redes eléctricas tiene varios trabajos centrados en métodos para mejorar la resiliencia [16], [29–32]. Estos métodos se clasifican de la siguiente manera: (i) líneas de transmisión subterráneas, construcción de rutas redundantes de transmisión y fortalecer los cimientos y estructuras de la red de transmisión utilizando materiales más resistentes [33], [34]; (ii) reforzamiento de los componentes existentes y agregar generación distribuida de respaldo [35], [36], [37]; (iii) mejorar el manejo de la vegetación que está cerca de las líneas de transmisión [38]; (iv) asignación óptima de recursos de energía flexibles (por ejemplo, unidades de almacenamiento de energía), mejorar la capacidad de reserva y la redundancia mediante la construcción de nuevos equipos de

transmisión [39]; y (v) control activo de los sistemas de transmisión utilizando interruptores para la reconfiguración del sistema y dispositivos de sistemas de transmisión de corriente alterna flexibles (FACTS del inglés Flexible AC Transmission System) para controlar el flujo de energía de las líneas de transmisión [20].

Por otra parte, los métodos para mejorar la resiliencia basados en la planificación de la red podrían ser prohibitivamente costosos y, por lo tanto, las inversiones generalmente están limitadas por un presupuesto. Por consiguiente, varios estudios previos sobre la planificación de la red eléctrica considerando desastres naturales o ataques terroristas se centran principalmente en dos marcos: optimización estocástica [35], [36], [40], [41] y optimización robusta [42], para decidir las inversiones óptimas con el fin de mejorar la resiliencia. Adicionalmente, varios estudios utilizan un marco de programación binivel que modela ataques terroristas y desastres naturales a medida que los adversarios apuntan a maximizar el daño en el sistema eléctrico [43], [44]. Otros estudios proponen modelos de tres niveles con etapas de defensor-atacante-defensor para el problema de planificación de recursos en defensa de la red eléctrica [45–47].

2.3. Optimización estocástica aplicada a resiliencia de sistemas eléctricos

Durante los últimos años, la resiliencia ha introducido un enfoque diferente en el desarrollo de los problemas de optimización tanto para la evaluación de los sistemas eléctricos, como en la planificación de inversiones en la red [30]. Dependiendo del estudio, el modelo de planificación de la expansión podría formularse como un problema programación estocástica de una etapa, programación estocástica en dos etapas con recurso y programación estocástica restringida probabilísticamente [48]. En este estudio nos centramos en particular en la optimización estocástica para la planificación de redes resilientes. Por ejemplo, en [40] se presenta un enfoque de programación estocástica para reforzar y expandir de manera óptima la red de transmisión para mitigar el impacto de los ataques deliberados. En [49] se propone un modelo estocástico de dos etapas para capturar la naturaleza multietapa del problema de planificación de la transmisión aplicando el método de Monte Carlo.

Por otra parte, debido a la naturaleza estocástica de los eventos naturales adversos, la incertidumbre es un aspecto importante del problema de planificación de la resiliencia. En los estudios previos más relevantes para este trabajo se han desarrollado modelos estocásticos de dos etapas para optimizar la selección de estrategias de mejora de la resiliencia de los sistemas eléctricos frente a eventos naturales. En [36] se propone un modelo de optimización no lineal estocástico entero-mixto para determinar las inversiones de reforzamiento (generadores, líneas y subestaciones) óptimo para mejorar la resiliencia en el sistema eléctrico ante eventos climáticos extremos. En [50] se propone un programa estocástico de dos etapas y una solución heurística de estrategia de endurecimiento para mejorar la resiliencia frente a terremotos, bajo el supuesto de que los tiempos de reparación para tipos similares de componentes siguen una distribución uniforme, lo que simplifica el problema en cierta medida. En [41] se propone un modelo estocástico de dos etapas y un algoritmo de solución para optimizar la expansión de la capacidad de generación y transmisión para mejorar la resiliencia del sistema eléctrico frente a la ocurrencia de terremotos. Otro marco estocástico de dos

etapas se propone en [35] para identificar inversiones en la red para mejorar la resiliencia frente a terremotos, utilizando un portafolio que contiene una combinación de nuevas líneas, reforzamiento de subestaciones y generación distribuida de respaldo, por consiguiente, esto confirma que los enfoques de optimización estocástica son una herramienta prometedora para tomar decisiones resilientes apropiadas.

2.3.1. Optimización vía simulación

El desarrollo de modelos detallados para simular la operación real de los sistemas eléctricos es de alta complejidad debido a la gran adopción de generación intermitente, los requisitos adicionales de confiabilidad y las necesidades para permitir el desarrollo de un sistema más resiliente para enfrentar eventos de baja probabilidad y alto impacto (p. ej., terremotos, inundaciones, etc.) [51], por lo tanto, su incorporación en los modelos de optimización es muy desafiante. De hecho, para tomar una decisión de inversión óptima en grandes sistemas eléctricos, se debe hacer un ajuste entre la precisión para modelar la operación del sistema y la optimización de la metodología implementada para encontrar la mejor solución.

Por consiguiente, si se utiliza una programación matemática de optimización completa, se realiza una simplificación en el modelo de operación [52], como: reducción en el número de barras o en el número de restricciones en el modelo de unit commitment, simplificación del comportamiento de demanda cronológica a través de la agrupación o representación por bloque [53], etc. Por otro lado, si la operación del sistema eléctrico se modela con detalle, entonces se deben utilizar algunas metodologías heurísticas para encontrar una buena solución. Por ejemplo, en [54] y [55], los autores resuelven la planificación de expansión de la red de transmisión utilizando algoritmos genéticos y Búsqueda tabú, respectivamente.

Tomando en cuenta este trade-off entre la precisión del modelado de la operación del sistema eléctrico y la optimización del procedimiento para encontrar la mejor solución de un problema de planificación, la OvS busca determinar el conjunto óptimo de parámetros que optimiza una función objetivo cuando se requiere una representación detallada del sistema e información sobre la calidad de la solución, y cuyo valor sólo puede ser estimado a través de un modelo de simulación [56]. De hecho, sea cual sea la forma en que se enfrente este problema, se debe lidiar con tres grandes inconvenientes [57]:

- i En el problema de OvS no se cuenta con una expresión analítica de la función objetivo. Esto imposibilita el cálculo exacto del gradiente de la función, que es el punto de partida de la mayoría de los bien conocidos algoritmos de optimización de programación matemática.
- ii La función objetivo es una función estocástica de los parámetros del sistema. Esto hace imposible conocer con exactitud cuál es el valor de la función objetivo para una cierta solución factible del problema de optimización; solamente se puede obtener una estimación de dicho valor. Además, esta aleatoriedad dificulta enormemente la comparación entre dos o más soluciones.
- iii En general, correr un modelo de simulación puede tomar un tiempo considerable. Por lo tanto, el costo de cada evaluación de la función objetivo es mucho mayor que el que se enfrenta cuando se cuenta con una expresión analítica. Esto lleva a que la eficiencia

de la estrategia de optimización sea un tema crucial.

Se han realizado algunos desarrollos en temas de inversión de la red para mejorar la confiabilidad y la resiliencia. En [58], [59] se propone un enfoque de optimización discreta vía simulación (DOvS [60]) para identificar portafolios óptimos de inversión en la red que mejoren la confiabilidad del sistema eléctrico, en aquellos casos se requieren una comprensión profunda de los aspectos operativos y los posibles candidatos son variables enteras. Por otra parte, en [35], [61] se propone un marco estocástico de optimización para identificar inversiones en la red para mejorar la resiliencia frente a terremotos, utilizando un enfoque de optimización a través de la simulación para resolver problemas de decisión discreta.

2.3.2. Métodos de aproximación por promedio muestral

Un enfoque para incorporar eventos HILP dentro de la planificación de inversiones en la red propone adoptar modelos estocásticos que consideren explícitamente las probabilidades asociadas y los impactos resultantes en el sistema eléctrico [3]. Sin embargo, para resolver problemas de programación estocástica que involucran distribuciones de probabilidad para tratar de representar escenarios con muy baja probabilidad, exigen condiciones para lidiar con un tamaño del espacio muestral excesivamente grande o con cálculos de esperanzas que pueden llegar a ser muy complejas y costosas en términos computacionales. Para hacer frente a esto, se utiliza el método de aproximación por promedio muestral propuesta por Shapiro [62], que selecciona aleatoriamente una muestra entre todos los escenarios posibles y determina una aproximación del valor objetivo para el problema real resolviendo una muestra. El método SAA se ha convertido en una técnica ampliamente utilizada para resolver problemas de programación estocástica a gran escala [63]. Esto se debe principalmente a su facilidad de aplicación. Asimismo, se ha demostrado que las soluciones obtenidas por el método de SAA convergen a la solución óptima cuando el tamaño de la muestra es suficientemente grande. Por ejemplo, en [64] se propone un enfoque de programación estocástica de enteros-mixtos para la solución del problema de planificación de expansión de generación y transmisión, incluida la confiabilidad del sistema y aplicando el método de SAA para tratar las incertidumbres aleatorias en la generación, líneas de transmisión y cargas. Por otra parte, existen muy pocos estudios de planificación de redes eléctricas resilientes que consideren la incertidumbre debido a eventos naturales adversos. Un caso particular se presenta en [61] que propone un marco de optimización para tomar decisiones de inversión en redes resilientes mediante el método de SAA, con el fin de dar un tratamiento adecuado a la incertidumbre de los terremotos y las fallas de los componentes.

Capítulo 3

Metodología

Nomenclatura

Set de Índices

D Conjunto de nodos con demanda

n_b Conjunto de nodos

n_g Conjunto de generadores

n_l Conjunto de tramos

Set de Parámetros

ζ_d Costo de la energía no suministrada en el nodo d

F_{max} Flujo máximo del tramo

P_d Potencia activa consumida en el nodo d

$p_g^{i,pre}$ Potencia inyectada por el generador en la unidad g

p_g^{max} Potencia activa máxima de la unidad g

p_g^{min} Potencia activa mínima de la unidad g

Q_d Potencia reactiva consumida en el nodo d

q_g^{max} Potencia reactiva máxima de la unidad g

q_g^{min} Potencia reactiva mínima de la unidad g

RD_g Límite de rampa de bajada de la unidad g

RU_g	Límite de rampa de subida de la unidad g
v_m^{max}	Límite máximo de la magnitud de voltaje del nodo b
v_m^{min}	Límite mínimo de la magnitud de voltaje del nodo b

Set de Variables

Θ	Ángulos de voltaje
ENS_d	Energía no suministrada en el nodo d
F_f	Flujo representado en unidades de capacidad generadas del nodo $from$
F_t	Flujo representado en unidades de capacidad generadas del nodo to
P_g	Potencia activa
$P_g(\xi)$	Capacidad de la unidad g dada la realización del escenario ξ
Q_g	Potencia reactiva
$v_g(\xi)$	Variable binaria que es igual a 1 si la unidad g está en servicio y 0 en caso contrario
V_m	Magnitud de voltaje

3.1. Descripción general del modelo

El modelo propuesto de optimización vía simulación determina la inversión cuasi-óptima en equipos de compensación reactiva, con el fin de mitigar los efectos adversos de eventos sísmicos en el suministro eléctrico y así mejorar la resiliencia de la red. Este modelo consiste en una estructura de dos etapas del problema de inversión en la red, que, mientras el optimizador toma decisiones de inversión en equipos de compensación reactiva en distintos puntos de la red, el simulador evalúa las mejoras en resiliencia mediante simulaciones secuenciales de Monte Carlo con dos niveles de incertidumbre: realización del terremoto y las consecuentes fallas de la red. El optimizador y el simulador iteran hasta encontrar una propuesta de mejora de la red cuasi-óptima y resiliente. Un diagrama del marco propuesto se presenta en la figura 3.1.

Para el simulador, se utiliza una metodología con varias etapas que se centra en la caracterización de la amenaza, la vulnerabilidad de los componentes y la respuesta del sistema, cuyos detalles se proporcionan en la siguiente sección. Estas etapas son ejecutadas secuencialmente dentro del simulador para obtener una simulación completa de la red eléctrica antes y durante la ocurrencia del evento sísmico. Para el optimizador, se propone un procedimiento de optimización vía simulación basado en un algoritmo genético, para determinar el portafolio (casi) óptimo de mejoras de la red. Dichas mejoras incluyen la instalación de nuevos activos de red tales como equipos de compensación de potencia reactiva.

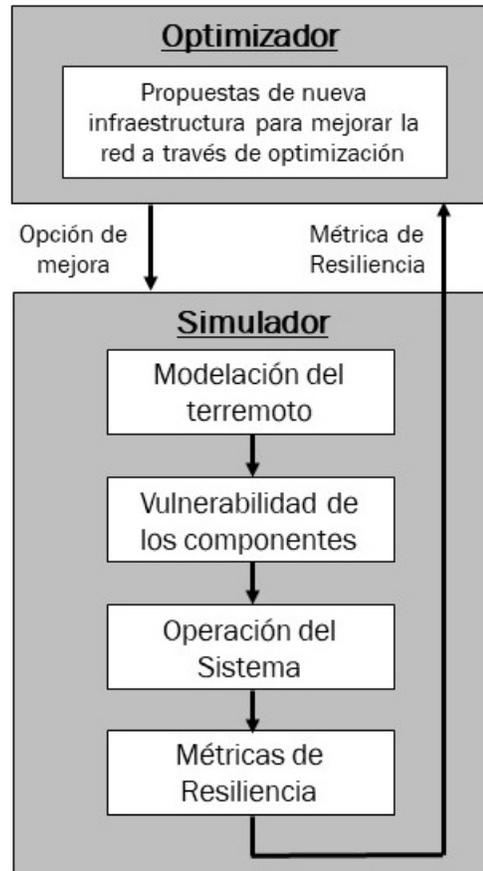


Figura 3.1: Metodología

3.2. Simulador

El simulador presenta dos niveles de modelación de la incertidumbre que representan la realización del evento sísmico y las consecuentes fallas de la red. El primer nivel de incertidumbre se origina por la naturaleza estocástica del terremoto y el segundo nivel por el posterior daño en los componentes de acuerdo con las curvas de fragilidad.

A continuación, se presentan las diferentes etapas del simulador que forman parte de la metodología propuesta para evaluar la resiliencia del sistema eléctrico frente a la ocurrencia de eventos sísmicos.

3.2.1. Modelación de terremotos

Se utiliza un enfoque probabilístico para modelar la incertidumbre de los terremotos. En particular, se ejecuta un modelo de simulación Monte Carlo que genera diferentes escenarios para un terremoto seleccionado. En este caso, es necesario modelar la ubicación del terremoto y, en segundo lugar, su perfil de atenuación (espacial). La ubicación del terremoto se modela utilizando generación aleatoria uniformemente distribuida dentro de un plano. Para la atenuación se utiliza el modelo propuesto por Boroschek (adecuado para Chile), pero esto se puede cambiar de acuerdo a la aplicación específica del modelo. Boroschek propuso que la

atenuación de la aceleración máxima del suelo (PGA del inglés Peak Ground Acceleration) en cualquier posición del plano desde el epicentro del terremoto sigue la siguiente ecuación [65]:

$$PGA(x, y; ex, ey, h, M) = 10^{-1,55+0,26M+0,01h-0,01R-(1,52-0,10M) \log_{10}(R)} \quad (3.1)$$

donde M es la magnitud del movimiento telúrico en la escala de magnitud de momento, también depende de la posición específica en el mapa (x, y) . Dado el hipocentro (ex, ey, h) , entonces $r = \sqrt{(ex - x)^2 + (ey - y)^2}$ y R es $\sqrt{r^2 + (0,07 \cdot 10)^{0,36}}$. Los resultados están en unidades de $[g]$, la constante de aceleración de la gravedad.

3.2.2. Vulnerabilidad sísmica de componentes

Para determinar los niveles de daño de los componentes vulnerables del sistema, condicionados a la ocurrencia de un terremoto, se utilizan las curvas de fragilidad que entregan la distribución de probabilidad sobre dos o más estados de daño en función de un PGA dado, obtenido de 3.1. Las funciones de daño para los componentes del sistema eléctrico se caracterizan en forma de curvas de fragilidad lognormal que correlacionan la probabilidad de estar o exceder un estado de daño para un parámetro sísmico dado. Según [66], cada curva de fragilidad se caracteriza por una mediana y una desviación estándar lognormal (σ) del parámetro PGA, que corresponde a los umbrales del estado de daño y la variabilidad asociada. La probabilidad de residir o exceder un estado de daño estructural (ϑ) se describe a continuación:

$$P[\vartheta|\sigma] = \Phi \left[\frac{1}{\sigma_{\vartheta}} \ln \frac{S_d}{\bar{S}_{d,\vartheta}} \right] \quad (3.2)$$

donde S_d es el desplazamiento espectral; $\bar{S}_{d,\vartheta}$, es el valor medio; σ_{ϑ} es la desviación estándar correspondiente al logaritmo natural del desplazamiento espectral en el que una estructura alcanza el umbral del estado de daño; y Φ es la función de distribución normal acumulada.

Para evaluar cuantitativamente el impacto de un evento sísmico en las instalaciones del sistema eléctrico con una PGA dada, se debe cuantificar la probabilidad asociada con diferentes estados de daño estructural. En la figura 3.2 se muestran diferentes curvas de fragilidad.

En particular, en este trabajo se consideran las curvas de fragilidad para la siguiente infraestructura:

Generadores: Para representar el daño (porcentaje de falla), se utilizan las curvas de fragilidad basadas en la metodología de evaluación de riesgo sísmico HAZUS [66], las curvas de fragilidad para las centrales eléctricas asignan uno de cinco posibles estados de daño: completamente funcional (sin daño), leve, moderado, severo y completo, que corresponden a una disminución o derating de la capacidad operativa de la central de generación de 0, 5, 40, 70 y 100%, respectivamente. El porcentaje de capacidad de operación tiene sentido en este marco, ya que después de un evento sísmico una central de generación que se compone de varias unidades podría tener sólo una porción de esas unidades fuera de servicio, así, la central de generación será capaz de trabajar a una capacidad máxima degradada. En las figuras 6.1 y 6.2 se muestran las curvas de fragilidad utilizadas para las centrales de generación según su potencia instalada.

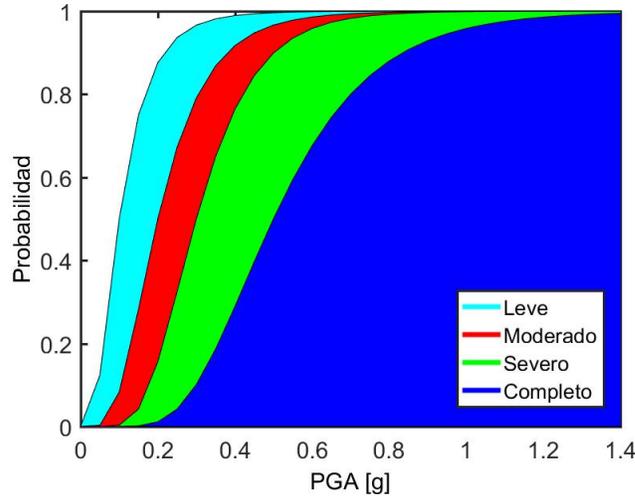


Figura 3.2: Dada la PGA en el eje x, la probabilidad de estar en un determinado estado es la diferencia entre la curva y la curva que está debajo de esta. También existe un estado sin daños, cuya probabilidad es la diferencia entre 1 y la curva por encima de todas las demás (curva de estado leve)

Subestaciones: Se propone representar la vulnerabilidad de la subestación combinando curvas de fragilidad con la modelación del daño de los componentes a nivel de paños. Para esto, se utilizan las curvas de fragilidad propuestas en [66] considerando cinco estados de daño: completamente funcional (sin daño), leve, moderado, severo y completo, que corresponden a una disminución o derating de la capacidad de la subestación de 0, 5, 40, 70 y 100 %, respectivamente. En la figura 6.3 se muestran las curvas de fragilidad utilizadas para las subestaciones. Dado que en los modelos de despacho (necesarios para determinar la respuesta del sistema y que se explican en la siguiente sección) las subestaciones no presentan explícitamente un valor de capacidad, la mencionada reducción de la capacidad de una subestación se traduce en la indisponibilidad de un conjunto de paños que forman parte de dicha subestación. Por ejemplo, se supone que los componentes de un paño sufren daños debido a un terremoto, entonces la subestación podría seguir en funcionamiento, si es que algunos componentes (líneas de transmisión y transformadores) pueden seguir conectados a otros paños. Por lo tanto, la subestación perderá su funcionamiento cuando todos los paños estén fuera de servicio.

De esta manera, se trata de representar que la capacidad no disponible de la subestación modelada por bahías es similar al método que disminuye el valor de la capacidad de todos los elementos conectados a esa subestación (líneas, unidades de generación, etc.). Nuestro modelo tiene cierta redundancia inherente para permitir que la subestación funcione, incluso si algunos componentes en los paños sufren daños. La contribución clave en el tema de la resiliencia relacionada con la vulnerabilidad de la subestación es que el efecto de una modelación más detallada a nivel de los paños puede influir en los resultados finales de la ENS. Curiosamente, nuestra propuesta está en línea con la evidencia empírica observada en Chile, donde, por ejemplo, en el terremoto de 2010 (escala 8.8 Richter), solo 2 km de líneas de transmisión fallaron, mientras que 25 subestaciones de transmisión presentaron algún nivel de daño (ver tabla 1.1).

Torres de transmisión: Cuando la línea de transmisión está conectada por torres en serie y siguen una disposición equiespaciada, la desconexión de toda la línea puede ser causada por el colapso de cualquier torre individual. En este caso, se utiliza una sola curva de fragilidad [67] como se muestra en la figura 6.4, para representar si la torre está en servicio o fuera de servicio. Por lo tanto, en base a los supuestos de que las torres fallan de forma independiente, la probabilidad de falla P_{FL} de una línea de transmisión es:

$$P_{FL} = 1 - \prod_{tw=1}^N (1 - P_{FT,tw}) \quad (3.3)$$

donde $P_{FT,tw}$ es la probabilidad de falla de la tw -ésima torre, N es el número total de torres a lo largo de la línea de transmisión que está determinado por la longitud de las líneas y la distancia entre torres.

El algoritmo 1 presenta un pseudocódigo para generar los parámetros del escenario en la simulación. Primero se muestrea un epicentro con un valor de intensidad fija, luego, de acuerdo con estos parámetros, se calcula la PGA en cada ubicación donde hay componentes del sistema y posteriormente se pueden calcular umbrales que determinan la probabilidad de que los componentes del sistema funcionen a un cierto nivel de capacidad. El pseudocódigo entrega el nivel de capacidad de operación de las unidades de generación y un parámetro binario para cada línea que indica si esta falla.

3.2.3. Operación del sistema

Después de determinar el estado de daño de cada componente de la red, se ejecutan simulaciones de Monte Carlo para determinar varios escenarios en los que los componentes de la red están indisponibles o parcialmente disponibles. Para estas condiciones de la red (donde cada una puede presentar varias interrupciones simultáneas), se realiza un AC-OPF para evaluar los parámetros eléctricos y garantizar que el sistema opera dentro de parámetros eléctricos admisibles.

Para determinar la respuesta del sistema se proponen dos modelos de AC-OPF bien establecidos: el primero es un predespacho (UC del inglés Unit Commitment) para determinar las condiciones iniciales y el segundo es un despacho post-contingencia, el cual está condicionado a los resultados obtenidos por el primero. La modelación de la operación del sistema se realiza durante un solo período de tiempo (hora de demanda máxima porque es el caso más severo) que es significativo para la amenaza concreta que se estudia en este trabajo.

Para esto, primero se ejecuta el modelo de predespacho para definir las condiciones iniciales del sistema que se denomina pre-contingencia (antes del desastre). Una vez determinada las condiciones de operación del sistema pre-contingencia, se generan escenarios de eventos sísmicos que ocasionan la desconexión simultánea de los componentes del sistema, y luego se realiza el modelo de despacho post-contingencia considerando las restricciones de reservas disponibles, los límites de la tasa de rampa, límites de potencia mínima, etc., que se determinan en el despacho pre-contingencia.

Algorithm 1 Generación de escenarios $L_{max} = 210 [km]$, $M = 7,2 [M_W]$, $h = 30 [km]$

Require: Parámetro de curvas de fragilidad para función de distribución lognormal para las subestaciones $((\mu_b^{ds}, (\sigma_b^{ds})^2))$ y para las unidades de generación $((\mu_g^{ds}, (\sigma_g^{ds})^2))$ por cada estado de daño $ds \in \{completo, severo, moderado, leve\}$, (α_{ds}) es el porcentaje de capacidad disponible para cada estado de daño ds dado para las subestaciones y (β_{ds}) para las unidades de generación, M es la magnitud del terremoto que es un valor fijo, h es la profundidad del terremoto que es un valor fijo, e es el epicentro con coordenadas $(x_i; y_i)$ y L_{max} es la longitud máxima del plano que tiene el área cuadrada.

- 1: Muestrear $r \sim unif[0; 1]$ y $s \sim unif[0; 1]$ y sea $e = (x_i; y_i) = (r \cdot L_{max}; s \cdot L_{max})$.
 - 2: **for** $j \in nb$ **do**
 - 3: Calcular el PGA en las subestaciones en el nodo j , PGA_j , luego utilizarlo para calcular el valor de la probabilidad de causar cualquier estado de daño. Generar un número aleatorio $p \sim unif(0; 1)$, la siguiente indicación se realiza en el orden que se presenta.
 - 4: **for** $ds \in \{completo, severo, moderado, leve\}$ **do**
 - 5: Sea $q = \Phi \left[\frac{1}{\sigma_b^{ds}} \ln \frac{PGA_j}{\mu_b^{ds}} \right]$
 - 6: **if** $p \leq q$ **then**
 - 7: Sea $\gamma_{1j} = \alpha_{ds}$
 - 8: Break
 - 9: **for** $g \in ng$ **do**
 - 10: Calcular la PGA en los generadores en el nodo $j(g)$, $PGA_{j(g)}$. Generar un número aleatorio $p \sim unif(0; 1)$, la siguiente indicación se realiza en el orden que se presenta.
 - 11: **for** $ds \in \{completo, severo, moderado, leve\}$ **do**
 - 12: Sea $q = \Phi \left[\frac{1}{\sigma_g^{ds}} \ln \frac{PGA_{j(g)}}{\mu_g^{ds}} \right]$
 - 13: **if** $p \leq q$ **then**
 - 14: $\gamma_{2g} = \beta_{ds}$
 - 15: Break
 - 16: **for** $tw \in n_{tw}$ **do**
 - 17: Calcular la PGA en las torres de transmisión, PGA_{tw} . Generar un número aleatorio $p \sim unif(0; 1)$, la siguiente indicación se realiza en el orden que se presenta.
 - 18: **for** $ds \in \{completo\}$ **do**
 - 19: Sea $q = \Phi \left[\frac{1}{\sigma_{tw}^{ds}} \ln \frac{PGA_{tw}}{\mu_{tw}^{ds}} \right]$
 - 20: **if** $p \leq q$ **then**
 - 21: $\gamma_{3tw} = \Gamma_{ds}$
 - 22: Break
 - 23: Sea $P_g^{i,max}(\xi) = P_g^i \min\{\gamma_{1j(g)}, \gamma_{2g}\}$. Si algún $P_g^i(\xi)$ es 0 extraerlo del conjunto ng para formar $G(\xi)^0$. Sea $E(l, \xi)^0 = E$.
 - 24: **return** $([P_g^i(\xi), E(x, \xi)]_{g \in ng}, \xi)$
-

Para la operación del sistema eléctrico bajo la ocurrencia de distintas fallas en sus componentes, el modelo post-contingencia incorpora varios escenarios de contingencias que contienen diferentes estados de conexión y desconexión de generadores, líneas y cargas en función del análisis de vulnerabilidad de los componentes. En este sentido, el modelo post-contingencia determina los flujos óptimos de potencia activa y reactiva, y además permite cuantificar la ENS del sistema. Adicionalmente, el modelo de despacho post-contingencia puede poner en marcha unidades adicionales que no se hayan visto afectadas por el terremoto y que inicialmente no hayan participado en el pre-despacho.

Flujo óptimo de potencia AC

El problema de flujo óptimo de potencia AC es un modelo de optimización no lineal que optimiza el despacho del flujo de potencia en un sistema eléctrico en un solo período, dado el estado del sistema en el período anterior. El algoritmo se implementa como una extensión del paquete MATPOWER que permite calcular flujos de potencia y flujos de potencia óptimos en MATLAB. A continuación, se describe la versión estándar del problema de optimización AC-OPF que resuelve MATPOWER. Para mayor detalle de la nomenclatura y las ecuaciones revisar el manual [68].

$$\underset{u}{\text{mín}} \quad f(u) \quad (3.4)$$

sujeto a

$$g(u) = 0 \quad (3.5)$$

$$h(u) \leq 0 \quad (3.6)$$

$$u_{\min} \leq u \leq u_{\max} \quad (3.7)$$

La función objetivo $f(u)$ consiste en el costo polinómico de las inyecciones del generador, las restricciones de igualdad $g(u)$ son las ecuaciones de equilibrio de potencia, las restricciones de desigualdad $h(u)$ son los límites de flujo en el tramo, y los límites u_{\min} y u_{\max} incluyen ángulos de barra de referencia, magnitudes de voltaje e inyecciones del generador. El número de barras, tramos y generadores son n_b , n_l y n_g , respectivamente.

El vector de optimización u para el problema de AC-OPF consiste en los vectores $n_b \times 1$ de ángulos de voltaje Θ y magnitudes V_m , y los vectores $n_g \times 1$ de inyecciones de potencia activa y reactiva P_g y Q_g , respectivamente.

$$x = \begin{bmatrix} \Theta \\ V_m \\ P_g \\ Q_g \end{bmatrix} \quad (3.8)$$

La función objetivo $f(u)$ en la ecuación 3.4 es una suma de funciones de costo polinomiales individuales f_p^i y f_q^i de inyecciones de potencia activa y reactiva, respectivamente, para cada generador:

$$f(P_g, Q_g) = \sum_{i=1}^{n_g} f_P^i(p_g^i) + f_Q^i(q_g^i) \quad (3.9)$$

Las restricciones de igualdad en la ecuación 3.5 son el conjunto completo de $2 \cdot n_b$ ecuaciones no lineales de balance de potencia activa y reactiva, P_{bus} y Q_{bus} respectivamente, expresadas como funciones de los ángulos Θ y las magnitudes de voltaje V_m , las inyecciones del generador P_g y Q_g y la matriz de conexión C_g , donde P_d y Q_d son la cantidad de potencia activa y reactiva consumida en una barra, respectivamente.

$$g_P(\Theta, V_m, P_g) = P_{bus}(\Theta, V_m) + P_d - C_g P_g = 0 \quad (3.10)$$

$$g_Q(\Theta, V_m, Q_g) = Q_{bus}(\Theta, V_m) + Q_d - C_g Q_g = 0 \quad (3.11)$$

Las restricciones de desigualdad en la ecuación 3.6 consisten en dos conjuntos de n_l límites de flujo del tramo como funciones no lineales de las magnitudes y ángulos de voltaje de la barra, una para el extremo f y otra para el extremo t de cada tramo:

$$h_f(\Theta, V_m) = |F_f(\Theta, V_m)| - F_{max} \leq 0 \quad (3.12)$$

$$h_t(\Theta, V_m) = |F_t(\Theta, V_m)| - F_{max} \leq 0 \quad (3.13)$$

Los límites variables de la ecuación 3.7 incluyen una restricción de igualdad en cualquier ángulo de barra de referencia y los límites superior e inferior en todas las magnitudes de voltaje de barra e inyecciones de potencia activa y reactiva del generador.

$$\theta_i^{ref} \leq \theta_i \leq \theta_i^{ref}, \quad i \in \mathfrak{I}_{ref} \quad (3.14)$$

$$v_m^{i,min} \leq v_m^i \leq v_m^{i,max}, \quad i = 1 \dots n_b \quad (3.15)$$

$$p_g^{i,min} \leq p_g^i \leq p_g^{i,max}, \quad i = 1 \dots n_g \quad (3.16)$$

$$q_g^{i,min} \leq q_g^i \leq q_g^{i,max}, \quad i = 1 \dots n_g. \quad (3.17)$$

Flujo óptimo de potencia AC para resiliencia

En esta sección, se modifica la formulación de AC-OPF y se incorpora el índice de energía no suministrada con un costo asociado. Los parámetros aleatorios considerados son la disponibilidad de una línea (es decir $E(\xi; x)$) y la capacidad de las unidades de generación ($P_g(\xi)$), bajo el escenario ξ . Además, x representa la topología del sistema considerando las decisiones de inversión que entrega el optimizador. Entonces, dado el estado del sistema en el modelo pre-contingencia, se propone el siguiente modelo AC-OPF post-contingencia:

$$\min_{\Theta, V_m, P_g, Q_g} \left\{ \sum_{i \in n_g(\xi)} (f_P^i(p_g^i) + f_Q^i(q_g^i)) + \sum_{j \in n_b} \zeta_d^j ENS_d^j \right\} \quad (3.18)$$

sujeto a

$$g_P(\Theta, V_m, P_g) = P_{bus}(\Theta, V_m) + P_d - C_g P_g + ENS_d = 0 \quad (3.19)$$

$$g_Q(\Theta, V_m, Q_g) = Q_{bus}(\Theta, V_m) + Q_d - C_g Q_g = 0 \quad (3.20)$$

$$h_f(\Theta, V_m) = |F_f(\Theta, V_m)| - F_{max} \leq 0, \quad \forall f \in E(x, \xi) \quad (3.21)$$

$$h_t(\Theta, V_m) = |F_t(\Theta, V_m)| - F_{max} \leq 0, \quad \forall t \in E(x, \xi) \quad (3.22)$$

$$\theta_i^{ref} \leq \theta_i \leq \theta_i^{ref}, \quad i \in \mathcal{I}_{ref} \quad (3.23)$$

$$v_m^{i,min-post} \leq v_m^i \leq v_m^{i,max-post}, \quad \forall i \in n_b \quad (3.24)$$

$$p_g^{i,min} v_g^i \leq p_g^i \leq p_g^{i,max}(\xi) v_g^i, \quad \forall i \in n_g(\xi) \quad (3.25)$$

$$q_g^{i,min} v_g^i \leq q_g^i \leq q_g^{i,max}(\xi) v_g^i, \quad \forall i \in n_g(\xi) \quad (3.26)$$

$$p_g^i \leq (p_g^{i,pre} + RU_g) v_g^i, \quad \forall i \in n_g(\xi) \quad (3.27)$$

$$p_g^i \leq (p_g^{i,pre} - RD_g) v_g^i, \quad \forall i \in n_g(\xi) \quad (3.28)$$

$$v_g \in \{0, 1\}, p_g^i \geq 0, ENS_d \geq 0, \quad \forall i \in n_g(\xi) \quad (3.29)$$

En la ecuación 3.18 el costo de la energía no suministrada ζ_d^j se modela con un par de órdenes de magnitud mayor que el costo de producción. El modelo incorpora la idea de que es más costoso no suministrar energía que asumir un costo de generación adicional. Las restricciones de las ecuaciones 3.19 y 3.20 son el conjunto completo ecuaciones no lineales de balance de potencia activa y reactiva en cada nodo de la red, respectivamente. La ENS_d es la energía no suministrada en las barras de carga. Para obtener la ENS para cada contingencia, se conectan generadores virtuales en las barras que existe carga para garantizar que el sistema siga convergiendo cuando uno o varios componentes (generadores o líneas) se desconectan y de esta forma la ENS puede obtenerse de una forma relativamente sencilla. La capacidad de estos generadores virtuales es igual a la cantidad de carga en la barra al que están conectados. Estos generadores virtuales permiten representar la ENS de cada contingencia asumiendo un alto costo de interrupción. Además, los generadores virtuales no generarán ninguna cantidad de energía a menos que sea necesario, ya que se establecen un alto valor de costo de generación, y el flujo óptimo de potencia siempre irá primero por el generador más barato. Las restricciones de las ecuaciones 3.21 y 3.22 son funciones no lineales del flujo en la línea de transmisión que corresponde una para el extremo f y otra para el extremo t , respectivamente. Cada línea disponible debe cumplir con su capacidad dependiendo del escenario de contingencia. En la ecuación 3.23 cada barra en el sistema tiene asociado un ángulo de voltaje (θ) y en la ecuación 3.24 los límites superior e inferior de las magnitudes de voltaje para condiciones de emergencia. En las ecuaciones (3.25-3.29) se representa la generación, que contiene valores de generación de capacidad mínima y máxima por unidad. La capacidad de generación depende de la realización del escenario de algún daño en la red. El generador no puede exceder su rampa de subida (RU_g) y su rampa de bajada (RD_g). Suponer que la potencia inyectada por el generador ($p_g^{i,pre}$) y la variable binaria (v_g^i) que es igual a 1 si la unidad g está disponible y 0 en caso contrario, se dan como un estado inicial para el período post-contingencia.

3.2.4. Métricas de resiliencia

Dependiendo del objetivo del estudio de resiliencia, el desempeño de los sistemas eléctricos se puede medir utilizando diferentes métricas [10]. Una métrica que se ha utilizado ampliamente en los estudios de confiabilidad y se ha adoptado en estudios de resiliencia, se refiere al valor esperado de la ENS, es decir, EENS (del inglés Expected Energy Not Supplied) que se refiere a los valores dominados por eventos creíbles (tales como N-1 o N-2). Por otro lado, en [1] se explica que las mejoras resilientes pueden entenderse como limitantes de la exposición a eventos HILP que generalmente se colocan en la “cola” (derecha) de la función de densidad de probabilidad de la ENS, donde los valores de la ENS son más altos (ver figura 3.3). Para representar matemáticamente esa cola, se podría usar varias métricas de riesgo, como el valor condicional en riesgo (CVaR) o cualquier valor de expectativa condicional de ENS en esos escenarios que componen la cola. El valor esperado condicional de la ENS cuando está condicionado a eventos HILP, es decir, CEENS (del inglés Conditional Expected Energy Not Supplied) permite describir el impacto del evento extremo dentro de un marco de tiempo. Mientras que CVaR mide el déficit esperado debido a los eventos de mayor impacto más allá de un umbral de riesgo previamente especificado, α . Dado que ambas métricas cuantifican específicamente las pérdidas extremas debido a eventos de baja probabilidad, son adecuadas para la evaluación comparativa de los beneficios potenciales ofrecidos por las alternativas de inversión en la planificación de sistemas eléctricos. Por lo tanto, para este trabajo se utiliza como métrica el valor CEENS.

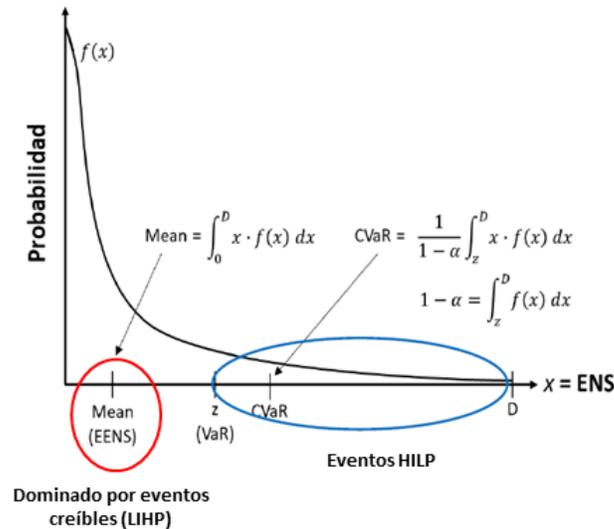


Figura 3.3: Métricas de Resiliencia [1]

Además, se pueden utilizar otras métricas como las propuestas en [10] dentro de un marco probabilístico para mejorar un aspecto específico de la resiliencia. Estas métricas son definidas por los autores como el sistema FLEP (del inglés Fast-Low-Extensive-Promptly) en términos de resiliencia operativa y de infraestructura. Estas se introducen específicamente para capturar las características críticas de degradación y restauración que el sistema eléctrico puede experimentar durante un evento extremo. El triángulo de resiliencia presentado en la figura 3.4 permite representar gráficamente la degradación de la funcionalidad del sistema por daños e interrupciones, así como la restauración en el tiempo de una infraestructura

después del evento. De acuerdo con la figura 3.4, el nivel de resiliencia del sistema eléctrico expuesto a terremotos se puede representar en tres intervalos de tiempo. La primera fase, cubre el intervalo de tiempo $[t_0, t_{oe}]$, donde se muestra el nivel de resiliencia del sistema antes del evento disruptivo. Cuando se trata de un terremoto cuya duración del impacto es en segundos, se produce una degradación de la resiliencia que puede ser severa e inmediata en el tiempo t_{oe} . Durante este período, el nivel de resiliencia del sistema disminuye gradualmente desde el valor inicial R_{0o}, R_{0i} (operativa y de infraestructura respectivamente) hasta su valor mínimo, es decir, R_{pdo}, R_{pdi} . Luego con el inicio del proceso de restauración en el momento t_r , el nivel de resiliencia del sistema eléctrico vuelve gradualmente a su estado original (el valor deseado antes del desastre, R_{0o}, R_{0i}). El tiempo después de T_{or}, T_{oi} es el estado de resiliencia después de completar el proceso de recuperación del sistema.

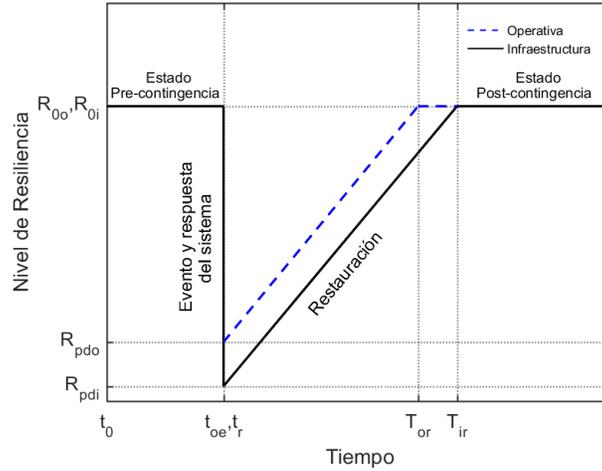


Figura 3.4: Triángulo de Resiliencia

3.3. Optimizador

En esta sección, se propone un procedimiento de optimización que considera la salida del modelo de simulación como una función general $\mu(x)$ con estructura desconocida que, en este caso, cuantifica el nivel de resiliencia de una red eléctrica dada y cuyo valor se desea optimizar. Una formulación general de la OvS se plantea de la siguiente forma:

$$\min_{x \in X} \mu(x) \quad (3.30)$$

donde el conjunto X tiene un número finito de soluciones factibles, y $\mu(x)$ es una función desconocida (las denominadas funciones de caja negra o black-box¹), es decir, solo se puede estimar $\mu(x)$ numéricamente mediante muestreo.

Por lo tanto, se supone que el aumento de la resiliencia de la red puede traducirse directamente en una minimización de la esperanza condicional de la energía no suministrada que

¹El término black-box hace referencia a un objeto, sistema o algoritmo que se estudia desde el punto de vista de las entradas que recibe y las salidas o respuestas que produce, sin tener en cuenta su funcionamiento interno.

resulta como consecuencia de terremotos de gran magnitud. Dicho problema de minimización tendrá que presentar una restricción de presupuesto que contribuya a reflejar la aversión al riesgo del planificador (es decir, cuanto mayor sea el presupuesto, mayor será la aversión y la voluntad de invertir en mejoras resilientes contra eventos HILP). En consecuencia, el modelo se puede escribir como se muestra en la ecuación 3.31.

$$\begin{aligned}
& \underset{x}{\text{mín}} \quad \{F(x) = \mathbb{E}[ENS(x, \xi)]\} \\
& \text{s.t.} \quad \sum_{i \in X} a_i x_i \leq b, \\
& \quad \quad x_i \in \{0, 1\}, \forall i \in X.
\end{aligned} \tag{3.31}$$

donde las variables binarias x_i representan todas las decisiones de mejora de la red. Los parámetros a_i representan los costos asociados a la aplicación de x_i y b es el presupuesto total que se permite invertir en mejorar la resiliencia del sistema. El conjunto X contiene todas las posibles propuestas de mejora de la red y ξ corresponde a la realización de la incertidumbre, en este caso, las fallas del sistema debido a los terremotos.

Por consiguiente, se considera que el costo de cualquier mejora de la red es el mismo, lo que equivale a tener $a_i = 1$ para todo i y, por lo tanto, el presupuesto b se convierte en un valor entero que representa el posible número de inversiones simultáneas de la red que se pueden llevar a cabo y tengan mayor impacto en la reducción al mínimo de las ENS causadas por los terremotos. Las decisiones de inversión permitidas son instalar equipos de compensación reactiva en las barras. Estos equipos distribuidos estratégicamente permiten mejorar la distribución de los flujos de potencia y mejorar la capacidad de transporte de las líneas de transmisión, y también permiten mantener el perfil de voltaje dentro de condiciones de operación aceptables, sin embargo, evaluar esta alternativa plantea un problema de análisis combinatorial importante, porque se analiza todas las posibles ubicaciones de los equipos y con diferentes presupuestos.

Para lidiar con esto se utiliza el algoritmo de OvS basado en un algoritmo genético. El algoritmo genético utilizado es una función de la herramienta Global Optimization Toolbox de Matlab, que permite resolver problemas de optimización en los que la función objetivo es una función black-box. Para más detalles, ver sección 6.5 de los Apéndices.

El algoritmo considera todo el espacio de probabilidad, donde cada muestra representa una realización aleatoria de un terremoto y las consecuentes fallas de la red (ver figura 3.5) que, en un sistema grande representar toda esta incertidumbre significa un gran conjunto de escenarios que dificulta su resolución. Por lo tanto, la aplicación directa del modelo de simulación mediante Monte Carlo no se puede lograr de una manera computacionalmente efectiva.

Se utiliza el método de SAA para tratar este problema de dimensionalidad. La técnica de muestreo se emplea para reducir el número de escenarios del sistema, fijando parte de la incertidumbre dada por la distribución de los terremotos al inicio de la optimización (ver figura 3.6).

3.3.1. Aproximación por promedio muestral

La metodología de SAA aborda el problema de cálculo del valor esperado $\mathbb{E}[ENS(x, \xi)]$ mediante la generación de muestras de un vector aleatorio ξ , y el posterior proceso de promediar los resultados. Suponiendo que ξ_1, \dots, ξ_N son N realizaciones de vectores aleatorios para todas las incertidumbres en el modelo, de modo que el valor esperado $\mathbb{E}[ENS(x, \xi)]$ es aproximado por la función promedio de las muestras obtenidas. Esto conduce al problema de aproximación por promedio muestral (SAA)

$$\min_{x \in X} \left\{ \hat{F}_N(x) = \frac{1}{N} \sum_{j=1}^N ENS(x, \xi_j) \right\} \quad (3.32)$$

del problema original 3.31. Debe tenerse en cuenta que cada escenario ocurre con probabilidad $\frac{1}{N}$ dentro de la función SAA. Para una realización particular de la muestra aleatoria, el correspondiente problema de SAA es un problema de programación estocástica con los respectivos escenarios ξ_1, \dots, ξ_N cada uno tomado con probabilidad $\frac{1}{N}$.

Según la Ley de los Grandes Números, bajo la condición de que $\hat{F}_N(x)$ converge de forma casi segura a $F(x)$ cuando $N \rightarrow \infty$ (la muestra es independiente e idénticamente distribuida), se tiene que $\mathbb{E}[\hat{F}_N(x)] = F(x)$, es decir, $\hat{F}_N(x)$ es un estimador insesgado de $F(x)$. Sea ϑ^* el valor óptimo del problema original (3.31) y $\hat{\vartheta}_N$ y \hat{x}_N el valor óptimo y la solución óptima del problema de SAA (3.32), respectivamente. Suponer que se tiene un punto factible $\bar{x} \in X$ como candidato para una solución óptima del problema original. Luego, utilizando el método de SAA, es posible estimar el gap de optimalidad

$$gap(\bar{x}) = F(\bar{x}) - \vartheta^*$$

asociado con \bar{x} , al resolver muchos problemas de optimización como el problema (3.32).

Considerar que $\hat{\vartheta}_N \leq \vartheta^*$, por lo tanto, $\hat{\vartheta}_N$ constituye un límite inferior del valor objetivo óptimo. Notar que:

$$\vartheta^* = \min_{x \in X} \{\mathbb{E}[F(x, \xi)]\} = \min_{x \in X} \left\{ \mathbb{E} \left[\frac{1}{N} \sum_{j=1}^N F(x, \xi_j) \right] \right\} \quad (3.33)$$

Dado que $\hat{\vartheta}_N$ es la solución óptima del problema de SAA, entonces lo siguiente es cierto:

$$\min_{x \in X} \left\{ \frac{1}{N} \sum_{j=1}^N F(x, \xi_j) \right\} \leq \frac{1}{N} \sum_{j=1}^N F(x, \xi_j) \quad (3.34)$$

Tomando la esperanza en ambos lados, la ecuación 3.34 se convierte en:

$$\mathbb{E} \left[\min_{x \in X} \left\{ \frac{1}{N} \sum_{j=1}^N F(x, \xi_j) \right\} \right] \leq \mathbb{E} \left[\frac{1}{N} \sum_{j=1}^N F(x, \xi_j) \right] \quad (3.35)$$

Dado que el SAA es un estimador insesgado de la media de la población

$$\mathbb{E}[\hat{\vartheta}_N] \leq \min \left\{ \mathbb{E} \left[\frac{1}{N} \sum_{j=1}^N F(x, \xi_j) \right] \right\} = \vartheta^* \quad (3.36)$$

que constituye un límite inferior del valor objetivo óptimo. A continuación, se presentan los detalles para obtener estimaciones de límite inferior y superior.

Estimaciones del límite inferior

Sea $\bar{v}_{N,M}$ un estimador insesgado de $\mathbb{E}[\hat{\vartheta}_N^k]$, que puede estimarse generando M lotes independientes, cada uno de N muestras.

$$\bar{v}_{N,M} = \frac{1}{M} \sum_{k=1}^M \hat{\vartheta}_N^k. \quad (3.37)$$

Sea $\hat{\sigma}_{N,M}^2$ un estimador de varianza de $\bar{v}_{N,M}$.

$$\hat{\sigma}_{N,M}^2 = \frac{1}{M} \left[\frac{1}{M-1} \sum_{k=1}^M (\hat{\vartheta}_N^k - \bar{v}_{N,M})^2 \right] \quad (3.38)$$

El límite inferior de confianza del $100(1 - \alpha)\%$ del valor esperado $\mathbb{E}[\hat{\vartheta}_N^k]$ (y, por lo tanto, del valor óptimo del problema original dada la condición 3.36) es

$$L_{N,M} = \hat{v}_{N,M} - t_{\alpha, M-1} \hat{\sigma}_{N,M}. \quad (3.39)$$

donde $t_{\alpha, M-1}$ es el valor de un t-student con una significancia del $100 \times \alpha\%$ y $M - 1$ grados de libertad.

Estimaciones del límite superior

Se puede obtener una estimación aproximada del límite superior del $100 \times (1 - \alpha)\%$ de

$$U_{N_U}(\bar{x}) = \hat{F}_{N_U}(\bar{x}) + z_\alpha \bar{\sigma}_{N_U}(\bar{x}), \quad (3.40)$$

donde \bar{x} es la solución candidata dada, N_U es el número que da la estimación promedio de la muestra de $F(\bar{x})$, y

$$\sigma_{N_U}^2(\bar{x}) = \frac{1}{N_U(N_U - 1)} \sum_{j=1}^{N_U} \left[F(\bar{x}, \xi_j) - \hat{F}_{N_U}(\bar{x}) \right]^2, \quad (3.41)$$

una estimación de la varianza de $\hat{F}_{N_U}(\bar{x})$. Se supone que el valor de N_U es muy grande, por lo tanto, el valor crítico z_α proviene de una distribución normal estándar en lugar de una distribución t-student.

Finalmente, el método de SAA se usa para estimar un límite superior en el valor del gap de la solución candidata \bar{x} :

$$\mathbb{E}[\hat{F}_{N_U}(\bar{x}) - \bar{v}_{N,M}] = F(\bar{x}) - \mathbb{E}[\hat{\vartheta}_N] = \text{gap}(\bar{x}) + \vartheta^* - \mathbb{E}[\hat{\vartheta}_N] \geq \text{gap}(\bar{x}), \quad (3.42)$$

Por lo tanto, $\hat{F}_{N_U}(\bar{x}) - \bar{v}_{N,M}$ es un estimador sesgado del $gap(\bar{x})$. Y se puede obtener un límite superior de confianza del $100(1 - \alpha)\%$ para el $gap(\bar{x})$ de

$$\hat{F}_{N_U}(\bar{x}) - \bar{v}_{N,M} + z_\alpha \sqrt{\hat{\sigma}_{N,M}^2 + \bar{\sigma}_{N_U}^2(\bar{x})}.$$

Hay dos tipos de error al usar $\bar{v}_{N,M}$ como estimador de ϑ^* , a cococer, el sesgo $\vartheta^* - \mathbb{E}[\bar{\vartheta}_N]$ y la variabilidad de $\bar{v}_{N,M}$ medida por su varianza. Ambos errores pueden reducirse aumentando N , y la varianza $\hat{\sigma}_{N,M}^2$ también puede reducirse aumentando M . Sin embargo, hay que tener en cuenta que el esfuerzo computacional en el cálculo de $\bar{v}_{N,M}$ es proporcional a M , ya que los correspondientes problemas de SAA deben ser resueltos M veces y al tiempo computacional para resolver un solo problema de SAA basado en una muestra de tamaño N . En los casos en que la complejidad computacional de los problemas de SAA crece rápidamente con el aumento del tamaño de la muestra N , puede ser más ventajoso utilizar un mayor número de repeticiones M . El sesgo $\hat{F}_{N_U}(\bar{x}) - \bar{v}_{N,M}$ no depende de M , cuando el procedimiento de optimización es exacto para obtener la solución óptima del problema 3.32. Ver Proposición 5.6 de [69]. Si la muestra es i.i.d., entonces $\mathbb{E}[\hat{\vartheta}_N] \leq \mathbb{E}[\hat{\vartheta}_{N+1}]$ para cualquier $N \in \mathbb{N}$. De esto se deduce que el sesgo $\vartheta^* - \mathbb{E}[\hat{\vartheta}_N]$ disminuye monotónicamente con un aumento de la muestra tamaño N , ver Teorema 5.7 de [69].

Debe tenerse en cuenta que la solución obtenida con este enfoque basado en muestras no garantiza como tal la optimización en el problema original 3.31. Las soluciones óptimas basadas en muestreo, cuando se obtienen con diferentes conjuntos de muestras, más bien proporcionan una inferencia estadística de un intervalo de confianza de la solución óptima real.

Algorithm 2 Procedimiento Secuencial de Monte Carlo (SMC)

Require: La topología del sistema $x \in \Omega$.

- 1: Resolver un predespacho dada la topología existente del sistema.
 - 2: Muestrear un escenario de terremoto dado por $\psi \in \Psi(x)$ (Ψ es el soporte de los parámetros que describen la ocurrencia de un determinado terremoto con ciertas características). Luego obtener la realización del daño en la red $\delta(\psi(x))$.
 - 3: Resolver un AC-OPF utilizando la nueva topología afectada. Obtener la $[ENS_d]_{d \in nb}$ que es la energía no suministrada de la solución óptima (o cercana a la óptima).
 - 4: **return** $ENS(x, \xi = (\psi, \delta(\psi))) = \sum_{d \in nb} ENS_d + P_d - P_d(\xi)$
-

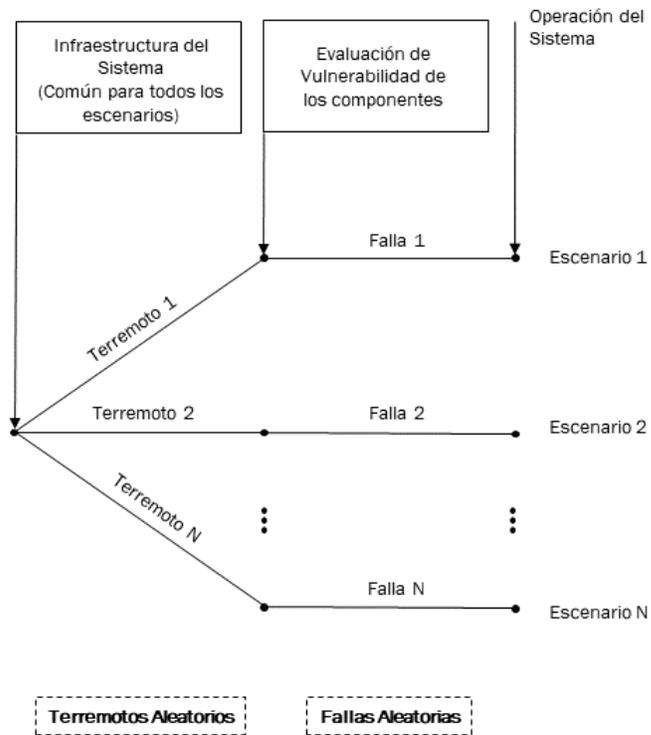


Figura 3.5: Marco de total incertidumbre: árbol de escenarios

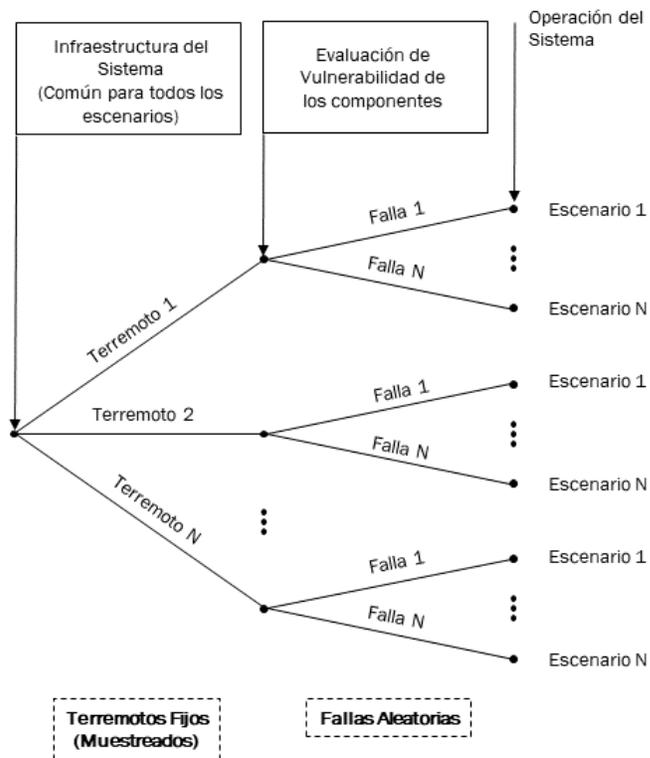


Figura 3.6: SAA: árbol de escenarios

Capítulo 4

Casos de estudio y resultados

En este capítulo se presentan los casos de estudio para evaluar el modelo de simulación y optimización y determinar la inversión cuasi-óptima de equipos de compensación reactiva, con el fin de mejorar la resiliencia del sistema eléctrico frente a la ocurrencia de eventos sísmicos. Para esto se utiliza el sistema de prueba IEEE RTS de 24 barras modificado para una evaluación de múltiples contingencias.

En la etapa de simulación se utiliza la metodología propuesta en la sección 3.2. Para la realización de escenarios se consideran terremotos de magnitud de 7.8 Mw con una profundidad focal de 20 *km*, la ubicación del epicentro se genera mediante variables aleatorias uniformemente distribuidas en un mapa ficticio con un área de $210 \times 210 \text{ km}^2$ mostrada en la figura 4.1, que también muestra la ubicación de los componentes de la red y la atenuación de la PGA para la realización de un terremoto en particular. Todo el proceso de generación de escenarios de terremotos y las consecuentes fallas de los componentes de la red son obtenidas mediante simulaciones secuenciales de Monte Carlo e implementado en MATLAB. Luego, se realiza un AC-OPF para determinar los parámetros eléctricos en cada escenario de contingencia generado a través de las simulaciones. Esta etapa se implementa en MATPOWER [68], que es una librería de código abierto para la simulación y optimización de sistemas eléctricos. El problema de optimización se resuelve utilizando la función *ga* de la herramienta Global Optimization Toolbox de MATLAB.

A continuación, se presentan los casos de estudio del modelo propuesto para identificar la mejor solución de inversión en equipos de compensación de potencia reactiva para interrupciones originadas por terremotos de gran magnitud. Estos casos de estudio consisten en: el caso base, donde no se aplica ninguna estrategia de mejora a la red de prueba y, por otra parte, se consideran 24 soluciones candidatas (un equipo por cada barra del sistema) como propuestas de mejora para aumentar la resiliencia del sistema frente a eventos sísmicos. Los dispositivos de compensación de potencia reactiva corresponden a activos adicionales que se pueden agregar/instalar, esta es una decisión para fortalecer la infraestructura existente (en este ejemplo, se supone que una barra es en realidad una subestación de transmisión, excepto las barras 3 y 24 que forman una subestación y las barras 9, 10, 11 y 12 forman otra subestación).

Finalmente, se presenta el análisis de resultados de la validación del modelo propuesto de optimización vía simulación. Primero, se utiliza una técnica de ranking para realizar la evaluación completa de todo el conjunto de propuestas de mejora de la red, que es significativamente más costoso en términos computacionales. Segundo, se utiliza el algoritmo de OvS para realizar la búsqueda de la solución cuasi-óptima en la etapa de inversión, y se evalúan y comparan el marco de total incertidumbre y el método de SAA para demostrar la robustez de las soluciones.

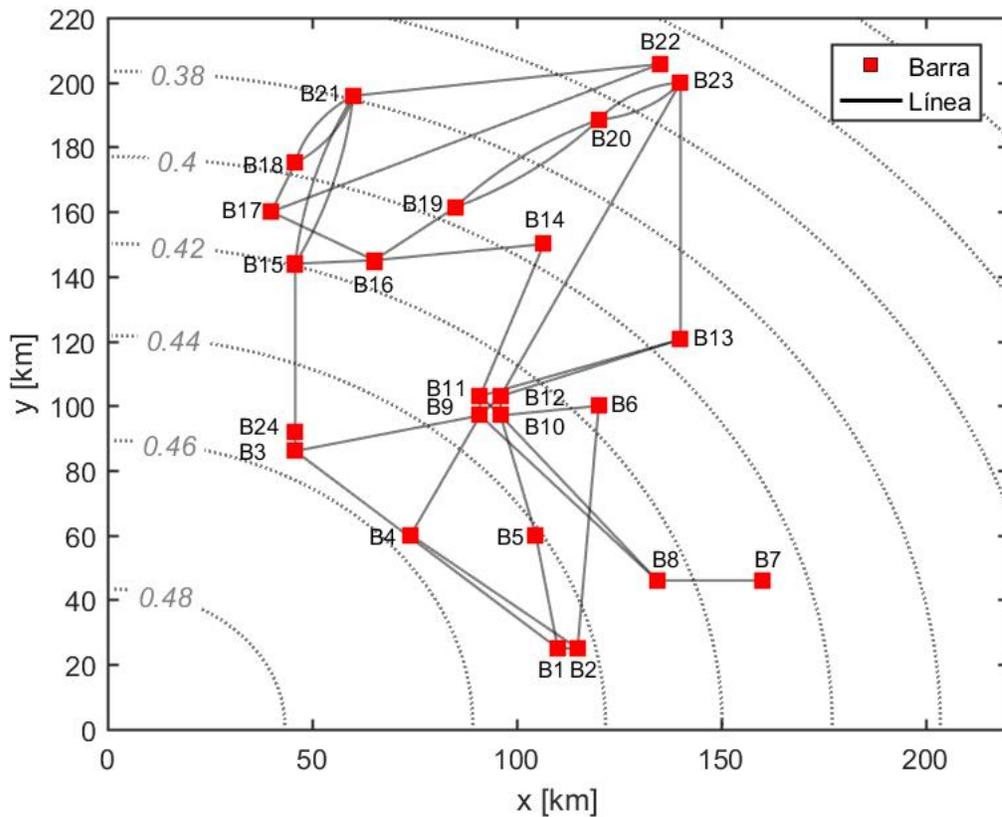


Figura 4.1: Configuración espacial de la red y atenuación logarítmica de la PGA para un terremoto ilustrativo con un epicentro en (0,0) km. Los valores de PGA (es decir, contornos) se muestran en [g].

4.1. Descripción de los datos de entrada

El modelo propuesto en el presente trabajo se aplica en el sistema de prueba IEEE-RTS de 24 barras modificado, ver la figura 4.2. Esta red consiste en 24 barras, 33 líneas de transmisión en configuración simple circuito, 5 transformadores y 33 unidades de generación. Se pueden encontrar más detalles sobre esta red de prueba en [15]. Cabe mencionar que para el desarrollo de este trabajo se realizaron algunas modificaciones a la red de prueba, las cuales se detallan a continuación:

- a) Se incremento la condición de demanda máxima del sistema como se describe en la tabla 6.1.
- b) Se incremento el vector de capacidades instaladas de generación como se describe en la tabla 6.1.

Hay que considerar que las modificaciones a) y b) son particularmente adecuadas para permitir realizar un análisis más razonable, con el objetivo de evaluar los efectos de los cambios topológicos en la transmisión e identificar las limitaciones existentes en la operación del sistema debido a la desconexión de varios componentes de forma simultánea producto de los terremotos. Otros datos importantes son las ubicaciones de los componentes vulnerables (generadores y subestaciones) de la red eléctrica, estos se presentan en la tablas 6.2 y 6.3 respectivamente.

4.2. Descripción de los casos de estudio

En esta sección se presentan los casos de estudio para cuantificar el riesgo y determinar la inversión cuasi-óptima en equipos de compensación de potencia reactiva, con el fin de mitigar los efectos adversos de eventos naturales en el suministro eléctrico y así mejorar la resiliencia de las redes eléctricas.

4.2.1. Caso base

El caso base corresponde a la implementación de la metodología descrita en el capítulo 3 bajo las siguientes consideraciones:

- Se cuantifica el riesgo frente a la ocurrencia de terremotos considerando métricas de resiliencia e indicadores de resiliencia en la infraestructura.
- Se evalúa el efecto del impacto de los terremotos en variables eléctricas del sistema. Se consideran los voltajes de las barras y los flujos en las líneas de transmisión.
- No se realiza inversión en equipos de compensación de potencia reactiva.

Además, para asegurar que el nivel de riesgo asociado a cada una de las soluciones se encuentre dentro de un intervalo de confianza aceptable se evalúan 10000 simulaciones y se considera un grado de confianza del 95 %.

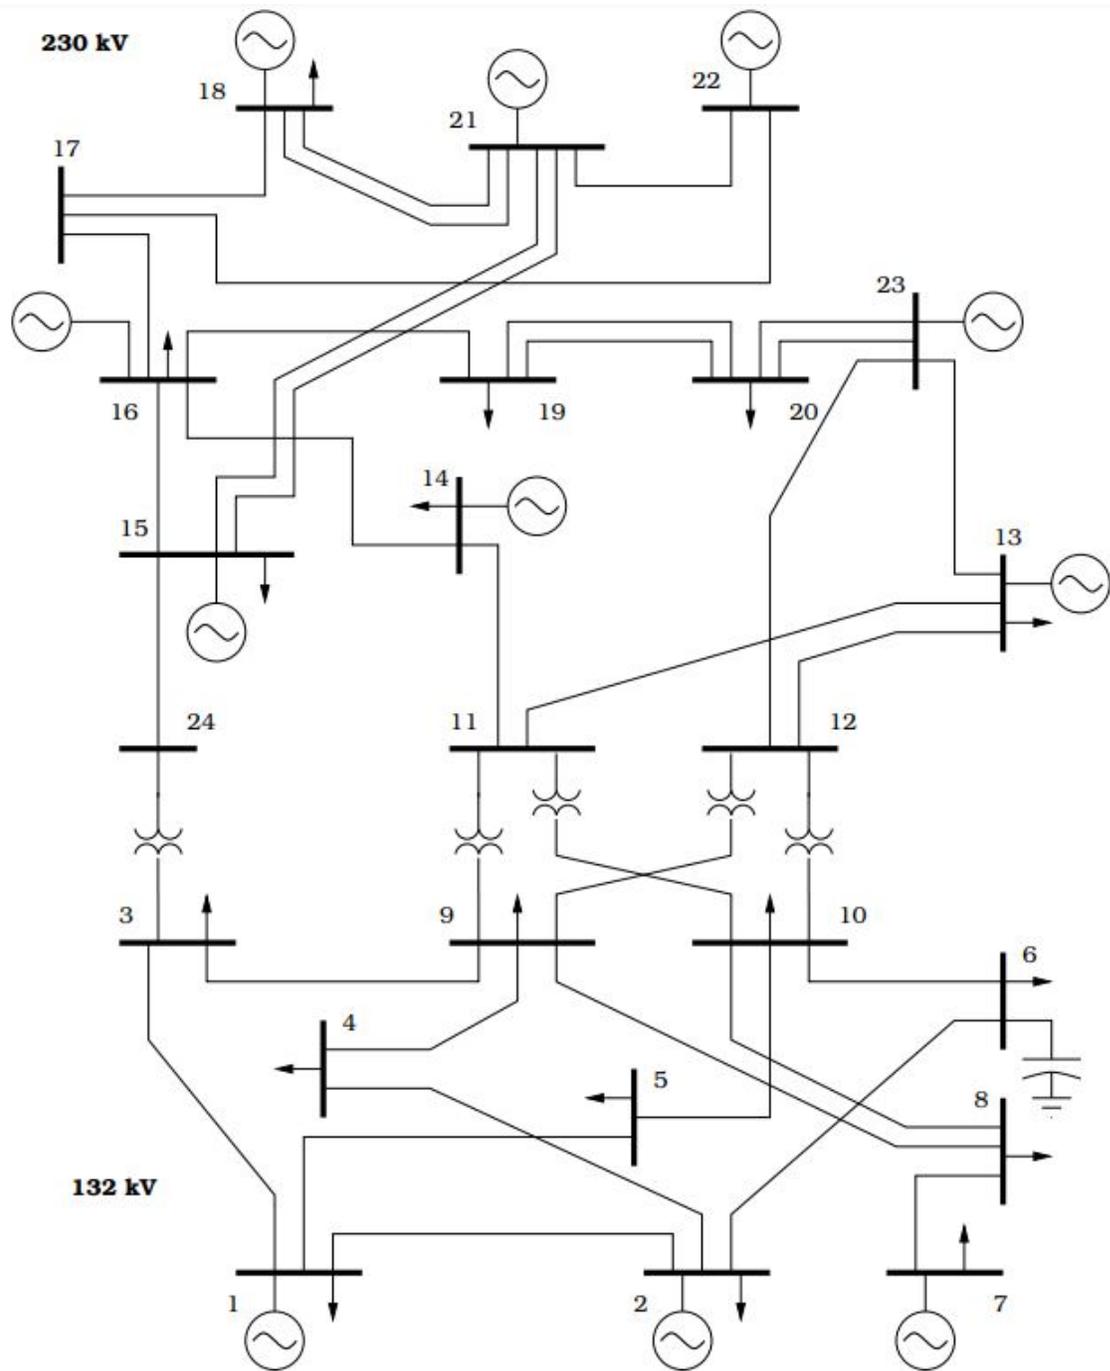


Figura 4.2: Sistema de prueba IEEE-RTS de 24 barras

4.2.2. Cuantificación del riesgo

Los casos de estudio de cuantificación del riesgo permiten representar el impacto e identificar los componentes vulnerables de la red eléctrica en el instante que ocurren los eventos sísmicos. Para esto, se utilizan métricas de resiliencia e indicadores de resiliencia en la infraestructura para cuantificar el impacto en la energía no suministrada de las redes eléctricas y representar la vulnerabilidad de la transmisión mediante mapas de riesgo para obtener una imagen completa del nivel de resiliencia del sistema prevaleciente.

En el marco de simulación se adopta una visión probabilística de las métricas e indicadores para cuantificar un aspecto específico de la resiliencia en los siguientes términos:

Métrica de riesgo

En respuesta a la necesidad de métricas de resiliencia cuantitativas y basadas en el riesgo, se ha introducido un proceso iterativo para el análisis de resiliencia. Este marco da como resultado la representación de las métricas desarrolladas como funciones de densidad de probabilidad de las consecuencias de una o más amenazas a una red eléctrica. Las métricas no solo se utilizan para medir la resiliencia de un sistema existente frente a eventos extremos, sino también para analizar escenarios de inversión alternativos para mejorar la resiliencia.

La métrica de riesgo utilizada es el valor de CEENS condicionado a los eventos sísmicos. Esta métrica ha sido utilizada en la planificación de redes resilientes para cuantificar no sólo los impactos potenciales de los eventos exógenos, sino también para la evaluación comparativa de los posibles beneficios que ofrecen las alternativas de inversión en la planificación.

Mapas de Riesgo

Los mapas de riesgo son una herramienta útil para visualizar y generar información sobre las áreas o componentes del sistema que serán altamente vulnerables a un evento extremo y, además, permite mejorar el conocimiento de las zonas de alto riesgo. La aplicación de esta herramienta en los casos de estudio se centra en cuantificar el impacto de los terremotos en términos de ENS y utilizar indicadores de resiliencia de la infraestructura tales como el número de líneas de transmisión en servicio y subestaciones en servicio.

4.2.3. Impacto en variables eléctricas

Las redes eléctricas se debilitan después de un evento extremo debido a daños físicos en la infraestructura eléctrica. A medida que el sistema se debilita, podría limitar la capacidad de transmisión y junto con la indisponibilidad de generación podría dar lugar a la escasez de fuentes de generación para el suministro reactivo y problemas de control de voltaje que podrían afectar la seguridad de la red eléctrica.

Por lo tanto, en esta sección se evalúan los efectos de las múltiples interrupciones de los componentes del sistema que pueden conducir a la violación de los límites de voltaje de las barras y la capacidad de transmisión en las líneas. Para esto, se realizan simulaciones en el sistema de prueba mediante el modelo de AC-OPF para verificar las condiciones de operación del sistema en los estados pre-contingencia y post-contingencia.

Lo importante en esta sección es tratar de entender dónde está el riesgo, y determinar los componentes vulnerables del sistema, que no necesariamente podrían ser los de mayor ENS. En este sentido, es necesario realizar la medición y visualización de ciertas variables eléctricas que permitan determinar los componentes vulnerables durante el análisis de resiliencia.

4.2.4. Coberturas al riesgo mediante equipos de compensación reactiva

En esta sección se presentan los casos de estudio para resolver el problema de optimización que permite identificar la inversión cuasi-óptima en equipos de compensación de potencia reactiva, dado una restricción de presupuesto. Tanto para el caso base, donde no se aplica ninguna estrategia de mejora en la red de prueba, como para el caso donde se consideran 24 soluciones candidatas (un equipo de 100 MVar por cada barra del sistema) se utilizan dos enfoques para resolver el problema de optimización. En el primero enfoque se utiliza un método de ranking para evaluar todas las posibles soluciones, mientras que en el segundo enfoque se utiliza un algoritmo de OvS basado en un procedimiento heurístico de búsqueda para determinar las mejores soluciones del espacio factible, las cuales posteriormente son comparadas entre sí.

Además, es importante mencionar que para efectuar un análisis comparativo se utiliza un portafolio óptimo de soluciones candidatas considerando diferentes presupuestos. Para la restricción de presupuesto igual a 1, se utiliza el método de ranking para validar la correcta implementación del algoritmo de OvS. También, muestra cómo las principales características del algoritmo de OvS permite encontrar buenas soluciones. Cada evaluación se realiza fácilmente en esta configuración, lo que permite asignar una gran cantidad de evaluaciones a cada solución recién muestreada. Para presupuestos más grandes, los resultados se obtienen mediante el algoritmo de OvS.

Ranking

En este caso se consideran las propuestas de mejora que corresponden a una sola acción, es decir, agregar un único activo (equipo de compensación de potencia reactiva) en cada una de las barras. La evaluación propuesta considera que el conjunto completo de soluciones factibles presenta 24 equipos candidatos (uno por cada barra) más el caso base sin mejora. Cada una de las alternativas se evalúan a través de 10000 simulaciones con la metodología propuesta, y se clasifican en un ranking, en el cual se puede seleccionar la solución que sea estadísticamente mejor comparada con otras soluciones reportadas.

Optimización

Para resolver el problema de optimización mediante el algoritmo de OvS propuesto se utilizan y comparan dos métodos diferentes que ya fueron mencionados en las secciones anteriores. Los dos métodos experimentales son:

- Marco de total incertidumbre (OvS-FU)
- Aproximación por promedio muestral (OvS-SAA)

Tanto para el método de OvS-FU como para el método de OvS-SAA se utiliza el mismo modelo de optimización vía simulación propuesto y se establecen los mismos parámetros de configuración. Sin embargo, la diferencia entre ambos métodos está en el muestreo de la realización del terremoto. Para el método de OvS-FU, se muestrea todo el espacio de probabilidad y para cada simulación se obtiene una nueva muestra de la realización de terremoto y consecuentes fallas de la red. Mientras que para el método de OvS-SAA se puede muestrear un subconjunto de N escenarios fijos al inicio de la optimización y promediar los resultados de todos los escenarios.

Para el método de SAA se fijan 25 muestras de terremotos al inicio del procedimiento de optimización, por lo tanto, una sola evaluación requiere 25 simulaciones para cada solución. Para esto, primero se coloca la red de prueba en un mapa ficticio con un área de $210 \times 210 \text{ km}^2$, luego se divide arbitrariamente el mapa en 25 regiones como se muestra en la figura 4.3. En cada región se genera un terremoto con una ubicación fija del epicentro (ver tabla 6.4 en el Apéndice) y con parámetros iguales de intensidad y profundidad. Por otro lado, para muestrear la ubicación de los terremotos considerando el marco de total incertidumbre, se genera una variable aleatoria uniformemente distribuida en el área de $210 \times 210 \text{ km}^2$.

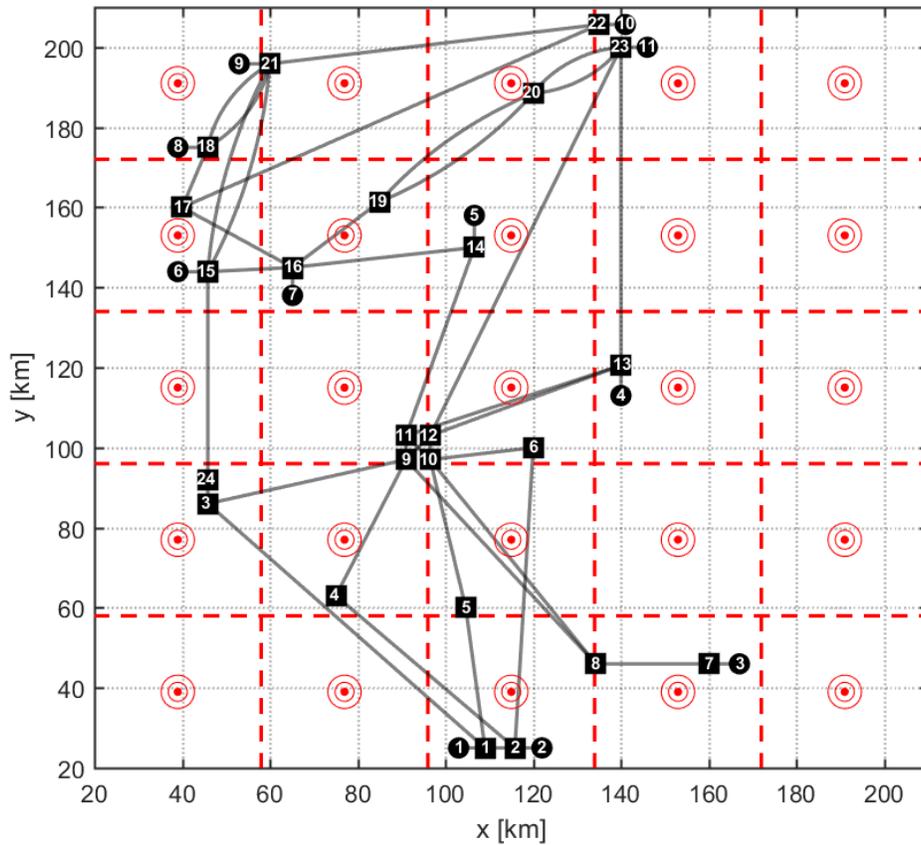


Figura 4.3: Localización de los terremotos en el plano

Es importante señalar que el algoritmo de OvS propuesto es esencialmente un método heurístico cuyo resultado puede cambiar en cada corrida debido a su naturaleza probabilística.

ca. Para hacer frente a esto, se propone una estrategia de dos etapas que permita determinar la mejor propuesta de inversión en equipos de compensación reactiva en la red eléctrica. En primer lugar, esta estrategia construye un conjunto de buenas soluciones candidatas que pueden ser obtenidas ejecutando 10 veces el algoritmo de OvS. Luego, en un segundo paso, se identifican las mejores soluciones reportadas entre el conjunto de equipos candidatos realizando un análisis por fuera de la muestra (del inglés out-of-sample ¹) para cada una de ellas.

El número de evaluaciones que se realiza en cada corrida depende del cumplimiento del criterio de parada del algoritmo, para este caso la solución debe cumplir con cierto nivel de confianza impuesto arbitrariamente para detener el algoritmo. No obstante, si la solución no llega a cumplir el criterio de parada impuesto se detendrá en un número de evaluaciones previamente fijado. Para comparar los resultados entre los métodos de OvS-FU y OvS-SAA, a cada una de las alternativas de solución se realiza un análisis out-of-sample, donde cada muestra representa una realización aleatoria de un terremoto y las consecuentes fallas de la red, a través de simulaciones secuenciales de Monte Carlo para medir el nivel de riesgo asociado a cada una de las soluciones.

Es importante mencionar que, para efectos de este trabajo, se evalúa el algoritmo de OvS para diferentes presupuestos, como se presenta a continuación:

- Para el presupuesto igual a 1, que permite validar los resultados del algoritmo de OvS comparando con los resultados obtenidos utilizando el método de ranking.
- Para presupuestos mayores a 1, se utiliza solo la heurística previamente descrita, correspondiente al algoritmo de OvS, dado que la complejidad del problema de optimización implica un crecimiento exponencial en el tiempo de cálculo de soluciones al aumentar el presupuesto permitido y el número de soluciones.

4.3. Resultados

En esta sección se muestran los resultados obtenidos de los casos de estudio descritos anteriormente.

4.3.1. Cuantificación del riesgo

Métrica de riesgo

La figura 4.4 muestra un histograma de la energía no suministrada condicional a los terremotos que se obtuvieron de los resultados de las simulaciones en el instante que ocurre el evento. Esta métrica se utiliza para medir la resiliencia en el suministro de energía de la red existente sin considerar nuevos activos de inversión.

A partir del histograma se puede observar en los resultados obtenidos para el sistema, que la CEENS para este caso tiene un valor medio de 1581.3 MWh/h, que representa el

¹El análisis “out-of-sample” se realiza mediante escenarios de prueba para cubrir el espectro de incertidumbre.

valor promedio de la ENS que se obtuvo en los escenarios de interrupción originados por los terremotos en el instante que ocurre el evento. En general, la mayoría de ENS se concentra sobre la media, pero también se puede observar que existen escenarios que se colocan en la cola de la distribución, donde los valores de la ENS son más altos.

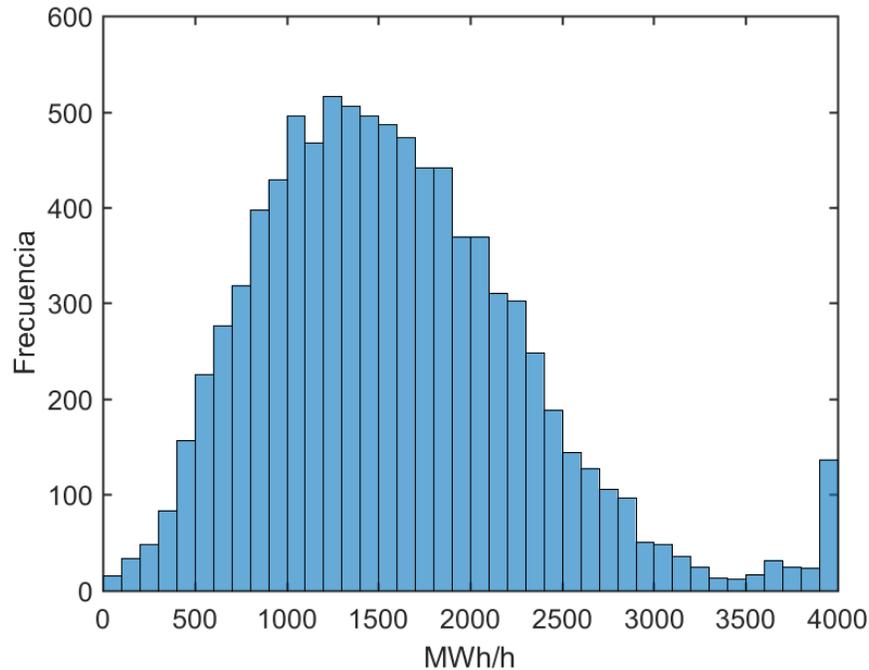


Figura 4.4: Histograma de la ENS

Mapa de riesgo de la ENS

En la figura 4.5 se representa gráficamente el nivel de exposición al riesgo medido en ENS condicionada a una serie de terremotos generados aleatoriamente. Cada círculo del mapa indica la cantidad de energía no suministrada normalizada (medida en este caso a través de un índice igual a $[Demanda - ENS]/Demanda$) por cada barra en el instante que ocurre la contingencia realizando 10000 simulaciones. Los niveles de riesgo se indican mediante el uso de colores sucesivos desde azul ($[Demanda - ENS]/Demanda$ igual a cero) a rojo ($[Demanda - ENS]/Demanda$ igual a uno). Es importante mencionar que no se está considerando riesgo en las barras 11, 12, 17, 21, 22, 23 y 24 porque no contienen demanda.

Esta figura muestra que el punto de mayor riesgo es la barra 6 con un valor de 0.58, mientras que el punto de menor riesgo es la barra 18 que es igual a 0.23. De esta forma, se puede observar que la zona de mayor nivel de riesgo se concentra en las barras 4, 5 y 6, esto puede ser porque estas barras tienen menor conectividad con otros componentes del sistema. Mientras que las barras 15 y 18 son las que presentan menor riesgo, esto claramente demuestra en este caso particular que, las barras que tienen una menor conectividad con otros componentes del sistema presentan mayor nivel de riesgo.

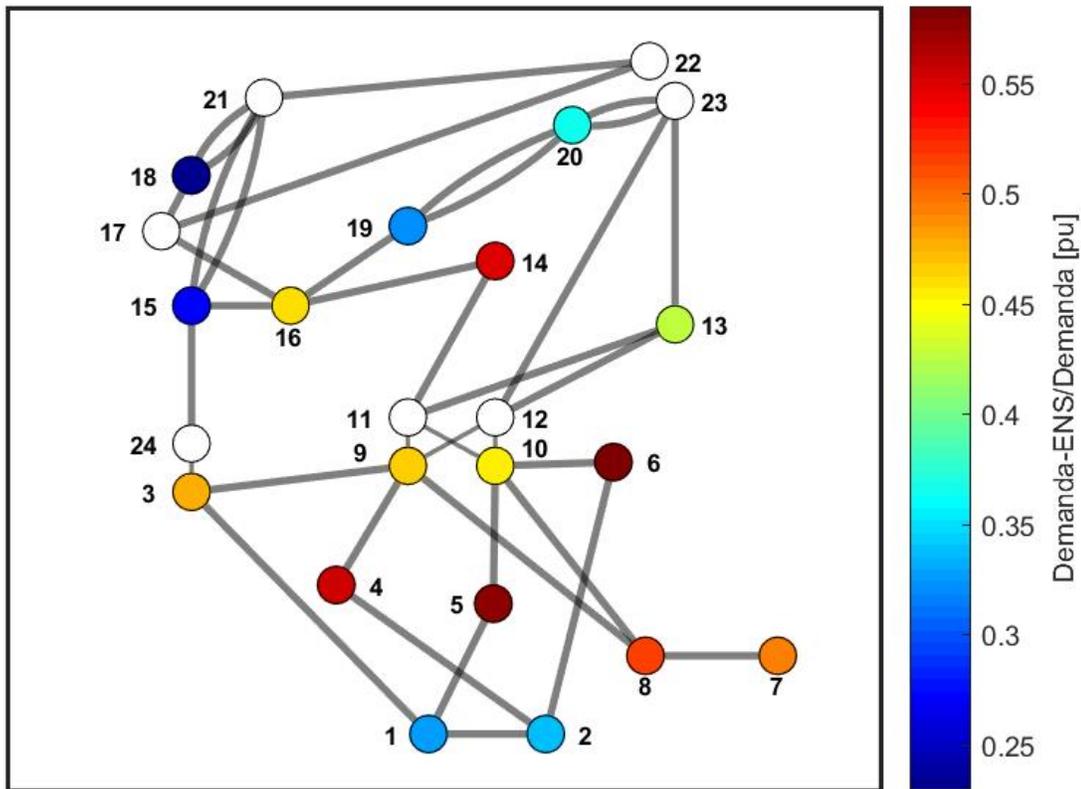


Figura 4.5: Mapa de riesgo de la ENS

Mapa de riesgo de vulnerabilidad de la red de transmisión

La figura 4.6 representa el riesgo que fallen los activos del sistema, esto significa la probabilidad de desconexión de las líneas de transmisión y las subestaciones. Para este caso, se utiliza el indicador de resiliencia en infraestructura que permite determinar el número de veces en promedio que se puede desconectar una línea de transmisión, ya sea por fallas propias en la infraestructura o fallas en los paños de línea de las subestaciones a las cuales están conectadas. Por otra parte, el indicador de resiliencia en las subestaciones representa el número de veces en promedio que se desconecta completamente la subestación debido a fallas en todos los paños o por la desconexión de las líneas que se conectan a la misma, provocando que la subestación quede aislada. Por lo tanto, este indicador permite mostrar el nivel de riesgo medido en infraestructura de la red eléctrica.

Esta figura muestra el número de veces en promedio que las líneas de transmisión y subestaciones componente están fuera de servicio, para este caso el color negro representa el índice más bajo de riesgo para probabilidades de falla entre 0 y 20%. El color gris representa la probabilidad de falla del componente entre 20% y 40%, el color amarillo representa la probabilidad de falla del componente entre el 40% y 60%, el color naranja representa la pro-

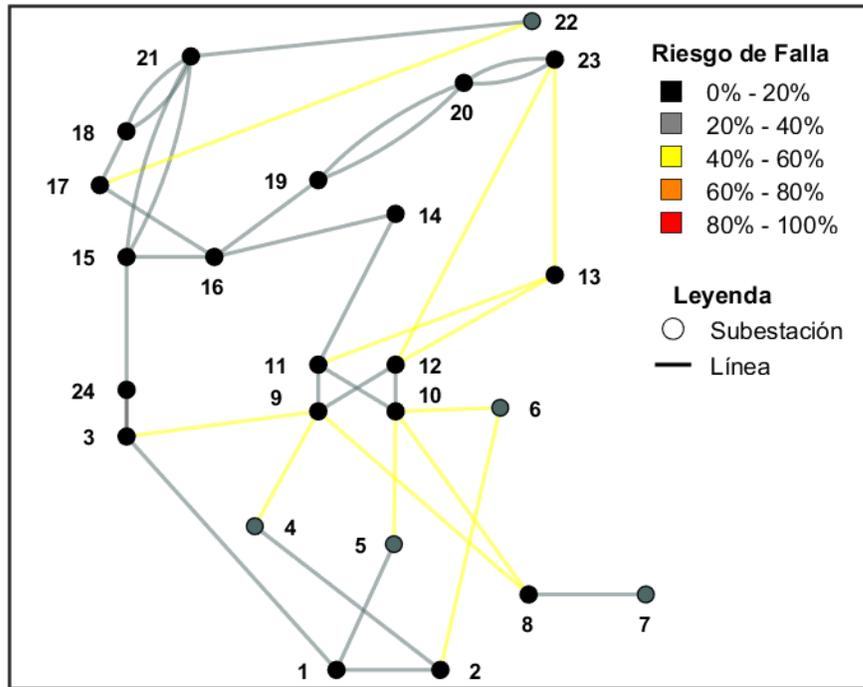


Figura 4.6: Mapa de Vulnerabilidad de la red de transmisión

babilidad de falla del componente entre el 60 % y 80 %, el color rojo representa la probabilidad de falla entre el 80 % al 100 %.

Como se puede observar en la figura, las líneas de transmisión que están pintadas de color amarillo representan a los componentes que están más propensos a sufrir fallas debido a la ocurrencia de los terremotos muestreados. Además, este mapa permite complementar el análisis de los resultados mostrados en la figura 4.5, porque las barras que presentan mayor riesgo de ENS están conectadas con las líneas que presentan mayor riesgo de falla. Esta relación demuestra que, dependiendo de la vulnerabilidad de los componentes del sistema, el nivel de ENS del sistema puede verse afectado en menor o mayor medida.

La tabla 4.1 presenta los resultados de los componentes vulnerables del sistema de transmisión. En este caso particular, se puede observar que en promedio 4 barras de las 24 en total presentan alto riesgo de fallar completamente debido a la ocurrencia de los terremotos muestreados y esto representa un 14.8 % del total de barras del sistema. Por otra parte, en promedio una línea de transmisión podría desconectarse por fallas propias en la infraestructura, esto representa un 3.2 % del total. Mientras tanto evaluando la desconexión de las líneas de transmisión por indisponibilidad en los paños de la subestación se obtiene en promedio 12 líneas de transmisión podrían estar fuera de servicio, esto representa un 33.8 % del total de líneas del sistema. Esto demuestra que empleando un análisis granular de las subestaciones a nivel de paños puede representar de forma más realista la desconexión de los componentes que se conectan a las subestaciones debido a la ocurrencia de eventos exógenos extremos. Por

lo tanto, esto evidencia que los componentes presentan mayor exposición al riesgo cuando se considera un análisis a nivel de paños de las subestaciones.

Total de Instalaciones	Total	Con Daños	%
Barras	24	4	14.80
Líneas de Transmisión	33	1	3.2
Detalle en los paños de las subestaciones	Total	Con Daños	%
Líneas de Transmisión	33	12	33.80
Transformadores	5	2	24.84

Tabla 4.1: Resultados del análisis de vulnerabilidad de los componentes

4.3.2. Impacto en variables eléctricas

Voltaje

En la figura 4.7 se pueden observar los voltajes para el estado pre-contingencia y los voltajes promedio en cada una de las barras del sistema evaluados en 10000 escenarios para el estado post-contingencia. Para el caso pre-contingencia los voltajes se mantienen dentro del rango de voltaje admisible que es $\pm 3\%$ p.u., con algunas barras en el límite superior del rango, esto es debido a que algunas líneas de transmisión están sobrecargadas. Por otra parte, para el caso post-contingencia el rango de voltaje admisible aumenta a $\pm 5\%$ debido a que se ajusta los límites de voltaje para estados de emergencia. En la figura se muestra el voltaje en promedio de cada una de las barras considerando los escenarios de contingencia simulados. Esto permite identificar las barras del sistema que presenten voltajes críticos producto de las desconexiones de los componentes debido a la ocurrencia de los terremotos.

Flujo por las líneas de transmisión

En la figura 4.8 se puede observar la cargabilidad de cada una de las líneas de transmisión en los estados pre-contingencia y post-contingencia. La cantidad de flujo por las líneas depende del punto de operación del sistema, en este caso la demanda está en el punto máximo de operación. En el caso pre-contingencia el sistema presenta algunas líneas sobrecargadas, pero es capaz de abastecer la demanda cumpliendo con las capacidades máximas de las líneas de transmisión. Por otra parte, para el caso post-contingencia las líneas de transmisión aumentan los flujos de potencia debido a la desconexión de los componentes del sistema, esto obliga a incrementar la capacidad de transferencia de las líneas para mantener los voltajes dentro de un rango admisible de operación.

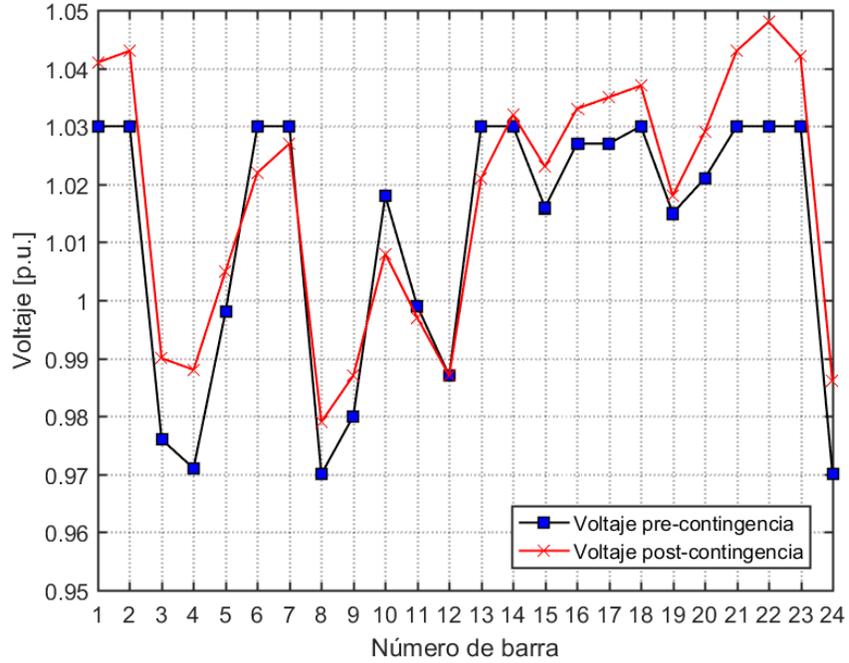


Figura 4.7: Voltajes en las barras

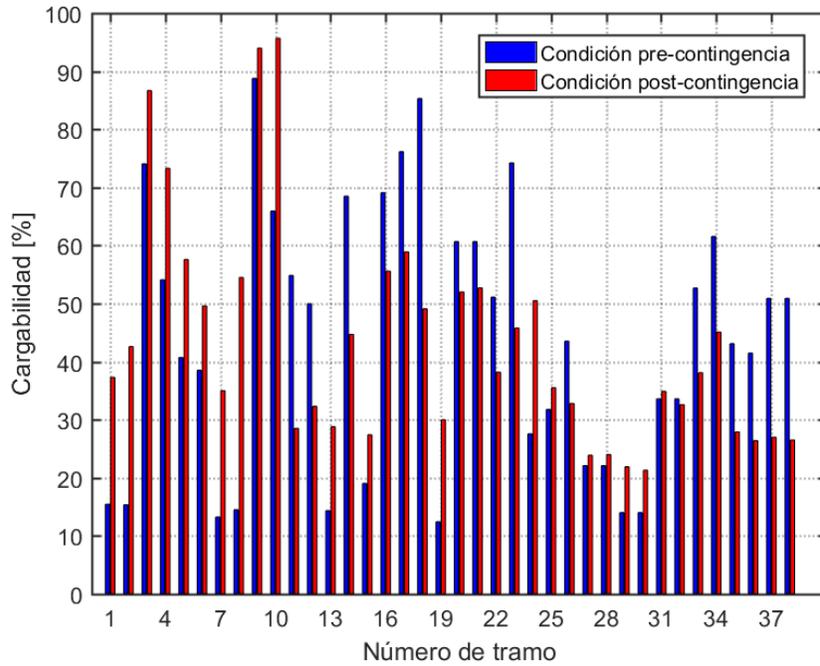


Figura 4.8: Cargabilidad de las líneas de transmisión

4.3.3. Coberturas al riesgo mediante equipos de compensación reactiva

Ranking

La tabla 4.2 presenta un resumen del ranking completo de soluciones para un presupuesto igual a 1. En esta tabla, de izquierda a derecha, la primera columna indica el ranking de las soluciones obtenidas. La segunda columna muestra la barra donde se conecta el equipo de compensación reactiva. La tercera columna muestra los valores de CEENS para cada solución, seguido de las columnas que corresponden al número de evaluaciones, el coeficiente de variación (CV) y los intervalos de confianza del 95 % para cada solución, respectivamente. Es importante mencionar que en esta sección no se utiliza el algoritmo de OvS.

El método de ranking evalúa 10000 veces cada solución y luego compara todas contra todas, gastando aproximadamente 63 minutos en promedio para evaluar cada solución. Como se puede observar en la tabla 4.2, las cinco primeras soluciones del ranking no son estadísticamente diferentes, al comparar las soluciones individualmente, los intervalos de confianza se superponen. Además, las soluciones obtenidas están muy próximas entre sí y tienen aproximadamente un 50 % de coeficiente de variación.

Optimización para presupuesto igual a 1

En esta sección, se han realizado dos pruebas para determinar la solución cuasi-óptima para un presupuesto igual a 1. Primero, se construye un conjunto de buenas soluciones candidatas, ejecutando 10 corridas del algoritmo de OvS. Las tablas 4.3 y 4.4 presentan los resultados obtenidos con las técnicas de muestreo de OvS-FU y OvS-SAA respectivamente. Para ambos casos, en la primera columna se muestra el número de corrida, seguido de las columnas de la solución obtenida, el valor de CEENS, el número de evaluaciones realizadas y el CV, respectivamente. A lo largo de todos los experimentos que involucran el método de SAA, se utiliza $N = 25$ para el número de escenarios muestreados (fijos) antes de cada una de las 10 optimizaciones.

Después de determinar el conjunto de soluciones candidatas, la solución cuasi-óptima se aproxima resolviendo un análisis out-of-sample. Para ambos métodos se realizan 10 corridas, con el fin de proporcionar una comparación justa de las soluciones reportadas y los tiempos de ejecución entre los métodos. Para cada solución reportada se realiza un análisis out-of-sample con 10000 muestras y se clasifican en un ranking, en el cual se puede seleccionar la solución que sea estadísticamente mejor comparada con las otras soluciones. Las tablas 4.5 y 4.6 presentan un resumen de los resultados del ranking de soluciones obtenidas con 10 optimizaciones para las técnicas de muestreo de OvS-FU y OvS-SAA, respectivamente. En este caso, para determinar la solución cuasi-óptima utilizando el algoritmo de OvS se considera el índice de robustez (tal como se realiza en [35]), considerando que la robustez es el número de veces que se repite una solución en el análisis out-of-sample, los resultados se presentan en la tabla 4.8. Nótese que la solución cuasi-óptima entregada por el modelo después de ejecutar todas las corridas, corresponde al promedio de los valores que se han obtenido en los diferentes procesos de muestreo.

Ranking	Solución	CEENS (MWh/h)	N	CV	5 %Q	95 %Q
1	9	1521.4	10000	0.485	1516.2	1526.6
2	3	1522.9	10000	0.507	1518.3	1527.5
3	11	1523.6	10000	0.480	1518.8	1528.4
4	13	1523.8	10000	0.498	1519.1	1528.5
5	14	1529.9	10000	0.515	1524.9	1534.9
6	12	1533.4	10000	0.506	1528.6	1538.2
7	1	1536.3	10000	0.503	1532.5	1540.1
8	23	1536.6	10000	0.487	1531.9	1541.3
9	17	1539.1	10000	0.491	1534.5	1543.5
10	7	1539.2	10000	0.511	1534.3	1543.9
11	2	1540.5	10000	0.506	1535.0	1543.4
12	18	1541.7	10000	0.497	1536.6	1544.4
13	5	1544.5	10000	0.501	1537.3	1546.1
14	20	1545.3	10000	0.518	1540.2	1548.8
15	16	1546.1	10000	0.486	1541.2	1549.4
16	19	1546.6	10000	0.502	1542.1	1550.1
17	24	1547.3	10000	0.507	1542.1	1551.1
18	21	1549.0	10000	0.498	1542.1	1552.5
19	10	1551.8	10000	0.519	1544.3	1553.7
20	22	1554.4	10000	0.497	1546.6	1557.0
21	6	1556.0	10000	0.501	1549.9	1558.9
22	15	1556.4	10000	0.489	1551.7	1560.3
23	4	1556.6	10000	0.507	1551.9	1560.9
24	8	1556.6	10000	0.486	1552.0	1561.2
25	Caso base	1581.3	10000	0.498	1576.1	1586.5

Tabla 4.2: Resultados del método de ranking

Según los resultados mostrados en la tabla 4.6, el método de OvS-SAA presenta un mejor desempeño considerando que se obtiene una mayor robustez en la solución reportada. El método de OvS-SAA encuentra la primera (barra 9) de las 5 mejores soluciones obtenidas con el método de ranking en 10 corridas diferentes para el mismo presupuesto. En el caso del método de OvS-FU, puede verse en la tabla 4.5 que las soluciones 9 y 3 se repiten 7 y 3 veces, respectivamente, en las 10 corridas realizadas. Estas soluciones también están dentro de las 5 mejores soluciones obtenidas con el método de ranking. Por lo tanto, la solución cuasi-óptima más prometedora estadísticamente hablando es instalar un equipo de compensación reactiva en la barra 9. La barra 9 es un componente crítico de la red de prueba, debido a que tiene la mayor conectividad con otros componentes (ver tabla 6.1), y además conecta a un transformador y una demanda considerable para el sistema.

Corrida	Solución	CEENS (MWh/h)	Evaluaciones	CV
1	9	1535.1	11294	0.519
2	9	1511.5	10958	0.498
3	3	1523.1	10503	0.502
4	9	1524.4	11133	0.507
5	3	1512.0	9897	0.510
6	3	1531.1	10127	0.480
7	9	1524.4	12405	0.533
8	9	1533.5	9867	0.519
9	9	1512.7	9998	0.499
10	9	1513.1	10505	0.527

Tabla 4.3: Resultados del método OvS-FU

Corrida	Solución	CEENS (MWh/h)	Evaluaciones	CV
1	9	1525.2	359	0.076
2	9	1521.7	345	0.075
3	9	1530.1	456	0.077
4	9	1534.8	546	0.076
5	9	1527.3	399	0.071
6	9	1531.6	422	0.070
7	9	1542.2	489	0.070
8	9	1524.5	365	0.071
9	9	1520.7	457	0.070
10	9	1516.9	396	0.072

Tabla 4.4: Resultados del método OvS-SAA

Ranking	Solución	CEENS (MWh/h)	Evaluaciones	5 %Q	95 %Q
1	9	1527.7	10000	1521.5	1533.9
2	9	1532.1	10000	1526.2	1538.0
3	3	1537.1	10000	1531.1	1543.1
4	9	1541.5	10000	1535.6	1547.4
5	3	1544.6	10000	1538.9	1550.3
6	3	1544.9	10000	1539.1	1550.7
7	9	1545.1	10000	1539.0	1551.2
8	9	1557.4	10000	1551.8	1563.0
9	9	1561.4	10000	1555.6	1567.2
10	9	1565.2	10000	1559.1	1571.3

Tabla 4.5: Ranking de soluciones de 10 optimizaciones del método OvS-FU, e intervalo de confianza para cada solución.

Ranking	Solución	CEENS (MWh/h)	Evaluaciones	5 %Q	95 %Q
1	9	1524.7	10000	1518.6	1530.8
2	9	1531.2	10000	1525.4	1537.0
3	9	1534.4	10000	1528.6	1540.2
4	9	1536.5	10000	1530.3	1542.7
5	9	1538.2	10000	1532.5	1543.9
6	9	1538.9	10000	1532.9	1544.9
7	9	1541.5	10000	1535.9	1547.1
8	9	1542.6	10000	1536.8	1548.4
9	9	1544.3	10000	1538.0	1550.6
10	9	1544.7	10000	1539.0	1550.4

Tabla 4.6: Ranking de soluciones de 10 optimizaciones del método OvS-SAA, e intervalo de confianza para cada solución.

Optimización para presupuestos mayores a 1

En el contexto de soluciones para presupuestos mayores a 1, la idea de calcular la solución para todas las combinaciones posibles podría ser muy costosa en términos computacionales. En esta red en particular, por ejemplo, se tendría que probar 25, 301, 2325 y 12951 soluciones factibles para $b = 1, 2, 3$ y 4 , respectivamente, además se debe considerar que, para cada una de ellas se realizarían 10000 evaluaciones. Por lo tanto, aquí se busca validar nuestro modelo de optimización vía simulación para evitar probar todas las propuestas de mejora de la red. Para esto, se utiliza el mismo procedimiento de dos etapas que el presupuesto igual a 1, primero se construye un conjunto de buenas soluciones candidatas, ejecutando 10 corridas con los métodos OvS-FU y OvS-SAA. Luego, se identifican las mejores soluciones reportadas realizando un análisis out-of-sample con 10000 evaluaciones para cada de ellas. Los detalles de los resultados se muestran en las tablas 6.5 a 6.16 del Apéndice, que contienen las soluciones reportadas por cada corrida del algoritmo de OvS con los diferentes métodos de muestreo y el detalle del análisis out-of-sample de cada solución.

Para el caso del presupuesto igual a 2, las tablas 6.7 y 6.8 presentan los resultados para la optimización con los métodos de OvS-FU y OvS-SAA, respectivamente. Para el método de OvS-FU, el algoritmo reporta diferentes soluciones, sin embargo, la solución (3, 9) es la más robusta y coincide con la solución obtenida con el método de OvS-SAA. Para el caso del presupuesto igual a 3, las tablas 6.11 y 6.12 presentan los resultados en detalle de 10 optimizaciones realizadas para los métodos de OvS-FU y OvS-SAA, respectivamente. En este caso, los resultados con ambos métodos son similares, aunque se puede demostrar que el OvS-SAA aún puede proporcionar una solución con mayor robustez. Los patrones en las barras seleccionadas para instalar equipos de compensación reactiva parecen mantenerse según se incrementa el presupuesto del modelo de optimización vía simulación. Para el presupuesto

igual a 4, las tablas 6.15 y 6.16 presentan los resultados de las soluciones obtenidas con los métodos de OvS-FU y OvS-SAA, respectivamente.

El resumen de las soluciones obtenidas con los métodos de OvS-SAA y OvS-FU para los diferentes presupuestos se muestra en la tabla 4.7. Para comparar la efectividad del algoritmo de OvS utilizando el método de SAA, se determinan los límites inferior (LB del inglés Lower Bound) y superior (UB del inglés Upper Bound). La estimación de los límites superior e inferior para cada presupuesto se calcula utilizando lo indicado en la sección 3.3.1. Es importante considerar que, al comparar las soluciones de cada método individualmente, los dos métodos entregan soluciones que no son estadísticamente diferentes. Sin embargo, OvS-SAA ofrece soluciones más robustas que OvS-FU. Esto debido a que el método de SAA permite al algoritmo identificar eficientemente las mejores soluciones, cuando se muestrean suficientes escenarios representativos en cada optimización.

Método	Presupuesto	Solución	CEENS (MWh/h)	LB	UB
OvS-SAA	1	9	1524.7	1522.2	1530.8
OvS-FU	1	9	1527.7	-	-
OvS-SAA	2	3, 9	1512.4	1510.2	1518.3
OvS-FU	2	3, 9	1516.7	-	-
OvS-SAA	3	3, 9, 14	1501.7	1501.1	1507.9
OvS-FU	3	9, 14, 18	1506.3	-	-
OvS-SAA	4	3, 9, 14, 18	1430.1	1420.7	1436.2
OvS-FU	4	3, 9, 14, 20	1452.1	-	-

Tabla 4.7: Resultados de los métodos OvS-SAA y OvS-FU para todos los presupuestos, esta tabla resume los resultados del Apéndice 6.5 a 6.16.

Además, la tabla 4.8 presenta la robustez y los tiempos de simulación de las soluciones para cada presupuesto con su respectivo método. La robustez obtenida con el método de OvS-SAA es mayor comparada con el método de OvS-FU, pero disminuye a medida que aumenta el presupuesto. Para un presupuesto igual a 1, 10 de cada 10 soluciones obtenidas mediante el método de OvS-SAA alcanzan la misma solución. Mientras que para un presupuesto igual a 4, 6 de cada 10 soluciones obtenidas mediante el método de OvS-SAA alcanzan la misma solución. De esta forma, se selecciona la solución más robusta que se obtiene para cada uno de los presupuestos. Por lo tanto, la solución más prometedora para el problema propuesto de planificación de equipos de compensación reactiva es instalar cuatro equipos en las barras (3,9,14,18), uno por cada barra.

Método	Presupuesto	Solución	Robustez	Tiempo (min)
OvS-SAA	1	9	10	54.2
OvS-FU	1	9	7	61.2
OvS-SAA	2	3, 9	8	65.6
OvS-FU	2	3, 9	7	80.3
OvS-SAA	3	3, 9, 14	7	80.9
OvS-FU	3	9, 14, 18	5	110.1
OvS-SAA	4	3, 9, 14, 18	6	100.7
OvS-FU	4	3, 9, 14, 20	4	131.3

Tabla 4.8: Robustez y tiempos de simulación.

Finalmente, se ilustra las soluciones obtenidas de diferentes presupuestos con el modelo de optimización vía simulación propuesto para determinar la ubicación cuasi-óptima de equipos de compensación de potencia reactiva, con el fin de mitigar los efectos adversos de eventos sísmicos y mejorar la resiliencia de las redes eléctricas. La figura 4.9 muestra la diferencia en términos de mejoras CEENS entre soluciones. Era esperable observar que, la CEENS disminuye a medida que aumenta el presupuesto. Por lo tanto, con la solución obtenida para el presupuesto igual a 4 se puede concluir que la instalación de equipos de compensación reactiva localizados estratégicamente permite reducir la energía no suministrada esperada en un 10 % comparado con el caso base para este caso de estudio. Además, es importante mencionar que la localización estratégica de equipos sigue dos patrones: (i) asegurar las barras con grandes consumos de energía (barras 9 y 18) y (ii) aquellas con una gran cantidad de conexiones con otras barras y que tengan menor vulnerabilidad de desconexión debido a los eventos sísmicos.

Análisis

Se analizan cuatro diferentes presupuestos, para este caso particular los resultados obtenidos en la optimización con los dos métodos OvS-FU y OvS-SAA son los mismos para los presupuestos de 1 y 2, mientras que para los presupuestos 3 y 4 son distintos para los dos métodos. Es importante destacar que, para el presupuesto igual a 1, si bien el número de simulaciones crecen significativamente utilizando el método de Ranking (como se esperaba), el algoritmo de OvS necesita un número mucho menor de iteraciones para encontrar la solución cuasi-óptima. Además, para validar estadísticamente los resultados obtenidos con el algoritmo de OvS se realizó un análisis out-of-sample. Por otra parte, se determinaron los resultados mediante la comparación de la robustez de cada solución obtenida con los métodos OvS-FU y OvS-SAA. Es interesante observar que, aunque el problema original tiene un gran número de escenarios de falla, el método de SAA requiere solo un pequeño número de muestras que proporciona información suficiente del espacio de búsqueda para la optimización. Para estos ajustes, los resultados permiten concluir que corregir la incertidumbre al inicio

de la optimización entrega soluciones más robustas. Por lo tanto, para este caso de estudio el algoritmo de OvS con el método de SAA ofrece un método más robusto y práctico para identificar las mejoras en redes resilientes frente a eventos sísmicos.

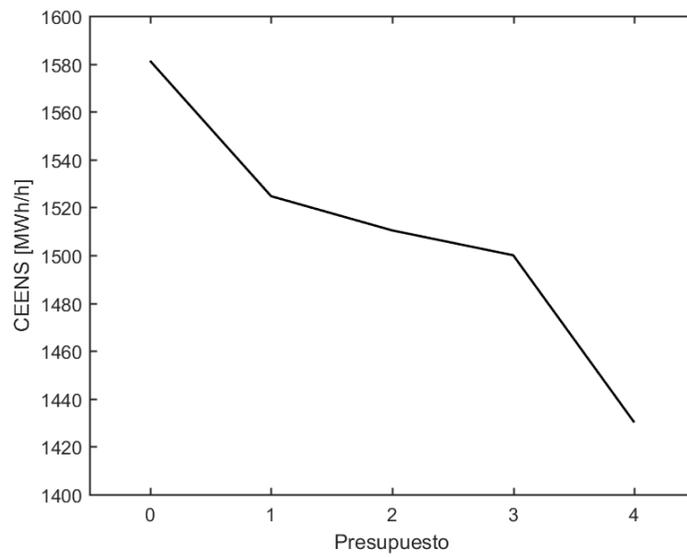


Figura 4.9: Esperanza condicional de la ENS en función del presupuesto

Capítulo 5

Conclusiones y trabajo futuro

5.1. Conclusiones

Este trabajo propone un modelo de optimización vía simulación para determinar la inversión eficiente de equipos de compensación de potencia reactiva distribuidos estratégicamente, con el fin de mejorar la resiliencia de las redes eléctricas frente a eventos sísmicos. En la etapa de optimización se toma decisiones de inversión en equipos de compensación reactiva en distintos puntos de la red, mientras que en la etapa de simulación se evalúan las mejoras en resiliencia mediante simulaciones secuenciales de Monte Carlo considerando dos niveles de incertidumbre relacionados a la ubicación del evento sísmico y las fallas de la red. Para efectos de la modelación se propone un modelo detallado de vulnerabilidad de las subestaciones a nivel de paños para obtener una representación más realista del comportamiento de la subestación. Además, se utilizó un método de aproximación por promedio muestral para realizar la búsqueda de la solución cuasi-óptima más robusta en la etapa de inversión.

Los resultados muestran que el algoritmo de optimización vía simulación propuesto utilizando el método de aproximación por promedio muestral encuentra soluciones más robustas que el método de total incertidumbre, para los mismos parámetros y número de corridas. Las soluciones obtenidas por ambos métodos no son estadísticamente diferentes para los presupuestos 1 y 2, mientras que en el caso de los presupuestos 3 y 4 el método de aproximación por promedio muestral entrega mejores soluciones, estadísticamente hablando. La robustez para ambos métodos disminuye a medida que aumenta el presupuesto. Mientras que el tiempo de ejecución incrementa para ambos métodos cuando se aumenta el presupuesto. Además, con la solución obtenida para el presupuesto igual a 4 se puede concluir que la instalación de equipos de compensación reactiva localizados estratégicamente permite reducir la energía no suministrada esperada en condiciones adversas en un 10%. Por lo tanto, aunque el problema original tiene un gran número de escenarios de falla, el método de aproximación por promedio muestral permite al algoritmo estimar efectivamente las mejores soluciones estadísticamente hablando, cuando se muestrean suficientes escenarios representativos en cada optimización.

5.2. Trabajo futuro

Luego de evaluar el algoritmo de optimización vía simulación se pudo evidenciar que el método de aproximación por promedio muestral permite obtener soluciones robustas comparado con el método de total incertidumbre, pero los tiempos de ejecución empleados no demuestran ventaja entre ambos métodos. Por lo tanto, se puede mejorar el método de SAA para encontrar un muestreo adecuado. Además, se plantea mejorar el algoritmo de optimización.

Con el objetivo de lograr un portafolio óptimo en la planificación de las redes eléctricas se propone considerar diversas soluciones en términos de acciones innovadoras de mitigación y adaptación mediante el uso de portafolios de inversión basados en activos tradicionales (transformadores y líneas), equipos de red flexibles (como Sistemas Flexibles de Transmisión de AC –FACTS–, equipos de Corriente Continua de Alta Tensión –HVDC–, Esquemas de Protección Especial –SPS–, etc.) y activos en redes de distribución, incluidos los recursos energéticos distribuidos (DER).

Además, se plantea la incorporación de otras métricas como las propuestas en [10], para mejorar algún aspecto específico de la resiliencia, como la rapidez de restauración del sistema o la tasa de recuperación.

Por último, se propone desarrollar un marco general para planificar la inversión en redes eléctricas teniendo en cuenta varios tipos de amenazas naturales (como inundaciones, terremotos, tsunamis, incendios forestales, condiciones climáticas adversas, etc.).

Bibliografía

- [1] G. Strbac, D. Kirschen, and R. Moreno, “Reliability standards for the operation and planning of future electricity networks,” *Foundations and Trends® in Electric Energy Systems*, vol. 1, no. 3, pp. 143–219, 2016.
- [2] J. C. Araneda, H. Rudnick, S. Mocarquer, and P. Miquel, “Lessons from the 2010 chilean earthquake and its impact on electricity supply,” in *2010 International Conference on Power System Technology*, 2010, pp. 1–7.
- [3] R. Moreno, M. Panteli, P. Mancarella, H. Rudnick, T. Lagos, A. Navarro, F. Ordoñez, and J. C. Araneda, “From reliability to resilience: Planning the grid against the extremes,” *IEEE Power and Energy Magazine*, vol. 18, no. 4, pp. 41–53, 2020.
- [4] M. Panteli, D. N. Trakas, P. Mancarella, and N. D. Hatziargyriou, “Boosting the power grid resilience to extreme weather events using defensive islanding,” *IEEE Transactions on Smart Grid*, vol. 7, no. 6, pp. 2913–2922, Nov 2016.
- [5] A. R. Berkeley III and M. Wallace, “A framework for establishing critical infrastructure resilience goals: Final goals and recommendations,” *Nat. Infrastruct. Advisory Council (NIAC), Washington, DC, USA, Tech. Rep.*, 2010.
- [6] “The definition and quantification of resilience,” <http://resourcecenter.ieee-pes.org/pes/product/technicalpublications/PESTR006504-18>, accessed:2018-08-03., 2018.
- [7] M. Panteli and P. Mancarella, “The grid: Stronger, bigger, smarter?: Presenting a conceptual framework of power system resilience,” *IEEE Power and Energy Magazine*, vol. 13, no. 3, pp. 58–66, May 2015.
- [8] Y. Wang, C. Chen, J. Wang, and R. Baldick, “Research on resilience of power systems under natural disasters—a review,” *IEEE Transactions on Power Systems*, vol. 31, no. 2, pp. 1604–1613, March 2016.
- [9] X. Liu, M. Shahidehpour, Z. Li, X. Liu, Y. Cao, and Z. Bie, “Microgrids for enhancing the power grid resilience in extreme conditions,” *IEEE Transactions on Smart Grid*, vol. 8, no. 2, pp. 589–597, March 2017.
- [10] M. Panteli, P. Mancarella, D. N. Trakas, E. Kyriakides, and N. D. Hatziargyriou, “Metrics and quantification of operational and infrastructure resilience in power systems,” *IEEE*

Transactions on Power Systems, vol. 32, no. 6, pp. 4732–4742, Nov 2017.

- [11] S. Espinoza, M. Panteli, P. Mancarella, and H. Rudnick, “Multi-phase assessment and adaptation of power systems resilience to natural hazards,” *Electric Power Systems Research*, vol. 136, pp. 352 – 361, 2016.
- [12] H. Zhang, H. Yuan, G. Li, and Y. Lin, “Quantitative resilience assessment under a tri-stage framework for power systems,” *Energies*, vol. 11, no. 6, p. 1427, 2018.
- [13] M. Panteli, C. Pickering, S. Wilkinson, R. Dawson, and P. Mancarella, “Power system resilience to extreme weather: Fragility modeling, probabilistic impact assessment, and adaptation measures,” *IEEE Transactions on Power Systems*, vol. 32, no. 5, pp. 3747–3757, Sep. 2017.
- [14] Z. Bie, Y. Lin, G. Li, and F. Li, “Battling the extreme: A study on the power system resilience,” *Proceedings of the IEEE*, vol. 105, no. 7, pp. 1253–1266, July 2017.
- [15] C. Wang, Y. Hou, F. Qiu, S. Lei, and K. Liu, “Resilience enhancement with sequentially proactive operation strategies,” *IEEE Transactions on Power Systems*, vol. 32, no. 4, pp. 2847–2857, July 2017.
- [16] M. Panteli, D. N. Trakas, P. Mancarella, and N. D. Hatziargyriou, “Power systems resilience assessment: Hardening and smart operational enhancement strategies,” *Proceedings of the IEEE*, vol. 105, no. 7, pp. 1202–1213, July 2017.
- [17] M. Noebels and M. Panteli, “Assessing the effect of preventive islanding on power grid resilience,” in *2019 IEEE Milan PowerTech*, June 2019, pp. 1–6.
- [18] H. Zhang, Z. Bie, C. Yan, and G. Li, “Post-disaster power system resilience enhancement considering repair process,” in *2018 China International Conference on Electricity Distribution (CICED)*, Sep. 2018, pp. 1550–1554.
- [19] N. Romero, N. Xu, L. K. Nozick, I. Dobson, and D. Jones, “Investment planning for electric power systems under terrorist threat,” *IEEE Transactions on Power Systems*, vol. 27, no. 1, pp. 108–116, Feb 2012.
- [20] H. Nagarajan, E. Yamangil, R. Bent, P. Van Hentenryck, and S. Backhaus, “Optimal resilient transmission grid design,” in *2016 Power Systems Computation Conference (PSCC)*, June 2016, pp. 1–7.
- [21] M. Yan, X. Ai, M. Shahidehpour, Z. Li, J. Wen, S. Bahramira, and A. Paaso, “Enhancing the transmission grid resilience in ice storms by optimal coordination of power system schedule with pre-positioning and routing of mobile dc de-icing devices,” *IEEE Transactions on Power Systems*, vol. 34, no. 4, pp. 2663–2674, 2019.
- [22] X. Liu, K. Hou, H. Jia, Y. Mu, X. Yu, Y. Wang, and J. Dong, “A quantified resilience assessment approach for electrical power systems considering multiple transmission line outages,” in *2017 IEEE Electrical Power and Energy Conference (EPEC)*, 2017, pp. 1–5.

- [23] S. Espinoza, A. Poulos, H. Rudnick, J. C. de la Llera, M. Panteli, P. Mancarella, R. Saacaan, A. Navarro, and R. Moreno, "Seismic resilience assessment and adaptation of the northern chilean power system," in *2017 IEEE Power Energy Society General Meeting*, July 2017, pp. 1–5.
- [24] P. Poulos, S. Espinoza, J. De la Llera, and H. Rudnick, "Seismic risk assessment of spatially distributed electric power systems," *16th World Conference on Earthquake, 16WCEE 2017, Santiago Chile*, January 2017.
- [25] M. Nazemi and P. Dehghanian, "Seismic-resilient bulk power grids: Hazard characterization, modeling, and mitigation," *IEEE Transactions on Engineering Management*, pp. 1–17, 2019.
- [26] S. Espinoza, A. Poulos, H. Rudnick, J. C. de la Llera, M. Panteli, and P. Mancarella, "Risk and resilience assessment with component criticality ranking of electric power systems subject to earthquakes," *IEEE Systems Journal*, vol. 14, no. 2, pp. 2837–2848, 2020.
- [27] J. Qiu, L. J. Reedman, Z. Y. Dong, K. Meng, H. Tian, and J. Zhao, "Network reinforcement for grid resiliency under extreme events," in *2017 IEEE Power Energy Society General Meeting*, 2017, pp. 1–5.
- [28] S. M. Ryan, J. D. McCalley, and D. L. Woodruff, "Long term resource planning for electric power systems under uncertainty," 2011.
- [29] Y. Lin, Z. Bie, and A. Qiu, "A review of key strategies in realizing power system resilience," *Global Energy Interconnection*, vol. 1, no. 1, pp. 70 – 78, 2018. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2096511718300094>
- [30] N. Bhusal, M. Abdelmalak, M. Kamruzzaman, and M. Benidris, "Power system resilience: Current practices, challenges, and future directions," *IEEE Access*, vol. 8, pp. 18 064–18 086, 2020.
- [31] G. Huang, J. Wang, C. Chen, C. Guo, and B. Zhu, "System resilience enhancement: Smart grid and beyond," *Frontiers of Engineering Management*, vol. 4, no. 3, p. 271, 2017.
- [32] J. Abdubannaev, Y. Sun, A. Xin, M. U. Jan, N. Makhamadjanova, and S. Rakhimov, "Enhancing power system resilience - a review," in *2019 IEEE 3rd Conference on Energy Internet and Energy System Integration (EI2)*, 2019, pp. 2350–2354.
- [33] M. Panteli and P. Mancarella, "Influence of extreme weather and climate change on the resilience of power systems: Impacts and possible mitigation strategies," *Electric Power Systems Research*, vol. 127, pp. 259 – 270, 2015. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S037877961500187X>
- [34] C. Wang, W. Wei, J. Wang, F. Liu, F. Qiu, C. M. Correa-Posada, and S. Mei, "Robust defense strategy for gas–electric systems against malicious attacks," *IEEE Transactions on Power Systems*, vol. 32, no. 4, pp. 2953–2965, 2017.

- [35] T. Lagos, R. Moreno, A. Navarro, M. Panteli, R. Sacaan, F. Ordonez, H. Rudnick, and P. Mancarella, “Identifying optimal portfolios of resilient network investments against natural hazards, with applications to earthquakes,” *IEEE Transactions on Power Systems*, pp. 1–1, 2019.
- [36] B. J. Pierre, B. Arguello, A. Staid, and R. T. Guttromson, “Investment optimization to improve power system resilience,” in *2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, 2018, pp. 1–6.
- [37] E. O. of the President, “Economic benefits of increasing electric grid resilience to weather outages - august 2013,” in *IEEE USA Books eBooks*, 2013.
- [38] D. Wanik, J. Parent, E. Anagnostou, and B. Hartman, “Using vegetation management and lidar-derived tree height data to improve outage predictions for electric utilities,” *Electric Power Systems Research*, vol. 146, pp. 236 – 245, 2017. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378779617300482>
- [39] B. Zhang, P. Dehghanian, and M. Kezunovic, “Optimal allocation of pv generation and battery storage for enhanced resilience,” *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 535–545, 2019.
- [40] M. Carrion, J. M. Arroyo, and N. Alguacil, “Vulnerability-constrained transmission expansion planning: A stochastic programming approach,” *IEEE Transactions on Power Systems*, vol. 22, no. 4, pp. 1436–1445, 2007.
- [41] N. R. Romero, L. K. Nozick, I. D. Dobson, N. Xu, and D. A. Jones, “Transmission and generation expansion to mitigate seismic risk,” *IEEE Transactions on Power Systems*, vol. 28, no. 4, pp. 3692–3701, Nov 2013.
- [42] W. Yuan, J. Wang, F. Qiu, C. Chen, C. Kang, and B. Zeng, “Robust optimization-based resilient distribution network planning against natural disasters,” *IEEE Transactions on Smart Grid*, vol. 7, no. 6, pp. 2817–2826, 2016.
- [43] B. Chen, “Applications of optimization under uncertainty methods on power system planning problems,” *Graduate Theses and Dissertations. 16511*, 2016.
- [44] J. M. Arroyo, “Bilevel programming applied to power system vulnerability analysis under multiple contingencies,” *IET Generation, Transmission Distribution*, vol. 4, no. 2, pp. 178–190, 2010.
- [45] N. Alguacil, A. Delgadillo, and J. M. Arroyo, “A trilevel programming approach for electric grid defense planning,” *Computers Operations Research*, vol. 41, pp. 282 – 290, 2014. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0305054813001664>
- [46] Y. Yao, T. Edmunds, D. Papageorgiou, and R. Alvarez, “Trilevel optimization in power network defense,” *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 37, no. 4, pp. 712–718, 2007.

- [47] W. Yuan, L. Zhao, and B. Zeng, “Optimal power grid protection through a defender–attacker–defender model,” *Reliability Engineering System Safety*, vol. 121, pp. 83 – 89, 2014. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S095183201300238X>
- [48] A. Alqurashi, A. H. Etemadi, and A. Khodaei, “Treatment of uncertainty for next generation power systems: State-of-the-art in stochastic optimization,” *Electric Power Systems Research*, vol. 141, pp. 233 – 245, 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0378779616303017>
- [49] A. H. van der Weijde and B. F. Hobbs, “Transmission planning under uncertainty: A two-stage stochastic modelling approach,” in *2010 7th International Conference on the European Energy Market*, 2010, pp. 1–6.
- [50] N. Romero, L. K. Nozick, I. Dobson, N. Xu, and D. A. Jones, “Seismic retrofit for electric power systems,” *Earthquake Spectra*, vol. 31, no. 2, pp. 1157–1176, 2015. [Online]. Available: <https://doi.org/10.1193/052112EQS193M>
- [51] M. Panteli and P. Mancarella, “Modeling and evaluating the resilience of critical electrical power infrastructure to extreme weather events,” *IEEE Systems Journal*, vol. 11, no. 3, pp. 1733–1742, 2017.
- [52] G. Latorre, R. D. Cruz, J. M. Areiza, and A. Villegas, “Classification of publications and models on transmission expansion planning,” *IEEE Transactions on Power Systems*, vol. 18, no. 2, pp. 938–946, 2003.
- [53] S. de la Torre, A. J. Conejo, and J. Contreras, “Transmission expansion planning in electricity markets,” *IEEE Transactions on Power Systems*, vol. 23, no. 1, pp. 238–248, 2008.
- [54] E. L. Da Silva, H. A. Gil, and J. M. Areiza, “Transmission network expansion planning under an improved genetic algorithm,” *IEEE Transactions on Power Systems*, vol. 15, no. 3, pp. 1168–1174, 2000.
- [55] E. L. Da Silva, J. M. A. Ortiz, G. C. De Oliveira, and S. Binato, “Transmission network expansion planning under a tabu search approach,” *IEEE Transactions on Power Systems*, vol. 16, no. 1, pp. 62–68, 2001.
- [56] J. Swisher, P. Hyden, S. Jacobson, and L. Schruben, “A survey of simulation optimization techniques and procedures,” *Proceedings of the 2000 Winter Simulation Conference*, p. 119–128, 2000.
- [57] F. Azadivar, “Simulation optimization methodologies,” *Proceedings of the 1999 Winter Simulation Conference*, p. 93–100, 1999.
- [58] R. Sacaan, H. Rudnick, T. Lagos, F. Ordóñez, A. Navarro-Espinosa, and R. Moreno, “Improving power system reliability through optimization via simulation,” in *2017 IEEE Manchester PowerTech*, 2017, pp. 1–6.

- [59] T. Lagos, F. Ordóñez, R. Sacaan, H. Rudnick, A. Navarro-Espinosa, and R. Moreno, “Discrete optimization via simulation to determine reliable network investments,” in *2017 IEEE Power Energy Society General Meeting*, 2017, pp. 1–5.
- [60] L. J. Hong and B. L. Nelson, “A brief introduction to optimization via simulation,” in *Winter Simulation Conference*, ser. WSC '09. Winter Simulation Conference, 2009, p. 75–85.
- [61] T. Lagos, R. Sacaan, H. R. A. Navarro-Espinosa, F. Ordonez, and R. Moreno, “Designing resilient power networks against natural hazards,” in *Optima 2017*, 2017, pp. 1–3.
- [62] A. Shapiro, “Monte carlo simulation approach to stochastic programming,” in *Proceeding of the 2001 Winter Simulation Conference (Cat. No.01CH37304)*, vol. 1, 2001, pp. 428–431 vol.1.
- [63] P. Seljom and A. Tomasgard, “Sample average approximation and stability tests applied to energy system design,” *Energy Systems*, pp. 1868–3975, 2019.
- [64] P. Jirutitijaroen and C. Singh, “Reliability constrained multi-area adequacy planning using stochastic programming with sample-average approximations,” *IEEE Transactions on Power Systems*, vol. 23, no. 2, pp. 504–513, 2008.
- [65] R. Boroschek and V. Contreras, “Strong ground motion from the 2010 mw 8.8 maule chile earthquake and attenuation relations for chilean subduction zone interface earthquakes,” *Proceedings of the International Symposium on Engineering Lessons Learned from the 2011 Great East Japan Earthquake, Tokyo, Japan*, March 2012.
- [66] FEMA, “Hazus - mh mr5: Technical manual,” *Federal Emergency Management Agency, Washington, DC*, 2015.
- [67] L. Xie, J. Tang, H. Tang, Q. Xie, and S. Xue, “Seismic fragility assessment of transmission towers via performance-based analysis,” *15th World Conference Earthquake Engineering*, p. 10, 2012.
- [68] R. D. Zimmerman and C. E. Murillo-Sánchez, “Matpower user’s manual,” Jun. 2019. [Online]. Available: <https://doi.org/10.5281/zenodo.3251118>
- [69] A. Shapiro, D. Dentcheva, and A. Ruszczyński, *Lectures on stochastic programming: modelling and theory*, 1st ed. USA: MPS-SIAM series on optimization, 2009.

Capítulo 6

Apéndice

6.1. Parámetros del caso de estudio IEEE RTS 24-Barras

Barra	Generación		Demanda		Conectividad
	[MW]	[MVA _r]	[MW]	[MVA _r]	
1	249.60	28.14	108	22	3
2	249.60	7.77	97	20	3
3	0	0	180	37	3
4	0	0	111	22.5	2
5	0	0	120.7	23.8	2
6	0	0	95.2	19.6	2
7	308.85	124.28	225	45	1
8	0	0	256.5	52.5	3
9	0	0	262.5	54	5
10	0	0	292.5	60	5
11	0	0	0	0	4
12	0	0	0	0	4
13	94.56	318.94	397.5	81	3
14	0	156.58	77.6	15.6	2
15	206.27	176	570.6	115.2	4
16	248	128	40	8	4
17	0	0	0	0	3
18	640	171.3	699.3	142.8	3
19	0	0	271.5	55.5	3
20	0	0	192	39	4
21	568.54	28	0	0	5
22	480	-31.4	0	0	2
23	1056	94.21	0	0	4
24	0	0	0	0	2

Tabla 6.1: Demanda máxima y capacidad de Generación localizada en cada barra

Barra	x [km]	y [km]
1	110	25
2	114.83	25
3	160	46
4	140	120.53
5	108.59	144
6	45.87	143.94
7	65.15	145
8	45.82	175
9	60	195.86
10	135	205.68
11	140	200

Tabla 6.2: Localización de los Generadores

Barra	x [km]	y [km]
1	110	25
2	114.83	25
3	45.87	86
4	74.05	60
5	104.63	60
6	120	100
7	160	46
8	134.25	46
9	91.02	100
10	91.02	100
11	91.02	100
12	91.02	100
13	140	120.53
14	108.59	144
15	45.87	143.94
16	65.15	145
17	40	160
18	45.82	175
19	85	161.4
20	120	188.49
21	60	195.86
22	135	205.68
23	140	200
24	45.87	86

Tabla 6.3: Localización de las barras

6.2. Curvas de fragilidad

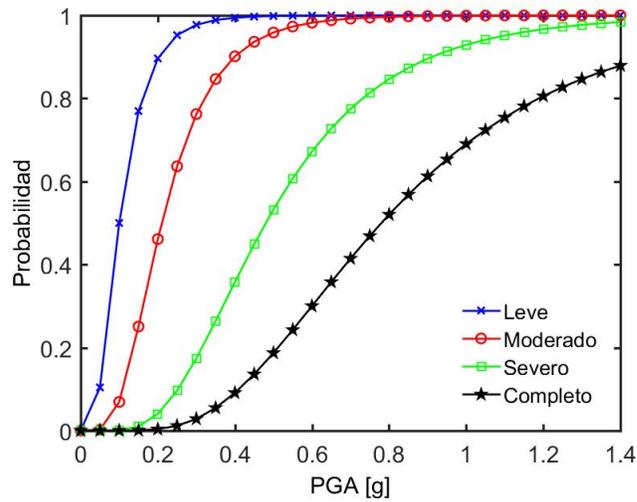


Figura 6.1: Curvas de fragilidad para instalaciones de pequeña generación con componentes anclados

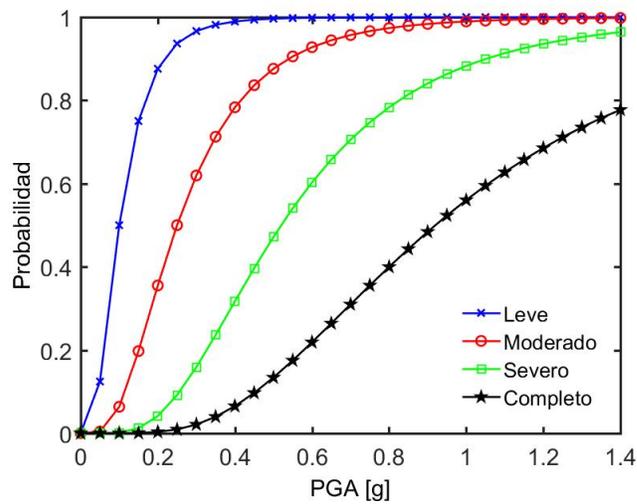


Figura 6.2: Curvas de fragilidad para instalaciones de mediana/grande generación con componentes anclados

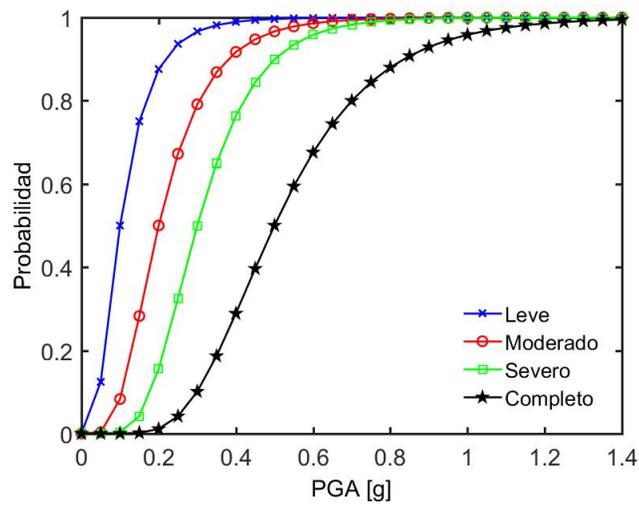


Figura 6.3: Curvas de fragilidad para subestaciones de medio voltaje con componentes sísmicos

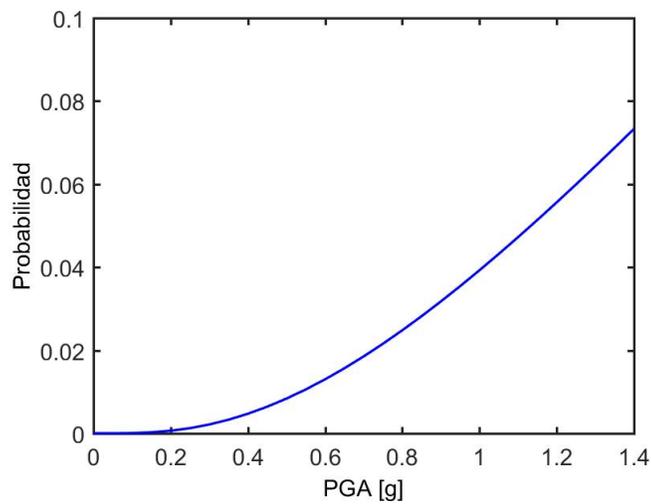


Figura 6.4: Curva de fragilidad para torres de transmisión

6.3. Datos de los terremotos

Ubicación	x [km]	y [km]
1	39	39
2	39	77
3	39	115
4	39	153
5	39	191
6	77	39
7	77	77
8	77	115
9	77	153
10	77	191
11	115	39
12	115	77
13	115	115
14	115	153
15	115	191
16	153	39
17	153	77
18	153	115
19	153	153
20	153	191
21	191	39
22	191	77
23	191	115
24	191	153
25	191	191

Tabla 6.4: Localización de los terremotos

6.4. Resultados de la optimización

6.4.1. Presupuesto igual a 2

Corrida	Solución	CEENS (MWh/h)	Evaluaciones	CV
1	3, 9	1535.1	12492	0.472
2	3, 9	1515.8	13362	0.532
3	3, 9	1527.1	11253	0.534
4	9, 14	1520.7	12751	0.477
5	3, 9	1514.5	10809	0.533
6	3, 9	1529.2	11452	0.507
7	9, 20	1512.7	13134	0.525
8	3, 9	1518.2	12340	0.508
9	9, 14	1512.1	11312	0.466
10	3, 9	1527.3	12864	0.549

Tabla 6.5: Resultados de 10 optimizaciones de OvS-FU

Corrida	Solución	CEENS (MWh/h)	Evaluaciones	CV
1	3, 9	1526.4	655	0.063
2	3, 9	1522.0	680	0.070
3	3, 9	1529.4	677	0.061
4	3, 9	1521.1	658	0.068
5	9, 14	1513.3	701	0.061
6	3, 9	1518.9	665	0.067
7	3, 9	1517.0	679	0.070
8	9, 14	1527.0	667	0.055
9	3, 9	1522.7	660	0.060
10	3, 9	1516.8	661	0.063

Tabla 6.6: Resultados de 10 optimizaciones de OvS-SAA

Ranking	Solución	CEENS (MWh/h)	Evaluaciones	5 %Q	95 %Q
1	3, 9	1516.7	10000	1510.6	1522.8
2	9, 14	1525.4	10000	1519.1	1531.7
3	3, 9	1529.9	10000	1524.3	1535.5
4	3, 9	1534.8	10000	1528.8	1540.8
5	3, 9	1544.2	10000	1538.0	1550.4
6	9, 14	1553.8	10000	1548.0	1559.6
7	3, 9	1559.0	10000	1553.1	1564.9
8	3, 9	1562.2	10000	1555.9	1568.5
9	3, 9	1565.2	10000	1559.5	1570.9
10	9, 20	1569.2	10000	1563.6	1574.8

Tabla 6.7: Ranking de soluciones de 10 optimizaciones de OvS-FU, e intervalo de confianza para cada solución.

Ranking	Solución	CEENS (MWh/h)	Evaluaciones	5 %Q	95 %Q
1	3, 9	1512.4	10000	1506.5	1518.3
2	3, 9	1519.8	10000	1513.9	1525.7
3	3, 9	1523.1	10000	1517.0	1529.2
4	3, 9	1523.2	10000	1517.5	1528.9
5	3, 9	1523.4	10000	1517.4	1529.4
6	9, 14	1525.1	10000	1519.1	1531.1
7	3, 9	1528.6	10000	1523.0	1534.2
8	3, 9	1535.9	10000	1530.1	1541.7
9	9, 14	1541.5	10000	1535.5	1547.5
10	3, 9	1542.4	10000	1536.6	1548.2

Tabla 6.8: Ranking de soluciones de 10 optimizaciones de OvS-SAA, e intervalo de confianza para cada solución.

6.4.2. Presupuesto igual a 3

Corrida	Solución	CEENS (MWh/h)	Evaluaciones	CV
1	9, 14, 18	1507.2	12439	0.507
2	9, 14, 18	1513.9	14372	0.478
3	9, 14, 20	1511.2	12149	0.500
4	3, 9, 14	1501.2	13011	0.501
5	9, 14, 18	1505.8	14308	0.488
6	9, 14, 18	1511.3	14015	0.475
7	9, 14, 20	1503.9	13523	0.508
8	9, 14, 18	1502.0	13500	0.545
9	9, 14, 20	1499.6	14274	0.521
10	3, 9, 20	1499.1	13446	0.493

Tabla 6.9: Resultados de 10 optimizaciones de OvS-FU

Corrida	Solución	CEENS (MWh/h)	Evaluaciones	CV
1	3, 9, 14	1495.7	836	0.074
2	3, 9, 14	1504.1	857	0.073
3	9, 14, 18	1510.8	846	0.066
4	3, 9, 14	1501.6	889	0.070
5	9, 14, 18	1499.5	806	0.073
6	3, 9, 14	1513.3	861	0.069
7	3, 9, 14	1512.4	824	0.070
8	3, 9, 14	1496.2	830	0.065
9	3, 9, 14	1502.3	823	0.075
10	9, 14, 20	1495.9	860	0.067

Tabla 6.10: Resultados de 10 optimizaciones de OvS-SAA

Ranking	Solución	CEENS (MWh/h)	Evaluaciones	5 %Q	95 %Q
1	9, 14, 18	1506.3	10000	1500.5	1512.1
2	9, 14, 20	1510.5	10000	1504.4	1516.6
3	9, 14, 18	1521.8	10000	1515.6	1528.0
4	9, 14, 20	1534.5	10000	1528.6	1540.4
5	9, 14, 18	1535.9	10000	1530.2	1541.6
6	9, 14, 20	1548.7	10000	1543.1	1554.3
7	9, 14, 18	1552.9	10000	1547.2	1558.6
8	9, 14, 18	1555.1	10000	1548.9	1561.3
9	3, 9, 14	1564.2	10000	1558.5	1569.9
10	3, 9, 20	1567.4	10000	1561.5	1573.3

Tabla 6.11: Ranking de soluciones de 10 optimizaciones de OvS-FU, e intervalo de confianza para cada solución.

Ranking	Solución	CEENS (MWh/h)	Evaluaciones	5 %Q	95 %Q
1	3, 9, 14	1501.7	10000	1495.5	1507.9
2	9, 14, 18	1512.9	10000	1506.9	1518.9
3	3, 9, 14	1513.6	10000	1507.7	1519.5
4	3, 9, 14	1518.0	10000	1511.7	1524.3
5	3, 9, 14	1521.2	10000	1515.1	1527.3
6	9, 14, 18	1521.4	10000	1515.6	1527.2
7	3, 9, 14	1525.2	10000	1518.9	1531.5
8	3, 9, 14	1526.8	10000	1521.1	1532.5
9	3, 9, 14	1531.3	10000	1525.3	1537.3
10	9, 14, 20	1534.9	10000	1529.2	1540.6

Tabla 6.12: Ranking de soluciones de 10 optimizaciones de OvS-SAA, e intervalo de confianza para cada solución.

6.4.3. Presupuesto igual a 4

Corrida	Solución	CEENS (MWh/h)	Evaluaciones	CV
1	3, 9, 14, 20	1483.6	14783	0.501
2	3, 9, 14, 18	1508.3	13919	0.548
3	3, 9, 14, 20	1500.9	14744	0.516
4	3, 9, 14, 20	1497.6	14142	0.494
5	9, 14, 18, 20	1503.4	14475	0.486
6	3, 14, 18, 20	1494.1	14840	0.518
7	9, 14, 18, 20	1481.8	15000	0.535
8	3, 9, 14, 20	1502.8	14998	0.546
9	3, 14, 18, 20	1497.3	14693	0.529
10	9, 14, 18, 20	1483.2	14996	0.515

Tabla 6.13: Resultados de 10 optimizaciones de OvS-FU

Corrida	Solución	CEENS (MWh/h)	Evaluaciones	CV
1	3, 9, 14, 18	1490.4	987	0.065
2	3, 9, 18, 20	1507.8	954	0.068
3	3, 9, 18, 20	1491.6	970	0.073
4	3, 9, 14, 18	1501.5	998	0.072
5	3, 9, 18, 20	1505.8	971	0.065
6	3, 9, 18, 20	1508.3	996	0.074
7	3, 9, 18, 20	1504.7	910	0.072
8	9, 14, 18, 20	1499.8	1006	0.073
9	3, 9, 18, 20	1501.0	972	0.073
10	3, 9, 18, 20	1500.7	1001	0.067

Tabla 6.14: Resultados de 10 optimizaciones de OvS-SAA

Ranking	Solución	CEENS (MWh/h)	Evaluaciones	5 %Q	95 %Q
1	3, 9, 14, 20	1452.1	10000	1445.8	1458.4
2	9, 14, 18, 20	1506.0	10000	1499.5	1512.5
3	3, 9, 14, 20	1522.9	10000	1517.1	1528.7
4	3, 9, 14, 20	1531.8	10000	1525.9	1537.7
5	9, 14, 18, 20	1538.2	10000	1532.1	1544.3
6	3, 9, 14, 20	1539.5	10000	1533.6	1545.4
7	9, 14, 18, 20	1540.5	10000	1534.6	1546.4
8	3, 14, 18, 20	1546.9	10000	1540.7	1553.1
9	3, 14, 18, 20	1550.1	10000	1543.8	1556.4
10	3, 9, 14, 18	1551.1	10000	1545.5	1556.7

Tabla 6.15: Ranking de soluciones de 10 optimizaciones de OvS-FU, e intervalo de confianza para cada solución.

Ranking	Solución	CEENS (MWh/h)	Evaluaciones	5 %Q	95 %Q
1	3, 9, 18, 20	1430.1	10000	1424.0	1436.2
2	3, 9, 14, 18	1503.5	10000	1497.6	1509.4
3	3, 9, 18, 20	1516.0	10000	1510.1	1521.9
4	3, 9, 18, 20	1519.0	10000	1513.2	1524.8
5	3, 9, 18, 20	1528.0	10000	1521.9	1534.1
6	3, 9, 18, 20	1531.2	10000	1525.2	1537.2
7	3, 9, 18, 20	1537.5	10000	1531.3	1543.7
8	3, 9, 14, 18	1540.6	10000	1534.3	1546.9
9	3, 9, 18, 20	1543.2	10000	1537.4	1549.0
10	9, 14, 18, 20	1543.6	10000	1537.5	1549.7

Tabla 6.16: Ranking de soluciones de 10 optimizaciones de OvS-SAA, e intervalo de confianza para cada solución.

6.5. Esquema de la función ga (Genetic Algorithm)

Global Optimization Toolbox proporciona funciones que buscan soluciones globales a problemas que contienen máximos o mínimos múltiples. Este toolbox ofrece solvers de pattern search, genetic algorithm, particle swarm, simulated annealing, multistart y global search. Puede utilizar estos solvers para problemas de optimización donde la función objetivo o de restricción sea continua, discontinua o estocástica, no posea derivadas o bien incluya simulaciones o funciones de tipo black-box.

El siguiente esquema resume cómo funciona el algoritmo genético de Matlab:

1. El algoritmo comienza creando una población inicial aleatoria.
2. El algoritmo luego crea una secuencia de nuevas poblaciones. En cada paso, el algoritmo utiliza a los individuos de la generación actual para crear la siguiente población. Para crear la nueva población, el algoritmo realiza los siguientes pasos:
 - (a) Califica a cada miembro de la población actual calculando su valor de aptitud. Estos valores se denominan puntajes de aptitud física en bruto.
 - (b) Escala los puntajes de aptitud física en bruto para convertirlos en un rango de valores más utilizable. Estos valores escalados se denominan valores esperados.
 - (c) Selecciona miembros, llamados padres, en función de sus expectativas.
 - (d) Algunos de los individuos en la población actual que tienen una condición física más baja son elegidos como elite. Estos individuos de élite pasan a la siguiente población.
 - (e) Produce hijos de los padres. Los hijos se producen haciendo cambios aleatorios en un solo padre (mutación) o combinando las entradas de vector de un par de padres (cruzados).
 - (f) Reemplaza la población actual con los hijos para formar la próxima generación.
3. El algoritmo se detiene cuando se cumple uno de los criterios de detención.