



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

INVERSIÓN EN REDES DE TRANSMISIÓN CONSIDERANDO FALLAS EN
CASCADA Y SEGURIDAD PROBABILÍSTICA

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

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

DANIEL SEBASTIÁN RIVERA MUÑOZ

PROFESOR GUÍA:
RODRIGO MORENO VIEYRA

MIEMBROS DE LA COMISIÓN:
CLAUDIA RAHMANN ZÚÑIGA
MATÍAS NEGRETE PINCETIC

SANTIAGO DE CHILE
2021

RESUMEN DE LA TESIS PARA OPTAR
AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO
AL GRADO DE MAGÍSTER EN CIENCIAS DE
LA INGENIERÍA, MENCIÓN ELÉCTRICA
POR: DANIEL SEBASTIÁN RIVERA MUÑOZ
FECHA: 2021
PROF. GUÍA: RODRIGO MORENO VIEYRA

INVERSIÓN EN REDES DE TRANSMISIÓN CONSIDERANDO FALLAS EN CASCADA Y SEGURIDAD PROBABILÍSTICA

Las fallas en cascada son la principal causa de grandes apagones. Estas se han incrementado en los últimos años provocando graves impactos económicos y sociales. Por tanto, es primordial considerar el riesgo de fallas en cascada en la planificación del sistema eléctrico.

En este contexto, planteamos un marco de seguridad probabilístico para incorporar el riesgo de fallas en cascada en problemas de planificación de la expansión de la transmisión (TEP). Como no existe una representación algebraica (lineal) de fallas en cascada que pueda incorporarse en un modelo de optimización, proponemos un enfoque basado en datos. Reglas derivadas de un árbol de decisión (DT) se incorporan al problema TEP mediante una formulación big-M. DTs se utilizan para predecir la energía esperada no suministrada (EENS) debido a fallas en cascada. Para encontrar un DT con predicciones precisas de EENS, presentamos un algoritmo donde el problema TEP se resuelve iterativamente. En cada iteración, ejecutamos un simulador de fallas en cascada para ajustar el DT.

Mediante varios casos de estudio, demostramos la importancia de considerar fallas en cascada en el problema TEP y las ventajas de nuestro enfoque sobre las soluciones de inversión clásicas obtenidas con los criterios de seguridad determinista $n - 1$ y probabilística.

A Dios y a mi familia

Agradecimientos

En primer lugar, quiero agradecer a mi familia ya que son el pilar fundamental de mi vida. Dar las gracias a mis padres, Elizabeth y Cristian, que se han preocupado de que no nos faltara nada a mi hermano y a mí. Agradecerles por siempre confiar y creer en mí, en que podría lograr mis sueños y metas. Quiero agradecer también a mis abuelos, Teresa y Manuel, por todos los momentos que he podido compartir con ellos, cada verano en el sur y en especial durante la cuarentena. Agradecerles por estar siempre apoyándome y dándome ánimo en momentos difíciles.

Agradecer a mi profesor guía, Rodrigo Moreno, por darme la oportunidad de realizar esta tesis y por todos los consejos, críticas y motivación que me permitieron sacar este trabajo adelante. Una buena frase que me llevo para la vida: “Lamentablemente no hay crecimiento sin dolor y sin que alguien nos diga que estamos haciendo mal. Lo importante es crecer”.

Quiero agradecer también a todos aquellos amigos que me acompañaron en este largo proceso. Desde los primeros años de universidad, Charlie y Maty, a los que estuvieron sorteando todos los desafíos de la especialidad, Claudio y Jota, y a los que estuvieron conmigo en todas esas tardes de ocio, Alinson, Tapir, Gato y Mario.

Finalmente, dar las gracias a todos los que han contribuido en mi vida, tanto en lo personal como académico, ya que han ayudado a convertirme en la persona que actualmente soy.

Tabla de Contenido

1. Introducción	1
1.1. Motivación	1
1.2. Hipótesis propuesta	3
1.2.1. Objetivo general	3
1.2.2. Objetivos específicos	3
1.3. Contribuciones	4
1.4. Estructura del trabajo	5
2. Revisión de literatura	6
2.1. Simuladores de fallas en cascada	6
2.2. Planificación del sistema eléctrico	8
2.3. Árboles de decisión	10
2.4. Enfoque propuesto	10
3. Metodología	12
3.1. Nomenclatura del capítulo	12
3.2. Descripción general de metodología	13
3.3. Muestreo-Simulación	14
3.3.1. Muestreo de inversiones y operación	14
3.3.2. Simulación de contingencias	15
3.4. Derivación de reglas	18
3.4.1. Entrenamiento del árbol de decisión (DT)	18
3.4.2. Extracción de reglas del DT	18
3.5. Implementación TEP	21
3.5.1. Implementación de reglas en TEP	21
3.5.2. Algoritmo TEP-Simulador	22
4. Estudio del sistema IEEE RTS	25
4.1. Datos de entrada	25
4.2. Casos de estudio	27
4.3. Resultados y discusión	28
4.4. Costos y riesgos generales: Análisis <i>out-of-sample</i>	29
4.5. Análisis de sensibilidad	30
4.5.1. Valor de la pérdida de carga (VoLL)	30
4.5.2. Ajuste de reglas del DT	30
4.5.3. Número de nodos terminales	31

4.5.4. Rendimiento del algoritmo: Evolución por iteración	32
5. Estudio del sistema IEEE-118	34
5.1. Datos de entrada	34
5.2. Resultados y discusión	35
6. Conclusiones y perspectivas	37
6.1. Conclusiones	37
6.2. Futura área de investigación	38
Bibliografía	38

Índice de Tablas

4.1. Costos de inversión IEEE-24.	26
4.2. Datos de generación.	27
4.3. Descripción de casos de estudio.	28
4.4. Resultados generales.	29
4.5. Sensibilidad parámetro γ	31
4.6. Sensibilidad número de nodos terminales.	32
5.1. Resultados del caso de estudio IEEE-118.	36

Índice de Ilustraciones

2.1. Metodología típica de fallas en cascada [1].	7
3.1. Diagrama general de metodología.	13
3.2. Simulador de fallas en cascada.	16
3.3. Estructura del árbol de decisión.	18
3.4. Esquema optimización-simulación propuesto.	22
4.1. Diagrama unilineal del sistema IEEE-24.	26
4.2. Costo total respecto a VoLL.	31
4.3. Evolución de costo total según iteración.	33
4.4. Evolución de EENS según iteración.	33
5.1. Diagrama unilineal del sistema IEEE-118.	34

Capítulo 1

Introducción

1.1. Motivación

Las fallas en cascada en la red de transmisión son la principal causa de grandes apagones [2], los cuales han aumentado en los últimos años involucrando graves impactos económicos y sociales. Por ejemplo, el apagón más severo que se produjo en el sistema estadounidense fue el apagón del 14 de agosto de 2003, donde al menos 50 millones de personas se vieron afectadas provocando un costo total de aproximadamente 10 mil millones de dólares [3]. El 1 de marzo de 2017, un apagón similar en Nueva York afectó alrededor de 21 millones de personas. Los hallazgos más relevantes en las causas de los apagones han sido la insuficiencia en la capacidad de transmisión y la necesidad de realizar nuevas inversiones para mejorar la confiabilidad del sistema [4]. Por lo tanto, resulta primordial considerar el riesgo de fallas en cascada en la planificación de la transmisión.

La vital importancia de la energía eléctrica en nuestra sociedad motiva los esfuerzos en mejorar la confiabilidad del sistema. En particular, las fallas en cascada atraen una gran atención tanto del mundo académico como de la industria para desarrollar nuevos métodos para evaluar sus riesgos [5]. No obstante, analizar y simular fallas en cascada en los sistemas eléctricos plantea grandes desafíos debido a las complejidades, dependencias e incertidumbres de este tipo de fenómenos, los que se pueden definir como una secuencia de eventos dependientes que debilitan o degradan sucesivamente el sistema [6]. En este sentido, en [1] se describen y comparan varias metodologías que modelan un estado cuasi-estacionario (QSS) para evaluar el riesgo de interrupciones en cascada en los sistemas eléctricos, las que difieren en los mecanismos de cascada considerados (por ejemplo, violaciones de flujo o voltaje) y en su modelado (flujo de potencia AC o DC). Adicionalmente, otras metodologías representan de manera simplificada fenómenos dinámicos de cascada (por ejemplo, inestabilidad de frecuencia [7–9]). De esta forma, destacamos que el compromiso entre la carga computacional y la fidelidad es un factor clave en la selección de un simulador de fallas en cascada.

En el contexto de la planificación de la expansión de la transmisión, la seguridad del sistema se ha considerado siguiendo un criterio determinista [10], probabilístico [11] y más recientemente, de distribución robusta [12]. En el caso del enfoque determinista se ignora

la probabilidad de las interrupciones y los desprendimientos de carga se consideran inaceptables, por lo que no puede reconocer adecuadamente el costo de la energía esperada no suministrada. Por otra parte, los enfoques estocásticos equilibran los costos de inversión en infraestructura frente a los costos operacionales y los riesgos posteriores a fallas asociados con desprendimientos de carga. Sin embargo, existe una tendencia a ignorar los riesgos de fallas en cascada en los modelos de planificación de la transmisión, lo que puede ser poco práctico debido a que se podrían estar subestimando los impactos que este tipo de eventos provocan en la energía no suministrada del sistema al descuidar las dependencias entre fallas y la evolución dinámica de la red en el transcurso de una contingencia [13].

Investigaciones recientes han comenzado a considerar las fallas en cascada en problemas de planificación de la transmisión. En [14, 15], se proponen enfoques para identificar líneas de transmisión críticas en la propagación de fallas en cascada a partir de índices de vulnerabilidad. En la metodología presentada en [16], se evalúan los riesgos para distintas políticas de expansión del sistema de transmisión y la mejor se selecciona mediante un análisis de costo/beneficio. Con el fin de formular el problema de expansión de la transmisión, el trabajo en [17] introduce un modelo de simulación-optimización que minimiza la probabilidad de fallas en cascada a través del uso de metaheurísticas para la búsqueda de las mejores soluciones. Además, se ha propuesto en [4] una optimización de enjambre de partículas multiobjetivo para encontrar un conjunto de Pareto óptimo entre los costos de inversión y la energía esperada no suministrada (que incluye el riesgo de fallas en cascada). Con relación a esto, hacemos énfasis en que los fenómenos físicos asociados a las fallas en cascada, usualmente modelados mediante simulaciones, son difíciles de incorporar dentro de un modelo de optimización debido a que son altamente no lineales.

Más recientemente, algoritmos de aprendizaje de máquinas han estado atrayendo mucha atención y se consideran alternativas valiosas o adiciones a los métodos tradicionales para mejorar el rendimiento del análisis y control de los sistemas eléctricos de potencia [18]. En este sentido, existe un interés particular en el uso de árboles de decisión (DT's) para la evaluación de la seguridad del sistema eléctrico, ya que no solo proporcionan la información de los conjuntos de datos con una carga computacional baja, sino que también revelan las reglas de decisión aprendidas para una interpretación adicional [19]. Dentro de la literatura, algunas de las contribuciones relevantes son [20] y [21] donde los autores presentan un método para incrustar reglas derivadas de un árbol de decisión dentro de un problema de flujo óptimo de potencia DC (DC-OPF) para garantizar la seguridad $n - 1$ del sistema. Asimismo, en [22] y [23], se propone un modelo AC-OPF que incorpora reglas de un árbol de decisión, y que garantiza la estabilidad de pequeña señal y la seguridad $n - 1$. Este enfoque es prometedor y un paso natural hacia la representación de fenómenos no lineales mediante reglas aprendidas desde conjuntos de datos. En este aspecto, el desafío de implementar este tipo de enfoque basado en datos en modelos de planificación y su uso en problemas de regresión (por ejemplo, en la predicción del riesgo del sistema) permanecen sin abordar en la literatura existente.

En este contexto, proponemos un marco de seguridad probabilístico para incorporar el riesgo de fallas en cascada en los problemas de planificación de expansión de la transmisión. Específicamente, dado que no existe una representación algebraica (lineal) de fallas en cascada que puedan incorporarse en un modelo de optimización, usamos un enfoque basado en datos. Los datos se toman de un simulador de fallas en cascada de flujo DC para entrenar un

árbol de decisión (DT) con el fin de predecir la energía esperada no suministrada (EENS) en función de las condiciones de operación y las decisiones de inversión. Luego, incorporamos reglas derivadas del árbol de decisión al modelo de planificación a través de una formulación big-M. Por tanto, el modelo corresponde a un problema de programación lineal entera mixta (MILP). Llamamos al problema resultante, el problema de planificación de expansión de la transmisión probabilística basado en el árbol de decisión (DT-PTEP).

De esta forma, nuestro modelo incorpora una representación lineal del estado cuasi-estacionario del sistema, siendo capaz de capturar el riesgo de fallas en cascada dentro del problema de optimización a través de un conjunto de restricciones big-M. Estas restricciones se actualizan en un proceso iterativo de la siguiente manera. El modelo DT-PTEP (con el conjunto de restricciones big-M incorporadas) determina una solución de inversión (y operativa), sobre la cual se aplica un simulador de fallas en cascada para calcular la EENS y compararla con la aproximación del DT dentro de la optimización. El proceso iterativo continúa hasta que la EENS simulada y la EENS aproximada son iguales (dentro de una tolerancia). Además, el modelo puede incorporar restricciones de valor en riesgo condicional (CVaR) para protegerse contra la cola de la PDF de la ENS. Si bien ya se ha propuesto considerar las fallas en cascada en la planificación de inversiones de red (ver [4, 14–17, 24]), nuestro modelo es, según nuestro conocimiento, el primero que propone un enfoque para incorporar el riesgo de fallas en cascada en la planificación de la transmisión equilibrando de manera óptima los costos de inversión, operación y energía esperada no suministrada.

1.2. Hipótesis propuesta

Esta tesis busca demostrar que es posible identificar y optimizar nuevas inversiones en redes de transmisión (en conjunto con decisiones operativas de despacho) de manera de mitigar el riesgo de fallas en cascada en sistemas eléctricos.

1.2.1. Objetivo general

La presente tesis tiene como objetivo general desarrollar un programa de optimización matemática que optimice inversiones de red (líneas y transformadores), considerando la ocurrencia de fallas en cascadas. Para esto, se utilizan algoritmos de aprendizaje de máquinas, en particular, árboles de decisión, para predecir los impactos de dichas fallas en cascada, los que luego se incluyen dentro de un problema de minimización de costos de inversión, operación y energía esperada no suministrada.

1.2.2. Objetivos específicos

Los objetivos específicos de esta tesis son:

- Implementar un simulador de fallas en cascada basado en el flujo de potencia DC, para

estimar los impactos que este tipo de eventos provocan en el sistema dependiendo de la topología, carga de componentes y esquema operativo.

- Diseñar un procedimiento que genere una base de datos, de diversos puntos de operación y topologías, para entrenar un árbol de decisión (DT) que sea capaz de predecir, en función del estado del sistema, la energía esperada no suministrada del sistema cuando las fallas en cascada son consideradas.
- Diseñar un método generalizable para incorporar reglas derivadas desde el árbol de decisión que consideren el riesgo de fallas en cascada en un modelo de planificación de la red de transmisión.
- Desarrollar un algoritmo que incorpore un simulador de fallas en cascada en el proceso de optimización para validar las soluciones obtenidas y corregir errores en la predicción del riesgo.
- Validar la metodología propuesta en el sistema IEEE RTS, a fin de observar los beneficios y los impactos de reconocer la ocurrencia de interrupciones en cascada en un sistema eléctrico.
- Demostrar la escalabilidad de nuestra metodología en el sistema IEEE-118.

1.3. Contribuciones

En general, las principales contribuciones de este documento son:

- Formular un modelo de optimización de TEP con seguridad probabilística que considera fallas en cascada y que captura de manera apropiada el riesgo del sistema mediante un árbol de decisión.
- Proponer un algoritmo novedoso que incorpora un simulador de fallas en cascada dentro del proceso de optimización propuesto que valida la solución obtenida y que corrige errores en la predicción del riesgo proveniente del árbol de decisión.
- Demostrar las ventajas del enfoque propuesto frente al estado del arte en TEP con seguridad probabilística.
- Demostrar la importancia de considerar las fallas en cascadas en la planificación de la red y como la planificación determinista $n - 1$ puede tener ventajas frente a la planificación probabilística cuando las fallas en cascadas son ignoradas en esta última.

1.4. Estructura del trabajo

Este documento está estructurado en 6 capítulos de la siguiente manera. El Capítulo 1 motiva e introduce el trabajo de investigación. El Capítulo 2 presenta una revisión de la literatura en términos de simuladores de fallas en cascada y el problema de planificación del sistema eléctrico. El Capítulo 3 describe la metodología para derivar el problema de planificación de expansión de la transmisión probabilística basado en el árbol de decisión propuesto (DT-PTEP). El Capítulo 4 y 5 demuestra la aplicabilidad y escalabilidad del modelo propuesto en dos sistemas de prueba, IEEE RTS y IEEE-118, respectivamente. Por último, el Capítulo 6 concluye y presenta futuros desafíos de investigación.

Capítulo 2

Revisión de literatura

En este capítulo realizamos una revisión del estado del arte de los conceptos fundamentales y principios de modelado utilizados en este documento. Específicamente, estos corresponden a simuladores de fallas en cascada, modelos de planificación del sistema eléctrico y algoritmos de aprendizaje de máquinas, en particular, árboles de decisión.

2.1. Simuladores de fallas en cascada

Las fallas en cascada, eventos de baja probabilidad y alto impacto, se conocen como amenazas importantes para la estabilidad y seguridad de los sistemas eléctricos. Según [25], una falla en cascada se define como la pérdida sucesiva no controlada de elementos del sistema provocada por un evento inicial o disparador. Los eventos disparadores son causados, por ejemplo, por cortocircuitos, fallas ocultas o errores de los operadores.

Las fallas en cascada ocurren debido a diferentes mecanismos tales como sobrecargas térmicas o inestabilidad de voltaje [25] y se pueden observar en cualquier apagón de un gran sistema eléctrico [26]. Los conceptos básicos de las fallas en cascada se dan en [5]. De acuerdo con [27], si bien muchos factores eléctricos afectan en la propagación de las fallas en cascada, la insuficiencia de la red de transmisión se ha identificado como una de las principales causas. De esta forma, realizar inversiones estratégicas en la infraestructura de la red puede reducir las consecuencias de estos eventos y, por ende, mejorar la confiabilidad del sistema. Sin embargo, debido a que este tipo de eventos responden a una secuencia de interrupciones interdependientes, su análisis plantea grandes desafíos y por lo tanto se requieren poderosas herramientas de simulación para evaluar y estimar sus impactos en el sistema eléctrico.

Se han propuesto varios modelos para estudiar las fallas en cascada, como el modelo OPA [26], CASCADE [28], TRELSS [29] y Manchester [30], entre otros. Estas metodologías modelan un estado cuasi-estacionario (QSS) para simular el comportamiento del sistema durante contingencias y evaluar el riesgo de las fallas en cascada. No obstante, difieren en los mecanismos en cascada considerados y en su modelado (flujo de potencia AC o DC).

Estas metodologías siguen un enfoque común que se ilustra en la figura 2.1 y que se resume de la siguiente manera. El sistema se inicializa en un estado normal de operación (previo a una contingencia) y se simula una o varias contingencias iniciales, es decir, eventos disparadores. Estos eventos pueden aumentar el estrés en los otros componentes del sistema, provocando sobrecargas en las redes de transmisión o incluso separando el sistema en islas, lo que puede generar las condiciones para que se gatillen otras fallas, es decir, fallas en cascada. Para analizar esto, se computa el estado del sistema posterior a la contingencia. Si uno o varios elementos están fuera de las condiciones de operación normal (por ejemplo, violaciones en los límites técnicos de flujo de los elementos de transmisión debido a la redistribución de flujos), se disparan. Posteriormente, si al menos un elemento fue disparado, entonces se realiza un nuevo cálculo del estado posterior a la contingencia, hasta que no se produzcan nuevas violaciones. Este proceso iterativo captura los cambios que ocurren en la topología del sistema y en las condiciones de operación producto de los elementos que se desconectan tanto por el evento disparador como por violar sus límites técnicos. Por último, las consecuencias finales son registradas, esto es, por lo general, la energía no suministrada debido al evento o contingencia inicial.

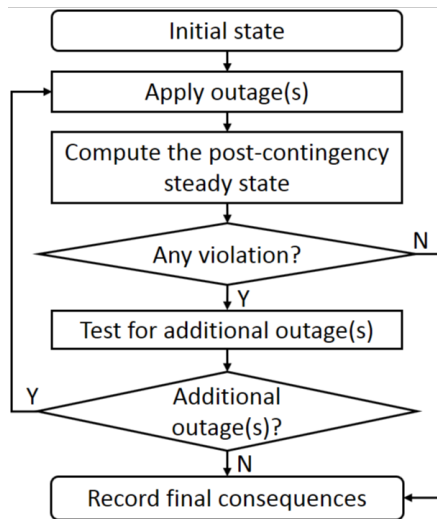


Figura 2.1: Metodología típica de fallas en cascada [1].

Vale la pena señalar que fallas en cascada debido a líneas sobrecargadas es un mecanismo considerado por todas las metodologías. El disparo de elementos sobrecargados representa la activación de un sistema de protección (por ejemplo, protecciones de sobrecorriente). De esta forma, cuando un elemento se encuentra sobre un porcentaje a definir de su capacidad nominal en operación normal se identifica y se dispara. El cálculo del estado posterior a un cambio de topología puede basarse en una solución directa de las ecuaciones de flujo de potencia (PF) o en un flujo óptimo de potencia (OPF) que captura el despliegue de acciones correctivas por parte del operador del sistema. Adicionalmente, en caso de existir un desequilibrio de carga/generación después de una división del sistema (cuando el sistema se separa en islas) o de la pérdida de una unidad generadora, un modelo simplificado de control de frecuencia primario se utiliza para simular la restauración del equilibrio carga/generación [1].

2.2. Planificación del sistema eléctrico

Los sistemas de transmisión deben diseñarse para entregar un suministro eficiente y seguro de la carga futura. El problema de planificación de la expansión de la transmisión (TEP) se lleva a cabo para determinar el plan de red óptimo que minimiza los costos de inversión en nuevos activos de la red de transmisión y los costos operacionales asociados a la generación de energía [31].

En el contexto de la planificación de la expansión de la transmisión, la seguridad del sistema se ha considerado tradicionalmente siguiendo un criterio determinista [10], probabilístico [11] y más recientemente, de distribución robusta [12]. En el marco determinista, el problema de planificación corresponde al equilibrio entre el costo de inversión de la red (anualizado) y el costo total de operación durante un año, como se muestra en la ecuación 2.1a:

$$\min C_{inv}(\vec{v}) + \sum_{b=1}^{\tau} C_{op}(\vec{x}_b, \vec{u}_b) \Delta T_b \quad (2.1a)$$

donde \vec{v} son las decisiones de inversión, τ es el número de intervalos utilizados para la discretización del tiempo a lo largo del año y ΔT_b denota la duración de cada intervalo. C_{op} es el costo de operación en el intervalo b y C_{inv} es el costo de inversión asociado con las mejoras de la red. En este enfoque se espera que los sistemas eléctricos resistan la ocurrencia de cualquier conjunto definido de contingencias creíbles (por ejemplo, una pérdida de uno o dos circuitos de acuerdo con el criterio $n - 1$ o $n - 2$, respectivamente) sin causar sobrecargas o voltajes inadecuados. Sin embargo, ignora la probabilidad de las interrupciones y los desprendimientos de carga se consideran inaceptables, por lo que no puede reconocer adecuadamente el costo de la energía esperada no suministrada [10].

Por otra parte, en el marco probabilístico el problema de planificación corresponde al equilibrio entre el costo de inversión de la red (anualizado), el costo total de operación del sistema intacto y los riesgos esperados posteriores a fallas asociados a desprendimientos de carga o energía no suministrada (ENS), como se muestra en la ecuación 2.2a.

$$\min C_{inv}(\vec{v}) + \sum_{b=1}^{\tau} \left\{ C_{op}(\vec{x}_b, \vec{u}_b) + \text{VoLL} \sum_{k=1}^M p_{k,b} \text{ENS}_{k,b} \right\} \Delta T_b \quad (2.2a)$$

A diferencia del enfoque determinista, en el enfoque probabilístico se incorpora el costo esperado de interrupciones de suministro, donde $p_{k,b}$ es la probabilidad de la interrupción k en el intervalo b y VoLL representa el valor de la pérdida de carga. De esta forma, los enfoques estocásticos permiten equilibrar el costo de operación e infraestructura de la red con los beneficios de seguridad entregados a los clientes del sistema.

No obstante, existe una tendencia a ignorar los riesgos de fallas en cascada en los modelos de planificación de la transmisión, subestimando, por tanto, los impactos que este tipo de eventos provocan en la energía no suministrada del sistema. Lo expuesto anteriormente implica que, de no considerarlas, se descuidan en el análisis de riesgo tanto las dependencias entre fallas como la evolución dinámica de la red en el transcurso de una contingencia [13].

En los últimos años, distintas investigaciones han comenzado a considerar las fallas en cascada en problemas de planificación de la transmisión. A continuación, se citan algunos artículos representativos. Los autores en [14, 15], proponen enfoques para identificar líneas de transmisión críticas, de acuerdo con sus impactos en el inicio y propagación de la falla en cascada en el sistema eléctrico, a partir del cálculo de índices de vulnerabilidad, lo que permite encontrar una solución que conduce a una mitigación efectiva contra las fallas en cascada. En la metodología presentada en [16], se evalúan los riesgos para distintas políticas de expansión del sistema de transmisión y la mejor se selecciona mediante un análisis de costo/beneficio. Con el fin de formular el problema de expansión de la transmisión, el trabajo en [17] introduce un marco de simulación-optimización que minimiza la probabilidad de fallas en cascada a través del uso de metaheurísticas para la búsqueda de las mejores soluciones, determinando decisiones de expansión de capacidad que incluyen la adición de nuevas líneas de transmisión y la adición de capacidad a las líneas existentes. La probabilidad de la falla en cascada se evalúa utilizando el método de simulación de Monte Carlo. El procedimiento de simulación comienza seleccionando al azar una línea para disparar. Luego, la probabilidad de una interrupción de la siguiente línea se evalúa utilizando un modelo de estado cuasi-estacionario. Este proceso en cascada continúa hasta que no hay nuevas interrupciones. Además, se ha propuesto en [4] una optimización de enjambre de partículas multiobjetivo para encontrar un conjunto de Pareto óptimo entre los costos de inversión y la energía esperada no suministrada (EENS). La EENS de cada escenario se evalúa utilizando la metodología OPA propuesta en [26] con el objetivo de considerar el riesgo de fallas en cascada. El modelo OPA es un modelo de fallas en cascada que es capaz de capturar la naturaleza de estos eventos y simular las dinámicas involucradas en el transcurso de una falla. En [32] se introduce un modelo OPA mejorado que considera la dinámica del sistema durante una falla, la influencia del flujo por los elementos de transmisión, condiciones operacionales de despacho, acciones correctivas del operador posterior a la contingencia y relés de protección.

Otras investigaciones relevantes de fallas en cascada son detalladas en seguida. En [33], se propone un grafo de influencia de Márkov para describir las probabilidades de interrupciones en líneas y posteriores fallas en cascada. La investigación enfatiza que en los estudios de TEP convencionales se ignora la probabilidad de que una interrupción cause interrupciones posteriores. Sin embargo, algunas interrupciones pueden propagarse a través de la red y causar fallas en cascada. Los autores concluyen que, mediante la inversión de nuevos activos de red, la configuración de la transmisión se puede actualizar para minimizar el riesgo de estos eventos. Por otro lado, en [34, 35] se propone un algoritmo estocástico de química aleatoria (RC) para identificar múltiples contingencias que inician grandes fallas en cascada. Debido a la complejidad de las fallas en cascada, un flujo de potencia DC es utilizado para estimar el impacto. El trabajo en [36] propuso un modelo de toma de decisiones para TEP utilizando índices de riesgo condicionales. Este método es útil para equilibrar cuidadosamente entre eventos de baja probabilidad-alto impacto y eventos de alta probabilidad-bajo impacto. También, los autores en [37] proponen un modelo para optimizar la planificación de la expansión de la transmisión considerando criterios de seguridad y resiliencia. Para considerar la resiliencia de la transmisión, el impacto de las fallas en cascada es evaluado utilizando un simulador. Adicionalmente, basado en el algoritmo de descomposición de Benders (BD), se desarrolla un procedimiento de solución de múltiples etapas para manejar las decisiones de inversión, las restricciones de seguridad y los requisitos de resiliencia de manera eficiente.

2.3. Árboles de decisión

En la actualidad, los algoritmos de aprendizaje de máquinas se consideran alternativas valiosas a los métodos tradicionales en el contexto de mejorar el rendimiento del análisis y control de los sistemas eléctricos de potencia [18]. Específicamente, existe una gran variedad de investigaciones que utilizan árboles de decisión (DT's) aplicados a problemáticas de análisis de datos y sistemas eléctricos. Lo anterior, debido a su alto rendimiento computacional e interpretabilidad. Entre las muchas aplicaciones de DT's en sistemas eléctricos, la evaluación de la seguridad es una de las más estudiadas. Con la ayuda de los DT's, la información relativa a los escenarios del sistema (por ejemplo, condiciones operativas, contingencias, topologías, voltaje, etc.) se puede expresar como un modelo para evaluar y predecir los estados de seguridad de los escenarios a partir de un vector de características [19]. En este aspecto, los DT's se han utilizado en el pasado utilizando muestras de Monte Carlo para construir, por ejemplo, predictores de la estabilidad dinámica de los sistemas eléctricos [38, 39].

Investigaciones recientes han ido más allá de la tarea de predicción y proponen un enfoque integral para utilizar predictores, como los árboles de decisión (DT), dentro de un marco de optimización estándar para fines de control. En este sentido, dentro de la literatura existente, alguna de las contribuciones relevantes en el contexto de modelos de optimización y DT's son [20] y [21] donde los autores presentan un método generalizable para incorporar reglas derivadas del DT en un modelo de toma de decisiones de operación, construyendo proxies de seguridad que cubren múltiples contingencias mientras enfrentan una incertidumbre de alta dimensión con respecto a las condiciones de operación. Asimismo, en [22] y [23], se derivan árboles de decisión desde grandes conjuntos de datos de puntos operativos, que capturan todos los requisitos de seguridad y permiten definir reglas de decisión manejables que se implementan en un modelo AC-OPF capaz de garantizar la estabilidad de pequeña señal y la seguridad $n - 1$.

De esta forma, los enfoques basados en datos mencionados en el párrafo anterior resultan prometedores y un paso natural hacia la representación de fenómenos no lineales mediante reglas aprendidas desde conjuntos de datos. No obstante, cabe señalar que el desafío de implementarlos en modelos de toma de decisiones de inversión y su utilización en problemas de regresión (por ejemplo, en la predicción del riesgo del sistema) no han sido abordados aún en la literatura existente.

2.4. Enfoque propuesto

Muchas investigaciones que consideran la dinámica de las fallas en cascada han reportado como mejora la confiabilidad del sistema al realizar inversiones en la red de transmisión (ver [4, 14–17, 24]). No obstante, en este documento por primera vez proponemos un enfoque para la planificación de la transmisión en donde se equilibra de manera óptima los costos de inversión, operación y energía esperada no suministrada, incorporando en esta última componente el impacto de las fallas en cascada.

En este contexto, planteamos un enfoque de seguridad probabilístico para incorporar el riesgo de fallas en cascada en los problemas de planificación de la expansión de la transmisión. En particular, dado que no existe una representación algebraica (lineal) de fallas en cascada que se pueda incorporar en un modelo de optimización, proponemos un enfoque basado en datos. Específicamente, incorporamos reglas derivadas de un árbol de decisión (DT) al problema de planificación a través de una formulación big-M, por lo que el modelo corresponde a un problema de programación lineal entera mixta (MILP). Utilizamos los DTs para predecir la energía esperada no suministrada (EENS), métrica que en nuestro modelo considera el impacto de las fallas en cascada en el sistema eléctrico. Asimismo, presentamos un novedoso algoritmo que incorpora un simulador de fallas en cascada en el proceso de optimización para validar la solución y corregir errores de predicción. Finalmente, en nuestro modelo también incorporamos restricciones de valor en riesgo condicional (CVaR) que permiten protegerse contra la cola de la PDF de la energía no suministrada (ENS).

Capítulo 3

Metodología

3.1. Nomenclatura del capítulo

Índices:

- b : Índice para periodos de tiempo o bloques de demanda de 1 a τ .
 c : Índice para elementos de transmisión candidatos de 1 a C .
 g : Índice para unidades de generación de 1 a G .
 i : Índice para nodos terminales de árbol de decisión de 1 a Ω .
 k : Índice para escenarios de falla de 1 a M .
 n : Índice para barras del sistema de 1 a N .
 s : Índice para muestras de base de datos de 1 a S .

Parámetros:

- $CVaR$: Límite superior de valor condicional en riesgo. [MWh/h]
 D_b^{tot} : Demanda total en bloque b . [MW]
 $E\hat{N}S_{i,k,b}$: Estimador de energía no suministrada en nodo i , escenario k y bloque b . [MWh/h]
 \vec{L}_l : Limitación componentes para estado normal. [MW]
 \vec{L}_m : Limitación componentes para estado emergencia largo plazo. [MW]
 \vec{L}_{sh} : Limitación componentes para estado emergencia corto plazo. [MW]
 M : Variable suficientemente grande o big-M. [p.u.]
 $p_{k,b}$: Probabilidad de escenario de falla k en bloque b . [p.u.]
 T : Número total de horas. [h]
 $VoLL$: Costo de energía no suministrada. [\$/MWh]
 α : Nivel de confianza de CVaR. [p.u.]
 $\Delta\varepsilon$: Tolerancia algoritmo TEP-Simulador. [MWh/h]
 ΔT_b : Número de horas en bloque b . [h]
 γ : Factor de corrección para restricciones del DT. [p.u.]

Variables de decisión:

\vec{u}_b	: Vector de variables de control para bloque b .	[MWh]
\vec{v}	: Vector de variables binarias asociadas a nuevas inversiones de transmisión. 1 si se decide invertir, 0 si no.	
var	: Valor en riesgo.	[MWh/h]
\vec{x}_b	: Vector de variables de estado para bloque b .	[MW,rad]
$z_{i,b}$: Variable binaria asociada a nodo terminal i en bloque b . 1 si se escoge, 0 si no.	

3.2. Descripción general de metodología

La metodología para derivar el problema de planificación de expansión de la transmisión probabilística basada en el árbol de decisión (DT-PTEP) que se propone en este documento se muestra como un diagrama de flujo en la figura 3.1.

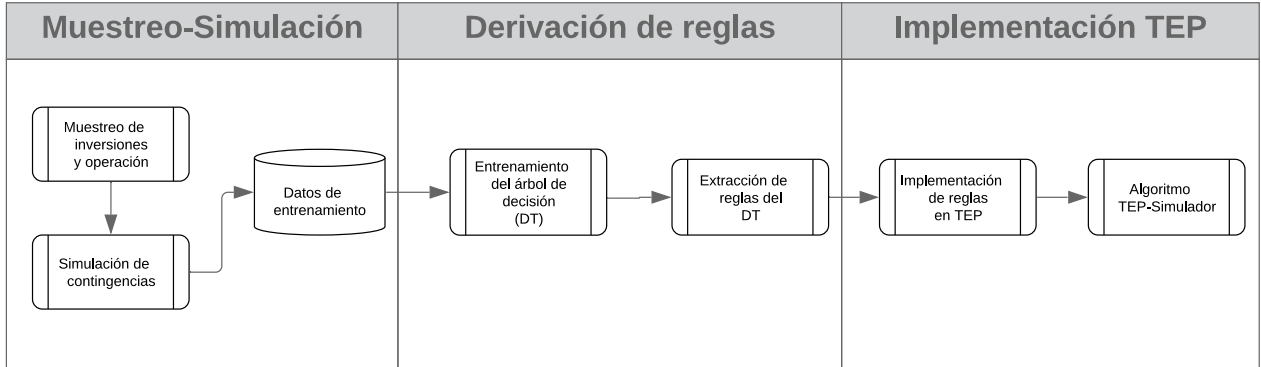


Figura 3.1: Diagrama general de metodología.

La primera parte consiste en el bloque de muestreo-simulación. Debido a que los datos históricos a menudo contienen un número limitado de situaciones anormales [40], los datos de simulación son necesarios para determinar con precisión el comportamiento del sistema luego de ocurrida una contingencia. La creación de dichos datos se describe en la sección 3.3, en donde se comienza con un muestreo de distintas inversiones y condiciones operativas, para posteriormente evaluar cada una de las muestras en un simulador de fallas en cascada. La segunda parte de la metodología utiliza estos datos para el entrenamiento de un árbol de decisión y desde el cual se derivan reglas para predecir la energía no suministrada de cada escenario de falla en función del estado del sistema (sección 3.4). La última parte, detallada en la sección 3.5, consiste en incorporar tales reglas en un problema TEP (a través de una formulación big-M) e implementar un algoritmo iterativo para validar la solución y corregir errores en la predicción de la energía no suministrada.

3.3. Muestreo-Simulación

El procedimiento de muestreo-simulación planteado consiste en crear S datos de entrenamiento con la forma (X, Y) , donde X corresponde a las características de entrenamiento e Y la variable a predecir. En primer lugar, se realiza un muestreo de condiciones operativas y decisiones de inversión, desde el cual se extraen las características de entrenamiento X . Luego, Y se obtiene a partir de un simulador de fallas en cascada que computa la energía no suministrada de cada muestra para todos los escenarios de falla que se considerarán en el problema TEP.

En este sentido, cabe mencionar que una parte sensible de los estudios basados en árboles de decisión es la creación de la base de datos de entrenamiento [40]. Los principales desafíos al generar una base de datos de este tipo se detallan a continuación. En primer lugar, el tamaño del problema a resolver, ya que es computacionalmente imposible evaluar todas las condiciones de operación y decisiones de inversión posibles debido al gran número de combinaciones que pueden existir en sistemas que superen algunas decenas de barras [41]. En segundo lugar, la calidad de la información. La precisión de las reglas obtenidas del árbol de decisión resultante se refleja en la calidad del conjunto de datos generado para el entrenamiento. Por tanto, la estrategia utilizada debe ser capaz de obtener la mayor cantidad de información del sistema en un número limitado de muestras.

3.3.1. Muestreo de inversiones y operación

Para generar diversas condiciones de operación, se utiliza como referencia la estrategia planteada en [20], donde el despacho de potencia $(P_{g,s})$ de las G unidades de generación se muestrea aleatoriamente a partir de una distribución uniforme no correlacionada dentro de su rango operativo específico, en particular, se establece 0 como límite inferior y la potencia máxima respectiva de cada generador del sistema como límite superior. Por otra parte, se asocia una demanda a cada una de las muestras, la que se escoge aleatoriamente entre τ bloques representativos de la curva de duración anual. Dado que la potencia total (P_s^{tot}) debe ser igual a la demanda (D_s^{tot}) asociada, las diferencias (Δ_s) se distribuyen entre todos los generadores ponderando en función de su potencia máxima (w_g) de acuerdo a las ecuaciones 3.1, 3.2 y 3.3 para los G generadores y las S muestras. Adicionalmente, aquellos generadores que en este proceso queden sobre su potencia máxima, se les fija en su límite superior y la diferencia es distribuida en los generadores restantes dentro de un proceso iterativo. De esta manera, la estrategia de muestreo asegura que se cumplan los límites técnicos de las unidades de generación.

$$w_g = \frac{P_{max_g}}{\sum_{j=1}^G P_{max_j}} \quad g = 1, \dots, G \quad (3.1)$$

$$\Delta_s = P_s^{tot} - D_s^{tot} \quad s = 1, \dots, S \quad (3.2)$$

$$P_{g,s} = P_{g,s} + \Delta_s w_g \quad g = 1, \dots, G \quad s = 1, \dots, S \quad (3.3)$$

En el caso del muestreo de las decisiones de inversión, se definen C líneas candidatas cuya decisión de inversión (1 si se decide invertir, 0 si no) distribuye como una Bernoulli de parámetro 0.5, lo que permite obtener un muestreo uniforme de todos los portafolios de inversión. Este muestreo se realiza para cada una de las S muestras de acuerdo a la ecuación 3.4.

$$XI_{c,s} \sim Be(0,5) \quad c = 1, \dots, C \quad s = 1, \dots, S \quad (3.4)$$

Posteriormente, se resuelve un flujo de potencia DC (DC-PF) para cada una de las muestras (utilizando las condiciones operativas y las decisiones de inversión respectivas) con la finalidad de extraer el flujo de potencia de las líneas del sistema. Todas las muestras que contengan líneas con un flujo mayor a su capacidad máxima en operación normal se descartan. Lo anterior, mejora la calidad de la información evitando datos con situaciones poco realistas o improbables. Finalmente, las características de entrenamiento X a utilizar en el entrenamiento del DT corresponden al flujo de potencia por cada una de las líneas del sistema (excluyendo las líneas candidatas) y las decisiones de inversión para cada una de las líneas candidatas.

3.3.2. Simulación de contingencias

Una vez realizado el muestreo de las condiciones de operación y las decisiones de inversión, se procede con el paso de simulación de contingencias, en donde la dinámica de las fallas en cascada está basada en la metodología de estado cuasi-estacionario (QSS) OPA [26], que utiliza la versión linealizada de las ecuaciones de flujo de potencia (DC-PF) para la representación del sistema de transmisión. Las S muestras creadas en el paso anterior se evalúan en el simulador de fallas en cascada propuesto (ver figura 3.2) para M escenarios de falla (escenarios a considerar en el problema TEP), obteniendo de esta forma la energía no suministrada de cada escenario de falla k para cada muestra s .

La figura 3.2 muestra el diagrama de flujo del método propuesto para la evaluación del riesgo del sistema cuando las fallas en cascada son consideradas. El procedimiento paso a paso del método propuesto se describe a continuación. Se comienza con un evento inicial, correspondiente a uno de los M escenarios de falla, el cual puede aumentar el estrés en los otros componentes del sistema. La consecuencia de este evento puede provocar islas, sobrecargas en las redes de transmisión y variaciones de frecuencia y, como resultado, fallas en cascada, llevando finalmente a un apagón [32].

Después del evento inicial, se comprueba si el sistema fue separado en islas. Si ese fuera el caso, se continúa con el procedimiento para cada una de ellas. Posteriormente, se analiza si existen desequilibrios de potencia. En el caso de que no exista un desequilibrio de potencia, se ejecuta un flujo de potencia DC (DC-PF) en donde las líneas sobrecargadas con respecto a su

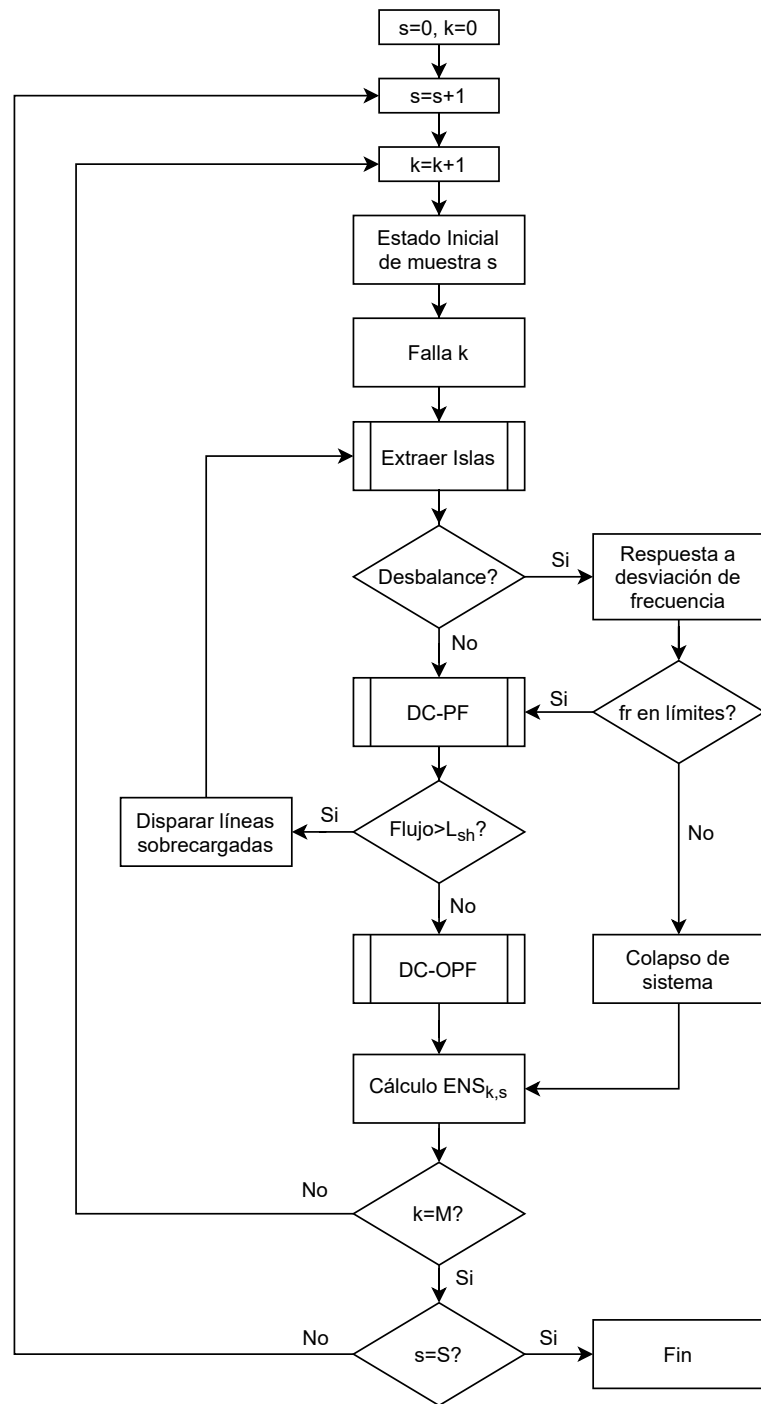


Figura 3.2: Simulador de fallas en cascada.

capacidad de emergencia de corto plazo \vec{L}_{sh} (generalmente un 25% adicional a la capacidad en operación normal) se identifican y se disparan [16]. Debido a esto, puede haber nuevas líneas sobrecargadas o haberse formado islas. De esta forma, este proceso iterativo continúa mientras existan nuevas líneas sobrecargadas.

Asimismo, después del evento inicial o después de cada paso de falla en cascada, puede haber un desequilibrio de potencia (ΔP) y, en consecuencia, una desviación de frecuencia

en el sistema (Δf). La desviación de frecuencia se considera de acuerdo con lo propuesto en [7], en donde todos los generadores con control primario de frecuencia (R_g) responden a este desequilibrio. También, se considera la característica de frecuencia de las cargas de cada una de las barras del sistema (D_n) en respuesta a la desviación de potencia. En consecuencia, la desviación de frecuencia del sistema se calcula a través de la ecuación 3.5. Adicionalmente, para mantener la frecuencia dentro de los límites se emplean esquemas de desconexión automática de carga o generación según corresponda. Cabe mencionar que si la frecuencia excede o cae el 5 % de la frecuencia nominal (± 2.5 Hz en 50 Hz), se asume que el sistema o la isla respectiva colapsó [8]. Caso contrario, se continúa con el procedimiento descrito cuando no existen desequilibrios.

$$\Delta f = \frac{-\Delta P}{\sum_{n=1}^N D_n + \sum_{g=1}^G \frac{1}{R_g}} \quad (3.5)$$

En el caso de que no existan nuevas líneas sobrecargadas, se considera que el operador realizará acciones correctivas a través de un flujo óptimo de potencia DC (DC-OPF) utilizando la capacidad de emergencia de largo plazo de las líneas \vec{L}_m (generalmente un 20 % adicional a la capacidad en operación normal) [42]. Finalmente, se computa la energía no suministrada ($ENS_{k,s}$) para cada uno de los escenarios de falla y muestras.

A partir de las salidas del simulador de fallas en cascada, se definen los vectores de energía no suministrada porcentual ($ENS_{k,s}^{\%}$) de los distintos escenarios de falla y muestras de acuerdo a la ecuación 3.6. Posteriormente, a través de la ecuación 3.7, se calcula la energía esperada no suministrada porcentual de cada muestra ($EENS_s^{\%}$) con el objetivo de construir el vector Y a utilizar en el entrenamiento del árbol de decisión, con p_k igual a la probabilidad del escenario de falla k y D_s^{tot} la demanda total de la muestra s .

$$ENS_{k,s}^{\%} = \frac{ENS_{k,s}}{D_s^{tot}} \quad k = 1, \dots, M \quad s = 1, \dots, S \quad (3.6)$$

$$EENS_s^{\%} = \sum_{k=1}^M ENS_{k,s}^{\%} \cdot p_k \quad s = 1, \dots, S \quad (3.7)$$

Cabe mencionar que la probabilidad de cada estado se calcula asumiendo que todos los eventos de falla son independientes y distribuyen exponencialmente como se expresa en las ecuaciones 3.8 y 3.9 [11]. Pr_i es la probabilidad de encontrar el/los componente/s de red i en falla en el tiempo T , mientras que U^k y D^k son los conjuntos de componentes operativos y en falla en el estado k , respectivamente.

$$p_k = \prod_{i \in U^k} (1 - Pr_i) \prod_{j \in D^k} Pr_j \quad (3.8)$$

$$Pr_i = 1 - e^{-\lambda_i \cdot T} \quad (3.9)$$

3.4. Derivación de reglas

El objetivo de este módulo es encontrar reglas desde los datos de entrenamiento (X, Y) en forma de restricciones de desigualdad $d_{i,b}(x, z) \leq 0$ que sean capaces de predecir la energía no suministrada para cada escenario de falla. Estas restricciones se integran en el problema TEP a través de una formulación big-M.

3.4.1. Entrenamiento del árbol de decisión (DT)

Para obtener las reglas, se entrena un árbol de decisión de regresión (DT) a través del algoritmo de aprendizaje CART que divide sucesivamente el espacio de características x en dos en cada iteración, según un umbral b_n en función de los datos de entrenamiento (X, Y) , hasta que se cumpla un criterio de parada (por ejemplo, máximo número de nodos terminales, calidad de la división, etc.). En la figura 3.3 se muestra un ejemplo de la estructura del árbol de decisión de regresión, el cual está conformado por dos nodos de decisión (n_1 y n_2). Cada nodo de decisión tiene asociado una característica de los datos de entrenamiento (x_m) y un umbral (b_n) que divide el espacio en las regiones $x_m \leq b_n$ (rama izquierda) y $x_m > b_n$ (rama derecha). Adicionalmente, el DT consta de tres nodos terminales caracterizados con una predicción correspondiente al promedio de las muestras contenidas en cada uno de ellos. En particular, la predicción realizada por cada nodo terminal i corresponde a la ENS porcentual para cada uno de los escenarios de falla ($E\hat{N}S_{i,k}^{\%}$).




Figura 3.3: Estructura del árbol de decisión.

3.4.2. Extracción de reglas del DT

Las reglas del árbol de decisión pueden reformularse para modelos de optimización utilizando un enfoque de programación disyuntiva generalizada (GDP) con variables binarias. En particular, se utiliza la reformulación big-M planteada en [20]. Con lo anterior, es posible construir un conjunto de restricciones $d_{i,b}(x, z)$ con $b = 1, \dots, \tau$ y $i = 1, \dots, \Omega$, siendo τ la cantidad de bloques de demanda, Ω la cantidad de nodos terminales, x_m las características de entrenamiento asociada a cada nodo de decisión y $z_{i,b}$ variables binarias asociadas a cada

nodo terminal y bloque de demanda. Las restricciones asociadas a cada nodo terminal dependerán de si las características de entrenamiento involucradas en cada decisión son operativas (flujo por las líneas) o de inversión y de la ruta seguida desde el nodo raíz hasta el nodo terminal respectivo. Adicionalmente, dado que se entrena un único DT, las restricciones son las mismas independiente del bloque de demanda b .

En este contexto, si la variable x_m presente en un nodo de decisión corresponde al flujo por alguna de las líneas, entonces se procede de la siguiente manera comenzando desde el nodo raíz. Si del nodo actual la ruta hacia el nodo terminal i continúa hacia la rama izquierda, se añade a $d_{i,b}(x, z)$ la restricción 3.10, caso contrario, se incorpora 3.11. Este procedimiento se realiza hasta llegar al nodo terminal i y se repite para los Ω nodos. Dado que el uso de una desigualdad estricta (rama derecha en el DT) no es posible en optimización, se agrega un valor pequeño ε mayor a cero para cambiar a una desigualdad no estricta.

$$x_m \leq b_n z_{i,b} + M(1 - z_{i,b}) \quad i = 1, \dots, \Omega \quad b = 1, \dots, \tau \quad (3.10)$$

$$x_m \geq b_n z_{i,b} - M(1 - z_{i,b}) + \varepsilon \quad i = 1, \dots, \Omega \quad b = 1, \dots, \tau \quad (3.11)$$

Adicionalmente, las restricciones 3.10 y 3.11 pueden reformularse para añadir un factor de corrección (γ) de acuerdo con las ecuaciones 3.12 y 3.13, respectivamente. El factor γ permite ajustar y mejorar la calidad de las reglas, lo que se traduce en la obtención de mejores soluciones.

$$x_m \leq \gamma b_n z_{i,b} + M(1 - z_{i,b}) \quad i = 1, \dots, \Omega \quad b = 1, \dots, \tau \quad (3.12)$$

$$x_m \geq \gamma b_n z_{i,b} - M(1 - z_{i,b}) + \varepsilon \quad i = 1, \dots, \Omega \quad b = 1, \dots, \tau \quad (3.13)$$

En el caso de que la variable x_m presente en un nodo de decisión corresponda a una decisión de inversión se realiza lo siguiente. Si la ruta hacia el nodo terminal i continúa hacia la rama izquierda, entonces se añade la ecuación 3.14. Caso contrario, se utiliza la ecuación 3.15.

$$x_m \leq 1 - z_{i,b} \quad i = 1, \dots, \Omega \quad b = 1, \dots, \tau \quad (3.14)$$

$$x_m \geq z_{i,b} \quad i = 1, \dots, \Omega \quad b = 1, \dots, \tau \quad (3.15)$$

Una vez construido el conjunto de restricciones $d_{i,b}(x, z)$, la optimización se aplica para asignar exactamente un nodo terminal en cada bloque de demanda de acuerdo a la ecuación 3.16.

$$\sum_{i=1}^{\Omega} z_{i,b} = 1 \quad b = 1, \dots, \tau \quad (3.16)$$

Respecto a la predicción asociada a cada nodo terminal, el DT se entrena utilizando como variable objetivo el vector Y correspondiente a la energía esperada no suministrada porcentual. Sin embargo, se requiere que el DT sea capaz de predecir la energía no suministrada de cada contingencia. Para esto, posterior al entrenamiento, para cada subconjunto de muestras asociadas a cada nodo terminal se recuperan los vectores de energía no suministra porcentual (ver ecuación 3.6) correspondientes a los utilizados en el cálculo de los escalares de energía esperada no suministrada porcentual (ver ecuación 3.7). Luego, el promedio (punto a punto) de los vectores se utiliza como la predicción de la energía no suministrada porcentual para cada nodo terminal y para cada escenario de falla ($E\hat{N}S_{i,k}^{\%}$). Posterior a ello, se utiliza la ecuación 3.17 para obtener la estimación requerida asociada a cada bloque de demanda.

$$E\hat{N}S_{i,k,b} = E\hat{N}S_{i,k}^{\%} D_b^{tot} \quad i = 1, \dots, \Omega \quad k = 1, \dots, M \quad b = 1, \dots, \tau \quad (3.17)$$

Por último, se utiliza la formulación presentada en la ecuación 3.18 para penalizar la estimación de la energía esperada no suministrada ($E\hat{E}NS_b$) en el modelo TEP.

$$E\hat{E}NS_b = \sum_{k=1}^M p_{k,b} \sum_{i=1}^{\Omega} z_{i,b} E\hat{N}S_{i,k,b} \quad b = 1, \dots, \tau \quad (3.18)$$

El procedimiento anterior se justifica por dos razones principales. Primero, debido a que si bien existen árboles de decisión de salidas múltiples (que permiten entrenar con el vector de ENS directamente), en base a experimentos numéricos se pudo comprobar que el desempeño obtenido fue más pobre al compararlo con el árbol de decisión de una sola salida (utilizado en nuestro procedimiento). En segundo lugar, entrenar un solo DT con los datos de varios bloques de demanda (en vez de un DT para cada bloque) permite obtener una mayor cantidad y calidad de información, y por lo tanto, mejores predicciones. Adicionalmente, cabe mencionar que el objetivo de tener la predicción de la energía no suministrada de cada contingencia es para incorporar al modelo TEP un enfoque de aversión al riesgo mediante restricciones de valor en riesgo condicional (CVaR). Por lo tanto, si estas restricciones no son requeridas, las ecuaciones 3.17 y 3.18 pueden reemplazarse por las ecuaciones 3.19 y 3.20 que permiten trabajar directamente con la EENS y evitar la última parte del procedimiento descrito.

$$E\hat{E}NS_{i,b} = E\hat{E}NS_{i,b}^{\%} D_b^{tot} \quad i = 1, \dots, \Omega \quad b = 1, \dots, \tau \quad (3.19)$$

$$E\hat{E}NS_b = \sum_{i=1}^{\Omega} z_{i,b} E\hat{E}NS_{i,b} \quad b = 1, \dots, \tau \quad (3.20)$$

3.5. Implementación TEP

Esta parte de la metodología consiste en incorporar las reglas derivadas desde el árbol de decisión, de acuerdo a lo planteado en la sección 3.4, en un problema TEP. Posteriormente, se describe la implementación del algoritmo iterativo que valida la solución obtenida y corrige errores en la predicción de la energía no suministrada.

3.5.1. Implementación de reglas en TEP

La formulación del problema de planificación probabilística de la expansión del sistema de transmisión considerando fallas en cascada y basado en el árbol de decisión propuesto (DT-PTEP) está dada por las ecuaciones 3.21a-3.21g:

$$\min \quad C_{inv}(\vec{v}) + \sum_{b=1}^{\tau} \left\{ C_{op}(\vec{x}_b, \vec{u}_b) + \text{VoLL} \sum_{k=1}^M p_{k,b} \sum_{i=1}^{\Omega} z_{i,b} E\hat{N}S_{i,k,b} \right\} \Delta T_b \quad (3.21a)$$

$$\text{s.t.} \quad \vec{g}_b(\vec{x}_b, \vec{u}_b) = 0 \quad b = 1, \dots, \tau, \quad (3.21b)$$

$$\vec{h}_b(\vec{x}_b, \vec{u}_b) \leq \vec{L}_l \quad b = 1, \dots, \tau, \quad (3.21c)$$

$$d_{i,b}(\vec{x}_b, \vec{v}, z_{i,b}, \gamma) \leq 0 \quad i = 1, \dots, \Omega \quad b = 1, \dots, \tau, \quad (3.21d)$$

$$\sum_{i=1}^{\Omega} z_{i,b} = 1 \quad b = 1, \dots, \tau, \quad (3.21e)$$

$$\sum_{i=1}^{\Omega} z_{i,b} E\hat{N}S_{i,k,b} - \text{var} \leq \delta_{k,b} \quad k = 1, \dots, M \quad b = 1, \dots, \tau, \quad (3.21f)$$

$$\text{var} + \frac{1}{1-\alpha} \sum_{b=1}^{\tau} \sum_{k=1}^M \frac{\Delta T_b p_{k,b}}{T} \delta_{k,b} \leq CVaR \quad (3.21g)$$

donde C_{inv} es el costo de inversión asociado a la nueva infraestructura, con \vec{v} el vector de decisión de dichas inversiones, τ es el número de intervalos utilizados para la discretización del tiempo a lo largo del año y ΔT_b indica la duración de cada intervalo de tiempo. El subíndice b se refiere a la condición de operación en una captura particular de la demanda en todo el sistema. C_{op} es el costo operativo del sistema intacto, con \vec{x}_b y \vec{u}_b los vectores de estado (por ejemplo, flujo por la red de transmisión) y variables de control (por ejemplo, el despacho de los generadores), respectivamente. M representa el número de contingencias analizadas y $p_{k,b}$ la probabilidad del escenario de falla k en el intervalo b . VoLL representa el valor de la pérdida de carga, $z_{i,b}$ la variable binaria asociada a cada uno de los Ω nodos terminales del DT y $E\hat{N}S_{i,k,b}$ la predicción de la energía no suministrada asociada a cada uno de los nodos.

En la formulación probabilística propuesta, el problema de planificación corresponde al equilibrio entre el costo de inversión de red (anualizado), el costo total de la operación previa a una falla y el costo esperado de la energía no suministrada durante un año como se muestra en la ecuación 3.21a. Cabe mencionar que la última componente descrita corresponde a un estimador de la energía no suministrada, el cual depende del nodo terminal $z_{i,b}$ escogido en cada periodo b y su predicción asociada. De este modo, se logra considerar el riesgo de interrupciones en cascada en un problema TEP.

Por otro lado, la ecuación 3.21b constituye las restricciones del flujo de potencia DC,

mientras que la ecuación 3.21c tiene como objetivo evitar resultados infactibles con respecto a \vec{L}_l , vector que define la capacidad máxima de líneas en estado normal y los límites de las variables de control. Respecto a las ecuaciones 3.21d y 3.21e, estas incorporan las reglas derivadas del árbol de decisión a través del enfoque descrito en la sección 3.4.

Adicionalmente, se añade un marco de aversión al riesgo que puede ser utilizado para operar y diseñar sistemas de potencia más resilientes en función del perfil de riesgo del tomador de decisiones. De este modo, para restringir la exposición al riesgo de eventos HILP, se utiliza una representación lineal de CVaR de acuerdo a las ecuaciones 3.21f y 3.21g. El concepto de CVaR utilizado se define como la energía no suministrada (ENS) que se espera en los peores $(1 - \alpha)\%$ de los casos [43], donde var es el valor en riesgo, T el tiempo total a lo largo del año, $CVaR$ cota superior de valor en riesgo condicional y $\delta_{k,b}$ la pérdida de carga en el periodo b y escenario de falla k por encima de los niveles definidos por el umbral de valor en riesgo.

3.5.2. Algoritmo TEP-Simulador

En esta sección, se plantea un algoritmo iterativo que consiste en un esquema de optimización-simulación cuya visión general es presentada en la figura 3.4. El objetivo es corregir errores en la predicción de la EENS y determinar las soluciones óptimas de inversión (y operación) del sistema estudiado.

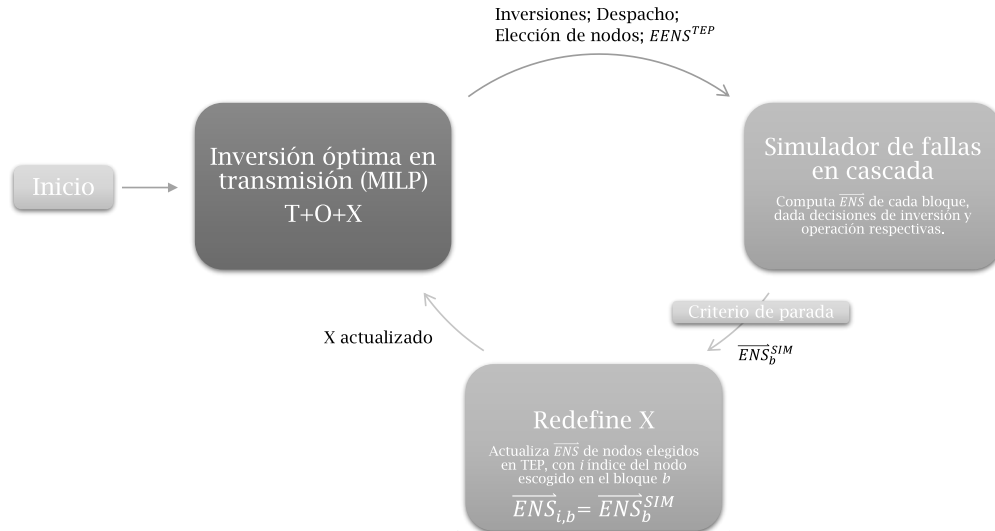


Figura 3.4: Esquema optimización-simulación propuesto.

En este contexto, la necesidad de implementar el algoritmo descrito se detalla a continuación. Los estimadores por definición son imperfectos. Por lo tanto, las predicciones provenientes del árbol de decisión están sujetas a errores. Específicamente, en [21] se detalla que pueden existir casos en los que una regla de seguridad sea extremadamente precisa para identificar puntos críticos, sin embargo, al utilizarla para realizar una óptima acción de control la precisión se vea reducida drásticamente. El caso anterior es una conclusión para árboles de decisión de clasificación. En el caso de los árboles de decisión de regresión, utilizados en este

documento, las implicaciones de este tema no se han abordado en la literatura existente. En este sentido, a través de diversas sensibilidades, se detectó que, en algunos casos, existía un error considerable entre la EENS estimada en el DT-PTEP y el valor obtenido en el simulador de fallas en cascada. Lo anterior, hace necesario verificar la validez de las predicciones mediante la ejecución de simulaciones y corregirlas en los casos que así lo ameriten.

Para esto, se resuelve el problema DT-PTEP utilizando como estimación inicial de la EENS la predicción proveniente desde el árbol de decisión. Posteriormente, la solución de inversión y operación encontrada es evaluada en el simulador de fallas en cascada propuesto. Si la diferencia entre la predicción de la EENS utilizada en el DT-PTEP con la calculada en el simulador es mayor a una tolerancia previamente definida, entonces la estimación asociada a cada uno de los nodos del DT escogidos en el DT-PTEP (un nodo del DT por cada bloque de demanda) es actualizada con los valores obtenidos en la simulación y el proceso se repite. Si no existe diferencia o esta es menor a la tolerancia definida, entonces se determina que el problema se ha resuelto de manera óptima y el proceso iterativo se finaliza.

Vale la pena señalar que la actualización de la predicción del DT mencionada puede reemplazarse por una combinación lineal convexa entre la predicción de la iteración anterior y los valores obtenidos en la simulación. No obstante, debido a que la actualización del DT no afecta a la topología o reglas de este, la solución obtenida en el DT-PTEP (para un nodo del DT y bloque de demanda específico) debería, en general, ser la misma en cada iteración, y, por lo tanto, los resultados del simulador (para ese caso particular) corresponderían a la predicción correcta. Lo anterior fue ratificado por medio de experimentos numéricos, donde se llegó a la misma solución óptima tanto cuando se reemplazaba el vector de ENS directamente como cuando se actualizaba utilizando la combinación lineal. Sin embargo, esta última requería más tiempo de cómputo, y, por tanto, resultaba en un rendimiento más pobre que al actualizar directamente con los resultados del simulador.

El pseudocódigo de la metodología propuesta en esta sección se detalla en el algoritmo 1. El criterio de parada o tolerancia se determina a través del parámetro $\Delta\varepsilon$, mientras que la estimación inicial de la energía no suministrada $E\hat{N}S_{i,k,b}$ es obtenida a partir de la ecuación 3.17.

Algoritmo 1: Algoritmo TEP-Simulador

```
1 Inicializar  $E\hat{N}S_{i,k,b}$  con estimación inicial;
2 while True do
3   Resolver DT-PTEP  $\leftarrow E\hat{N}S_{i,k,b}$ ;
4   Recoger solución  $(\vec{x}_b, \vec{u}_b, \vec{v}, z_{i,b}, E\hat{E}NS)$  ;
5   Resolver simulador  $\leftarrow (\vec{x}_b, \vec{u}_b, \vec{v})$  ;
6   Recoger solución  $(EE\hat{N}S^{SIM}, ENS_{k,b}^{SIM})$  ;
7   if  $|E\hat{E}NS - EE\hat{N}S^{SIM}| \leq \Delta\varepsilon$  then
8     Solución óptima  $\leftarrow \vec{x}_b, \vec{u}_b, \vec{v}$ ;
9     break;
10  else
11    for  $b \leftarrow 1$  to  $\tau$ ,  $i \leftarrow 1$  to  $\Omega$  do
12      if  $z_{i,b} = 1$  then
13        for  $k \leftarrow 1$  to  $M$  do
14           $E\hat{N}S_{i,k,b} \leftarrow ENS_{k,b}^{SIM}$ 
15        end
16      end
17    end
18  end
19 end
```

Capítulo 4

Estudio del sistema IEEE RTS

Esta sección estudia el desempeño económico y de confiabilidad de los planes de expansión de red y condiciones operativas cuando se optimiza considerando fallas en cascada. Para hacerlo, presentamos tres casos de nuestra metodología (DT-PTEP) en los que estudiamos los impactos de considerar este tipo de eventos para distintos perfiles de riesgo. Estos tres casos se comparan con el enfoque de seguridad probabilística (PTEP) y el criterio de seguridad determinista $n - 1$ (DTEP). Adicionalmente, realizamos un análisis de sensibilidad para los parámetros de nuestro modelo: valor de la pérdida de carga, γ y número de nodos terminales. Utilizamos este caso de estudio para ilustrar y validar el modelo propuesto.

4.1. Datos de entrada

El diagrama unilineal del sistema se muestra en la Fig. 4.1. Modificamos el sistema IEEE RTS descrito en [44] por:

- a) Triplicando la potencia máxima de los generadores y demanda de sistema original.
- b) Añadiendo cinco nuevas líneas al sistema original: 14-16, 6-10, 10-12 y dos líneas en 7-8.

Tenga en cuenta que los cambios descritos están destinados a congestionar el sistema y poder realizar análisis más razonables, en un contexto de expansión del sistema. Además, consideramos los siguientes 6 activos de red candidatos (adicionales a la infraestructura existente informada en [44]) en el problema de planificación de la red: 1-5, 3-9, 4-9, 6-10, 12-13 y 20-23.

Los costos de inversión de red para líneas y transformadores son obtenidos desde [45] y se muestran en la tabla 4.1. Otros datos de costos relevantes incluyen un VoLL igual a 10 k\$/MWh, mientras que los costos de combustible se señalan en la tabla 4.2 [46]. La anualidad del costo de inversión de red se compara con el costo de un año de operación del sistema, que representa el estado del sistema cuando los activos de transmisión ya están construidos,

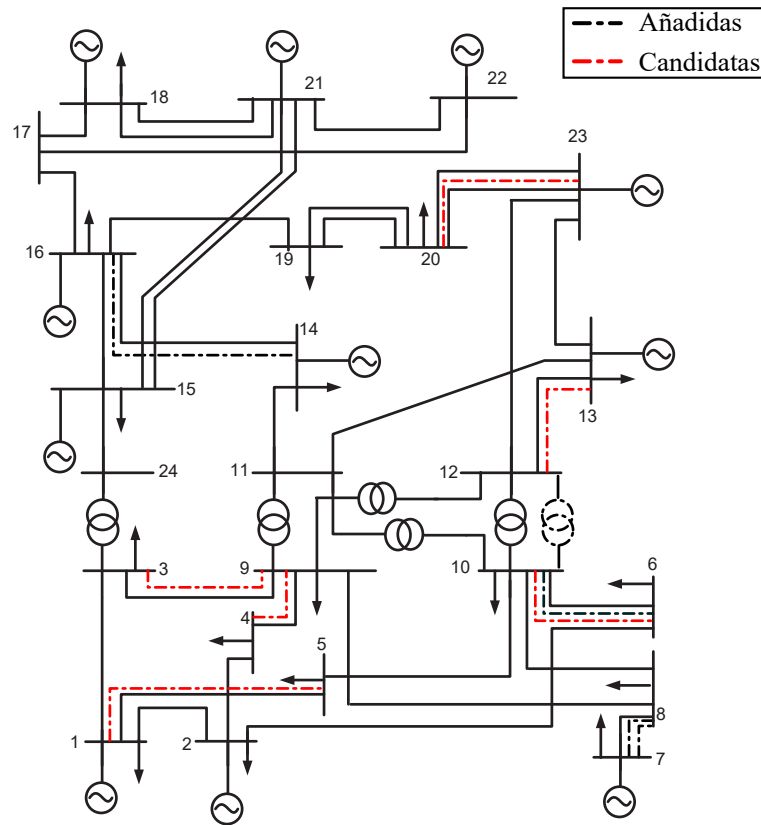


Figura 4.1: Diagrama unilineal del sistema IEEE-24.

es decir, años después de que las decisiones de inversión se hayan tomado originalmente. Con respecto a las condiciones de operación, el año se divide en tres bloques de demanda representativos utilizando el algoritmo k-means.

Tabla 4.1: Costos de inversión IEEE-24.

Elemento candidato	Costo de inversión anualizado [millón \$]
1-5	2.2
3-9	3.1
4-9	2.7
6-10	1.6
12-13	6.6
20-23	3.0

El conjunto de escenarios de falla considera todos los eventos $n - 1$ de transmisión y eventos $n - 2$ en circuitos dobles ($n - d$). Las tasas de fallas de los elementos de red son las presentadas en [44]. Las capacidades de líneas y transformadores posteriores a la falla son 25% y 20% más altas que las pre-falla en las condiciones de operación de emergencia de corto y largo plazo, respectivamente.

50000 muestras fueron creadas para construir los datos de entrenamiento (X, Y) . El árbol

Tabla 4.2: Datos de generación.

Unidad	Capacidad [MW]	Costo variable [\$/MWh]
U12	12	56.56
U20	20	130.00
U50	50	0.00
U76	76	16.08
U100	100	43.66
U155	155	12.39
U197	197	48.58
U350	350	11.85
U400	400	4.42

de decisión se entrenó mediante el algoritmo CART implementado en el paquete scikit-learn [47] con Python 3.7.3, utilizando las configuraciones predeterminadas (por ejemplo, minimizar el error cuadrático medio) excepto por el máximo número de nodos terminales permitido que fue fijado en 500.

Otros parámetros son γ igual a 0.99, cuyo objetivo es restringir las reglas obtenidas desde el árbol de decisión en un 1% adicional, y $1 - \alpha$ es igual a 1E-4. En cuanto al algoritmo optimización-simulación, una diferencia menor o igual a 0.1 MW entre la energía esperada no suministrada anual estimada en el problema de planificación y el valor computado en el simulador de fallas en cascada fue requerida como criterio de parada.

4.2. Casos de estudio

Analizamos tres enfoques para estudiar los impactos de fallas en cascada en la planificación de inversiones de red (ver tabla 4.3):

- 1) Enfoque de seguridad probabilística (PTEP), donde las fallas en cascada se ignoran, evidentemente, ya que el enfoque no es capaz de modelarlas.
- 2) Enfoque de seguridad tradicional determinista $n - 1$ (DTEP), donde el desprendimiento de carga para contingencias simples no está permitido.
- 3) Enfoque propuesto (DT-PTEP), donde reglas derivadas de un árbol de decisión son utilizadas para reconocer el riesgo del sistema cuando las fallas en cascada son consideradas. Además, se analizan tres casos de este enfoque para distintos perfiles de riesgo dados por el parámetro $\text{CVaR}_{99\%}$, a fin de analizar los efectos de la aversión al riesgo en la planificación de la red.

Utilizamos una computadora con un procesador Intel i5-8265U (1.6 GHz) y 8 GB de RAM. El modelo de planificación y el simulador de falla en cascada se implementaron utilizando

Tabla 4.3: Descripción de casos de estudio.

Caso	Desprendimiento de carga	Contingencias modeladas	Fallas en cascada	Restricción de CVaR
Determinista $n - 1$ (DTEP)	No	$n - 1$	No	No
Probabilístico (PTEP)	Si	$n - 1$ y $n - d$	No	No
Propuesto (DT-PTEP)	Si	$n - 1$ y $n - d$	Si	Si

FICO Xpress [48] y MATPOWER [46], respectivamente.

4.3. Resultados y discusión

La Tabla 4.4 presenta una descripción general de los resultados para cada enfoque, donde se muestran y comparan datos económicos, de confiabilidad y de infraestructura. La discusión se proporciona a continuación.

- 1) *Solución determinista $n - 1$ (DTEP)*: La Tabla 4.4 muestra que, en el caso determinista $n - 1$, el modelo invierte significativamente, instalando 6 activos de red a un costo de inversión total de \$ 19.2 millones. Además, el costo de operación programado es el más alto e igual a \$645.14 millones para hacer frente a todas las interrupciones de red $n - 1$. Dado que los desprendimientos de carga no están permitidos, se necesitan altos niveles de redundancia tanto en transmisión como en generación para asegurar el sistema.
- 2) *Solución probabilística (PTEP)*: En este caso, la Tabla 4.4 muestra que el modelo no realiza ninguna inversión en red. Además, los costos de operación son considerablemente menores que los del enfoque determinista $n - 1$, totalizando un costo anual de \$560.93 millones. Como era de esperar, esto es posible debido a que el modelo equilibra los costos de inversión y operación con los costos esperados de energía no suministrada asociados a los posibles estados de interrupción $n - 1$ y $n - d$. A pesar de ello, los resultados obtenidos a partir de un análisis *out-of-sample* evidencian que este modelo subestima el costo de EENS debido a que ignora la ocurrencia de fallas en cascada. Específicamente, se obtiene una diferencia de aproximadamente 9 veces entre el costo de EENS obtenido en la optimización y el análisis *out-of-sample*, correspondientes a \$19.23 millones y \$176.04 millones, respectivamente.
- 3) *Solución probabilística considerando fallas en cascada (DT-PTEP 1)*: Este caso corresponde a un perfil neutral al riesgo, equivalente a ejecutar el enfoque propuesto sin restricciones de CVaR. Debido a la consideración de las fallas en cascada en la planificación, el modelo cubre el riesgo a través de mayores inversiones en red y costos operacionales como se muestra en la Tabla 4.4 en comparación con el modelo probabilístico tradicional (PTEP). En este sentido, encontramos que la solución del enfoque propuesto presenta un costo total mayor a la solución probabilística tradicional, que no considera el riesgo de la ocurrencia de fallas en cascada, cuando se comparan los resultados obtenidos en la optimización y cuyos costos son iguales a \$623.72 millones y \$580.16 millones, respectivamente. En cambio, cuando se consideran los costos del

análisis *out-of-sample* nuestro enfoque presenta un costo total igual a \$624.32 millones frente a los \$736.97 millones de la solución probabilística, lo que evidencia las ventajas de nuestro enfoque en reconocer el riesgo de las fallas en cascada y la necesidad de considerar este tipo de eventos en la planificación de la red.

Tabla 4.4: Resultados generales.

Ítem	DTEP	PTEP	DT-PTEP #1	DT-PTEP #2	DT-PTEP #3
Parámetro CVaR _{99%} [MWh/h]	N/A	N/A	2000	1200	700
Costo de inversión [millón \$]	19.2	0	5.3	5.2	6.1
Costo de operación (planificado, pre-falla) [millón \$]	645.14	560.93	561.84	582.26	622.17
Costo de EENS [millón \$]	0	19.23	56.58	43.16	7.99
Costo total [millón \$]	664.74	580.16	623.72	630.62	636.26
Costo de EENS [millón \$]*	2.25	176.04	57.18	43.51	8.21
Costo total [millón \$]*	666.59	736.97	624.32	630.97	636.48
Costo de CVaR _{99%} -ENS [millón \$]*	20.63	362.73	148.60	107.07	41.46
Número de nuevos activos instalados	6	0	2	2	2

* Resultados obtenidos de un análisis *out-of-sample* con contingencias más allá de $n - 1$ y $n - d$.

4.4. Costos y riesgos generales: Análisis *out-of-sample*

El análisis *out-of-sample* realizado permite validar las decisiones obtenidas en la optimización (inversión y operación) a través de numerosas ejecuciones en el simulador de fallas en cascada para cada uno de los casos estudiados. Particularmente, se realizaron simulaciones de Monte Carlo con contingencias aleatorias (considerando fallas más allá de $n - 1$ y $n - d$). Lo anterior, se realizó para 3000 años de simulación, con una resolución de 1 hora, utilizando como datos de entrada las soluciones provenientes del optimizador junto a la magnitud de los bloques de demanda y su duración anual respectiva. Con esto, las métricas de riesgo computadas corresponden a la EENS y CVAR_{99%}-ENS.

En este sentido, la Tabla 4.4 muestra los beneficios de considerar las fallas en cascada en la planificación de la red sobre los costos y riesgos totales. De hecho, la Tabla 4.4 muestra que el enfoque determinista $n - 1$ puede tener ventajas frente a la planificación probabilística cuando las fallas en cascadas son ignoradas, a causa de que este último subestima significativamente el costo de EENS. Adicionalmente, es importante mencionar que ambos modelos carecen de

reconocer explícitamente los riesgos de las fallas en cascada, por lo que cuando estos riesgos son modelados a través de nuestro enfoque se obtienen soluciones más eficientes.

De igual manera, el modelo propuesto también incorpora restricciones de CVaR que permiten que el sistema sea más resiliente cuando se reduce la exposición al riesgo de eventos HILP. En este sentido, los casos DT-PTEP 2 y 3 representan distintos niveles de aversión al riesgo como se señala en la Tabla 4.4 a través del parámetro $\text{CVaR}_{99\%}$. Como era de esperar, las soluciones obtenidas presentan un costo total mayor (\$630.97 y \$636.48 millones, respectivamente) en comparación al caso DT-PTEP 1 (\$624.32 millones), a causa de que se generan costos de inversión y operación más altos para así disminuir los riesgos. Esto último se refleja en una reducción del costo $\text{CVaR}_{99\%}$ (\$107.07 y \$41.46 millones, respectivamente) frente a los \$148.60 millones obtenidos en el caso DT-PTEP 1.

Asimismo, la Tabla 4.4 demuestra que el enfoque propuesto es capaz de reconocer y predecir adecuadamente el riesgo de la EENS cuando las fallas en cascada son consideradas. Particularmente, al comparar el costo de EENS que predice nuestro modelo con el costo de EENS efectivo obtenido en el análisis *out-of-sample*, el error es bastante bajo. Esto es, para los casos DT-PTEP 1, 2 y 3 el error porcentual de la predicción es de 1.05 %, 0.80 % y 2.68 %, respectivamente.

4.5. Análisis de sensibilidad

4.5.1. Valor de la pérdida de carga (VoLL)

Realizamos un análisis de sensibilidad en el valor de la pérdida de carga para un amplio rango de valores, en particular, de 0 a 25k\$/MWh. La Fig. 4.2 muestra una comparación de los costos totales entre las soluciones obtenidas por nuestro enfoque propuesto y para la solución determinista $n - 1$, que por definición es insensible al VoLL. En este sentido, cabe mencionar que las soluciones utilizadas en la comparación son las provenientes de un análisis *out-of-sample*, por lo que en la Fig. 4.2 se puede observar un aumento en los costos totales de la solución determinista $n - 1$ a medida que el valor de VoLL aumenta. En este sentido, la Fig. 4.2 demuestra que nuestro modelo propuesto es consistente al entregar soluciones que dependen del VoLL asignado y que además corresponden a soluciones más eficiente que la determinista $n - 1$ para todo el rango de valores de VoLL estudiado.

4.5.2. Ajuste de reglas del DT

Para estudiar el efecto de γ , el cual permite ajustar las reglas obtenidas desde el árbol de decisión, analizamos las soluciones obtenidas para un rango de valores entre 1 y 0.96 de este parámetro. La Tabla 4.5 demuestra que al reducir su valor, y por ende hacer más conservadoras las reglas, se obtiene un compromiso entre disminuir los costos de EENS y un aumento de los costos de operación. En particular, cuando γ se reduce de 1 a 0.99 existe una reducción en los costos totales de \$10.83 millones, dados por una reducción en los costos

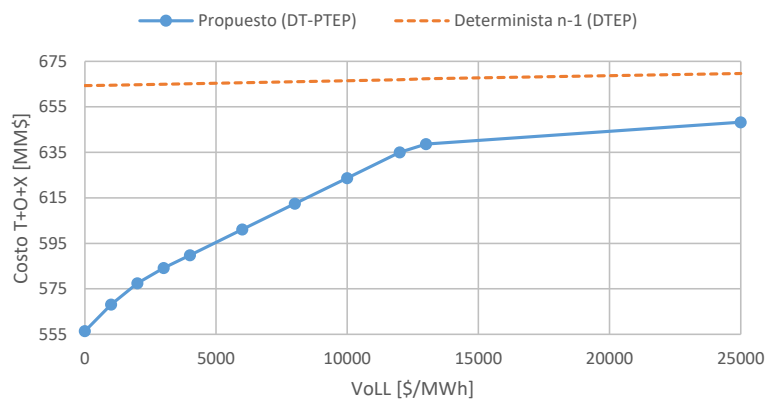


Figura 4.2: Costo total respecto a VoLL.

EENS de \$11.15 millones y un leve aumento en los costos de operación iguales a \$0.32 millones. Luego, cuando el parámetro se continúa reduciendo, si bien existe una reducción en los costos de EENS, esta es menor que los aumentos obtenidos en los costos de operación. De esta forma, para este caso de estudio, la solución más eficiente resulta ser $\gamma = 0,99$. Adicionalmente, resulta interesante notar que, para este caso en particular, la inversión en infraestructura no se ve afectada al modificar el parámetro γ .

Tabla 4.5: Sensibilidad parámetro γ .

Ítem	Caso #1	Caso #2	Caso #3	Caso #4	Caso #5
Parámetro γ	1	0.99	0.98	0.97	0.96
Costo de inversión [millón \$]	5.3	5.3	5.3	5.3	5.3
Costo de operación (planificado, pre-falla) [millón \$]	561.52	561.84	562.19	563.10	564.43
Costo de EENS [millón \$]	67.73	56.58	56.58	56.16	56.16
Costo total [millón \$]	634.55	623.72	624.08	624.55	625.89
Número de nuevos activos instalados	3	3	3	3	3

4.5.3. Número de nodos terminales

La Tabla 4.6 muestra como el costo total de la solución cambia con el número de nodos terminales y VoLL utilizado. En este sentido, la Tabla 4.6 demuestra que para un VoLL de 1k\$/MWh, el número de nodos terminales no influye en el costo total de la solución obtenida. Por otro lado, cuando se considera un VoLL igual a 10k\$/MWh, existe una reducción de \$ 11.98 millones cuando el número de nodos aumenta de 50 a 100, mientras que un aumento

adicional en estos no genera ningún cambio en la solución. Análogamente, cuando se considera un VoLL de 20k\$/MWh es posible reducir el costo total de la solución en \$37.3 millones al aumentar los nodos de 50 a 250. De este modo, encontramos que el número de nodos terminales es un parámetro que puede afectar considerablemente en la solución obtenida, debido a que aumenta la granularidad de la discretización realizada con el árbol de decisión. No obstante, encontramos que este parámetro resulta ser más relevante a medida que aumenta el VoLL.

Tabla 4.6: Sensibilidad número de nodos terminales.

VoLL [k\$/MWh]	1	10	20
	Costo total [millón \$]	Costo total [millón \$]	Costo total [millón \$]
50	568.13	635.70	681.56
100	568.13	623.72	664.79
150	568.13	623.72	664.79
200	568.13	623.72	648.23
250	568.13	623.72	644.26
300	568.13	623.72	644.26
500	568.13	623.72	644.26

4.5.4. Rendimiento del algoritmo: Evolución por iteración

Para ilustrar el rendimiento del algoritmo de optimización-simulación propuesto, a continuación, se describe un caso ilustrativo. En la Fig. 4.3 se muestra la evolución del costo total de la solución obtenida en el modelo de optimización y la obtenida en el simulador de fallas en cascada para cada iteración. De forma análoga, en la Fig. 4.4 se muestra la evolución de la energía esperada no suministrada, donde se observa que en cada iteración existe un error entre la predicción de la EENS considerada en el problema TEP con el valor real computado en el simulador, lo que a su vez implica una diferencia en los costos totales. Asimismo, se puede ver que las iteraciones se extienden hasta que se cumple el criterio de parada del algoritmo, lo que para este caso en particular ocurre en la iteración 18. Adicionalmente, en la Fig. 4.3 se puede ver que el costo total del problema TEP es creciente, como era de esperar, debido a que la solución que era la óptima en una iteración en particular contiene un error en la predicción de la EENS que se corrige, y por ende, otra solución igual o más costosa debe obtenerse en la iteración siguiente. De esta manera, validamos y justificamos la necesidad de utilizar un algoritmo como el propuesto.

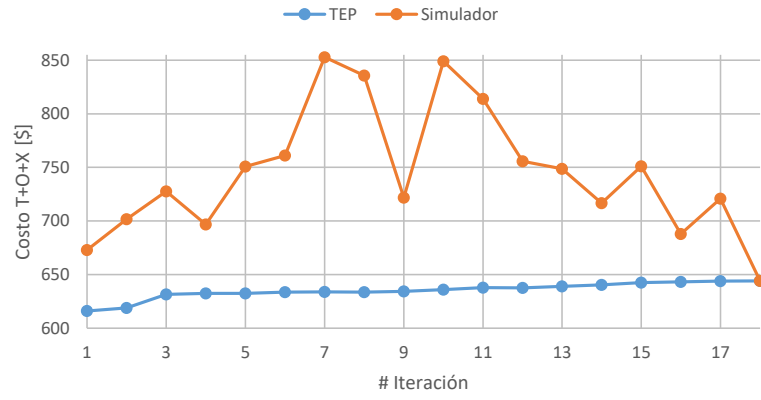


Figura 4.3: Evolución de costo total según iteración.

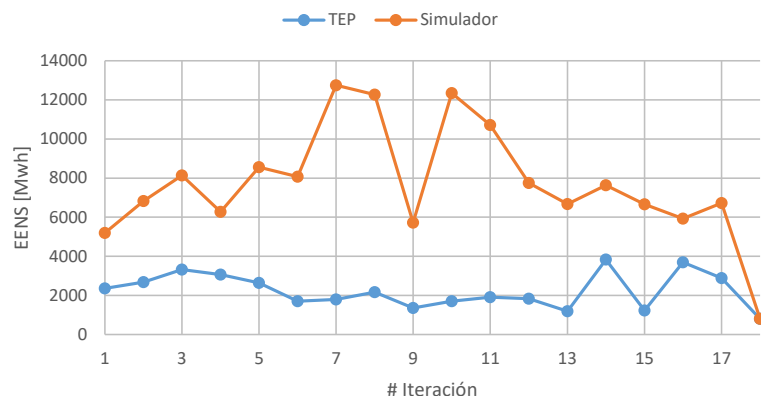


Figura 4.4: Evolución de EENS según iteración.

Capítulo 5

Estudio del sistema IEEE-118

Esta sección demuestra la escalabilidad de nuestro enfoque propuesto. Para hacerlo, lo aplicamos en el sistema de prueba IEEE-118 presentado en [49] y cuyo diagrama unilineal se muestra en la Fig. 5.1.

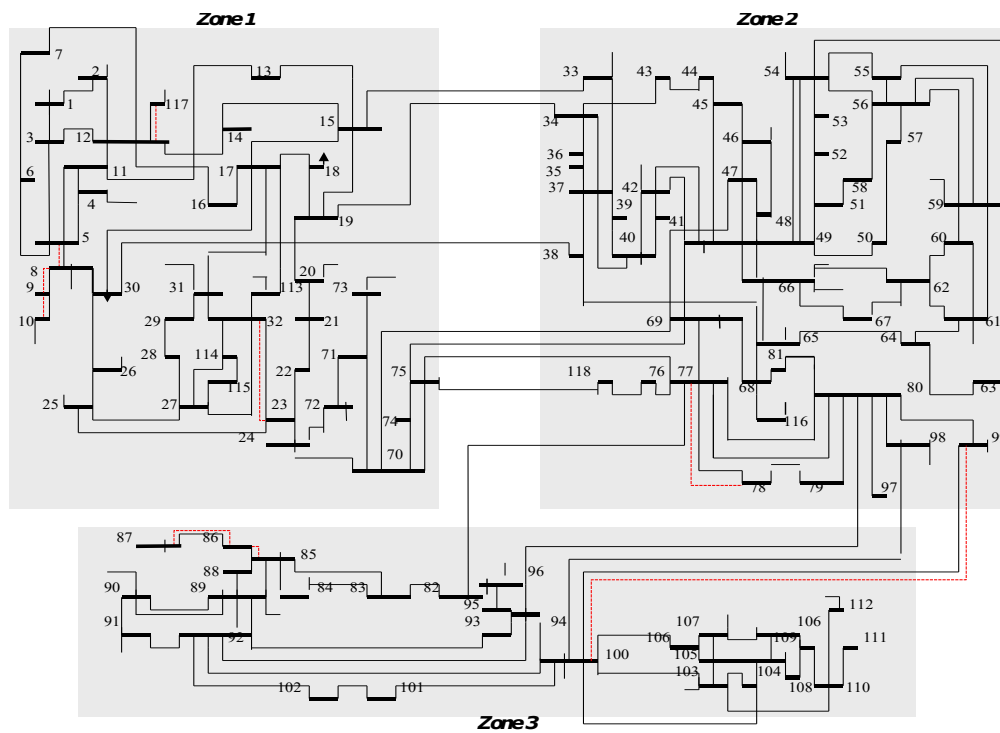


Figura 5.1: Diagrama unilineal del sistema IEEE-118.

5.1. Datos de entrada

Aumentamos un 20 % la potencia máxima de los generadores. Además, añadimos un 20 % extra a la demanda y redujimos un 20 % la capacidad de los elementos del sistema de transmi-

sión para aumentar los niveles de congestión. Consideramos 9 líneas candidatas. Con respecto a los datos de confiabilidad, las tasas de interrupción de referencia son 1.75 occ/año para contingencias $n - 1$ en elementos de transmisión y 0.26 occ/año para contingencias $n - d$. El VoLL utilizado es igual a 10 k\$/MWh. Por otra parte, un MIP_{gap} de 0.5% fue requerido en el modelo de optimización. Por último, 100000 muestras fueron utilizadas como datos de entrenamiento para el árbol de decisión.

5.2. Resultados y discusión

La Tabla 5.1 demuestra la escalabilidad de nuestro enfoque contra diferentes bloques de demanda y número de nodos terminales. En efecto, se consideran 10 y 20 bloques de demanda a lo largo de un año. Asimismo, el problema se resuelve para un número de 100 y 200 nodos terminales.

En este caso particular, la Tabla 5.1 muestra que las decisiones de inversión son sensibles al número de bloques y también al número de nodos terminales con el que se construye el árbol de decisión, lo que demuestra la importancia de escoger adecuadamente estos parámetros. En este sentido, se obtiene que al aumentar el número de bloques a 20 (caso 2) se invierte en una línea adicional respecto al caso base (caso 1) debido a que se capturan situaciones peligrosas que no estaban modeladas con 10 bloques. Asimismo, se observa que al aumentar el número de nodos terminales a 200 (caso 3) se añade mayor nivel de detalle a la discretización realizada con el árbol de decisión, consiguiendo de esta forma una disminución en la inversión y en los costos totales respecto a lo obtenido en el caso base. No obstante, aumentar el número de nodos terminales al doble provoca que los tiempos de ejecución también lo hagan aproximadamente en la misma proporción respecto al caso base, aumentando de 15 a 34 minutos.

Es interesante notar que los tiempos totales de ejecución no aumentan en forma lineal cuando se incrementa el número de bloques de demanda considerado. Sin embargo, para todos los casos analizados, cada iteración es resuelta en el orden de segundos lo que lo convierte en un problema manejable. Adicionalmente, destacamos el uso reducido de memoria RAM. Estos resultados también demuestran las ventajas de la computación paralela, reduciendo el tiempo de ejecución en aproximadamente 2 veces al comparar la resolución paralela (caso 1) con la resolución serie (caso 4). Cabe mencionar que el tiempo de ejecución corresponde a la resolución del algoritmo optimización-simulación, donde en cada iteración la simulación de las fallas en cascada fue la que se realizó en paralelo para cada uno de los bloques utilizando 5 workers con 1 thread cada uno.

Tabla 5.1: Resultados del caso de estudio IEEE-118.

Ítem	Caso #1	Caso #2	Caso #3	Caso #4
Número de bloques	10	20	10	10
Número de nodos	100	100	200	100
Serie o paralelo	Paralelo	Paralelo	Paralelo	Serie
Tiempo de ejecución [min]	15	249	34	33
Número de iteraciones	51	58	78	51
Tiempo por iteración [s]	17	258	26	39
Máxima RAM usada [GB]	4.9	7.8	4.9	3.6
Costo de inversión [millón \$]	3.55	4.62	3.05	3.55
Costo de operación [millón \$]	1518.01	1516.21	1518.06	1518.01
Costo de EENS [millón \$]	17.73	20.79	16.46	17.73
Costo Total [millón \$]	1539.29	1541.62	1537.57	1539.29
Número de nuevos activos instalados	4	5	3	4

Capítulo 6

Conclusiones y perspectivas

6.1. Conclusiones

En este documento planteamos un enfoque de seguridad probabilística con restricciones de CVaR para planificar la infraestructura de red futura que reconoce adecuadamente la ocurrencia de fallas en cascada y su impacto en la energía no suministrada del sistema. Para hacerlo, propusimos un modelo de planificación basado en datos, que determina el plan de expansión de la transmisión, la programación de la generación y realiza una predicción de la energía no suministrada para varias contingencias en función del estado del sistema considerando el riesgo de fallas en cascada.

Dado que no existe una representación algebraica (lineal) de las fallas en cascada que pueda incorporarse a un modelo de optimización, hemos extraído reglas de un árbol de decisión (DT) que modelan un estado cuasi-estacionario capaz de capturar la evolución del sistema posterior a una contingencia y que predicen los impactos de las fallas en cascada en la energía no suministrada. Estas reglas son incorporadas al modelo de planificación a través de una formulación big-M. Adicionalmente, la metodología propuesta utiliza un algoritmo novedoso capaz de resolver el problema TEP al tiempo que valida, y corrige en caso de ser necesario, la predicción de la energía no suministrada mediante la ejecución de simulaciones.

A través de una serie de evaluaciones cuantitativas en el sistema IEEE RTS, podemos afirmar que:

- Ignorar los riesgos de fallas en cascada en los modelos de planificación de la transmisión conduce a soluciones ineficientes. Lo anterior, se debe a que al no considerarlos se descuida el estado cuasi-estacionario posterior a una contingencia, es decir, la evolución dinámica del sistema y las dependencias entre fallas, subestimando por tanto los impactos que este tipo de eventos provocan en la energía no suministrada del sistema. En este sentido, demostramos la necesidad de incorporar fallas en cascada en la planificación de la transmisión y las ventajas de nuestro enfoque frente a las soluciones del criterio de seguridad determinista $n - 1$ y seguridad probabilística. En particular, los modelos DTEP y PTEP carecen de reconocer explícitamente los riesgos de las fallas

en cascada. En este sentido, cuando estos riesgos son modelados se obtienen soluciones más eficientes.

- Cuando el riesgo de fallas en cascada es ignorado en la optimización, al realizar un análisis *out-of-sample*, que considera la dinámica de las fallas en cascada, la planificación determinista $n - 1$ tiene ventajas frente a la planificación probabilística, puesto que esta última subestima los riesgos asociados a dichos eventos.
- Al incorporar restricciones de CVaR en nuestro enfoque, se obtienen soluciones que hacen que el sistema sea más resiliente cuando se reduce la exposición al riesgo de eventos baja probabilidad y alto impacto (HILP). De esta forma, se mitiga de forma costo/eficiente el riesgo de estos eventos, que incluyen el impacto de las fallas en cascada.

Finalmente, demostramos la escalabilidad del modelo propuesto al aplicarlo en el sistema IEEE-118. En este aspecto, realizamos sensibilidades en torno a diferentes bloques de demanda y número de nodos terminales.

6.2. Futura área de investigación

En el futuro, mejoraremos el enfoque propuesto para utilizar un flujo de potencia AC y añadir de esta forma otros mecanismos de cascadas, por ejemplo, inestabilidad de voltaje.

Además, en el modelo de optimización MILP propuesto si queremos trabajar con más bloques representativos o con más nodos terminales, hay un aumento significativo en las variables binarias activas. Por lo tanto, puede ser conveniente utilizar algún método de descomposición. Por otra parte, es importante destacar que los datos de entrenamiento son una parte sensible de la metodología. En este sentido, realizar el muestreo mediante el uso de otras técnicas (por ejemplo, el muestreo de importancia) y cómo esto puede afectar en la solución final se propone como una investigación adicional.

Por último, el enfoque propuesto proporciona un marco generalizable que puede ser aplicado a otros desafíos operativos y de planificación, siendo capaz de acomodar una amplia variedad de simuladores, abriendo así nuevos casos de estudio.

Bibliografía

- [1] P. Henneaux, E. Ciapessoni, D. Cirio, E. Cotilla-Sanchez, R. Diao, I. Dobson, A. Gaikwad, S. Miller, M. Papic, A. Pitto *et al.*, “Benchmarking quasi-steady state cascading outage analysis methodologies,” in *2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*. IEEE, 2018, pp. 1–6.
- [2] H. Guo, C. Zheng, H. H.-C. Iu, and T. Fernando, “A critical review of cascading failure analysis and modeling of power system,” *Renewable and Sustainable Energy Reviews*, vol. 80, pp. 9–22, 2017.
- [3] H. Haes Alhelou, M. E. Hamedani-Golshan, T. C. Njenda, and P. Siano, “A survey on power system blackout and cascading events: Research motivations and challenges,” *Energies*, vol. 12, no. 4, p. 682, 2019.
- [4] E. Karimi and A. Ebrahimi, “Inclusion of blackouts risk in probabilistic transmission expansion planning by a multi-objective framework,” *IEEE Transactions on Power Systems*, vol. 30, no. 5, pp. 2810–2817, 2014.
- [5] R. Baldick, B. Chowdhury, I. Dobson, Z. Dong, B. Gou, D. Hawkins, H. Huang, M. Joung, D. Kirschen, F. Li *et al.*, “Initial review of methods for cascading failure analysis in electric power transmission systems ieeepes task force on understanding, prediction, mitigation and restoration of cascading failures,” in *2008 IEEE Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century*. IEEE, 2008, pp. 1–8.
- [6] I. Dobson and D. E. Newman, “Cascading blackout overall structure and some implications for sampling and mitigation,” *International Journal of Electrical Power & Energy Systems*, vol. 86, pp. 29–32, 2017.
- [7] O. A. Mousavi, R. Cherkaoui, and M. Bozorg, “Blackouts risk evaluation by monte carlo simulation regarding cascading outages and system frequency deviation,” *Electric Power Systems Research*, vol. 89, pp. 157–164, 2012.
- [8] O. A. Mousavi, M. Bozorg, R. Cherkaoui, and M. Paolone, “Inter-area frequency control reserve assessment regarding dynamics of cascading outages and blackouts,” *Electric power systems research*, vol. 107, pp. 144–152, 2014.
- [9] W. Ju, K. Sun, and R. Yao, “Simulation of cascading outages using a power-flow model

- considering frequency,” *IEEE Access*, vol. 6, pp. 37 784–37 795, 2018.
- [10] G. Strbac, D. Kirschen, R. Moreno *et al.*, “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.
- [11] R. Moreno, D. Pudjianto, and G. Strbac, “Transmission network investment with probabilistic security and corrective control,” *IEEE Transactions on Power Systems*, vol. 28, no. 4, pp. 3935–3944, 2013.
- [12] D. Alvarado, A. Moreira, R. Moreno, and G. Strbac, “Transmission network investment with distributed energy resources and distributionally robust security,” *IEEE Transactions on Power Systems*, vol. 34, no. 6, pp. 5157–5168, 2018.
- [13] P. Henneaux, P.-E. Labeau, and J.-C. Maun, “A level-1 probabilistic risk assessment to blackout hazard in transmission power systems,” *Reliability Engineering & System Safety*, vol. 102, pp. 41–52, 2012.
- [14] S. Armaghani, A. H. Naghshbandy, and S. M. Shahrtash, “A novel multi-stage adaptive transmission network expansion planning to countermeasure cascading failure occurrence,” *International Journal of Electrical Power & Energy Systems*, vol. 115, p. 105415, 2020.
- [15] C. Luo, J. Yang, Y. Sun, J. Yan, and H. He, “Identify critical branches with cascading failure chain statistics and hypertext-induced topic search algorithm,” in *2017 IEEE Power & Energy Society General Meeting*. IEEE, 2017, pp. 1–5.
- [16] E. Karimi and A. Ebrahimi, “Considering risk of cascading line outages in transmission expansion planning by benefit/cost analysis,” *International Journal of Electrical Power & Energy Systems*, vol. 78, pp. 480–488, 2016.
- [17] J. Shortle, S. Rebennack, and F. W. Glover, “Transmission-capacity expansion for minimizing blackout probabilities,” *IEEE Transactions on Power Systems*, vol. 29, no. 1, pp. 43–52, 2013.
- [18] D. Zhang, X. Han, and C. Deng, “Review on the research and practice of deep learning and reinforcement learning in smart grids,” *CSEE Journal of Power and Energy Systems*, vol. 4, no. 3, pp. 362–370, 2018.
- [19] C. Liu, Z. H. Rather, Z. Chen, and C. L. Bak, “An overview of decision tree applied to power systems,” *International Journal of Smart Grid and Clean Energy*, vol. 2, no. 3, pp. 413–419, 2013.
- [20] J. L. Cremer, I. Konstantelos, G. Strbac, and S. H. Tindemans, “Sample-derived disjunctive rules for secure power system operation,” in *2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*. IEEE, 2018, pp. 1–6.
- [21] J. L. Cremer, I. Konstantelos, S. H. Tindemans, and G. Strbac, “Data-driven power system operation: Exploring the balance between cost and risk,” *IEEE Transactions on*

Power Systems, vol. 34, no. 1, pp. 791–801, 2018.

- [22] F. Thams, S. Chatzivasileiadis, P. Pinson, and R. Eriksson, “Data-driven security-constrained opf,” in *10th Bulk Power Systems Dynamics and Control Symposium*, 2017.
- [23] L. Halilbašić, F. Thams, A. Venzke, S. Chatzivasileiadis, and P. Pinson, “Data-driven security-constrained ac-opf for operations and markets,” in *2018 Power Systems Computation Conference (PSCC)*. IEEE, 2018, pp. 1–7.
- [24] Y. Gong, S. Mei, D. Peng, W. Long, and M. Guo, “An improved opa model in power system considering planning,” in *Proceedings of the 33rd Chinese Control Conference*. IEEE, 2014, pp. 2817–2822.
- [25] J. Bialek, E. Ciapessoni, D. Cirio, E. Cotilla-Sanchez, C. Dent, I. Dobson, P. Henneaux, P. Hines, J. Jardim, S. Miller *et al.*, “Benchmarking and validation of cascading failure analysis tools,” *IEEE Transactions on Power Systems*, vol. 31, no. 6, pp. 4887–4900, 2016.
- [26] I. Dobson, B. A. Carreras, V. E. Lynch, and D. E. Newman, “An initial model for complex dynamics in electric power system blackouts,” in *hicss*. Citeseer, 2001.
- [27] P. D. Hines, I. Dobson, and P. Rezaei, “Cascading power outages propagate locally in an influence graph that is not the actual grid topology,” *IEEE Transactions on Power Systems*, vol. 32, no. 2, pp. 958–967, 2016.
- [28] I. Dobson, B. A. Carreras, and D. E. Newman, “A probabilistic loading-dependent model of cascading failure and possible implications for blackouts,” in *36th Annual Hawaii International Conference on System Sciences, 2003. Proceedings of the*. IEEE, 2003, pp. 10–pp.
- [29] R. C. Hardiman, M. Kumbale, and Y. V. Makarov, “Multiscenario cascading failure analysis using trelss,” in *CIGRE/IEEE PES International Symposium Quality and Security of Electric Power Delivery Systems, 2003. CIGRE/PES 2003*. IEEE, 2003, pp. 176–180.
- [30] M. A. Rios, D. S. Kirschen, D. Jayaweera, D. P. Nedic, and R. N. Allan, “Value of security: modeling time-dependent phenomena and weather conditions,” *IEEE Transactions on Power Systems*, vol. 17, no. 3, pp. 543–548, 2002.
- [31] S. Sarhadi and T. Amraee, “Robust dynamic network expansion planning considering load uncertainty,” *International Journal of Electrical Power & Energy Systems*, vol. 71, pp. 140–150, 2015.
- [32] S. Mei, F. He, X. Zhang, S. Wu, and G. Wang, “An improved opa model and blackout risk assessment,” *IEEE Transactions on Power Systems*, vol. 24, no. 2, pp. 814–823, 2009.
- [33] K. Zhou, I. Dobson, Z. Wang, A. Roitershtein, and A. P. Ghosh, “A markovian influence graph formed from utility line outage data to mitigate large cascades,” *IEEE*

Transactions on Power Systems, vol. 35, no. 4, pp. 3224–3235, 2020.

- [34] M. J. Eppstein and P. D. Hines, “A “random chemistry” algorithm for identifying collections of multiple contingencies that initiate cascading failure,” *IEEE Transactions on Power Systems*, vol. 27, no. 3, pp. 1698–1705, 2012.
- [35] P. Rezaei, P. D. Hines, and M. J. Eppstein, “Estimating cascading failure risk with random chemistry,” *IEEE Transactions on Power Systems*, vol. 30, no. 5, pp. 2726–2735, 2014.
- [36] X. Wang, S. Xie, X. Wang, and C. Qu, “Decision-making model based on conditional risks and conditional costs in power system probabilistic planning,” *IEEE Transactions on Power Systems*, vol. 28, no. 4, pp. 4080–4088, 2013.
- [37] M. Qorbani and T. Amraee, “Long term transmission expansion planning to improve power system resilience against cascading outages,” *Electric Power Systems Research*, vol. 192, p. 106972, 2021.
- [38] K. Sun, S. Likhate, V. Vittal, V. S. Kolluri, and S. Mandal, “An online dynamic security assessment scheme using phasor measurements and decision trees,” *IEEE transactions on power systems*, vol. 22, no. 4, pp. 1935–1943, 2007.
- [39] Y. Xu, Z. Y. Dong, R. Zhang, and K. Po Wong, “A decision tree-based on-line preventive control strategy for power system transient instability prevention,” *International Journal of Systems Science*, vol. 45, no. 2, pp. 176–186, 2014.
- [40] V. Krishnan, J. D. McCalley, S. Henry, and S. Issad, “Efficient database generation for decision tree based power system security assessment,” *IEEE Transactions on Power systems*, vol. 26, no. 4, pp. 2319–2327, 2011.
- [41] F. Thams, A. Venzke, R. Eriksson, and S. Chatzivasileiadis, “Efficient database generation for data-driven security assessment of power systems,” *IEEE Transactions on Power Systems*, 2019.
- [42] H. Sugihara, T. Funaki, and N. Yamaguchi, “Evaluation method for real-time dynamic line ratings based on line current variation model for representing forecast error of intermittent renewable generation,” *Energies*, vol. 10, no. 4, p. 503, 2017.
- [43] R. Moreno and G. Strbac, “Integrating high impact low probability events in smart distribution network security standards through cvar optimisation,” *IET International Conference on Resilience of Transmission and Distribution Networks (RTDN)*, 2015.
- [44] P. M. Subcommittee, “Ieee reliability test system,” *IEEE Transactions on power apparatus and systems*, no. 6, pp. 2047–2054, 1979.
- [45] R. Fang and D. J. Hill, “A new strategy for transmission expansion in competitive electricity markets,” *IEEE Transactions on power systems*, vol. 18, no. 1, pp. 374–380, 2003.

- [46] R. D. Zimmerman, C. E. Murillo-Sánchez, and R. J. Thomas, “Matpower: Steady-state operations, planning, and analysis tools for power systems research and education,” *IEEE Transactions on power systems*, vol. 26, no. 1, pp. 12–19, 2010.
- [47] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg *et al.*, “Scikit-learn: Machine learning in python,” *The Journal of machine Learning research*, vol. 12, pp. 2825–2830, 2011.
- [48] Xpress, “Fico xpress optimization suite,” *FX, Workbench*. [Online]. Available: <http://www.fico.com/>
- [49] IIT, “Index of data illinois institute of technology,” *Illinois Inst. Technol., Chicago, IL, USA*, 2016. [Online]. Available: <http://motor.ece.iit.edu/data/>