

UNIVERSIDAD DON BOSCO
FACULTAD DE INGENIERÍA



**UNIVERSIDAD
DON BOSCO**

TRABAJO DE GRADUACIÓN:

**PROPUESTA DE EVALUACIÓN ENERGÉTICA UTILIZANDO DATOS DE
TRANSACCIONES REGIONALES PARA CASO DE SUSPENSIÓN TOTAL
ENTRE GUATEMALA Y EL SALVADOR**

PARA OPTAR AL GRADO DE:

MAESTRO(A) EN GESTIÓN ENERGÉTICA Y DISEÑO AMBIENTAL

PRESENTADO POR:

ALEXIS ALEJANDRO HERNÁNDEZ CÓRDOVA

KATYA PATRICIA CAMPOS PORTILLO

RICARDO ANTONIO HERNÁNDEZ GONZÁLEZ

ASESOR:

ROBERTO EDUARDO SARAVIA GUTIÉRREZ

ANTIGUO CUSCATLÁN, LA LIBERTAD, EL SALVADOR, CENTROAMÉRICA

JUNIO DE 2025

ÍNDICE

ABREVIATURAS.....	1
CAPÍTULO 1.....	2
INTRODUCCIÓN.....	2
1.1 Objetivos.....	3
1.1.1 Objetivo General.....	3
1.1.2 Objetivos Específicos.....	3
1.2 Alcances.....	3
1.3 Justificación.....	4
1.4 Metodología.....	5
CAPÍTULO 2.....	7
ANÁLISIS DEL SISTEMA DE DESPACHO DEL MER Y TRANSACCIONES REGIONALES.....	7
2.1 Descripción del Funcionamiento del MER.....	7
2.2 Análisis del Cálculo y Formación de Precios Nodales.....	9
2.2.1 Desarrollo de un ejercicio práctico para el cálculo de precios nodales.....	10
2.3 Análisis Histórico de las Transacciones Regionales y su Relevancia para el MER.....	18
CAPÍTULO 3.....	21
DESARROLLO Y VALIDACIÓN DE UN MODELO DE OPTIMIZACIÓN PARA EL DESPACHO REGIONAL.....	21
3.1 Métodos de Optimización.....	21
3.2 PYPSA como Herramienta de Optimización del Despacho Regional.....	22
3.2.1. Instalación y configuración de PyPSA.....	22
3.2.2 Estructura de PyPSA y características de los elementos.....	25
3.3 Descripción de escenarios a modelar: Modelo base de validación (3 nodos) y Modelo de despacho para maximizar los ingresos de transmisión (8 nodos).....	27
3.3.1 Lógica general del modelo y secuencia de implementación.....	30
3.3.2 Organización de los datos de entrada y escenarios de simulación.....	31
3.3.3 Formulación del despacho óptimo con flujo de potencia AC no lineal.....	32
3.3.4 Modificación de la función objetivo para promover la utilización de la red...	33
3.3.5 Modelos simplificados para validación y análisis escalado.....	34
3.4 Resultados generales y observaciones.....	44
CAPÍTULO 4.....	46
INTELIGENCIA ARTIFICIAL COMO ALTERNATIVA A METODOS DE OPTIMIZACION EN MERCADOS ENERGETICOS.....	46
4.1 Introducción a la Inteligencia Artificial y su Aplicación en el Sector Energético...	46
4.2 Modelos de IA en la predicción de los Mercados Energéticos.....	48
4.3 Implementación de un Modelo de IA para Reproducir los Resultados del Modelo Simplificado de Despacho Regional.....	50

4.3.1 Evaluación de modelo base de validación (3 nodos).....	51
4.3.2 Evaluación de modelo para maximizar los ingresos de transmisión (8 nodos)...	58
CAPÍTULO 5.....	63
MODELO IA PARA EVALUAR LA SUSPENSIÓN DE TRANSACCIONES ENERGÉTICAS ENTRE GUATEMALA Y EL SALVADOR.....	63
5.1 Entrenamiento y Validación del Modelo de IA.....	63
5.1.1 Modelo de Machine Learning para el MER.....	63
5.1.2 Modelo de Machine Learning para el mercado nacional de El Salvador.....	68
5.2 Evaluación de Resultados del Modelo ante la salida de Guatemala del MER.....	70
5.2.1 Resultados de modelo para el MER.....	70
5.2.2 Resultados del modelo para el mercado nacional.....	72
CAPÍTULO 6.....	74
CONCLUSIONES Y RECOMENDACIONES.....	74
6.1 Conclusiones.....	74
6.2 Recomendaciones.....	75
REFERENCIAS.....	77
ANEXO A.....	79
Tabla A.1- Datos de entrada para sistema de 3 nodos.....	79
Tabla A.1-(Continuación).....	80
Tabla A.1-(Continuación).....	81
Tabla A.2- Resultado para sistema de 3 nodos.....	82
Tabla A.2- (Continuación).....	83
Tabla A.2- (Continuación).....	84
ANEXO B.....	85
Tabla B.1- Datos de entrada para sistema de 8 nodos.....	85
Tabla B.1- (Continuación).....	86
Tabla B.2- Resultados para sistema de 8 nodos.....	87
Tabla B.2- (Continuación).....	88
ANEXO C.....	89
Código de modelo de Random Forest aplicado a sistema de 8 nodos.....	89
ANEXO D.....	92
Código de entrenamiento de modelo para predicción del MER.....	92
ANEXO E.....	96
Código de entrenamiento de modelo para predicción del CMO.....	96
ANEXO F.....	98
Código de modelo ya entrenado para predicción del MER.....	98
ANEXO G.....	102
Código de modelo ya entrenado para predicción del CMO.....	102

ABREVIATURAS

IEEE	Institute of Electrical and Electronics Engineers
IA	Inteligencia Artificial
ML	Machine Learning
MER	Mercado Eléctrico Regional
CRIE	Comisión Regional de Interconexión Eléctrica
EOR	Ente Operador Regional
SIMECR	Sistema de Medición Comercial Regional
SIEPAC	Sistema de Interconexión Eléctrica de los Países de América Central
RTR	Red de Transmisión Regional
DFT	Derechos Físicos de Transmisión
CMO	Costo Marginal de Operación
AC	Corriente Alterna
DC	Corriente Continua
PyPSA	Python for Power System Analysis
LOPF	Flujo Óptimo de Potencia Linealizado

CAPÍTULO 1

INTRODUCCIÓN

Según consta en el informe mensual del Mercado Eléctrico Regional (MER) de agosto de 2021, con fecha 12 de julio de 2021 Guatemala anunció su intención de abandonar el MER[1]. En respeto a los tratados internacionales vigentes, Guatemala deberá permanecer como parte del MER durante diez años adicionales tras su notificación; por tanto, su salida oficial no podría hacerse efectiva sino hasta julio de 2031. La salida de Guatemala reviste gran importancia dado el peso de este país dentro del sistema eléctrico centroamericano: Guatemala es uno de los principales exportadores de electricidad en la región, aportando aproximadamente un 31.2% de las inyecciones de energía al mercado regional solo en agosto de 2021[1]. Consecuentemente, su eventual retiro plantea interrogantes sobre la estabilidad y eficiencia del mercado regional. Ante esta decisión, el presidente de la Comisión Regional de Interconexión Eléctrica (CRIE) aseguró que se garantizaría el funcionamiento adecuado del mercado e indicó que la CRIE había iniciado estudios técnicos para estimar los posibles impactos que una eventual y lejana salida de Guatemala del MER podría acarrear para la región[1].

Frente a este panorama, el presente trabajo describe el desarrollo de un estudio técnico del escenario de desconexión de Guatemala del MER, implementando modelos de optimización y predicción para anticipar sus efectos. Es importante señalar que, aunque el estudio considera la salida de Guatemala del sistema regional, el análisis se concentra exclusivamente en las implicaciones para El Salvador, particularmente en la alteración de sus transacciones energéticas regionales y sus implicaciones en precios. La metodología empleada se fundamenta en los principios de la economía de sistemas de potencia, en particular aquellos relativos al despacho óptimo de generadores y al cálculo de precios nodales[2]. Estos precios reflejan el costo marginal de suministrar una unidad adicional de electricidad en un punto específico de la red, considerando tanto los costos variables de generación como las restricciones físicas de transmisión[2]. En un sistema competitivo con múltiples agentes, esta información resulta clave para asignar los recursos de manera eficiente, señalar congestiones y determinar el valor económico de la electricidad en cada nodo[3].

Siguiendo las bases teóricas mencionadas en [2], se construyeron dos escenarios simplificados de optimización de despacho energético con el fin de validar preliminarmente la capacidad de los algoritmos de aprendizaje automático para manejar problemas de optimización de sistemas de potencia, incorporando las limitaciones físicas de transmisión y generación. Estos modelos fueron implementados en PyPSA, una herramienta de código abierto diseñada para la simulación y análisis de redes eléctricas, que permite representar topologías nodales y resolver problemas de despacho. A partir de los resultados generados por estos escenarios se construyeron bases de datos que sirvieron como insumo para entrenar y poner a prueba un sistema de predicción basado en algoritmos de aprendizaje automático. Este proceso permitió validar que los algoritmos de aprendizaje automático podían capturar el comportamiento resultante de un sistema eléctrico modelado con

criterios técnicos. Una vez comprobado su desempeño, el modelo de predicción fue replicado utilizando variables reales del MER, con el fin de proyectar escenarios operativos bajo condiciones futuras realistas [4]. Este modelo predictivo se basó en el algoritmo de Random Forest, una técnica de Machine Learning (ML) que permite capturar patrones no lineales en datos históricos y generar estimaciones robustas en entornos con alta variabilidad [5].

Este enfoque fue especialmente necesario dada la naturaleza hipotética del fenómeno analizado: la desconexión total de Guatemala del MER. Al no disponerse de datos históricos de un fenómeno de esta naturaleza, es necesario predecir el comportamiento del sistema y recrear su operación mediante simulación para evaluar con rigor los posibles impactos[5]. Esto permite cuantificar cómo cambiarían los flujos de potencia y los precios nodales en El Salvador ante la ausencia de Guatemala en el mercado regional, proporcionando una base técnica sólida para comprender las consecuencias de tal desconexión en el mercado eléctrico salvadoreño.

1.1 Objetivos

1.1.1 Objetivo General

Proponer una evaluación energética, utilizando datos de transacciones regionales para caso de suspensión total entre Guatemala y el MER con análisis para El Salvador.

1.1.2 Objetivos Específicos

- Analizar los sistemas de despacho del Mercado Eléctrico Regional, con el fin de establecer los criterios y parámetros técnicos necesarios para una evaluación energética.
- Desarrollar y validar un modelo simplificado de optimización del despacho regional, orientado a la estimación de precios bajo condiciones de restricción en la interconexión eléctrica.
- Implementar un modelo de Inteligencia Artificial(IA) como alternativa a los métodos tradicionales de optimización del despacho regional.
- Entrenar y validar un modelo de inteligencia artificial(IA) utilizando datos históricos del MER y del predespacho de El Salvador, con el fin de aplicarlo en escenarios de suspensión de transacciones energéticas Guatemala-MER con análisis para El Salvador.

1.2 Alcances

Este estudio desarrolla una metodología de análisis técnico-operativo para evaluar los efectos de una desconexión total de Guatemala del MER. A partir de esta simulación, el análisis se enfoca específicamente en el impacto que dicha suspensión puede tener sobre el comportamiento del sistema en El Salvador, con especial atención en la formación de precios nodales y los patrones de flujo de energía.

La investigación se restringe a la modelación del despacho regional desde una perspectiva técnica, sin considerar aspectos financieros o de infraestructura física. No se abordan inversiones en expansión de red ni cambios estructurales del mercado.

El enfoque metodológico incluye dos componentes: por un lado, se implementa un modelo de optimización simplificado que permite simular escenarios de despacho bajo diversas condiciones de restricción operativa para validar que es posible replicar sus resultados utilizando un modelo de aprendizaje automático(ML) ; por otro lado, se desarrolla un modelo de aprendizaje automático(ML), entrenado con datos históricos del MER, capaz de predecir precios nodales ante condiciones similares a las simuladas. Ambos modelos se aplican exclusivamente al caso de estudio planteado y no se extienden a otras interconexiones del sistema regional.

1.3 Justificación

El 12 de julio de 2021, Guatemala notificó su intención de abandonar el MER, lo que, en cumplimiento de los tratados vigentes, se haría efectivo a partir de 2031 [1]. Esta decisión introduce incertidumbre sobre la estabilidad del sistema regional, particularmente por el peso que Guatemala representa como uno de los principales exportadores de energía en Centroamérica. Aunque esta salida aún no se ha concretado, su posible materialización motiva la necesidad de anticipar técnicamente los impactos que podría acarrear.

La elección de este tema responde a la necesidad de analizar las implicaciones técnicas que tendría una suspensión total de las transacciones energéticas entre Guatemala y el MER, específicamente sobre el comportamiento del sistema en El Salvador. Aunque se simula una desconexión completa de Guatemala del mercado regional, el objetivo de este estudio no es evaluar el impacto regional, sino comprender de forma precisa cómo dicho escenario afectaría a uno de los países directamente vinculados operativamente: El Salvador.

El MER ha demostrado ser un mecanismo eficaz para reducir los costos de generación, mejorar la seguridad del suministro y permitir un uso más eficiente de los recursos eléctricos a nivel regional. Estos beneficios han sido ampliamente documentados por organismos como el Banco Interamericano de Desarrollo, que destaca el aporte técnico y económico de la integración centroamericana mediante el sistema de interconexión regional[6]. No obstante, esta misma integración plantea nuevos desafíos operativos ante eventuales interrupciones entre países, especialmente si involucran a actores centrales del sistema regional.

A pesar de que existen estudios sobre la arquitectura general y los logros del MER, aún es limitado el análisis técnico que simula escenarios de contingencia y evalúa, con datos reales, los efectos específicos sobre un país ante una interrupción regional. Este trabajo de graduación busca aportar mediante la construcción de un modelo que represente técnicamente un escenario de desconexión, enfocando el análisis en El Salvador para observar los cambios en los precios nodales y la redistribución de flujos eléctricos que podrían presentarse.

Para el estudio se desarrollaron dos escenarios de optimización de despacho energético fundamentados en criterios físicos y de mercado. Cada modelo representa una configuración de red distinta, incorpora las limitaciones de transmisión y generación y resuelve la asignación óptima de la generación, la demanda satisfecha y los precios nodales mediante la herramienta de código abierto PyPSA. A partir de estos despachos se construyeron bases de datos sintéticas que capturan de manera coherente la interacción entre topología de red, restricciones operativas y resultados de mercado.

Sobre los datos resultantes de dichos escenarios se entrenó un modelo predictivo de Machine Learning usando el algoritmo de Random Forest para demostrar que dicho algoritmo era capaz de resolver el mismo problema de optimización que un optimizador tradicional. Por su capacidad para aprender patrones no lineales en grandes volúmenes de datos, este modelo predictivo logra reproducir con alta fidelidad el comportamiento del despacho simulado y, una vez validado, se aplicó sobre variables reales del MER y del mercado nacional de El Salvador para proyectar escenarios operativos futuros.

En definitiva, esta investigación se justifica por su aporte metodológico al análisis del esquema regional y por su utilidad práctica para planificadores y autoridades del sector eléctrico salvadoreño, que requieren anticipar el comportamiento del sistema ante eventos que puedan comprometer su estabilidad.

1.4 Metodología

La presente investigación adopta un enfoque técnico-computacional estructurado en etapas, cuyo propósito central es evaluar el impacto que tendría, sobre el sistema eléctrico de El Salvador, una eventual desconexión de Guatemala del MER. Para ello, se parte de la construcción de modelos de optimización que simulan el despacho regional bajo condiciones controladas. Los resultados obtenidos se utilizan posteriormente como base de entrenamiento para modelos de predicción basados en técnicas de aprendizaje automático, con el objetivo de validar si dichas herramientas pueden replicar el comportamiento técnico del sistema ante un escenario hipotético.

En la primera etapa, se desarrollan escenarios de optimización orientados a representar el despacho económico de energía en el MER. Para ello, se estudia la lógica de operación del mercado, las restricciones físicas de transmisión, la asignación óptima de generación y la determinación de precios nodales. Con base en estos principios, se construyen modelos computacionales utilizando PyPSA, una biblioteca en Python para el modelado de sistemas eléctricos, que permite representar redes de corriente alterna, calcular flujos de potencia y resolver problemas de optimización considerando restricciones técnicas.

Se implementan dos configuraciones de red: una topología simplificada de tres nodos y otra de ocho nodos, que simulan esquemas interconectados de baja y media complejidad. Para cada red, se generan 200 escenarios con parámetros aleatorios de demanda, generación y capacidad de línea. Estos escenarios no buscan reproducir casos reales, sino generar un

conjunto de datos técnicos, como despachos, flujos y precios nodales, que sirva como insumo para posteriormente entrenar un modelo de aprendizaje automático.

En la segunda etapa, se entrena un algoritmo tipo Random Forest utilizando los datos generados por los modelos de optimización. Esto permite validar la capacidad del modelo de ML para aproximarse a los resultados del despacho técnico, evaluando si puede predecir precios nodales bajo diversas configuraciones de red. Una vez verificado este comportamiento en condiciones controladas, se procede al entrenamiento final del modelo utilizando información real del sistema interconectado.

Para ello, se recopila y estructura una base de datos del Ente Operador Regional (EOR), correspondiente al período enero 2024 a mayo 2025, con variables horarias como energía disponible, precios ofertados, ofertas de flexibilidad y precios resultantes (ex-ante). Cada variable se organiza por país, tipo de transacción y bloque horario. El modelo se entrena con los datos antes descritos y luego se utiliza un porcentaje para validar los resultados. Posteriormente, se construye una segunda base con igual estructura, pero eliminando todas las transacciones asociadas a Guatemala, simulando un escenario de desconexión total. El modelo predictivo, ya entrenado, se aplica sobre esta nueva base para estimar los precios nodales en El Salvador durante 2025.

Finalmente, se desarrolla un segundo modelo de predicción utilizando una base de datos histórica correspondiente al predespacho diario publicado por la Unidad de Transacciones (UT) de El Salvador, en el mismo período comprendido entre enero de 2024 a mayo de 2025. Esta base incluye información horaria detallada sobre los generadores despachados, la energía demandada por el sistema nacional, los intercambios de energía del MER hacia El Salvador, la lista de mérito diaria de los generadores y el Costo Marginal de Operación (CMO) asignado a cada hora.

A partir de este último modelo, se calcula la proyección de un precio promedio ponderado por tecnología de generación, el cual se asocia a la cantidad de energía despachada por hora. Con esta distinción, los datos se organizan por recurso, integrando su respectivo precio, demanda, intercambios y CMO para cada hora y cada día.

Al igual que con el modelo regional, la base de datos del año 2024 se emplea para entrenar el algoritmo, y la predicción se valida con los datos correspondientes a los meses del año 2025. En la etapa de simulación del escenario hipotético, se suprimen los intercambios de energía con Guatemala y se sustituyen los intercambios con Honduras por los resultados obtenidos a partir del modelo regional, de modo que las afectaciones percibidas por El Salvador reflejen los cambios originados a nivel centroamericano. De esta forma, se aplica el modelo predictivo sobre el nuevo conjunto de datos y se evalúan los cambios resultantes en el CMO para el sistema eléctrico nacional

CAPÍTULO 2

ANÁLISIS DEL SISTEMA DE DESPACHO DEL MER Y TRANSACCIONES REGIONALES

2.1 Descripción del Funcionamiento del MER

El MER permite que los países de Centroamérica puedan comercializar entre sí los excedentes de energía eléctrica, promoviendo un uso más eficiente de los recursos disponibles en la región. Esta integración no solo tiene un enfoque técnico y económico, sino también social, ya que busca contribuir al bienestar de las poblaciones mediante un suministro más estable, accesible y competitivo[8].

El MER se estableció con el fin de lograr una interconexión eficiente entre los sistemas eléctricos nacionales, facilitando el intercambio de energía, mejorando el desempeño operativo del sistema y reduciendo los costos de generación y suministro. Este modelo permite que los países complementen sus recursos energéticos de manera coordinada. Cuando un país dispone de mayor generación, puede comercializar el excedente a otro que lo requiera, generando beneficios mutuos

Uno de los pilares del MER es fomentar la competencia entre los agentes del mercado, lo que contribuye a reducir los precios y a mejorar el servicio. Además, se busca que el acceso a la infraestructura regional sea libre y equitativo para todos los participantes que cumplan con los requisitos técnicos establecidos. Esta apertura asegura que ningún participante tenga privilegios y que el uso de la red de transmisión se dé en igualdad de condiciones.

El mercado también promueve el uso eficiente de los recursos energéticos de la región, maximizando su aprovechamiento sin violar los límites técnicos de las redes nacionales. Este principio de eficiencia se complementa con el de no discriminación, que garantiza que todos los agentes del mercado, independientemente de su tamaño o actividad, puedan participar en igualdad de condiciones.

Para que este sistema funcione, el MER cuenta con una estructura institucional bien definida. La CRIE es el órgano regulador del mercado y se encarga de velar por el cumplimiento de la normativa, resolver conflictos entre agentes y tomar decisiones estratégicas para el desarrollo del mercado regional. Su rol es clave para mantener la transparencia y la confianza entre los participantes.

Por su parte, el EOR coordina la operación técnica del sistema eléctrico centroamericano. Se encarga de organizar el despacho de energía, validar las ofertas del mercado, supervisar los intercambios entre países y garantizar que el sistema opere de manera segura y eficiente. A nivel nacional, los operadores de sistemas (OS/OMS) se encargan de manejar las redes eléctricas internas y coordinarse con el EOR para cumplir con los lineamientos regionales.

Los agentes del MER, que incluyen generadores, transmisores, distribuidores y grandes consumidores de energía, participan en las transacciones del mercado siguiendo reglas


claras y bajo la supervisión de las entidades reguladoras y operativas. Cada uno tiene un rol bien definido que contribuye al equilibrio y funcionamiento del sistema.

Dentro del MER existen distintos mecanismos para comerciar electricidad. Uno de ellos es el mercado de contratos regionales, donde los agentes acuerdan el suministro de energía a mediano y largo plazo. Estos contratos permiten planificar el abastecimiento de forma estable. Otro mecanismo es el mercado de oportunidad regional, que permite la compra y venta de energía a corto plazo.

El precio de la energía en el MER se determina mediante un esquema de precios nodales, el cual asigna valores específicos a cada punto de la red en función de las ofertas y las condiciones locales de generación, demanda y capacidad de transmisión. Este sistema se implementa a través de un despacho económico basado en un modelo de optimización que busca maximizar los ingresos por transmisión, considerando las restricciones técnicas del sistema. Las transacciones resultantes se concilian y liquidan en base a modelos de optimización y ajustados con base en mediciones certificadas por el Sistema de Medición Comercial Regional (SIMECR), asegurando pagos precisos a todos los participantes. Para ello, el EOR mantiene una base de datos regional actualizada que respalda la operación técnica y comercial del mercado.

En los últimos años, el Mercado Eléctrico Regional ha evidenciado una evolución significativa en términos de eficiencia operativa, integración institucional y beneficios económicos para los países miembros del Sistema de Interconexión Eléctrica de los Países de América Central (SIEPAC). De acuerdo con el Informe de Evolución del EOR en el Marco de la Operación Técnica y Comercial del MER (2014–2018), las inyecciones anuales de energía aumentaron de 1,445.84 GWh en 2014 a 2,651.27 GWh en 2018, lo que representa un crecimiento del 83.4 % en cinco años[9]. Este comportamiento se ilustra en la Fig. 1, donde también se observa una reducción sostenida en el precio promedio de la energía, al pasar de 160.39 USD/MWh a 74.05 USD/MWh en el mismo período.

Estos resultados evidencian que el MER no solo ha optimizado la operación técnica y comercial del sistema eléctrico regional, sino que también ha cumplido con su objetivo fundamental de generar beneficios sociales sostenibles a través de un mercado más eficiente, integrado y competitivo. Este proceso ha continuado su consolidación en años recientes. Por ejemplo, según el informe de evaluación del MER de 2023, a pesar de desafíos operativos derivados del fenómeno de El Niño y de restricciones en la exportación de energía desde países como Panamá y Guatemala, el mercado mostró resiliencia y mantuvo condiciones de competencia adecuadas gracias al marco regulatorio regional y a una gestión eficiente de los recursos energéticos[10].



Fuente: tomado de [9]

Fig. 1. Evolución de las transacciones de energía en el MER (2014–2018).

2.2 Análisis del Cálculo y Formación de Precios Nodales

El objetivo de esta sección es comprender cómo los precios nodales reflejan tanto las intenciones de los participantes a través de sus ofertas, así como condiciones físicas del sistema. A diferencia de modelos con precios uniformes o zonales, el enfoque nodal adoptado por el MER asigna un valor específico de la energía en cada punto de la red, considerando tanto los costos marginales de generación como las restricciones físicas del sistema, tales como pérdidas y congestiones. Este esquema permite reflejar de manera precisa el costo real de abastecer una unidad adicional de demanda en un nodo determinado.

El precio nodal se define como el costo de abastecer una unidad adicional de energía eléctrica en un nodo específico de la red. Este valor refleja el costo marginal de generación y las condiciones físicas y operativas del sistema, como pérdidas eléctricas, impedancias y congestiones en las líneas de transmisión. Su cálculo se basa en un modelo de optimización del despacho económico que incorpora estas restricciones, permitiendo determinar tanto la asignación óptima de generación como los precios de la energía en cada nodo[2].

Para facilitar la comprensión de este concepto, a continuación se desarrollará un ejercicio técnico aplicado a una red simplificada de tres nodos. Este se divide en tres etapas de

análisis, en las cuales se incorporan gradualmente las restricciones físicas de la red, permitiendo analizar su impacto en la formación del precio nodal.

1. En primer lugar, se analizará un despacho económico sin restricciones físicas, en el cual la energía puede fluir libremente entre los nodos.
2. Luego, se incorporarán las restricciones físicas del sistema eléctrico, con el fin de evaluar si los flujos de potencia resultantes del despacho económico son técnicamente viables y se ajustan al comportamiento real de la red.
3. Finalmente, se incorporarán las limitaciones de capacidad en las líneas de transmisión, lo que exigirá reformular el despacho original mediante un redespacho de generación. Para analizar sus efectos, se evaluarán dos alternativas operativas, cada una basada en distintas rutas de redistribución de potencia, lo que permitirá observar cómo estas decisiones afectan los precios nodales y el costo total del sistema

Este ejercicio permitirá evidenciar cómo el precio de la energía varía en función de la configuración de la red, las restricciones técnicas y la localización tanto de la demanda como de la oferta. Aunque los análisis se desarrollan de forma manual con fines didácticos, en la práctica este tipo de estudios se realiza mediante herramientas computacionales especializadas. En el Capítulo 3, estos mismos escenarios serán validados utilizando *Python for Power System Analysis* (PyPSA), una librería de código abierto diseñada para modelar redes eléctricas complejas bajo criterios de optimización. El uso de PyPSA permite incorporar múltiples restricciones técnicas y operativas en sistemas de mayor escala, garantizando resultados más realistas y representativos del comportamiento del sistema eléctrico regional[11].


2.2.1 Desarrollo de un ejercicio práctico para el cálculo de precios nodales

Con el objetivo de ilustrar los conceptos fundamentales del precio nodal, se presenta a continuación un ejercicio aplicado a una red eléctrica simplificada de tres nodos. Este permitirá analizar cómo las condiciones técnicas del sistema afectan tanto la asignación de generación como la formación de precios.

a) Precio nodal en un despacho sin restricciones

Como punto de partida, se analiza un escenario ideal en el que la red eléctrica no presenta restricciones físicas, pérdidas ni limitaciones de capacidad. En estas condiciones, la energía puede fluir libremente entre nodos, lo que permite enfocar el análisis exclusivamente en criterios económicos. El despacho se realiza según el principio del mérito económico, priorizando las unidades con menor costo marginal hasta cubrir la demanda total. El precio resultante, uniforme en todos los nodos, corresponde al costo del último generador despachado y se conoce como precio marginal del sistema.

En la red simplificada de tres barras ilustrada en la Fig. 2, con parámetros eléctricos y datos de generación consignados en la Tabla 1 y la Tabla 2, la demanda total del sistema asciende a 410 MW.



Fuente: tomado de[2]

Fig. 2. Sistema simple de tres barras

Tabla 1. Datos de ramal para el sistema de tres barras de la Fig. 2

Ramal	Reactancia (p.u.)	Capacidad (MW)
1-2	0.2	126
1-3	0.2	250
2-3	0.1	130

Fuente: tomado de[2]

Tabla 2. Datos de ramal para el sistema de tres barras de la Fig. 2

Generador	Capacidad (MW)	Costo Marginal (\$/MWh)
A	140	7.5
B	285	6
C	90	14
D	85	10

Fuente: tomado de[2]

Aplicando el despacho económico:

- El generador B, con un costo marginal de 6.00 \$/MWh, se despacha a su capacidad máxima de 285 MW.
- El generador A, con un costo marginal de 7.50 \$/MWh, cubre los 125 MW restantes.
- Los generadores C y D no participan del despacho.

$$PB = 285 \text{ MW} \quad \text{a} \quad 6.00 \text{ \$/MWh}$$

$$PA = 125 \text{ MW} \quad \text{a} \quad 7.50 \text{ \$/MWh}$$

$$PC = PD = 0 \text{ MW}$$

Por tanto, el precio nodal en los tres nodos es igual a 7.50 \$/MWh, determinado por el generador A, que es el último en ser despachado para satisfacer la demanda.

Este escenario constituye una referencia fundamental, ya que, bajo condiciones ideales, la localización geográfica de la demanda no influye en el precio de la energía. En los apartados siguientes, se examinará cómo las restricciones físicas de la red y las leyes del flujo eléctrico modifican este resultado, generando precios nodales diferenciados que representan de manera más realista la operación del sistema.

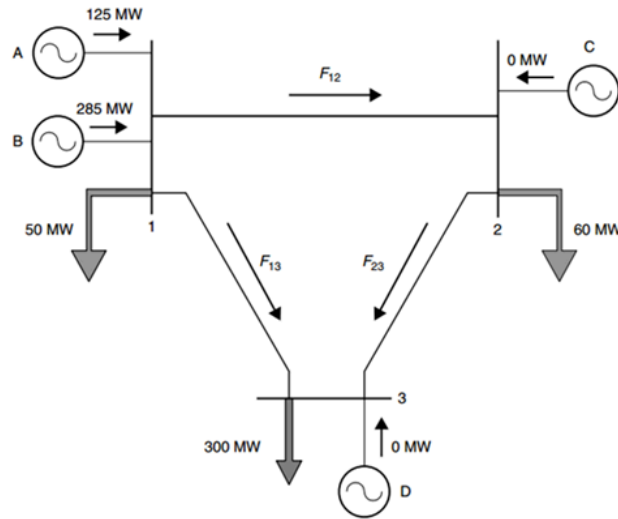
b) Evaluación de la viabilidad técnica del flujo de potencia

Una vez definido el despacho económico bajo condiciones ideales, es necesario verificar si dicho esquema puede ser implementado técnicamente en la red. Para ello, se analiza la distribución de los flujos de potencia resultantes entre los nodos, considerando las impedancias de las líneas y la configuración del sistema. Este paso permite identificar posibles sobrecargas a las capacidades de transmisión.

La red simplificada utilizada en este análisis, compuesta por tres nodos y tres ramas, se describe en la Tabla 1, donde se indican las reactancias y límites de capacidad de cada línea. Los datos técnicos de generación, incluidos costos marginales y capacidades máximas, se presentan en la Tabla 2. A partir del despacho económico previamente establecido donde los generadores A y B abastecen 125 MW y 285 MW respectivamente, se definen las inyecciones y retiros por nodo, y se calcula la distribución de flujos mediante un modelo de flujo de potencia lineal.

Para estimar los flujos en cada línea, se aplica el principio de reparto inversamente proporcional a las reactancias de las rutas disponibles entre nodos. Por ejemplo, la potencia entregada desde el nodo 1 hacia el nodo 3 puede fluir por dos trayectorias: la directa (línea 1-3) y la indirecta (a través de 1-2 y 2-3). La proporción de flujo que toma cada camino depende de su impedancia relativa.

La configuración de rutas de flujo se representa en la Fig. 3, la cual facilita el análisis del reparto de potencia entre rutas alternativas:



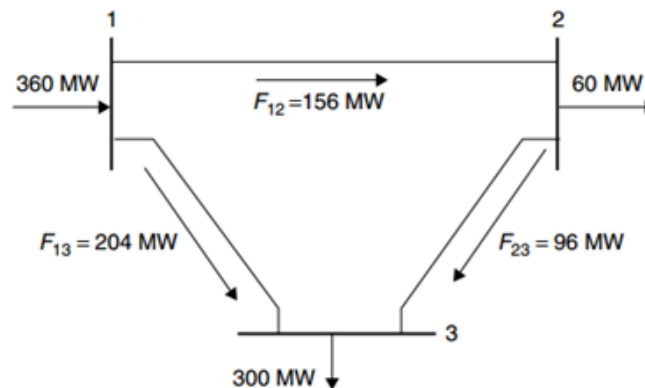
Fuente: tomado de[2]

Fig. 3. Despacho básico en el sistema de tres barras

El resultado del análisis se presenta en la Fig. 4, donde se muestran los flujos obtenidos en cada línea del sistema bajo el esquema de despacho económico:

De acuerdo con estos cálculos, el flujo sobre la línea 1–2 alcanza los 156 MW, superando su capacidad máxima de 126 MW indicada en la Tabla 1. Esta condición evidencia que, a pesar de ser óptimo en términos de costo, el despacho inicial no es técnicamente viable, ya que genera una sobrecarga que comprometería la seguridad del sistema.

Este ejemplo pone de manifiesto la necesidad de incorporar las restricciones físicas de la red en los modelos de operación. Sólo considerando estos límites es posible garantizar que el despacho económico sea factible desde el punto de vista eléctrico y que los precios resultantes reflejen adecuadamente las condiciones reales del sistema.



Fuente: tomado de[2]

Fig. 4. Flujos para el despacho económico en el sistema de tres barras

c) Cálculo del precio nodal considerando restricciones físicas

El análisis anterior evidenció que el despacho económico, aunque óptimo en términos de costos, no es técnicamente viable debido a la sobrecarga en la línea 1–2, la cual supera su capacidad máxima de 126 MW. Esta condición hace necesario reformular el despacho incorporando las restricciones físicas del sistema, específicamente las capacidades límite de las líneas de transmisión.

Cuando estas limitaciones se consideran, el sistema ya no puede operar con un único precio uniforme en todos los nodos. En su lugar, se generan precios nodales diferenciados, que reflejan tanto el costo marginal de generación como las condiciones locales de congestión y disponibilidad de recursos. Para resolver el problema, se evaluarán dos alternativas de redespacho, que permiten reducir la generación en la barra 1 y transferirla a nodos alternos, al tiempo que se mantiene constante la demanda total del sistema.

Primera alternativa: Redespacho hacia la barra 2

Se comienza evaluando el impacto de redespachar 1 MW desde la barra 2 hacia la barra 1. La Fig. 5 ilustra cómo este cambio altera los flujos de potencia: parte del flujo circula por la línea 1–2 (flujo A) y parte por la ruta 1–3–2 (flujo B). Aplicando las reactancias de las rutas involucradas:


$$X_A = X_{12} = 0.2 \text{ u.p.} \quad (2.1)$$

$$X_B = X_{23} + X_{13} = 0.3 \text{ u.p.} \quad (2.2)$$

Se obtiene que el flujo A representa 0.6 MW y el flujo B 0.4 MW:

$$F_A = 0,6 \text{ MW} \quad (2.3)$$

$$F_B = 0,4 \text{ MW} \quad (2.4)$$



Fuente: tomado de[2]

Fig. 5. Efecto de un cambio incremental en la generación en la barra 2

Cada megavatio transferido de la barra 1 a la barra 2 reduce en 0.6 MW el flujo en la línea 1–2; por tanto, para eliminar una sobrecarga de 30 MW, se requieren 50 MW de redespacho. La Fig. 6 muestra el nuevo esquema operativo, denominado despacho restringido, que respeta los límites físicos del sistema. Este ajuste también disminuye


parcialmente el flujo en la línea 1–3 y aumenta el de la línea 2–3, sin exceder su capacidad. En esta configuración, el generador de la barra 1 aporta 360 MW (50 MW para la demanda local y 310 MW a la red), y el de la barra 2 genera 50 MW, absorbiendo 10 MW para cubrir una demanda total de 60 MW.

El nuevo despacho queda definido de la siguiente manera:

- PA = 75 MW
- PB = 285 MW
- PC = 50 MW
- PD = 0 MW

Comparado con el escenario sin restricciones, se observa una reducción en la producción del Generador A, en lugar del Generador B, debido a su mayor costo marginal. El costo total del despacho restringido es:

$$C2 = MCA \times PA + MCB \times PB + MCC \times PC = 2,972.50 \text{ \$/h} \quad (2.5)$$



Fuente: tomado de[2]


Fig. 6. Combinación del redespacho de generación desde el bus 1 al bus 2 (b) con el despacho económico original (a), resultando en un despacho ajustado que cumple con las restricciones de flujo de línea (c).

Segunda alternativa: Redespacho hacia la barra 3

En el segundo escenario, se transfiere generación desde la barra 1 hacia la barra 3. La Fig. 7 muestra la nueva distribución de flujos. Aplicando las reactancias:

$$X_A = X_{12} + X_{23} = 0,3 \text{ u.p.} \quad (2.6)$$

$$X_B = X_{23} = 0,2 \text{ u.p.} \quad (2.7)$$



Fuente: tomado de[2]

Fig. 7. Efecto de un cambio incremental en la generación en la barra 3

Se obtienen los flujos:

$$F_A = 0,4 \text{ MW} \quad (2.8)$$

$$F_B = 0,6 \text{ MW} \quad (2.9)$$

En este caso, cada megavatio redespachado reduce el flujo en la línea 1–2 en sólo 0.4 MW, por lo que se requieren 75 MW de redespacho para aliviar la congestión. La Fig. 8 presenta el nuevo esquema de operación.

Dado que la generación total en el nodo 1 se reduce en 75 MW respecto al despacho original, el nuevo esquema de asignación de generación para este caso es el siguiente:

$$P_A = 50 \text{ MW}$$

$$P_B = 285 \text{ MW}$$

$$P_C = 0 \text{ MW}$$

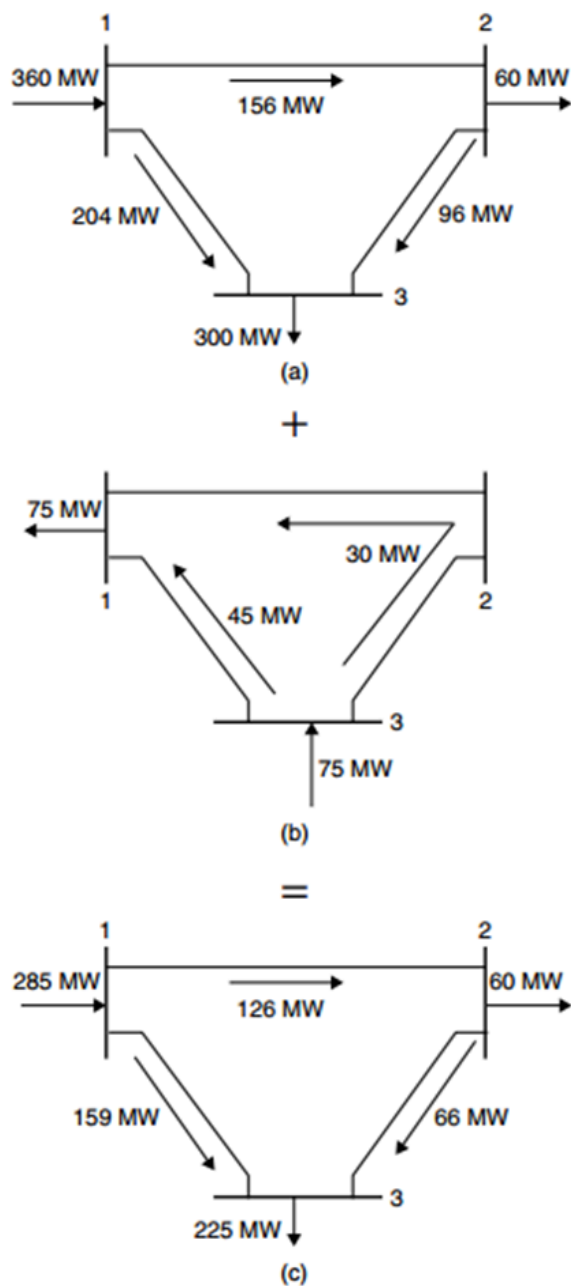
$$P_D = 75 \text{ MW}$$

El coste total de este despacho restringido es:

$$C_3 = MCA \cdot P_A + MCB \cdot P_B + MCD \cdot P_D = 2,835 \text{ \$/h} \quad (2.10)$$

La comparación de las dos alternativas de redespacho se resume en la Tabla 3, El traslado hacia la barra 2 implica menor redistribución de potencia, pero su mayor costo marginal

eleva tanto el costo total como el precio nodal. En cambio, el redespacho hacia la barra 3, aunque requiere mover más potencia, resulta más eficiente en términos económicos.



Fuente: tomado de[2]

Fig. 8. Combinación del redespacho de generación de la barra 1 a la barra 3 (b) sobre el despacho económico (a) para producir un despacho restringido que cumpla con las restricciones de los flujos de línea (c).

Tabla 3. Cuadro Resumen: comparación de alternativas de redespacho

Escenario	Generación en Barra 1 (PA) MW	Generación en Barra 2 (PA) MW	Generación en Barra 3 (PA) MW	Costo Total (\$/h)	Precio Nodal Barra 1 (\$/MWh)	Precio Nodal Barra 2 (\$/MWh)	Precio Nodal Barra 3 (\$/MWh)
Despacho económico sin restricciones	410	0	0	\$ 2,647.50	7.5	7.5	7.5
Redespacho hacia barra 2	360	50	0	\$ 2,972.50	7.5	14	7.5
Redespacho hacia barra 3	335	0	75	\$ 2,835.00	7.5	11.25	10

Fuente: Elaboración propia


El análisis de los escenarios con restricciones de transmisión muestra que el despacho económico original debe ajustarse para evitar sobrecargas. Al comparar dos alternativas, el redespacho hacia la barra 2 requiere trasladar 50 MW, elevando el costo total a 2,972.50 \$/h y el precio nodal a 14.00 \$/MWh, debido al alto costo marginal del generador C. En cambio, el redespacho hacia la barra 3 demanda una mayor redistribución (75 MW), pero su menor costo marginal reduce el costo total a 2,835.00 \$/h y el precio nodal a 11.25 \$/MWh. Desde el punto de vista económico, esta última opción resulta más eficiente, destacando la necesidad de incorporar tanto las restricciones físicas como los costos marginales para un despacho óptimo y una señal de precios adecuada en sistemas eléctricos interconectados.

2.3 Análisis Histórico de las Transacciones Regionales y su Relevancia para el MER.

Desde su puesta en operación, el MER ha evidenciado una tendencia general de crecimiento, siendo un elemento central en la integración eléctrica regional. A lo largo del período 2013–2025, los volúmenes de energía inyectada y retirada han mostrado un comportamiento ascendente, con picos importantes durante los años previos a la pandemia y una recuperación posterior que refleja la solidez del sistema regional. Este crecimiento sostenido ha sido impulsado por el fortalecimiento institucional del mercado, la expansión de la infraestructura de transmisión regional como la línea SIEPAC y la creciente participación de agentes con capacidad excedentaria. Como se observa en la Fig. 9, entre 2013 y 2019 las inyecciones programadas al MER aumentaron de forma constante, confirmando la confianza operativa en el esquema regional. Aunque en 2020 se registró una leve reducción atribuida a la pandemia de COVID-19, y en 2023 una caída más significativa del 14.76 % debido a condiciones hidrológicas adversas vinculadas al fenómeno de El Niño[12], el sistema logró recuperar su desempeño en 2021, lo que sugiere una adecuada capacidad de adaptación ante escenarios críticos. En este contexto, el MER ha representado una solución eficiente y flexible para enfrentar desequilibrios temporales entre oferta y demanda, permitiendo a países con déficit importar energía a menores costos y a exportadores colocar sus excedentes de manera rentable. Esta dinámica ha contribuido a mejorar la confiabilidad del suministro, reducir costos marginales y fomentar una integración energética más sólida en Centroamérica. Dado este marco de beneficios compartidos, cobra especial relevancia el análisis del comportamiento de Guatemala, uno de los principales exportadores netos del sistema, cuyo papel es fundamental para el

equilibrio del mercado y la seguridad energética de países altamente dependientes, como El Salvador.

El MER ha facilitado el intercambio de energía entre los países centroamericanos a través de la Red de Transmisión Regional (RTR). En este contexto, la interconexión de Guatemala representa un componente importante dentro del funcionamiento operativo del MER, especialmente por el papel constante de Guatemala como país exportador neto de energía hacia el sistema regional.




Fuente: Elaboración propia con datos de EOR

Fig. 9. Energía inyectada 2013-05/2025 en el MER

Al observar la evolución histórica del flujo neto anual de Guatemala, como se muestra en la Fig. 10, se evidencia una participación sostenida de este país como proveedor de energía. La magnitud de estos flujos ha representado un apoyo importante para la cobertura de la demanda eléctrica salvadoreña[13], particularmente en contextos de sequía o de restricciones internas de generación.


Adicionalmente, en la Fig. 11 se presenta el comportamiento del flujo neto registrado por El Salvador, el cual ha sido predominantemente negativo durante el período 2013–2022, es decir ha sido un importador neto. Esto confirma una dependencia estructural de las importaciones regionales, en particular provenientes de Guatemala.

Sin embargo, a partir del año 2023 se observa un cambio de importador a exportador de energía. Este cambio está asociado a transformaciones internas en la matriz energética de El Salvador, como la incorporación de nuevas fuentes renovables, incluyendo proyectos de energía solar a gran escala y la entrada en operación de la central térmica Energía del Pacífico (EDP) en el año 2022, lo cual ha contribuido a disminuir la dependencia de importaciones regionales.



Fuente: Elaboración propia con datos de EOR

Fig. 10. Flujo neto anual de energía desde Guatemala al MER 2013-05/2025



Fuente: Elaboración propia con datos de EOR

Fig. 11. Flujo neto anual de energía desde El Salvador al MER 2013-05/2025

Los resultados del análisis histórico reflejan no solo el crecimiento del MER, sino también la relevancia operativa de Guatemala como exportador neto de energía. Esta participación ha sido clave para equilibrar la oferta y la demanda en países como El Salvador, históricamente dependiente de las importaciones regionales. Considerando este contexto, se plantea como caso de estudio un escenario hipotético de desconexión de Guatemala del MER. Aunque dicho evento no se ha materializado, su análisis permite anticipar posibles vulnerabilidades del sistema regional e identificar medidas de mitigación, especialmente en lo relacionado con la variación de precios de la energía en El Salvador. Este planteamiento se fundamenta en el análisis de datos históricos de transacciones regionales y constituye la base para el desarrollo de un modelo predictivo, que será abordado en capítulos posteriores con el propósito de simular los efectos de una posible desconexión y analizar sus repercusiones sobre la estabilidad y el costo del abastecimiento eléctrico salvadoreño.

CAPÍTULO 3

DESARROLLO Y VALIDACIÓN DE UN MODELO DE OPTIMIZACIÓN PARA EL DESPACHO REGIONAL

3.1 Métodos de Optimización

Como se expuso en el capítulo anterior, la operación del MER se fundamenta en principios económicos y técnicos que determinan la asignación eficiente de generación y la formación de precios nodales. Para traducir estos principios en herramientas de análisis aplicables, los modelos computacionales ofrecen una vía efectiva para simular el comportamiento del sistema eléctrico bajo distintas condiciones operativas. A partir de esta base teórica, el presente capítulo aborda la implementación de modelos de optimización que permiten estimar el despacho de generación, los precios resultantes en cada nodo y los flujos de potencia asociados.

La modelación mediante técnicas de optimización constituye una de las estrategias más eficaces para representar la lógica de operación de los sistemas eléctricos modernos[14]. Estas técnicas permiten abordar los desafíos técnicos y económicos que surgen en la operación y planificación de redes complejas, caracterizadas por su gran escala, interdependencia y necesidad de alta confiabilidad. A través de formulaciones matemáticas, es posible incorporar múltiples restricciones como los límites de capacidad de generación y transmisión, los requerimientos de calidad del servicio y las condiciones de estabilidad del sistema, con el fin de alcanzar soluciones que garanticen un funcionamiento seguro, eficiente y económicamente racional[14].

En la operación diaria del sistema eléctrico, la optimización se aplica en problemas críticos como el compromiso de unidades, que determina qué generadores deben operar en cada instante para satisfacer la demanda al menor costo posible, y el flujo óptimo de potencia, que distribuye la energía a través de la red minimizando pérdidas y respetando restricciones técnicas. Esto también es esencial para integrar fuentes renovables, gestionar almacenamiento, aplicar estrategias de respuesta de la demanda y anticipar condiciones operativas mediante pronósticos de consumo y generación. La capacidad de adaptarse a dinámicas cambiantes, tanto en mercados regulados como en ambientes competitivos, hace que los modelos de optimización sean indispensables para garantizar la confiabilidad y eficiencia del suministro eléctrico [15].

Además de su aplicación operativa, la optimización cumple un rol estratégico en la planificación del sistema eléctrico. Facilita la evaluación de inversiones en infraestructura, la determinación de la expansión óptima de generación y transmisión, y el diseño de esquemas operativos que equilibren criterios técnicos, económicos y ambientales. En el actual contexto de transición energética, que exige una mayor flexibilidad operativa y una integración eficiente de tecnologías limpias, la optimización se convierte en un instrumento esencial para fortalecer la sostenibilidad y resiliencia de los sistemas eléctricos a largo plazo. Así, no solo mejora el desempeño técnico y económico, sino que apoya decisiones fundamentadas para el desarrollo de redes robustas ante escenarios futuros [15].

3.2 PYPSA como Herramienta de Optimización del Despacho Regional

Dado el enfoque adoptado en este trabajo, fue necesario identificar una herramienta computacional que permitiera implementar modelos de optimización con la flexibilidad y precisión requeridas para representar sistemas eléctricos interconectados. En ese marco, se seleccionó PyPSA (Python for Power System Analysis) como la plataforma principal de modelado, debido a su capacidad para simular redes eléctricas complejas, resolver problemas de despacho óptimo y adaptar sus estructuras a distintos enfoques analíticos. PyPSA combina un entorno de programación versátil con una arquitectura modular que facilita la incorporación de restricciones técnicas, objetivos personalizados y análisis de múltiples escenarios operativos, lo cual la convierte en una herramienta idónea para los fines de esta investigación[11]. Esta combinación posibilita analizar y ajustar el comportamiento del sistema en escenarios complejos. De este modo, PyPSA facilita la transformación de datos y modelos complejos en soluciones prácticas y sostenibles para mejorar la eficiencia y la estabilidad de los sistemas eléctricos.

PyPSA es una herramienta de código abierto desarrollada en Python para el modelado, la simulación y la optimización de sistemas eléctricos complejos. Se destaca por integrar el análisis físico de la red, representando elementos como buses, líneas de transmisión, generadores y cargas, con técnicas de optimización económica, tales como el despacho de generación y el cálculo de precios nodales [16].

En este estudio, se empleó PyPSA para construir dos modelos de despacho óptimo de energía en condiciones de red interconectada, con el objetivo de que sirvan de base para poder simular escenarios de suspensión de transacciones energéticas entre Guatemala y El Salvador. La herramienta se utilizó para representar topologías de red, esquemas de generación y demanda, estructuras de oferta y costos asociados a cada unidad generadora.

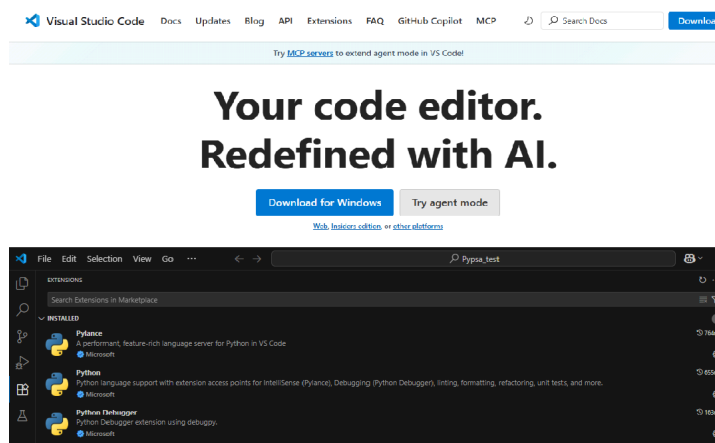
3.2.1. Instalación y configuración de PyPSA

Para implementar los modelos de optimización desarrollados en este estudio, fue necesario establecer un entorno de trabajo estable, organizado y libre de conflictos entre bibliotecas. Para ello, se optó por utilizar Visual Studio Code (VS Code) como entorno de desarrollo (IDE por sus siglas en inglés), debido a su compatibilidad con Python, su terminal integrada y su capacidad para gestionar entornos virtuales y ejecutar scripts de forma eficiente[11]. Sobre esta base, se llevó a cabo la instalación de la herramienta PyPSA. El proceso de instalación se desarrolló en cinco etapas principales:

1. Instalación del entorno de desarrollo Visual Studio Code (VS Code)
2. Instalación de Python
3. Creación del entorno virtual
4. Activación del entorno virtual
5. Instalación de PyPSA y bibliotecas

- Instalación del entorno de desarrollo Visual Studio Code (VS Code):

Se descargó el editor de código Visual Studio Code (VS Code) desde su sitio oficial Fig. 12, y se procedió a su instalación en un equipo con sistema operativo Windows [17]. Posteriormente, dentro del entorno de VS Code, se accedió a la sección de extensiones y se instaló la extensión oficial de Python, desarrollada por Microsoft. Esta extensión es fundamental para habilitar funciones como reconocimiento de entornos virtuales, resaltado de sintaxis, ejecución de scripts y depuración de código en Python

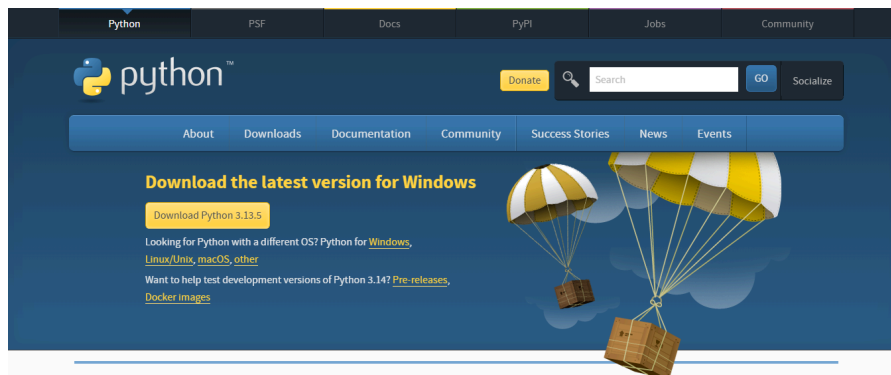


Fuente: Elaboración propia.

Fig. 12. Instalación de Visual Studio Code y extensión de Python.

- Instalación de Python:

Desde el sitio web oficial de Python, se descargó el instalador correspondiente a la versión estable para Windows[18], Fig. 13. Durante el proceso de instalación, se activó la casilla “Add Python to PATH”, lo cual permite que el sistema reconozca los comandos de Python desde cualquier ubicación en la terminal. Esta configuración es indispensable para ejecutar Python correctamente desde Visual Studio Code o cualquier otra interfaz de línea de comandos.



Fuente: Elaboración propia.

Fig. 13. Instalación de Python desde su sitio oficial.

- Creación del entorno virtual:

Con Python correctamente instalado, se procedió a abrir Visual Studio Code y a iniciar un nuevo proyecto en una carpeta vacía. Desde la terminal integrada de VS Code, se ejecutó el comando `python -m venv pypsa-env`. Este comando crea un entorno virtual llamado `pypsa-env`, que contiene una estructura aislada de bibliotecas y configuraciones específicas del proyecto, evitando conflictos con otras instalaciones de Python existentes en el sistema.

```
PS C:\Users\alexi\Documents\Python\Pypsa_test> python -m venv
pypsa-env
```

- Activación del entorno virtual:

Una vez creado el entorno virtual, se activó en la terminal utilizando el comando correspondiente al sistema operativo, mostrado a continuación. Al activarse, la terminal debe mostrar un prefijo con el nombre del entorno, lo cual indica que todos los paquetes instalados en adelante quedarán contenidos dentro de ese entorno, garantizando un entorno de trabajo limpio y reproducible.

```
PS C:\Users\alexi\Documents\Python\Pypsa_test>
.\pypsa-env\Scripts\activate
(pypsa-env) PS C:\Users\alexi\Documents\Python\Pypsa_test>
```

- Instalación de PyPSA y bibliotecas:


Una vez activo el entorno virtual, se procedió a la instalación del paquete PyPSA mediante el gestor de paquetes `pip`, lo que permitió incorporar todas las dependencias necesarias para la modelación eléctrica y la resolución de problemas de optimización. Esta instalación incluye bibliotecas fundamentales para el funcionamiento de la herramienta, como `pandas`, utilizada para manipulación tabular y definición temporal de escenarios; `NumPy` y `SciPy`, esenciales en los cálculos numéricos en las funciones de PyPSA; `Pyomo`, encargado de formular el modelo algebraico del despacho óptimo; y `Network`, que permite representar la red y realizar análisis[11]. En cuanto a la resolución del modelo, se configuró el uso de solvers compatibles como `HiGHS` o `CBC`, los cuales fueron invocados automáticamente desde la herramienta para resolver el problema de optimización planteado.

```
PS C:\Users\alexi\Documents\Python\Pypsa_test>
.\pypsa-env\Scripts\activate
(pypsa-env) PS C:\Users\alexi\Documents\Python\Pypsa_test> pip
install pypsa
```

3.2.2 Estructura de PyPSA y características de los elementos

Con el entorno ya operativo, la atención se dirige ahora a la forma en que PyPSA organiza internamente la representación de los sistemas eléctricos. Su arquitectura, basada en una estructura modular y orientada a objetos, permite construir modelos detallados y adaptables según el nivel de complejidad requerido. Esta flexibilidad resulta especialmente útil en estudios de despacho, planificación y simulación, donde la coherencia entre estructura de datos y funcionalidades es clave para lograr resultados robustos y técnicamente consistentes[11].

A continuación, se presenta un ejemplo construido en PyPSA que permite visualizar la estructura inicial del modelo simple de 3 nodos descrito en el capítulo 2, y representado nuevamente en la Fig. 14, desde la creación de la red hasta la incorporación de las cargas:



Fuente: tomado de[2]

Fig. 14. Sistema simple de tres barras

La construcción de un modelo en PyPSA comienza con la creación de una red mediante el objeto “Network”, que actúa como contenedor central para todos los componentes del sistema eléctrico [19]. Este objeto no solo organiza los datos del sistema, sino que también proporciona herramientas de simulación y optimización. Sobre esta red se agregan de manera modular diversos componentes utilizando el método “network.add”, lo que permite construir modelos altamente personalizables y adaptados a diferentes objetivos de análisis.

```
# 1. Crear la red y el carrier
network = pypsa.Network()
network.add("Carrier", "AC")
```

Uno de los primeros elementos que se integran a la red son los buses o nodos, que representan los nodos eléctricos del sistema, es decir, los puntos de interconexión entre diferentes equipos. Cada bus se asocia a un tipo de energía mediante un “carrier”, que puede representar electricidad en AC, corriente continua (DC), calor, hidrógeno, entre

otros. Esta asociación permite a PyPSA gestionar múltiples vectores energéticos dentro de un mismo modelo[19].

```
# 2. Añadir los buses
network.add("Bus", "Bus 1", carrier="AC")
network.add("Bus", "Bus 2", carrier="AC")
network.add("Bus", "Bus 3", carrier="AC")
```

Luego, se añaden las líneas de transmisión, configurando parámetros eléctricos esenciales. Entre ellos destacan: la resistencia, que determina las pérdidas por efecto Joule; la reactancia, que influye en el flujo de potencia entre nodos; y la capacidad térmica máxima, que establece el límite superior de transferencia de energía. Estas propiedades son clave para evaluar el comportamiento de la red bajo distintas condiciones de carga.

```
# 3. Añadir las líneas de transmisión
network.add("Line", "Line 1-2",
            bus0="Bus 1", bus1="Bus 2",
            s_nom=126, x=0.2, r=0.001,
            carrier="AC")
network.add("Line", "Line 1-3",
            bus0="Bus 1", bus1="Bus 3",
            s_nom=250, x=0.2, r=0.001,
            carrier="AC")
network.add("Line", "Line 2-3",
            bus0="Bus 2", bus1="Bus 3",
            s_nom=130, x=0.1, r=0.001,
            carrier="AC")
```

A continuación, se incorporan los generadores, definiendo atributos como la capacidad máxima de producción, el perfil de generación (en caso de renovables) y el costo marginal, lo que permite realizar estudios económicos y de planificación. Las cargas, por su parte, representan la demanda energética en cada bus y pueden ser fijas o variar en el tiempo según perfiles horarios o estacionales.

```
# 4. Añadir generadores
generators_data = {
    "A": {"bus": "Bus 1", "p_nom": 140, "marginal_cost": 7.5},
    "B": {"bus": "Bus 1", "p_nom": 285, "marginal_cost": 6},
    "C": {"bus": "Bus 2", "p_nom": 90, "marginal_cost": 14},
    "D": {"bus": "Bus 3", "p_nom": 85, "marginal_cost": 10},
}
for name, d in generators_data.items():
    network.add("Generator", name,
                bus=d["bus"],
                p_nom=d["p_nom"],
                marginal_cost=d["marginal_cost"],
                carrier="AC")
```

Finalmente, se integran las cargas, que representan la demanda energética en cada nodo del sistema. En este modelo, se implementaron como generadores negativos, una estrategia común en PyPSA que consiste en definir una fuente con signo inverso y un costo marginal negativo equivalente al valor de la energía para el sistema. Esta configuración permite que las cargas sean tratadas dentro del mismo conjunto de restricciones que los generadores, simplificando el balance nodal de potencia y permitiendo que el optimizador determine, en función del despacho, si se satisface total o parcialmente la demanda de cada nodo según las condiciones técnicas y económicas del sistema.


```
# 5. Añadir cargas como generadores negativos
loads_data = {
    "Load 1":{"bus": "Bus 1", "p_nom": 50, "marginal_value":
30},
    "Load 2":{"bus": "Bus 2", "p_nom": 60, "marginal_value":
30},
    "Load 3":{"bus": "Bus 3", "p_nom": 300, "marginal_value":
30},
}
for name, d in loads_data.items():
    network.add("Generator", name,
                bus=d["bus"],
                p_nom=d["p_nom"],
                marginal_cost=-d["marginal_value"],
                sign=-1,
                carrier="AC")
```

Estas secciones iniciales del código constituyen un ejemplo introductorio que ilustra cómo se puede modelar un sistema eléctrico en PyPSA, sirviendo como referencia para la construcción de modelos más complejos. Hasta este punto, se ha definido la red eléctrica básica incorporando buses, líneas, generadores y cargas, estableciendo así la configuración inicial necesaria para representar un sistema eléctrico simplificado. Cabe destacar que, el código presentado corresponde únicamente a la parte estructural del modelo. Elementos más avanzados, como la definición temporal, la ejecución del solver y la visualización de resultados, se desarrollan en la segunda parte del script y serán mostrados más adelante.

3.3 Descripción de escenarios a modelar: Modelo base de validación (3 nodos) y Modelo de despacho para maximizar los ingresos de transmisión (8 nodos).

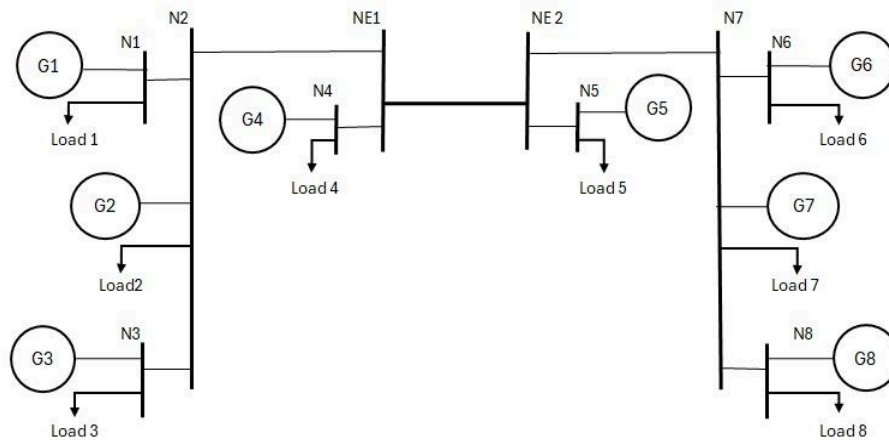
En esta sección se presenta la implementación progresiva de modelos de optimización eléctrica desarrollados en el entorno PyPSA. El objetivo es construir representaciones simplificadas pero funcionales de despacho energético, permitiendo evaluar su desempeño en condiciones controladas y escalables. Esta aproximación modular facilita la validación de la herramienta, la incorporación de restricciones técnicas realistas y la simulación de distintos escenarios operativos mediante redes de distinta complejidad estructural.

Se parte de una validación conceptual básica utilizando un sistema de tres nodos basado en un caso de referencia teórico presentado en la Fig. 14, y que de manera más conceptual puede apreciarse en Fig. 15, para comprobar el correcto funcionamiento de la herramienta PyPSA. Posteriormente, se construyó un modelo más complejo de ocho nodos, apreciable en Fig. 16, que emula de manera simplificada una red regional, incorporando múltiples generadores, cargas distribuidas y precios asociados.



Fuente: Tomado de [2]

Fig. 15. Topología simplificada del sistema de 3 nodos para validación del modelo de despacho.



Fuente: Elaboración propia.

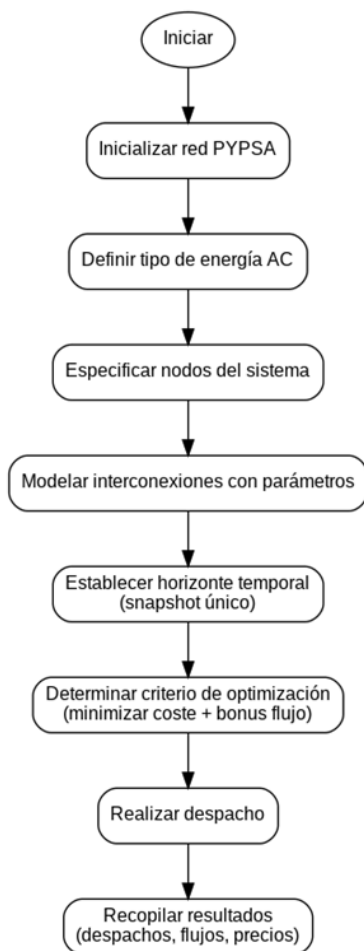
Fig. 16. Modelo de red interconectada de 8 nodos para simulación de escenarios.

Ambos modelos fueron desarrollados con el propósito de generar una base estructurada de datos que permita estudiar el comportamiento del sistema eléctrico bajo una amplia variedad de configuraciones operativas. Para ello, se construyeron doscientas simulaciones

independientes para cada modelo, en las que se variaron de forma controlada los niveles de demanda, las capacidades instaladas de generación y los costos de generación. Estos escenarios no se construyeron a partir de eventos históricos específicos, sino que fueron diseñados para cubrir una variedad amplia de condiciones técnicas. Su propósito es permitir la exploración sistemática del comportamiento del modelo bajo diferentes configuraciones del sistema eléctrico, y generar una base de datos robusta para el posterior entrenamiento de algoritmos de ML, como se desarrollará en el capítulo siguiente.

A continuación se expone la lógica que estructura el modelo, seguida de una descripción de la organización de los datos de entrada. Luego se presenta la formulación matemática del despacho óptimo considerando flujo de potencia en AC, en la que se incluyen el balance de potencia en cada nodo y las restricciones técnicas de generación. También se detalla la modificación incorporada a la función objetivo para incentivar el uso eficiente de la red de transmisión. Finalmente, se explica el propósito de cada uno de los modelos empleados, resaltando su rol dentro del enfoque metodológico de este estudio.

3.3.1 Lógica general del modelo y secuencia de implementación



Fuente: Elaboración propia

Fig. 17. Diagrama de flujo con la secuencia de pasos implementados en PyPSA para el modelo de despacho óptimo AC.

Tras haber introducido previamente la estructura base de un modelo de despacho energético y la representación de sus componentes principales en PyPSA, en esta sección se expone la lógica completa de implementación, abarcando la secuencia operativa desde la definición de la red hasta la formulación de la función objetivo y la resolución del modelo. El desarrollo del modelo de despacho energético sigue una secuencia estructurada que permite representar con fidelidad el comportamiento de una red eléctrica simplificada. El proceso inicia con la creación de un objeto *Network* en PyPSA con configuración en AC. Luego se definen los nodos del sistema junto con sus atributos eléctricos. A cada nodo se le asignan parámetros como demanda local, y cuando corresponde, unidades de generación junto con sus respectivos costos de operación. Una vez establecida la topología de la red, se define el horizonte temporal de simulación, considerando un único intervalo de tiempo correspondiente a un despacho de potencia en régimen permanente. A continuación, se configura la función objetivo del modelo, la cual minimiza el costo total de generación e

incorpora un término adicional que bonifica el uso de las líneas de transmisión, tal como se detalla más adelante.

Antes de aplicar los modelos desarrollados en este estudio, se realizó una validación funcional de la herramienta PyPSA mediante la replicación de un modelo conceptual de tres nodos extraído de la literatura técnica, representado en la Fig. 14. En esta etapa se reprodujo un único caso de prueba con parámetros definidos, con el objetivo de comprobar que los resultados obtenidos por PyPSA coincidieran con los valores teóricos reportados. La simulación replicó el escenario de redespacho hacia la barra 3, y los resultados obtenidos coincidieron plenamente con los presentados en la Tabla 3. Esta validación permitió confirmar el correcto funcionamiento del motor de optimización, así como la coherencia en el cálculo de flujos de potencia y precios nodales dentro de la plataforma.

Comprobada la coherencia del modelo base, se generaron 200 escenarios independientes utilizando la misma topología de tres nodos. En cada escenario se variaron parámetros como la demanda por nodo, la capacidad máxima de los generadores y sus costos marginales, con el fin de representar una diversidad amplia de condiciones operativas. Posteriormente, se aplicó esta misma lógica metodológica a un modelo ampliado de ocho nodos, representado en la Fig. 16, que emula una red regional apegada al MER, interconexiones, generación distribuida y cargas variables.

Ambos conjuntos de simulaciones permitieron observar el comportamiento del sistema ante diferentes configuraciones técnicas y sirvieron como base para la construcción del conjunto de datos utilizado en el entrenamiento de modelos de ML, lo cual se aborda en el capítulo siguiente. Una vez configurados los modelos, se ejecutó el despacho óptimo mediante las funciones de optimización, se recopilaron los resultados correspondientes al despacho de generación, los flujos de potencia en las líneas de transmisión y los precios nodales calculados para cada barra del sistema.

3.3.2 Organización de los datos de entrada y escenarios de simulación

Con el objetivo de evaluar el desempeño de los 2 modelos representados en la Fig. 15 y Fig. 16, en un amplio rango de condiciones operativas, se diseñó una serie de 200 escenarios para ambas topologías estudiadas. En estos escenarios se modificaron sistemáticamente tres elementos fundamentales del sistema eléctrico: las demandas asignadas a cada nodo, los costos marginales de las unidades generadoras, y la capacidad de producción disponible en cada una de ellas. Esta variabilidad introducida buscó representar distintas situaciones del sistema, incluyendo tanto condiciones normales como exigentes, permitiendo así examinar la sensibilidad y robustez de la solución obtenida.

Los datos correspondientes a cada escenario fueron organizados en estructuras tabulares, de forma que cada conjunto de parámetros definiera completamente un caso independiente de análisis. Esta estructura permitió aplicar de manera ordenada la metodología de optimización a un número significativo de condiciones diversas, asegurando una base sólida para el análisis posterior de los resultados. En particular, el diseño de los escenarios garantiza una cobertura adecuada de variaciones técnicas y económicas en la red, haciendo

posible identificar patrones de operación, comportamiento de precios nodales y aparición de restricciones técnicas relevantes.

3.3.3 Formulación del despacho óptimo con flujo de potencia AC no lineal

Previo a la ejecución de los escenarios de simulación, resulta pertinente presentar la formulación matemática sobre la cual se estructura el modelo de optimización de PyPSA. El modelo de optimización de PyPSA se basa en un despacho óptimo de potencia que considera las características completas del sistema eléctrico en AC. Su propósito principal es determinar la combinación más eficiente de generación eléctrica para abastecer la demanda en todos los nodos, minimizando el costo total de operación y respetando las limitaciones técnicas de la red. La formulación incluye una función objetivo centrada en reducir el costo de generación, asignando prioridad a las unidades con menor costo marginal siempre que estén disponibles.

$$\min \sum_{g \in G} (C_g * P_g) \quad (3.1)$$

donde:

C_g : costo marginal de generación para la unidad g [\$/MWh],

P_g : potencia activa generada por g [MW],

G : conjunto de generadores disponibles.

A esto se suman varias restricciones fundamentales: el equilibrio entre generación y demanda en cada nodo, lo que garantiza la conservación de la energía, los límites de capacidad de las líneas de transmisión, y los márgenes técnicos de operación de los generadores. El modelo considera explícitamente el flujo de potencia en AC, es decir, se incluyen las condiciones no lineales que rigen el comportamiento real del sistema eléctrico, como la dependencia del flujo de energía respecto a los ángulos de fase y las tensiones en los nodos. Esta representación permite capturar de manera más realista fenómenos como las pérdidas por efecto Joule, así como las diferencias de voltaje entre distintos puntos de la red.

Además, se imponen restricciones que evitan la sobrecarga de las líneas, limitando la transferencia de energía a su capacidad máxima admisible. De igual forma, se definen los rangos dentro de los cuales cada generador puede operar, en función de su disponibilidad técnica. En cuanto a las tensiones, si bien no se fijan restricciones explícitas sobre sus valores, el modelo busca soluciones que mantengan el sistema dentro de márgenes aceptables, confiando en la estabilidad inherente del flujo AC cuando la operación se encuentra bien balanceada. Una característica destacada de esta formulación es que, al resolverse el problema de optimización, se obtienen también los precios nodales de forma implícita. Estos precios reflejan el costo marginal de entregar energía en cada punto de la red y están influenciados tanto por los costos de generación como por las limitaciones en la infraestructura de transmisión. En consecuencia, los resultados del modelo no solo permiten

identificar el despacho técnico más eficiente, sino también analizar señales económicas clave para la operación y planificación del sistema eléctrico.

3.3.4 Modificación de la función objetivo para promover la utilización de la red

Una de las particularidades de esta implementación es la inclusión de un término adicional en la función objetivo que incentiva el uso de las líneas de transmisión. En lugar de minimizar únicamente el costo de generación, se modificó la función objetivo para premiar los despachos que aprovechen más activamente la capacidad de transferencia de la red, modelando un incentivo que reduce el costo total cuando hay flujos elevados por las líneas. Este enfoque busca emular una lógica similar a la del MER, donde se reconoce el valor del uso físico de la infraestructura de transmisión [8]. En este contexto, las transacciones eléctricas pueden valorarse en función del grado efectivo en que ocupan la capacidad disponible de las líneas, asignando así mayores beneficios proporcionales al nivel de utilización. Este principio promueve un uso más eficiente, coordinado y equitativo de los recursos de red, alineando el modelo con prácticas observadas en mercados reales donde el flujo físico es un criterio clave en la asignación de costos de transmisión. Matemáticamente, este término puede entenderse como $-\alpha \sum_{(i,j)} |P_{ij}|$, donde α es un coeficiente positivo que representa la bonificación por unidad de potencia transmitida y P_{ij} es el flujo por la línea i-j. De esta forma, el solver buscará, en igualdad de condiciones, soluciones donde las líneas carguen más potencia, ya que cada MW en una línea reduce el costo objetivo (un efecto equivalente a considerar un costo negativo por uso de la línea). La motivación detrás de esta modificación es promover el uso eficiente de la infraestructura de transmisión: si existe capacidad ociosa en las líneas y generación barata en una zona que podría abastecer demanda en otra zona, el término de bonificación impulsa al algoritmo a utilizar esa capacidad antes de recurrir a generación más costosa local. En esencia, se fuerza una internalización de un “beneficio” por transportar energía, contrarrestando parcialmente la tendencia natural de un despacho económico puro que consideraría neutro el flujo excepto por sus límites. Con esta modificación, mayores flujos resultan en menor costo total, lo cual tiende a aplanar las diferencias de precio entre áreas (al incentivar enviar toda la energía barata posible a donde haga falta). La integración de este término en PyPSA se logró aprovechando la funcionalidad de objetivos personalizados. PyPSA, a través de su método *Network.lopf()*, que permite al usuario modificar el problema de optimización mediante la opción *extra_functionality*. En esta implementación, se empleó dicha capacidad para añadir el término que maximiza la transmisión al objetivo una vez construido el modelo. Más adelante se muestra el fragmento del código en Python donde se incorpora este término a la función objetivo, mediante la definición de una función auxiliar que modifica el modelo interno de PyPSA y que es integrada al proceso de optimización mediante el argumento *extra_functionality*.

Para acceder al flujo en cada línea dentro del modelo de PyPSA, se introdujeron variables auxiliares o se aprovechó que PyPSA ya considera las potencias en ramas como variables en el flujo AC no lineal. Cabe señalar que la incorporación de un valor absoluto de flujo requiere linealizarlo o modelarse mediante variables separadas por dirección; en este

trabajo se asumió simétricamente la bonificación por magnitud de flujo, representándola de forma compatible con el solver, por ejemplo, descomponiendo P_{ij} en componentes positivas y negativas, o simplemente aplicando la bonificación al flujo neto sabiendo que el despacho AC determinará direcciones coherentes. La implementación cuidadosa de este término adicional fue posible sin alterar el código base de PyPSA, únicamente mediante las facilidades de personalización mencionadas. Así, el modelo resultante minimiza una función objetivo modificada:

$$\min \sum_g (Cg * Pg) - \alpha \sum_{(i,j)} |P_{ij}| \quad (3.2)$$

```
# Modificación de la función objetivo
def add_flow_objective(network, snapshots):
    m = network.model
    total_flow = sum(
        m.variables["Line-s"].sel(Line=line).sum("snapshot")
        for line in network.lines.index
    )
    m.objective = m.objective - total_flow
```

Sujeta a todas las restricciones de balance y límites previamente descritas. Con un valor adecuado de α , se garantiza que la prioridad primaria siga siendo minimizar costos de generación, pero otorgando un beneficio secundario por utilizar las líneas, sin llegar a distorsionar completamente el despacho económico. Esto se calibró para que la modificación influya notablemente solo cuando hay alternativas de despacho similares en costo, inclinando la solución hacia aquella que implique mayores intercambios de potencia entre nodos.

3.3.5 Modelos simplificados para validación y análisis escalado

Para comprobar el funcionamiento de la metodología propuesta y su aplicabilidad en distintos niveles de complejidad, se desarrollaron dos modelos de optimización de distinta escala. El primero, de carácter simplificado, corresponde a un sistema de tres nodos, mientras que el segundo se diseñó con ocho nodos para emular una red más compleja.

A. Modelo de 3 nodos:

Modelo de 3 nodos: Este modelo fue concebido como una etapa de validación conceptual. Al tratarse de una red pequeña, con un número reducido de líneas de transmisión y unidades generadoras, resultó ideal para probar el comportamiento general del algoritmo, depurar errores en la implementación y asegurar que las funciones esenciales se integran correctamente. Su simplicidad permite revisar de forma manual los resultados y compararlos con lo que se esperaría según la teoría, por ejemplo, verificando que en ausencia de congestiones los precios nodales se mantuvieran iguales, o que ante restricciones en la red se priorizará el uso de las líneas disponibles antes de recurrir a generación más costosa. Este modelo además de tener como propósito la validación del

modelo, también facilitó la comprensión de la lógica del despacho como un primer paso para construir confianza en el comportamiento del modelo antes de escalar a sistemas más complejos. En el siguiente desarrollo, se presenta una descripción progresiva de los bloques que conforman el código para el Escenario 1 de los 200 mencionados anteriormente, con sus respectivas funciones y lógica de implementación.

- Definición de red, líneas, generadores y cargas

En este primer segmento se inicializa la biblioteca PyPSA y se crea el objeto central Network, el cual representa el sistema eléctrico. A continuación, se agregan los tres nodos, que representan los nodos eléctricos donde se conectan los demás componentes. Posteriormente se definen las líneas de transmisión que interconectan dichos nodos, asignando parámetros como capacidad de transmisión, reactancia y resistencia, necesarios para el cálculo de flujos de potencia. Luego se incorporan los generadores con su respectiva ubicación, capacidad instalada y costo marginal. Finalmente, se añaden las cargas modeladas como generadores negativos.

```
import pypsa
import pandas as pd

# 1. Crear la red y el carrier
network = pypsa.Network()
network.add("Carrier", "AC")

# 2. Añadir los 3 buses
network.add("Bus", "Bus 1", carrier="AC")
network.add("Bus", "Bus 2", carrier="AC")
network.add("Bus", "Bus 3", carrier="AC")

# 3. Añadir las líneas de transmisión
network.add("Line", "Line 1-2",
            bus0="Bus 1", bus1="Bus 2",
            s_nom=126, x=0.2, r=0.001,
            carrier="AC")
network.add("Line", "Line 1-3",
            bus0="Bus 1", bus1="Bus 3",
            s_nom=250, x=0.2, r=0.001,
            carrier="AC")
network.add("Line", "Line 2-3",
            bus0="Bus 2", bus1="Bus 3",
            s_nom=130, x=0.1, r=0.001,
            carrier="AC")

# 4. Añadir generadores
generators_data = {
    "A": {"bus": "Bus 1", "p_nom": 243, "marginal_cost": 10.72},
    "B": {"bus": "Bus 1", "p_nom": 2, "marginal_cost": 16.47},
```

```

    "C": {"bus": "Bus 2", "p_nom": 210, "marginal_cost": 11.68},
    "D": {"bus": "Bus 3", "p_nom": 268, "marginal_cost": 11.38},
}
for name, d in generators_data.items():
    network.add("Generator", name,
               bus=d["bus"],
               p_nom=d["p_nom"],
               marginal_cost=d["marginal_cost"],
               carrier="AC")

# 5. Añadir cargas como generadores negativos
loads_data = {
    "Load 1": {"bus": "Bus 1", "p_nom": 122, "marginal_value":
30},
    "Load 2": {"bus": "Bus 2", "p_nom": 149, "marginal_value":
30},
    "Load 3": {"bus": "Bus 3", "p_nom": 72, "marginal_value":
30},
}
for name, d in loads_data.items():
    network.add("Generator", name,
               bus=d["bus"],
               p_nom=d["p_nom"],
               marginal_cost=-d["marginal_value"],
               sign=-1,
               carrier="AC")

```

- Configuración temporal, función objetivo y ejecución de la optimización

En esta segunda sección se define el horizonte temporal de análisis, configurando un único snapshot que representa el instante de simulación. A continuación, se implementa una modificación a la función objetivo añadiendo el término que busca incentivar el uso activo de las líneas de transmisión, tal como se explicó anteriormente. Esta modificación tiene como propósito emular criterios de despacho donde se reconoce el valor del uso físico de la red, promoviendo un mayor aprovechamiento de su capacidad disponible. Finalmente, se ejecuta el modelo de optimización utilizando el solucionador HiGHS, o CBC en caso de que el primero no esté disponible, resolviendo el despacho económico bajo las restricciones técnicas y la función objetivo definida.

```

# 6. Definir el único snapshot
network.set_snapshots(pd.Index(['now']))

# 7. Modificación de la función objetivo para maximizar el uso de
la red
def add_flow_objective(network, snapshots):
    m = network.model

```

```

total_flow = sum(
    m.variables["Line-s"].sel(Line=line).sum("snapshot")
    for line in network.lines.index
)
m.objective = m.objective - total_flow

# 8. Ejecutar la optimización
try:
    import highspy
    solver = 'highs'
except ImportError:
    solver = 'cbc'
network.optimize(
    network.snapshots,
    solver_name=solver,
    extra_functionality=add_flow_objective
)

```

- **Presentación de resultados del modelo**

Finalmente, se imprimen los principales resultados de la simulación. Primero, se presenta el despacho de generadores ordenado por su costo marginal, lo que permite verificar si el modelo responde a una lógica de mínimo costo. Luego, se muestra el nivel de cobertura de las cargas, es decir, qué proporción de la demanda fue efectivamente servida. Posteriormente, se reportan los flujos eléctricos por cada línea y su porcentaje de utilización respecto a su capacidad máxima. Por último, se muestran los precios nodales resultantes, que reflejan el costo marginal de servir la demanda en cada nodo dadas las condiciones del sistema.

```

# 9. Mostrar resultados ordenados

# 9.1 Despacho de generadores
sorted_gens = sorted(
    generators_data.items(),
    key=lambda x: x[1]['marginal_cost']
)
print("\n--- Despacho de generadores (MW) ---")
for name, d in sorted_gens:
    p = network.generators_t.p.at[('now', name)]
    status = "ON" if p > 0 else "OFF"
    print(f"{name} (bus {d['bus']}, cost {d['marginal_cost']}):
{p:.1f} MW - {status}")

# 9.2 Cargas servidas
sorted_loads = sorted(
    loads_data.items(),
    key=lambda x: x[1]['marginal_value'],

```

```

        reverse=True
    )
print("\n--- Cargas servidas (MW) ---")
for name, d in sorted_loads:
    p = network.generators_t.p.at[('now', name)]
    served = abs(p)
    status = "Served" if served > 0 else "Not served"
    print(f"{name} (bus {d['bus']}, value {d['marginal_value']}):
{served:.1f} MW - {status}")

# 9.3 Flujo en las líneas
print("\n--- Flujo de líneas (MW) ---")
for line in network.lines.index:
    f = network.lines_t.p0.at[('now', line)]
    print(f"{line}: {f:.1f} MW")

# 9.4 Utilización de líneas
print("\n--- Utilización de líneas (% of MVA) ---")
for line in network.lines.index:
    f = abs(network.lines_t.p0.at[('now', line)])
    cap = network.lines.s_nom[line]
    print(f"{line}: {f/cap*100:.2f}%")

# 9.5 Precios nodales ($/MWh)
print("\n--- Precios Nodales ($/MWh) ---")
# network.buses_t.marginal_price es un DataFrame snapshot × bus
for bus in network.buses.index:
    price = network.buses_t.marginal_price.at['now', bus]
    print(f"{bus}: {price:.2f} $/MWh")

```

A partir de la ejecución del modelo, se obtuvieron los resultados correspondientes al Escenario 1, cuyo conjunto de datos se muestra de manera resumida en la Tabla 4. Esta tabla presenta las variables clave de entrada utilizadas en la simulación, así como los resultados obtenidos en términos de despacho de generadores, cobertura de carga y precios nodales en cada uno de los nodos. Este ejercicio representa una instancia específica dentro de los 200 escenarios generados para el modelo de 3 nodos, utilizados tanto para validar el comportamiento del sistema como para alimentar el modelo predictivo descrito en capítulos posteriores. La totalidad de los 200 escenarios puede consultarse en el Anexo A.

Tabla 4. Datos de entrada y resultados para el Escenario 1 del modelo de 3 nodos.

Categoría	Variable	Escenario 1
Entrada	Load 1 (MW)	122.00
Entrada	Load 2 (MW)	149.00
Entrada	Load 3 (MW)	72.00
Entrada	Gen A p_nom (MW)	243.00
Entrada	Coste A (\$/MWh)	10.72
Entrada	Gen B p_nom (MW)	2.00
Entrada	Coste B (\$/MWh)	16.47
Entrada	Gen C p_nom (MW)	210.00
Entrada	Coste C (\$/MWh)	11.68
Entrada	Gen D p_nom (MW)	238.00
Entrada	Coste D (\$/MWh)	11.38
Resultado	Despacho Gen A (MW)	243.00
Resultado	Despacho Gen B (MW)	0.00
Resultado	Despacho Gen C (MW)	100.00
Resultado	Despacho Gen D (MW)	0.00
Resultado	Carga servida 1 (MW)	122.00
Resultado	Carga servida 2 (MW)	149.00
Resultado	Carga servida 3 (MW)	72.00
Resultado	Precio N1 (\$/MWh)	12.28
Resultado	Precio N2 (\$/MWh)	11.68
Resultado	Precio N3 (\$/MWh)	10.88

Fuente: Elaboración propia.

B. Modelo de 8 nodos: (Modelo de despacho para maximizar los ingresos de transmisión)

Una vez validado el enfoque en el modelo reducido, se diseñó una red de ocho nodos que permitiera simular un contexto más amplio y representativo de una red regional. Esta topología incorpora mayor número de barras, interconexiones y generadores distribuidos, lo que hace posible analizar situaciones más complejas, como la interacción entre distintas áreas geográficas, la aparición de congestiones en ciertas rutas de transmisión o la variación de precios nodales entre zonas.

Un elemento relevante en este modelo es la incorporación de nodos de enlace, también conocidos como nodos intermedios o buses de acoplamiento, los cuales para nuestro caso no cuentan con generación ni demanda propia, pero cumplen una función estructural clave: facilitar la conexión entre subsistemas o actuar como puntos estratégicos de transferencia de energía. Su presencia mejora la flexibilidad operativa de la red, ya que permite redirigir flujos de potencia y explorar rutas alternativas cuando ciertas líneas se encuentran congestionadas o fuera de servicio. Estos nodos también influyen en la determinación de precios nodales, ya que su ubicación dentro de rutas críticas puede afectar los costos marginales observados en distintos extremos del sistema[8]. La inclusión de este tipo de nodos se alinea con las características observadas en redes de transmisión reales, donde la planificación considera no solo la ubicación de generadores y cargas, sino también la necesidad de estructuras intermedias que soportan el flujo eficiente de energía. Aunque se trata de una red abstracta, su estructura busca emular de manera cualitativa el comportamiento de sistemas eléctricos reales, donde la ubicación de la generación, la demanda y sus precios influyen directamente en los resultados del despacho. Este modelo permitió también evaluar cómo se comporta el algoritmo frente a la escalabilidad, y qué impacto puede tener la bonificación por flujo en la utilización de rutas de transmisión

cuando existen múltiples alternativas posibles. A continuación, se presenta una descripción del código correspondiente al Escenario 1 de los 200 simulados, dividida en bloques funcionales:

- Definición de nodos, líneas, generadores y cargas

Este bloque amplía la lógica del modelo anterior, ya que cuenta con la variante de la incorporación de los nodos de enlace (NE1 y NE2), los cuales no poseen generación ni demanda, pero sirven como puntos estructurales que conectan las dos áreas principales de la red. Su inclusión permite representar trayectorias alternativas de flujo y reflejar estructuras típicas de redes interconectadas a nivel regional. La incorporación de líneas de transmisión, generadores y cargas sigue el mismo procedimiento aplicado en el modelo de 3 nodos.

```
import pypsa
import pandas as pd
# 1. Crear la red y el carrier
network = pypsa.Network()
network.add("Carrier", "AC")

# 2. Añadir 8 buses activos y 2 nodos de enlace (sin generación
ni carga)
buses_activos = [f"N{i}" for i in range(1, 9)]
enlaces = ["NE1", "NE2"]
for bus in buses_activos + enlaces:
    network.add("Bus", bus, carrier="AC")

# 3. Definir líneas manualmente (bus0, bus1, s_nom, x, r)
d = {
    # Área 1: N1 y N3 conectados a N2, que conecta a NE1; N4
directo a NE1
    "L1_N2": {"bus0": "N1", "bus1": "N2", "s_nom": 150, "x":
0.2, "r": 0.001},
    "L3_N2": {"bus0": "N3", "bus1": "N2", "s_nom": 145, "x":
0.2, "r": 0.001},
    "L2_NE1": {"bus0": "N2", "bus1": "NE1", "s_nom": 160, "x":
0.2, "r": 0.001},
    "L4_NE1": {"bus0": "N4", "bus1": "NE1", "s_nom": 140, "x":
0.2, "r": 0.001},
    # Área 2: N6 y N8 conectados a N7, que conecta a NE2; N5
directo a NE2
    "L6_N7": {"bus0": "N6", "bus1": "N7", "s_nom": 155, "x":
0.2, "r": 0.001},
    "L8_N7": {"bus0": "N8", "bus1": "N7", "s_nom": 150, "x":
0.2, "r": 0.001},
    "L7_NE2": {"bus0": "N7", "bus1": "NE2", "s_nom": 150, "x":
0.2, "r": 0.001},
```

```

    "L5_NE2": {"bus0": "N5", "bus1": "NE2", "s_nom": 145, "x":
0.2, "r": 0.001},
    # Interconexión entre áreas
    "L_NE1_NE2": {"bus0": "NE1", "bus1": "NE2", "s_nom": 150, "x":
0.2, "r": 0.001},
}
# Añadir cada línea al network
for name, p in d.items():
    network.add("Line", name,
                bus0=p["bus0"], bus1=p["bus1"],
                s_nom=p["s_nom"], x=p["x"], r=p["r"],
                carrier="AC")

# 4. Definir generadores en cada nodo activo
generators_data = {
    "G1": {"bus": "N1", "p_nom": 105, "marginal_cost": 24.41},
    "G2": {"bus": "N2", "p_nom": 178, "marginal_cost": 24.84},
    "G3": {"bus": "N3", "p_nom": 135, "marginal_cost": 28.21},
    "G4": {"bus": "N4", "p_nom": 92, "marginal_cost": 11.36},
    "G5": {"bus": "N5", "p_nom": 100, "marginal_cost": 17.69},
    "G6": {"bus": "N6", "p_nom": 148, "marginal_cost": 27.66},
    "G7": {"bus": "N7", "p_nom": 176, "marginal_cost": 10.13},
    "G8": {"bus": "N8", "p_nom": 225, "marginal_cost": 15.62},
}
for name, gd in generators_data.items():
    network.add("Generator", name,
                bus=gd["bus"], p_nom=gd["p_nom"],
                marginal_cost=gd["marginal_cost"], carrier="AC")

# 5. Definir cargas en cada nodo activo como generadores
negativos
loads_data = {
    "Load1": {"bus": "N1", "p_nom": 122, "marginal_value": 30},
    "Load2": {"bus": "N2", "p_nom": 149, "marginal_value": 30},
    "Load3": {"bus": "N3", "p_nom": 72, "marginal_value": 30},
    "Load4": {"bus": "N4", "p_nom": 24, "marginal_value": 30},
    "Load5": {"bus": "N5", "p_nom": 130, "marginal_value": 30},
    "Load6": {"bus": "N6", "p_nom": 139, "marginal_value": 30},
    "Load7": {"bus": "N7", "p_nom": 160, "marginal_value": 30},
    "Load8": {"bus": "N8", "p_nom": 63, "marginal_value": 30},
}
for name, ld in loads_data.items():
    network.add("Generator", name,
                bus=ld["bus"], p_nom=ld["p_nom"],
                marginal_cost=-ld["marginal_value"], sign=-1,
                carrier="AC")

```

- Configuración temporal, función objetivo y ejecución de la optimización

Esta sección mantiene la misma lógica empleada en el modelo reducido. Se define un único snapshot de análisis y se modifica la función objetivo con un término adicional que premia los flujos a través de las líneas de transmisión con el objetivo de favorecer soluciones que utilicen activamente la red disponible. La única diferencia relevante radica en la escala del sistema, que ahora involucra más líneas y buses, por lo que el término agregado al objetivo se aplica sobre un conjunto más amplio de variables de flujo.

```
# 6. Definir snapshot único
network.set_snapshots(pd.Index(["now"]))

#7. Modificación de la función objetivo para maximizar el uso de
la red
def add_flow_objective(network, snapshots):
    m = network.model
    total_flow = sum(
        m.variables["Line-s"].sel(Line=line).sum("snapshot")
        for line in network.lines.index
    )
    m.objective = m.objective - total_flow

# 8. Ejecutar optimización
try:
    import highspy
    solver = 'highs'
except ImportError:
    solver = 'cbc'
network.optimize(network.snapshots, solver_name=solver,
extra_functionality=add_flow_objective)
```

- Resultados del modelo

El bloque final conserva la misma estructura que en el modelo de 3 nodos, aunque naturalmente presenta un volumen mayor de resultados. Se imprime el despacho de generadores ordenado por su costo marginal, seguido del nivel de carga servida por nodo, los flujos en cada línea y su utilización relativa. Finalmente, se presentan los precios nodales para todos los nodos del sistema, incluyendo los de enlace, permitiendo observar cómo se propagan los efectos de congestión o restricción a través de la red ampliada.

```
# 9. Mostrar resultados ordenados
# 9.1 Despacho de generadores
sorted_gens = sorted(generators_data.items(), key=lambda x:
x[1]['marginal_cost'])
print("\n--- Despacho de generadores (MW) ---")
for name, gd in sorted_gens:
    p = network.generators_t.p.at(["now", name])
```

```

    status = "ON" if p > 0 else "OFF"
    print(f"{name} (bus {gd['bus']}), cost {gd['marginal_cost']}:
{p:.1f} MW - {status}")

# 9.2 Cargas servidas
sorted_loads = sorted(loads_data.items(), key=lambda x:
x[1]['marginal_value'], reverse=True)
print("\n--- Cargas servidas (MW) ---")
for name, ld in sorted_loads:
    p = network.generators_t.p.at(["now", name])
    served = abs(p)
    status = "Served" if served > 0 else "Not served"
    print(f"{name} (bus {ld['bus']}): {served:.1f} MW -
{status}")

# 9.3 Flujo de líneas
print("\n--- Flujo de líneas (MW) ---")
for line, params in d.items():
    f = network.lines_t.p0.at(["now", line])
    print(f"{line}: {f:.1f} MW")

# 9.4 Utilización de líneas (% of MVA)
print("\n--- Utilización de líneas (% of MVA) ---")
for line, params in d.items():
    f = abs(network.lines_t.p0.at(["now", line]))
    cap = params['s_nom']
    print(f"{line}: {f/cap*100:.2f}%")

# 9.5 Precios Nodales ($/MWh)
print("\n--- Precios Nodales ($/MWh) ---")
for bus in network.buses.index:
    price = network.buses_t.marginal_price.at['now', bus]
    print(f"{bus}: {price:.2f} $/MWh")

```

A continuación, la Tabla 5 resume los datos de entrada y los resultados del Escenario 1 del modelo. La información presentada permite observar la distribución de cargas, capacidades de generación, costos marginales de generación, despacho óptimo, energía servida y precios nodales resultantes en cada nodo del sistema. El conjunto completo de escenarios evaluados se encuentra disponible en el Anexo B.

Tabla 5. Datos de entrada y resultados para el Escenario 1 del modelo de 8 nodos.

Categoría	Variable	Entrada	Resultado
Cargas	Load 1 (MW)	122.00	122.00
	Load 2 (MW)	149.00	149.00
	Load 3 (MW)	72.00	72.00
	Load 4 (MW)	24.00	24.00
	Load 5 (MW)	130.00	130.00
	Load 6 (MW)	139.00	139.00
	Load 7 (MW)	160.00	160.00
	Load 8 (MW)	63.00	63.00
Generadores	G1 p_nom (MW)	105.00	105.00
	G1 costo (\$/MWh)	24.41	---
	G2 p_nom (MW)	178.00	173.00
	G2 costo (\$/MWh)	24.84	---
	G3 p_nom (MW)	135.00	0.00
	G3 costo (\$/MWh)	28.21	---
	G4 p_nom (MW)	92.00	92.00
	G4 costo (\$/MWh)	11.36	---
	G5 p_nom (MW)	100.00	100.00
	G5 costo (\$/MWh)	17.69	---
	G6 p_nom (MW)	148.00	0.00
	G6 costo (\$/MWh)	27.66	---
	G7 p_nom (MW)	176.00	176.00
	G7 costo (\$/MWh)	10.13	---
	G8 p_nom (MW)	225.00	213.00
	G8 costo (\$/MWh)	15.62	---
Precios	Precio N1 (\$/MWh)	---	25.84
	Precio N2 (\$/MWh)	---	24.84
	Precio N3 (\$/MWh)	---	25.84
	Precio N4 (\$/MWh)	---	24.84
	Precio N5 (\$/MWh)	---	23.84
	Precio N6 (\$/MWh)	---	24.84
	Precio N7 (\$/MWh)	---	23.84
	Precio N8 (\$/MWh)	---	15.62
	Precio NE1 (\$/MWh)	---	23.84
	Precio NE2 (\$/MWh)	---	22.84

Fuente: Elaboración propia

Ambos modelos se complementaron dentro del estudio. El modelo de tres nodos permitió confirmar que la lógica implementada funcionaba correctamente en condiciones controladas, mientras que el modelo de ocho nodos ofreció una visión más completa de cómo se comporta la metodología bajo escenarios más variados y con mayor complejidad, similares a los que se pueden presentar en un sistema eléctrico interconectado real.

3.4 Resultados generales y observaciones

Los resultados generados por PyPSA abarcan información detallada sobre el despacho óptimo de generación, los flujos de potencia en cada línea del sistema y los precios nodales asociados a cada bus. Esta información se obtuvo a partir de los 200 escenarios para los modelos de 3 y 8 nodos, permitiendo identificar patrones clave en el comportamiento de la red eléctrica ante diferentes combinaciones de demanda, capacidad instalada y costos marginales. En general, se observó que los generadores con menores costos marginales

tienden a ser priorizados por el optimizador, siempre que las condiciones de la red lo permitan. Del mismo modo, los precios nodales tienden a aumentar en nodos donde hay congestión en las líneas de entrada, reflejando el costo adicional de satisfacer la demanda en dichas ubicaciones. Estas señales de precio permiten evaluar la eficiencia del despacho y los cuellos de botella en la red. Los resultados obtenidos a través de estos escenarios funcionarán como base de datos para entrenar y validar un modelo de predicción mediante técnicas de aprendizaje automático, las cuales se estudiarán en capítulos futuros.

Los escenarios de simulación también permitieron identificar zonas del sistema que, de forma recurrente, operaban con precios altos o bajos, lo que ofrece una base para análisis económico y de planificación futura. En algunos casos se incluyó una bonificación experimental por uso de líneas para inducir el aprovechamiento más eficiente de la red, lo cual mostró una distribución más equitativa del flujo de potencia. En la tabla 6 se muestra una comparativa que resume la estructura de entrada y salida aplicada en ambos modelos.

Tabla 6. Estructura de datos de entrada y salida en modelos de simulación

Categoría	Variable	Modelo de 3 Nodos	Modelo de 8 Nodos
Entrada	Demanda por nodo	Load 1, Load 2, Load 3	Load 1 a Load 8
	Generadores	A, B, C, D	G1 a G8 (según nodo asignado)
	Capacidad de generación	Individual para A–D	Individual para cada generador
	Costos marginales (\$/MWh)	Individual para A–D	Individual para cada generador
Salida	Despacho de generación (MW)	Por generador A–D	Por generador G1–G8
	Carga servida por nodo (MW)	En Load 1, 2 y 3	En cada Load 1 a 8
	Precio nodal (\$/MWh)	En buses 1, 2 y 3	En buses 1 a 8
	Flujo de potencia por línea (MW)	En líneas L1-2, L1-3 y L2-3	En todas las líneas del sistema

Fuente: Elaboración propia.

CAPÍTULO 4

INTELIGENCIA ARTIFICIAL COMO ALTERNATIVA A METODOS DE OPTIMIZACION EN MERCADOS ENERGETICOS

4.1 Introducción a la Inteligencia Artificial y su Aplicación en el Sector Energético

La IA es un campo de estudio dentro de la informática cuyo objetivo es diseñar y desarrollar sistemas capaces de simular comportamientos inteligentes, tales como el razonamiento, la percepción, el aprendizaje y la toma de decisiones autónomas. Stuart Russell y Peter Norvig, en su obra de referencia, definen la IA como “el estudio de los agentes que reciben percepciones del entorno y realizan acciones que maximizan sus posibilidades de éxito”[20].

El término fue introducido formalmente por John McCarthy en 1956[20], durante la conferencia de Dartmouth, donde se establecieron las bases de un área multidisciplinaria que integraría la lógica, las matemáticas, la filosofía, la lingüística y la neurociencia. Desde entonces, el campo ha evolucionado desde enfoques simbólicos y basados en reglas hacia modelos estadísticos y algorítmicos que aprenden directamente de los datos.

Según su nivel de capacidad, la IA se clasifica comúnmente en tres categorías:

- IA débil (narrow AI): sistemas diseñados para tareas específicas, como asistentes virtuales, motores de recomendación o sistemas de diagnóstico médico. No poseen conciencia ni comprensión generalizada.
- IA fuerte (general AI): una forma hipotética de IA que iguala la inteligencia humana, con capacidad de razonamiento abstracto, aprendizaje en múltiples dominios y transferencia de conocimientos.
- IA superinteligente: una IA futura que, en teoría, superaría la inteligencia humana en todos los aspectos cognitivos.

Uno de los subcampos más relevantes de la IA en las últimas décadas es el ML. Esta disciplina se basa en el diseño de algoritmos que permiten a los sistemas aprender patrones a partir de conjuntos de datos, sin requerir una programación explícita para cada tarea. Estos modelos mejoran su desempeño a medida que procesan nueva información histórica.

El ML se clasifica principalmente en tres enfoques:

- Aprendizaje supervisado: el modelo se entrena con ejemplos etiquetados (con salidas conocidas).
- Aprendizaje no supervisado: el sistema identifica patrones y agrupaciones sin etiquetas previas.
- Aprendizaje por refuerzo: un agente aprende a tomar decisiones mediante un sistema de recompensas o penalizaciones dentro de un entorno dinámico.

Una de las aplicaciones más relevantes de la IA en el sector energético es la predicción de precios de la electricidad en mercados mayoristas. Estos entornos se caracterizan por una alta volatilidad y la influencia de múltiples factores en la formación de precios, como la demanda, la disponibilidad de generación, las restricciones de red y las condiciones operativas del sistema. En este contexto, los modelos tradicionales basados en regresión lineal o análisis estadístico clásico resultan insuficientes para capturar la complejidad subyacente.

La IA, en particular el ML y el aprendizaje profundo (Deep Learning), ofrece herramientas potentes para modelar relaciones no lineales y dependencias temporales en los datos del mercado. Estas técnicas permiten construir modelos predictivos capaces de estimar, con alta precisión, los precios horarios o diarios de la energía, lo cual es fundamental para la toma de decisiones de generadores, comercializadores, operadores del sistema y consumidores finales.

En una etapa preliminar, se considera oportuno realizar la evaluación de más de un método de IA para el caso de estudio, de esta manera validar que la herramienta seleccionada será la que brinde mejores resultados de aprendizaje, más adelante en este capítulo se revisará la comparación de resultados de ML y aprendizaje profundo.

Entre los modelos más utilizados en la predicción de precios eléctricos se encuentran:

- Árboles de decisión y bosques aleatorios (Random Forests): útiles para segmentar escenarios según variables relevantes y generar reglas interpretables.
- Máquinas de soporte vectorial (SVM): eficaces en clasificación y regresión de patrones no lineales.
- Redes neuronales artificiales (ANN): adecuadas para series temporales y predicción de precios con complejidad moderada.
- Redes neuronales recurrentes (RNN), especialmente LSTM (Long Short-Term Memory): diseñadas para modelar dependencias de largo plazo en datos secuenciales.

Estos modelos se alimentan de conjuntos de datos históricos como:

- Series de precios spot y futuros.
- Datos de carga eléctrica.
- Disponibilidad de generación y mantenimientos programados.
- Topología de red y restricciones de transmisión

Su implementación permite a los actores del mercado:

- Optimizar estrategias de operación y comercialización.
- Predicción de precios de energía.
- Mejorar la planificación de recursos energéticos

En mercados como el MER, donde la interacción entre restricciones de red y condiciones económicas incide directamente en la formación de los precios nodales, la aplicación de técnicas de IA representa una herramienta estratégica y técnicamente justificada para anticipar el comportamiento del mercado. Estos precios, calculados a nivel de nodo dentro del sistema interconectado, reflejan no solo los costos marginales de generación, sino también las pérdidas eléctricas y las restricciones físicas del sistema.

El uso de modelos de ML permite anticipar eventos de congestión, simular escenarios tarifarios y optimizar decisiones operativas, utilizando exclusivamente datos históricos del MER, como precios nodales, flujos de energía entre nodos, y estados operativos de la red. A diferencia de otros enfoques que integran variables meteorológicas, este estudio se enfoca en información económica y estructural, asegurando su aplicabilidad en contextos donde los datos ambientales no están disponibles o son irrelevantes.

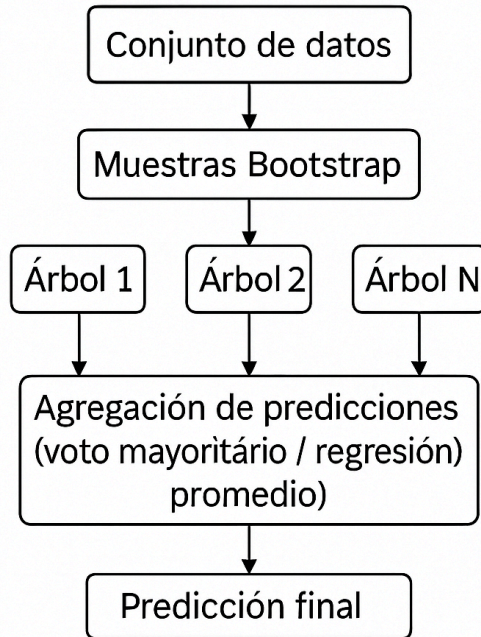
En este trabajo, se propone el uso de árboles de decisión, técnica supervisada conocida por su capacidad para modelar relaciones no lineales, su baja complejidad computacional y su interpretabilidad. Se pretende usar esta técnica en los modelos vistos en el capítulo anterior y el sistema del MER para predecir los precios ex ante y energía transada y en el mercado nacional salvadoreño para obtener el costo marginal operativo.

Estudios previos han demostrado la eficacia de los modelos de IA en mercados eléctricos. Por ejemplo, Vega Muñoz (2024) aplicó redes neuronales en el mercado eléctrico español y concluyó que los métodos basados en IA superan a los enfoques estadísticos clásicos, al capturar mejor la volatilidad y la dependencia histórica de los precios spot[21]. Esta evidencia respalda la adecuación técnica y metodológica del uso de árboles de decisión en el contexto del MER, como herramienta predictiva del comportamiento nodal.

4.2 Modelos de IA en la predicción de los Mercados Energéticos

En el marco de esta tesis, se adopta el modelo “Random Forest” debido a su robustez, facilidad de implementación, bajo costo computacional y alto rendimiento demostrado en aplicaciones energéticas recientes[7].

Este algoritmo funciona con árboles de decisión que se entrenan con diferentes subconjuntos de muestras de datos, la cantidad de árboles a utilizar ayuda a mejorar la precisión y la robustez de los modelos individuales. Es decir que se entrenan múltiples árboles de forma individual y luego se agregan los resultados de cada uno para calcular el promedio de las predicciones.



Fuente: Elaboración propia.

Fig. 18. Diagrama de flujo de como funciona Random Forest.

Diversos estudios respaldan el uso de modelos de IA en los mercados eléctricos, destacando la eficacia de Random Forest (RF) en entornos complejos y con alta variabilidad operativa. Mei et al. desarrollaron un enfoque en línea basado en RF para el mercado de Nueva York, incorporando actualización dinámica y estimación probabilística de precios, lo cual mejoró significativamente la precisión del pronóstico bajo condiciones cambiantes [7]. Leal et al. Aplicaron técnicas de IA en el Mercado Ibérico de Electricidad (MIBEL) para proyectar precios en escenarios de alta penetración renovable, demostrando su utilidad en la planificación energética de largo plazo[22]. Asimismo, Magalhães et al. propusieron una versión optimizada de RF para pronóstico de carga a corto plazo, integrando selección de variables y ajuste de hiper parámetros para mejorar la precisión en sistemas eléctricos distribuidos[23]. Estas investigaciones, entre muchas otras, respaldan el enfoque adoptado en este estudio, que plantea el uso de “Random Forest” como herramienta predictiva para evaluar el impacto de una eventual pérdida de interconexión entre Guatemala y El Salvador. En este contexto, se busca predecir cómo dicho evento afectaría los precios de la energía en nuestro país.

4.3 Implementación de un Modelo de IA para Reproducir los Resultados del Modelo Simplificado de Despacho Regional

Con el objetivo de validar el método de predicción seleccionado, se realiza una evaluación preliminar del algoritmo en el modelo de despacho simplificado demostrado en el punto 3.3. Lo que se espera obtener es la validación de que el modelo logra capturar de manera adecuada las relaciones entre las entradas y salidas de los datos del despacho.

Pero antes, es importante comprender cómo funciona este modelo de predicción con las herramientas disponibles en python, para esto se plantea un ejercicio sencillo de aplicación de Random Forest:

Primero, se descarga la librería a utilizar, en este caso la que contiene distintos algoritmos de machine learning, el de nuestro interés es RandomForestRegressor.

```
from sklearn.ensemble import RandomForestRegressor
```

Ahora, se crea el modelo definiendo sus hiper parámetros, donde `n_estimators` es la cantidad de árboles de decisión y `random_state` es la semilla a fijar para que siempre se obtengan los mismos árboles.

```
#Crear el modelo
rf = RandomForestRegressor(n_estimators=100, random_state=42)
```

Luego, se ingresan los datos y se entrena el modelo para que aprenda a relacionar las entradas y las salidas.

```
# Entrenar (fit) con datos de ejemplo
# X: lista de valores de la variable independiente
# y: lista de valores que queremos predecir
X = [[1], [2], [3], [4]]      # p. ej. entradas
y = [2, 4, 6, 8]             # p. ej. salidas = 2 · x

rf.fit(X, y)
```

Por último, se realiza la predicción de nuevos datos con distintas entradas.

```
# 3. Predecir (predict) para nuevos datos
nuevos = [[5], [6]]
preds = rf.predict(nuevos)

print(preds) # → [10. 12.]
```

En definitiva, un entendimiento profundo del modelo permite aplicarlo de forma versátil a distintos casos de estudio, ajustar y optimizar sus hiper parámetros, adaptar el número y tipo de variables de entrada y salida, y personalizar su configuración para obtener siempre el mejor desempeño según las necesidades específicas.

4.3.1 Evaluación de modelo base de validación (3 nodos)

El replicar con “Machine Learning” los resultados brindados por un modelo de optimización que se aplique a despachos eléctricos puede ayudar a visualizar distintas correlaciones de variables, a simplificar la evaluación de cambios de resultados ante distintas entradas sin la necesidad de modelar detalladamente el origen de estos cambios. Si bien, busca ser un apoyo para prevenir situaciones de cambios no contemplados o señalar ciertos puntos que podrían reforzarse en el modelo de optimización, puede utilizarse como una herramienta de apoyo mas no como única fuente de evaluación.

Para evaluar los distintos métodos de Machine Learning que se pueden aplicar en modelos de despachos de energía se deben considerar las diferencias en cada uno y así poder elegir el que mejor funcione para el caso específico que se presenta.

La ruta de pruebas que se aplicaron en esta investigación fue delimitar al menos dos algoritmos de ML que han sido utilizados en otros casos de estudio y que tengan cierto nivel de similitud en cuanto a las variables a predecir y a partir de los resultados obtenidos tomar la decisión de cuál se adecua mejor.

En las pruebas realizadas se consideraron los algoritmos de redes neuronales y de random forest; el primero es considerado de aprendizaje profundo y el segundo es un conjunto de árboles de decisión.

Para la evaluación de ambos se tomó un caso simplificado de un despacho eléctrico de 3 nodos, en el cual se contaba con 50 escenarios donde se conocían sus entradas y salidas, ambos modelos se entrenaron con una relación del 80% de datos para entrenar y un 20% para las pruebas de predicción y así evaluar cual predecía mejor las salidas de todas las variables consideradas. Ambos modelos funcionaron en rangos aceptables para la mayoría de las variables.

Se realizó una segunda evaluación, esta vez considerando 200 escenarios para observar si a mayor exposición de casos los errores en la predicción disminuían en alguno de los modelos. En este proceso se observó un comportamiento particular en el modelo de red neuronal al predecir las variables de precios: debido a la baja variabilidad presente en las salidas durante el entrenamiento, la red neuronal tendía a fijar un único valor constante para todos los escenarios predichos.

Este fenómeno, conocido como colapso a la media, puede ocurrir cuando el modelo no logra captar adecuadamente la relación no lineal entre las variables de entrada y salida. Aunque esta estrategia reducía el error promedio (por ejemplo, el MAE), evidenciaba una

falta de sensibilidad ante cambios en las entradas, limitando su utilidad práctica para escenarios en los que se espera que los precios respondan de forma dinámica a variaciones en el despacho o en otras condiciones del sistema.

En cambio, el modelo de “Random Forest” mostró mejores resultados en su capacidad de aprendizaje disminuyendo su error absoluto entre más datos conocía del despacho, sin caer en mantener la predicción de una variable en un valor fijo, lo cual indicaba que preservaba la sensibilidad a las entradas.

El código en Python para la elaboración del modelo de Random Forest se puede explicar por etapas:

- Como etapa inicial se importan todas las librerías necesarias para el código, se puede resaltar pandas para el manejo de datos, randomforestregressor para crear el modelo, train_test_split para dividir los datos en entrenamiento y validación.

```
import pandas as pd
import numpy as np
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split,
RandomizedSearchCV
from sklearn.metrics import mean_squared_error,
mean_absolute_error
import joblib
```

- Cargar los datos a utilizar y definir las variables como entradas y salidas para el modelo, hacer una limpieza y estructuración de la base de ser necesario.

```
# 1. Cargar datos de Excel (encabezados en fila 2 -> header=1)
ruta = r"C:\Users\kpcampos\Desktop\Pruebas\Escenarios PYPISA -
MER.xlsx"
df_ent = pd.read_excel(ruta, sheet_name="Entradas-3nodos",
header=1)
df_sal = pd.read_excel(ruta, sheet_name="Resultados-3nodos",
header=1)
# Unir por 'Escenario'
df = pd.merge(df_ent, df_sal, on="Escenario", how="inner")

# 2. Definir columnas de entrada y salida
X_cols = [
    "Load 1 (MW)", "Load 2 (MW)", "Load 3 (MW)",
    "Gen A p_nom (MW)", "Coste A ($/MWh)",
    "Gen B p_nom (MW)", "Coste B ($/MWh)",
    "Gen C p_nom (MW)", "Coste C ($/MWh)",
    "Gen D p_nom (MW)", "Coste D ($/MWh)"
]
```

```

y_cols = [
    "Despacho Gen A (MW)", "Despacho Gen B (MW)", "Despacho Gen C
(MW)", "Despacho Gen D (MW)",
    "Carga servida 1 (MW)", "Carga servida 2 (MW)", "Carga
servida 3 (MW)",
    "Precio Bus 1 ($/MWh)", "Precio Bus 2 ($/MWh)", "Precio Bus 3
($/MWh)",
    "Flujo L1-2 (MW)", "Flujo L1-3 (MW)", "Flujo L2-3 (MW)"
]

# 3. Preprocesamiento: eliminar filas con NA
data = df[[*X_cols, *y_cols, 'Escenario']].dropna()
X = data[X_cols]
y = data[y_cols]
scenarios = data['Escenario']

```

- Separar los datos de entrenamiento y prueba, para este ejemplo donde no existe la variable de tiempo (fecha) asociada a los escenarios, puede hacerse esta división de manera aleatoria.

```

# 4. División entrenamiento/prueba
X_train, X_test, y_train, y_test, sc_train, sc_test =
train_test_split(
    X, y, scenarios, test_size=0.2, random_state=42

```

- Se definen los hiperparámetros, que son el número de árboles a utilizar para entrenar el modelo, la profundidad de ajuste de cada árbol, el número mínimo de nodos en que se divide y cuántas variables se prueban en cada división de nodos.

```

# 5. Definir rango de hiperparámetros para RandomizedSearchCV
param_dist = {
    'n_estimators': [100, 200, 300, 500],
    'max_depth': [None, 10, 20, 30, 40],
    'min_samples_split': [2, 5, 10],
    'min_samples_leaf': [1, 2, 4],
    'max_features': ['auto', 'sqrt', 'log2']
}

```

- Entrenar el modelo sobre los datos seleccionados para este proceso y la validación de predicción sobre los datos de prueba

```

# 6. Configurar RandomizedSearchCV
base_rf = RandomForestRegressor(random_state=42)
search = RandomizedSearchCV(
    estimator=base_rf,
    param_distributions=param_dist,
    n_iter=20,

```

```

        cv=3,
        scoring='neg_mean_squared_error',
        n_jobs=-1,
        random_state=42,
        verbose=1
    )

# 7. Ajustar y obtener el mejor modelo
search.fit(X_train, y_train)
best_rf = search.best_estimator_
print("Mejores hiperparámetros:", search.best_params_)

```

- Por último, se calculan las métricas para conocer el error de predicción por cada variable y se guardan los resultados.

```

# 8. Predicción y evaluación con el modelo optimizado
y_pred = best_rf.predict(X_test)

mse_values = mean_squared_error(y_test, y_pred,
                                multioutput='raw_values')
rmse_values = np.sqrt(mse_values)
mae_values = mean_absolute_error(y_test, y_pred,
                                 multioutput='raw_values')

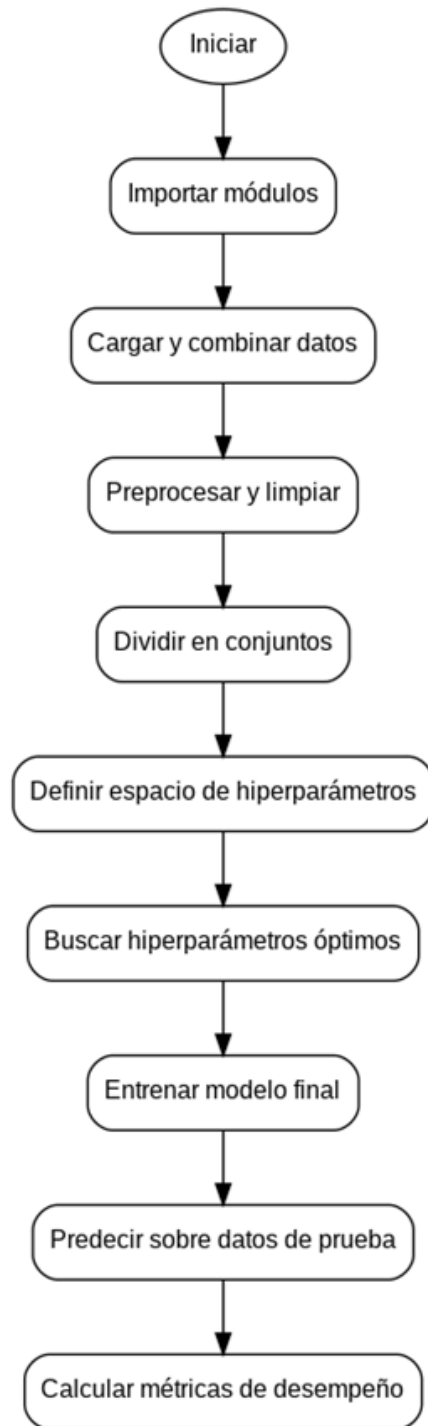
print("\nMétricas tras optimización:")
for col, rmse, mae in zip(y_cols, rmse_values, mae_values):
    print(f" - {col}: RMSE = {rmse:.3f}, MAE = {mae:.3f}")

# 9. Guardar comparativa real vs. predicho en Excel
results_df = pd.DataFrame({'Escenario':
                           sc_test}).reset_index(drop=True)
results_df = pd.concat([
    results_df,
    y_test.reset_index(drop=True),
    pd.DataFrame(y_pred, columns=[f'Pred_{c}' for c in y_cols])
], axis=1)
results_df.to_excel("resultados_comparacion_optimo.xlsx",
                   index=False)
print("Resultados optimizados guardados en
resultados_comparacion_optimo.xlsx")

# 10. Guardar el modelo final
joblib.dump(best_rf, "rf_multisalida_best.pkl")
print("Modelo optimizado guardado en rf_multisalida_best.pkl")

```

Para resumir, la lógica del código sería la descrita en la Fig. 19:



Fuente: Elaboración propia.

Fig. 19. Diagrama de flujo de la secuencia a seguir en los códigos de predicción.

A continuación en la Tabla 7 se presentan los resultados obtenidos para el modelo de Random Forest en cuanto al error de predicción en cada variable para el caso de 50 escenarios.

Tabla 7. Error de predicción modelo 3 nodos 50 escenarios

Predicción 3 nodos		
Variable analizada	Error absoluto medio (MAE)	Error porcentual absoluto medio (MAPE)
Despacho Gen A	59.858 [MWh]	49.84%
Despacho Gen B	49.114 [MWh]	46.19%
Despacho Gen C	58.111 [MWh]	29.72%
Despacho Gen D	62.894 [MWh]	24.11%
Carga servida 1	34.378 [MWh]	44.48%
Carga servida 2	26.408 [MWh]	59.25%
Carga servida 3	25.512 [MWh]	61.54%
Precio Bus 1	4.122 [\$/MWh]	32.98%
Precio Bus 2	4.122 [\$/MWh]	32.98%
Precio Bus 3	4.122 [\$/MWh]	32.98%
Flujo L1-2	31.511 [MW]	41.30%
Flujo L1-3	33.218 [MW]	38.17%
Flujo L2-3	46.051 [MW]	24.31%

Fuente: Elaboración propia.

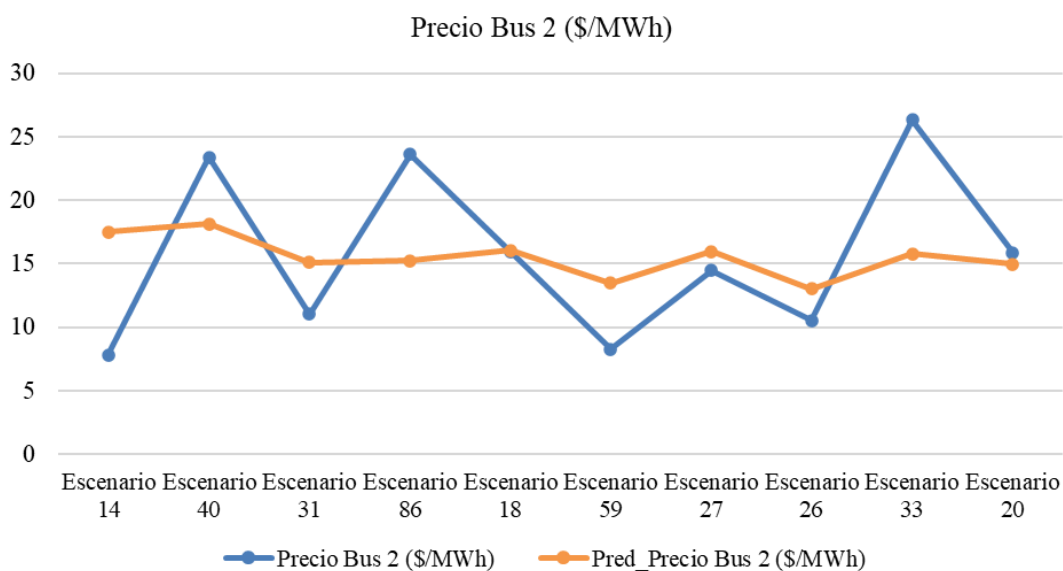
En la Tabla 8 se muestran los errores obtenidos para el mismo modelo de Random Forest pero con 200 escenarios, donde se puede apreciar una disminución considerable del error para la mayoría de variables evaluadas.

Tabla 8. Error de predicción modelo 3 nodos 200 escenarios

Predicción 3 nodos		
Variable analizada	Error absoluto medio (MAE)	Error porcentual absoluto medio (MAPE)
Despacho Gen A	72.079 [MWh]	9.70%
Despacho Gen B	56.163 [MWh]	4.27%
Despacho Gen C	61.616 [MWh]	38.09%
Despacho Gen D	43.424 [MWh]	0.34%
Carga servida 1	31.592 [MWh]	57.75%
Carga servida 2	30.33 [MWh]	33.76%
Carga servida 3	37.468 [MWh]	49.18%
Precio Bus 1	4.834 [\$/MWh]	15.39%
Precio Bus 2	4.834 [\$/MWh]	15.39%
Precio Bus 3	4.834 [\$/MWh]	15.39%
Flujo L1-2	39.931 [MW]	11.86%
Flujo L1-3	24.532 [MW]	6.51%
Flujo L2-3	41.374 [MW]	33.61%


Fuente: Elaboración propia.

En las Fig. 20 y Fig. 21 se puede observar el comportamiento de la predicción vs salida real para una variable de precio y una de despacho en el caso de 200 escenarios:



Fuente: Elaboración propia.

Fig. 20. Comparación de resultados de precios predichos vs salidas reales de modelo de 3 nodos



Fuente: Elaboración propia.

Fig. 21. Comparación de resultados de energía despachada predichos vs salidas reales de modelo de 3 nodos

De los resultados presentados, se puede concluir que a mayor cantidad de entradas se tengan para el modelo, este logra mejorar su nivel de aprendizaje disminuyendo el error obtenido en la predicción.

Los errores de predicción de las variables de precio resultaron homogéneos entre sí, mientras que las demás variables mostraron una mayor dispersión, alcanzando en algunos casos valores elevados. No obstante, pese a esta variabilidad, el modelo demuestra ser suficientemente robusto para los objetivos de esta investigación, ya que ofrece estimaciones que permiten identificar con claridad la tendencia de los valores de salida.

4.3.2 Evaluación de modelo para maximizar los ingresos de transmisión (8 nodos)

Para verificar que el modelo de Random Forest funcionará de manera idónea para un despacho más complejo, se realizó la misma prueba para un sistema de 8 nodos. Se necesitaba que los resultados fueran congruentes con los obtenidos en las pruebas del sistema de 3 nodos, por lo que, se siguió la misma ruta de verificación.

Donde se comprobó que el algoritmo de una red neuronal no lograba adaptarse a la sensibilidad de las entradas disponibles para el sistema, en contraste con el algoritmo de Random Forest, el cual mantenía su capacidad de aprendizaje y lograba mejoras en este al tener mayor número de escenarios disponibles.

La estructura del código es la misma que la descrita en la sección 4.3.1, donde se adecuó las variables de entrada y salida a las de esta nueva base de datos, el código se puede encontrar en el anexo C.

Se presentan los resultados obtenidos para la evaluación con 50 escenarios en la Tabla 9:

Tabla 9. Error de predicción modelo 8 nodos 50 escenarios

Predicción 8 nodos		
Variable analizada	Error absoluto medio (MAE)	Error porcentual absoluto medio (MAPE)
Despacho G1	63.695 [MWh]	23.72%
Despacho G2	71.879 [MWh]	14.29%
Despacho G3	58.517 [MWh]	22.71%
Despacho G4	57.274 [MWh]	17.74%
Despacho G5	64.748 [MWh]	20.12%
Despacho G6	57.678 [MWh]	31.69%
Despacho G7	60.264 [MWh]	31.93%
Despacho G8	55.664 [MWh]	30.91%
Carga servida 1	43.182 [MWh]	21.72%
Carga servida 2	38.579 [MWh]	22.56%
Carga servida 3	39.594 [MWh]	18.62%
Carga servida 4	47.265 [MWh]	22.52%
Carga servida 5	41.737 [MWh]	22.76%
Carga servida 6	41.851 [MWh]	24.87%
Carga servida 7	40.64 [MWh]	13.91%
Carga servida 8	41.996 [MWh]	24.47%
Precio N1	5.48 [\$/MWh]	19.03%
Precio N2	4.665 [\$/MWh]	17.83%
Precio N3	4.776 [\$/MWh]	19.51%
Precio N4	4.802 [\$/MWh]	17.72%
Precio N5	4.368 [\$/MWh]	25.20%
Precio N6	4.658 [\$/MWh]	26.40%
Precio N7	4.642 [\$/MWh]	26.49%
Precio N8	4.968 [\$/MWh]	28.55%
Precio NE1	4.533 [\$/MWh]	20.51%
Precio NE2	4.086 [\$/MWh]	22.85%
Flujo L1_N2	78.01 [MW]	26.95%
Flujo L3_N2	66.33 [MW]	20.21%
Flujo L2_NE1	65.304 [MW]	26.58%
Flujo L4_NE1	69.931 [MW]	19.80%
Flujo L6_N7	57.128 [MW]	33.99%
Flujo L8_N7	55.794 [MW]	34.43%
Flujo L7_NE2	76.738 [MW]	25.48%
Flujo L5_NE2	66.843 [MW]	28.72%
Flujo L_NE1_NE2	63.871 [MW]	30.30%

Fuente: Elaboración propia.


En la Tabla 10 se enlista el error resultante al aplicar el modelo de predicción con 200 entradas:

Tabla 10. Error de predicción modelo 8 nodos 200 escenarios

Predicción 8 nodos		
Variable analizada	Error absoluto medio (MAE)	Error porcentual absoluto medio (MAPE)
Despacho G1	50.153 [MWh]	3.88%
Despacho G2	49.283 [MWh]	17.85%
Despacho G3	39.344 [MWh]	6.62%
Despacho G4	43.552 [MWh]	8.17%
Despacho G5	60.012 [MWh]	33.31%
Despacho G6	50.63 [MWh]	12.40%
Despacho G7	34.75 [MWh]	4.24%
Despacho G8	47.855 [MWh]	53.08%
Carga servida 1	33.204 [MWh]	5.43%
Carga servida 2	23.488 [MWh]	11.94%
Carga servida 3	46.334 [MWh]	49.48%
Carga servida 4	22.027 [MWh]	11.26%
Carga servida 5	28.848 [MWh]	11.57%
Carga servida 6	25.893 [MWh]	79.80%
Carga servida 7	27.325 [MWh]	5.38%
Carga servida 8	38.459 [MWh]	4.56%
Precio N1	2.258 [\$/MWh]	10.99%
Precio N2	2.258 [\$/MWh]	10.99%
Precio N3	2.123 [\$/MWh]	5.89%
Precio N4	1.902 [\$/MWh]	0.76%
Precio N5	1.489 [\$/MWh]	13.19%
Precio N6	1.458 [\$/MWh]	16.23%
Precio N7	1.458 [\$/MWh]	16.23%
Precio N8	1.492 [\$/MWh]	12.47%
Precio NE1	1.879 [\$/MWh]	0.96%
Precio NE2	1.489 [\$/MWh]	13.19%
Flujo L1_N2	31.466 [MW]	2.27%
Flujo L3_N2	69.086 [MW]	1.46%
Flujo L2_NE1	93.776 [MW]	11.03%
Flujo L4_NE1	41.084 [MW]	22.84%
Flujo L6_N7	57.795 [MW]	56.31%
Flujo L8_N7	51.072 [MW]	82.63%
Flujo L7_NE2	65.786 [MW]	8.20%
Flujo L5_NE2	63.427 [MW]	29.25%
Flujo L_NE1_NE2	81.433 [MW]	2.80%

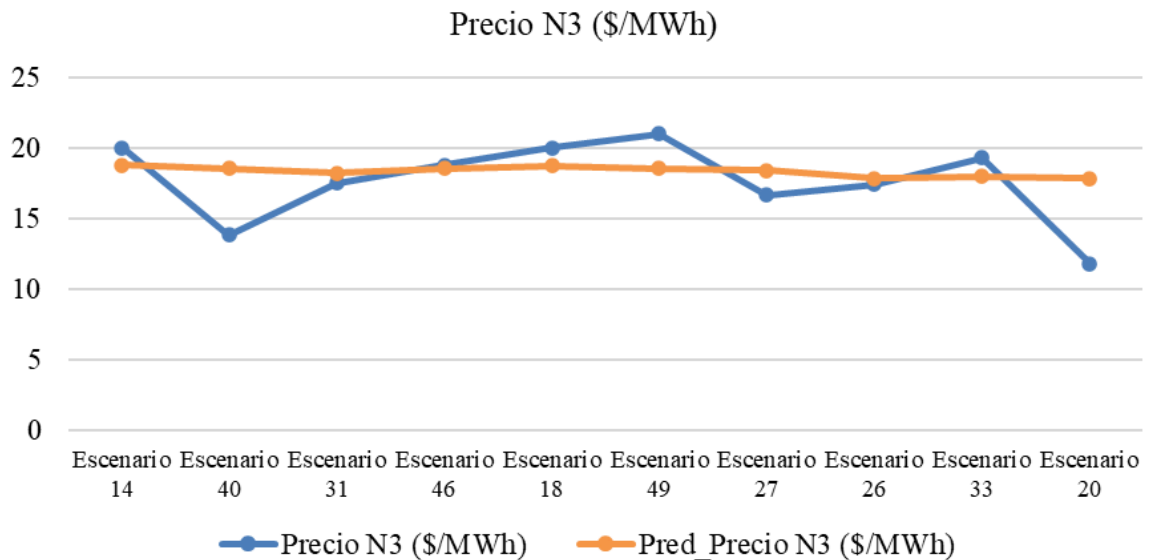
Fuente: Elaboración propia.

En la Fig. 22 y Fig. 23 se presentan ejemplos de comportamiento de las variables reales y las predichas por el modelo implementado para el caso de un sistema de 8 nodos:



Fuente: Elaboración propia.

Fig. 22. Comparación de resultados de energía despachada predicha vs salidas reales de modelo de 8 nodos



Fuente: Elaboración propia.

Fig. 23. Comparación de resultados de precios predichos vs salidas reales de modelo de 8 nodos

A partir de los resultados obtenidos, se concluye que el modelo de Random Forest representa una herramienta adecuada para la predicción de precios en un sistema eléctrico, ya que logra capturar de forma efectiva la relación entre las variables de entrada y salida.

Los valores predichos permiten aproximarse al comportamiento general del modelo de optimización utilizado en el sistema, proporcionando una visión útil para el análisis operativo y la toma de decisiones.

CAPÍTULO 5

MODELO IA PARA EVALUAR LA SUSPENSIÓN DE TRANSACCIONES ENERGÉTICAS ENTRE GUATEMALA Y EL SALVADOR

5.1 Entrenamiento y Validación del Modelo de IA

Tomando los resultados del capítulo 4, se establece el método de ML en el algoritmo de Random Forest como modelo de predicción para los sistemas de despacho de energía presentados en este estudio. Se realizarán dos vías de análisis: una en el mercado regional y otra en el mercado nacional; como se plantea en el punto 2.4, la influencia de los cambios ante la suspensión de transacciones de Guatemala debe evaluarse en estos dos niveles para trasladar las afectaciones que se percibirían a El Salvador.

5.1.1 Modelo de Machine Learning para el MER

Con el objetivo de entrenar un modelo predictivo del comportamiento de los precios nodales en el MER, se descargaron los reportes oficiales de predespacho publicados por el EOR, específicamente los archivos identificados como PUB004-PRE, que contienen las hojas TOP (Transacciones de Oportunidad Programadas) y TCP (Transacciones de Contratos Regionales). El periodo analizado abarca desde enero de 2024 hasta mayo de 2025, con datos horarios correspondientes a los seis países que conforman el sistema regional: Guatemala, El Salvador, Honduras, Nicaragua, Costa Rica y Panamá.

A partir de esta base de datos oficial, se procesaron y organizaron los campos necesarios para construir dos tablas de trabajo que servirán como insumo para el modelo de predicción. Entre los campos extraídas se encuentran: los megavatios declarados por bloque para cada país, las capacidades tanto de los contratos firmes, como la de los contratos no firmes físico-flexibles, los precios promedio ponderados por bloque, la energía total predespachada por país y el precio ex-ante correspondiente a cada hora.

Estos campos fueron estructurados para cada tabla siguiendo tres criterios fundamentales: país, tipo de transacción (inyección o retiro) y bloque horario. Con esta lógica se crearon dos conjuntos diferenciados de tablas. El primero contiene la operación histórica completa del MER, y fue utilizado para entrenar y validar el modelo predictivo dividiendo los datos en secciones independientes. El segundo conjunto replica la estructura del primero, pero con los datos correspondientes a Guatemala igualados a cero, con el fin de simular un escenario hipotético de desconexión total de este país del mercado regional. Este segundo conjunto sirvió como insumo para proyectar, mediante el modelo ya entrenado, los efectos de dicha desconexión, con énfasis específico en su impacto sobre El Salvador.

Dado que las tablas empleadas para este estudio contienen un número elevado de columnas, cada una identificada por una secuencia codificada que combina país, tipo de transacción, tipo de oferta o contrato y tipo de variable, se elaboró la Tabla 11 que actúa como guía de referencia para comprender su estructura. Esta tabla permite interpretar la organización lógica de las columnas, agrupándolas por segmento funcional: fecha, tipo de transacción, tipo de oferta o contrato, tipo de variable (energética o económica), así como sus unidades

y propósito dentro del modelo. A su vez, se construyó la Tabla 12 que estandariza las abreviaciones utilizadas en los nombres de las columnas, asignando un significado explícito a cada prefijo o código. Esta segunda tabla facilita la lectura técnica y la replicabilidad del proceso analítico.

Tabla 11. Estructura general de las tablas para entrenamiento del modelo predictivo.

Segmento de columna	Ejemplo de nombre	Unidad	Descripción
Fecha y periodo	fecha, periodo	—	Identificadores temporales. La fecha corresponde al día de operación y el periodo al bloque horario.
Tipo de transacción	i, r	MW	Indica si se trata de inyección (i) o retiro (r).
Modalidad de oferta	Opo, CFOi, CFrR, CNFi, CNFr, OiF, OrF	MW	Tipo de contrato o condición de participación de la energía: oportunidad, firme, no firme, flexibilidad, etc.
Variable energética	MDec, MPred	MW	Energía declarada (MDec) o predespachada (MPred) por país, tipo y modalidad.
Variable económica	Pprom, PEx	\$/MWh	Precio promedio ponderado (Pprom) o precio ex-ante (PEX) por país, tipo y modalidad.

Fuente: Elaboración propia.

Tabla 12. Abreviaciones empleadas en los nombres de columna

Abreviación	Significado
01	Guatemala (código de país)
02	El Salvador (código de país)
03	Honduras (código de país)
04	Nicaragua (código de país)
05	Costa Rica (código de país)
06	Panamá (código de país)
i	Inyección
r	Retiro
Opo	Oportunidad
CFOi	Contrato Firme Oportunidad de Inyección Flexibilidad
CFrR	Contrato Firme Retiro Requerido
CNFi	Contra No Firme Físico Flexible Inyección
CNFr	Contra No Firme Físico Flexible Retiro
OiF	Oportunidad de Inyección Flexibilidad
OrF	Oportunidad de Retiro Flexibilidad
MDec	MW Declarados
Pprom	Precio promedio por bloque
MPred	MW Predespachados
PEX	Precio Ex-ante

Fuente: Elaboración propia.

Al contar con la base de datos, se delimitó qué variables serían consideradas como las salidas a predecir, que para este caso fueron los MPred y los PEx de todos los países. El total de datos se dividió en dos partes: una para entrenar el modelo y la otra para validar la predicción. Se optó por tomar un año completo para entrenar el modelo ya que se abarcan las distintas estacionalidades y factores externos cíclicos que influyen en el comportamiento del mercado; y los datos del 2025 fueron los utilizados para la validación de la predicción.

El código en python para este modelo de predicción cuenta con una estructura muy similar a la mencionada en el apartado 4.3.1, solo que con mayor complejidad dado la cantidad de entradas y salidas. La mayor diferencia a resaltar es que acá la separación de datos si dependían de una condicionante temporal, por lo que, el *train_test_split* no fue utilizado.

```
# Split temporal: 2024 → train, 2025 → test
mask_train = df["fecha"].dt.year == 2024
mask_test  = df["fecha"].dt.year == 2025
```

Adicionalmente, se implementa una retroalimentación en las entradas, donde pueden conocer el comportamiento que tuvo 24 horas antes y 168 antes, lo que le permite mejorar su aprendizaje al saber la tendencia en esa hora cada día y cada semana. El código completo de este modelo puede revisarse en el Anexo D.

```
# Ingeniería de lags (solo 24h y 168h) y rolling (3h, 24h)
lags      = [1, 24, 168]
windows  = [3, 24]

for col in target_cols:
    for lag in lags:
        df[f"{col}_lag{lag}"] = df[col].shift(lag)
    for w in windows:
        df[f"{col}_roll{w}"] = df[col].rolling(w).mean().shift(1)

# Eliminar filas con NaN creadas por los lags/rolling
df.dropna(inplace=True)
```

Se realiza la predicción dando prioridad a los resultados de predicción para las variables de El Salvador, ya que si bien es un solo modelo de predicción siempre se observa el comportamiento de mejor aprendizaje para variables particulares, obteniendo los resultados predichos con un error descrito en la Tabla 13.

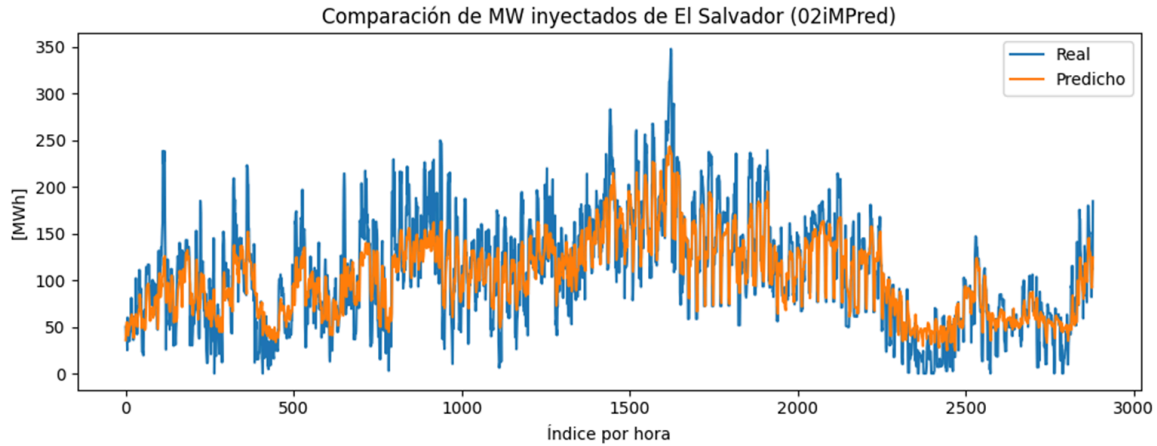
Tabla 13. Error de predicción modelo variables de El Salvador

Predicción MER		
variable	Error absoluto medio (MAE)	Error porcentual absoluto medio (MAPE)
01iMPred	18.485 [MWh]	13.29%
01rMPred	25.15 [MWh]	39.06%
01PEx	8.394 [\$/MWh]	8.42%
02iMPred	21.674 [MWh]	21.25%
02rMPred	29.736 [MWh]	25.33%
02PEx	5.332 [\$/MWh]	5.29%
03iMPred	0.645 [MWh]	165.66%
03rMPred	23.747 [MWh]	57.81%
03PEx	9.662 [\$/MWh]	9.38%
04iMPred	0.32 [MWh]	0.00%
04rMPred	11.544 [MWh]	9.67%
04PEx	13.197 [\$/MWh]	12.71%
05iMPred	34.419 [MWh]	46.05%
05rMPred	13.41 [MWh]	35.32%
05PEx	12.329 [\$/MWh]	12.01%
06iMPred	28.039 [MWh]	35.05%
06rMPred	8.997 [MWh]	69.21%
06PEx	13.363 [\$/MWh]	13.76%

Fuente: Elaboración propia.

Para visualizar mejor el comportamiento de las variables de mayor interés para el presente estudio, se grafican los resultados de las predicciones para El Salvador vs los resultados reales que se tienen de la base de datos.


Para el caso de las inyecciones por parte de El Salvador al Mercado Regional se puede observar en la Fig. 24, que si bien el porcentaje de error en los datos no alcanza niveles tan bajos, el modelo captura con precisión la dinámica de las inyecciones, reproduciendo fielmente sus fases de aumento y disminución.



Fuente: Elaboración propia.

Fig. 24. Comparación de energía inyectada por El Salvador vs la energía inyectada predicha con el modelo entrenado

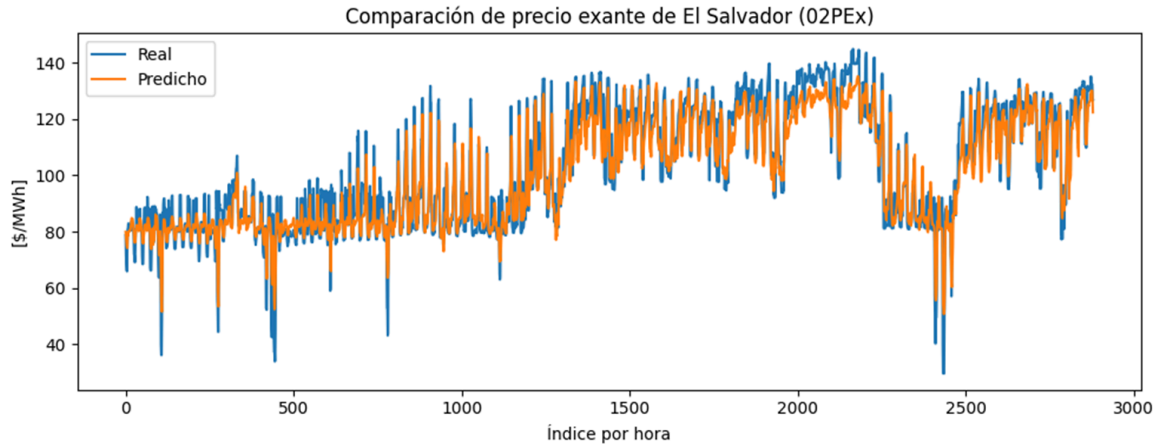
En el caso de la energía retirada mostrada en la Fig. 25 los valores resultantes del modelo de predicción mantienen la misma tendencia con valores más lineales, lo que provoca que al inicio del año donde en la realidad se retiró mayor cantidad de energía se perciba un distanciamiento en los datos.



Fuente: Elaboración propia.

Fig. 25. Comparación de energía retirada por El Salvador vs la energía retirada predicha con el modelo entrenado

El precio ex ante es la variable con mejor aprendizaje por el modelo, lo que permite que en la Fig. 26 se muestren resultados significativamente similares de valores predichos con los valores reales.



Fuente: Elaboración propia.

Fig. 26. Comparación de precio exante promedio para El Salvador vs el precio exante predicho en el modelo entrenado.

Con los resultados obtenidos de este modelo, se puede concluir que el algoritmo logra mantener la mejor predicción para las variables que representan los precios de la energía. La cantidad de datos de esta base del mercado regional es muy superior a las utilizadas en la evaluación preliminar del capítulo 4, por lo que, el incremento de error para algunas variables predichas puede verse afectado más en aquellas variables donde el comportamiento es más volátil. Sin embargo, para los objetivos de este estudio, se priorizan los resultados obtenidos para las variables relacionadas directamente a El Salvador, donde aún con el porcentaje de error que presentan, permiten brindar una idea clara de la tendencia de los resultados.

5.1.2 Modelo de Machine Learning para el mercado nacional de El Salvador

Para lograr trasladar las afectaciones del MER a El Salvador, se aplicó la misma metodología para los predespachos publicados por la UT donde se presentan los informes diarios de cómo opera el mercado salvadoreño, considerando las variables nacionales como los generadores disponibles, la demanda nacional, los costos de operación e incluyendo los resultados de las transacciones regionales para las dos interconexiones correspondientes al país con Honduras y Guatemala.

De estos reportes se extrajeron las variables de mayor influencia en el predespacho para la determinación del Costo Marginal Operativo, tales como la energía inyectada por recurso, el costo de cada recurso utilizado, en los cuales se optó por utilizar el promedio por recurso para simplificar los datos, y las transacciones regionales.

A partir de la creación de la base de datos con la estructura adecuada para entrenar el modelo de predicción, los datos de validación se dividirán en dos, inicialmente se verifica que el modelo aprendió a predecir el CMO resultante por hora en base al comportamiento

de las entradas y luego la predicción del CMO a partir de una base de datos donde las variables de transacciones regionales para El Salvador sean los resultados de la energía transada sin Guatemala obtenidos del modelo explicado en el punto 5.1.1.

El código utilizado para entrenar este modelo sigue la estructura descrita en el apartado 4.3.1. Aunque en este caso la predicción se limita a una única salida, la secuencia del procedimiento es la misma y puede consultarse en el Anexo E.


La estructura de la base de datos utilizada se presenta en la Tabla 14:

Tabla 14. Base de datos para entrenar modelo

Variable	Unidad	Descripción
Demanda nacional	[MWh]	Demanda nacional sin considerar efectos de transacciones regionales
Intercambios Guatemala	[MWh]	Intercambios netos (inyección y retiro) con Guatemala
Intercambios Honduras	[MWh]	Intercambios netos (inyección y retiro) con Honduras
Generación hidro inyectada	[MWh]	Suma de energía inyectada de generadores hidroeléctricos
Generación GRNC inyectada	[MWh]	Suma de energía inyectada de generadores renovables
Generación geotérmica inyectada	[MWh]	Suma de energía inyectada de generadores geotérmicos
Generación biomasa inyectada	[MWh]	Suma de energía inyectada de generadores con biomasa
Generación termica inyectada	[MWh]	Suma de energía inyectada de generadores térmica
CMO [\$/MWh]	[\$/MWh]	Costo Marginal de Operación
precio hidro	[\$/MWh]	Precio promedio de los generadores hidroeléctricos despachados
Precio termico	[\$/MWh]	Precio promedio de los generadores térmicos despachados
Precio biomasa	[\$/MWh]	Precio promedio de los generadores de biomasa despachados
precio geotermico	[\$/MWh]	Precio promedio de los generadores geotérmicos despachados
precio GRNC	[\$/MWh]	Precio promedio de los generadores renovables despachados

Fuente: Elaboración propia.

La Fig. 27, presenta el comportamiento del CMO estimado mediante Random Forest, modelo entrenado con los datos de 2024, durante los meses de enero a mayo de 2025.



Fuente: Elaboración propia.

Fig. 27. Comparación de CMO real vs CMO predicho con el modelo entrenado

En este modelo de predicción con Random Forest, los resultados obtenidos presentan un error absoluto medio de 7.11 \$/MWh el cual representa un 7.18% de error para la totalidad de los datos. Donde se confirma que el algoritmo seleccionado funciona de manera satisfactoria para la predicción de precios, siempre que se cuente con las entradas necesarias para permitir el aprendizaje de comportamiento.

El caso del mercado nacional se establece como un modelo más sencillo de predicción por ser de una única salida a predecir, lo que se contrasta con los modelos evaluados en el capítulo 4 y el punto 5.1.1, pero el algoritmo seleccionado cuenta con la flexibilidad de funcionar de manera adecuada para ambos casos.

5.2 Evaluación de Resultados del Modelo ante la salida de Guatemala del MER


Utilizando el modelo entrenado y validado en el punto 5.1 para los casos del mercado regional y nacional, se realiza el ejercicio de cargar los resultados con los datos de Guatemala nulos, para evaluar el cambio percibido en el comportamiento del resto de variables, con principal enfoque en aquellas que afectan directamente a El Salvador.

5.2.1 Resultados de modelo para el MER

Al tener los modelos de Random Forest entrenados y validados, se realizó la simulación con la base de datos que deja los valores de las transacciones de Guatemala en cero, para simular su no participación en el MER.

El código utilizado para la predicción puede revisarse en el anexo F llama a los archivos de salidas del modelo ya entrenado, como una continuación del anexo D donde se realizó el entrenamiento.


En la Fig. 28 se presentan los datos de inyección que percibiría El Salvador para el caso de que en el MER solo participan 5 países, donde se puede observar que los datos predichos tienden a ser menores a los datos reales debido a la menor disponibilidad de energía para transar.



Fuente: Elaboración propia.

Fig. 28. Comparación de energía inyectada por El Salvador vs la energía inyectada predicha ante la salida de Guatemala


De igual manera, para las transacciones de retiro de El Salvador la tendencia de comercializar menores cantidades de energía en el mercado se muestra en la Fig. 29:



Fuente: Elaboración propia.

Fig. 29. Comparación de energía retirada por El Salvador vs la energía retirada predicha ante la salida de Guatemala

En el caso del precio ex ante se puede observar en la Fig. 30, una disminución en la mayoría de los valores esto se puede relacionar con la disminución de la energía transada que se percibe en el MER.



Fuente: Elaboración propia.

Fig. 30. Comparación de precio ex ante promedio para El Salvador vs el precio ex ante predicho ante la salida de Guatemala

Los resultados de la simulación de un escenario de aislamiento de Guatemala en el MER muestran que las tendencias de El Salvador se mantienen alineadas con las observadas en la realidad, aunque con menor magnitud. En el mercado vigente, El Salvador actúa como un comercializador muy activo, principalmente comprando energía a Guatemala y luego inyectándola a Honduras, por lo que, si se elimina el aporte guatemalteco, resulta lógico que tanto la energía retirada como la inyectada experimenten una caída notable. Cuantificando los intercambios netos para El Salvador, se percibiría un 33.77% menos de energía transada, esto únicamente desde la perspectiva nacional.


5.2.2 Resultados del modelo para el mercado nacional

Para la evaluación de resultados en el mercado nacional ante la ausencia de participación de Guatemala, se trasladaron los resultados de transacciones del modelo del MER sin Guatemala para El Salvador, donde la energía neta transada se considera únicamente como entrada de los intercambios con Honduras.

Al hacer esta modificación puede llegar a existir demanda no suplida por importaciones que será reemplazada con mayor probabilidad por energía térmica, lo que podría implicar un aumento en el generador que margine el costo de la energía por hora. Esto se vería reflejado en un aumento del comportamiento del CMO para El Salvador.

En el anexo G se encuentra el código para la validación de este escenario, donde se llama al modelo ya entrenado resultante del anexo E para hacer la predicción de estos nuevos datos.

En la Fig. 31, se presentan los resultados de esta simulación, donde se percibe un aumento en los valores predichos del CMO.



Fuente: Elaboración propia.

Fig. 31. Comparación de CMO real vs CMO predicho ante la salida de Guatemala.

Como resultado de este ejercicio de simulación se pueden tener nociones de las afectaciones percibidas para El Salvador ante esta disminución de energía disponible en el MER. Si bien, el suplir la demanda nacional no depende únicamente de la importación que entre al país, sin embargo, sí llega a influir en la determinación del costo marginal operativo, ya que en lugar de encender un generador de un costo mayor, cierta parte de la demanda se abastece con importaciones, así que de los cambios notorios que podrían percibirse sería el incremento del CMO.

De igual manera, se tendrían consecuencias económicas en otros ámbitos, como la disminución de comercialización de energía por parte de los participantes de mercado o comercializaciones con menor margen de ganancia, dado que también se presentaría una disminución en las exportaciones a través de Honduras. Este tipo de cambios no se percibirían directamente por el mercado nacional, sin embargo si dificultará el crecimiento de los participantes ya establecidos o la incorporación de nuevos participantes.

Los resultados permiten concluir que se percibiría una tendencia en el incremento de los costos de la energía para el mercado salvadoreño, en esta simulación se obtiene un incremento de 10.33 \$/MWh en promedio a lo largo de los meses estudiados, mostrando la influencia de las transacciones de Guatemala en El Salvador.

CAPÍTULO 6

CONCLUSIONES Y RECOMENDACIONES

6.1 Conclusiones

- El análisis del sistema de despacho y las transacciones regionales del MER demuestra que este mecanismo ha sido fundamental para optimizar el uso de los recursos energéticos en Centroamérica, permitiendo una operación más eficiente, integrada y competitiva, como lo reflejan las Fig. 9, 10 y 11, que evidencian el crecimiento sostenido de las transacciones regionales de energía y la consolidación operativa del mercado en distintos contextos técnicos y económicos, reafirmando el aporte estructural del MER a la eficiencia del sistema eléctrico regional. La implementación del esquema de precios nodales, basado en modelos de optimización con restricciones físicas, ha permitido reflejar de manera precisa las condiciones operativas del sistema, facilitando un despacho técnicamente viable y una asignación eficiente de la generación. Asimismo, la evolución histórica del mercado evidencia su capacidad para adaptarse a contextos operativos complejos, resaltando el rol estratégico de Guatemala como principal exportador neto y la reciente transición de El Salvador hacia una mayor autonomía energética. Estos resultados refuerzan la importancia del MER como un sistema eficiente, confiable y con alto grado de flexibilidad operativa en el contexto regional.
- El modelo simplificado de optimización desarrollado en este estudio permitió representar con solidez el comportamiento del despacho eléctrico regional ante distintas configuraciones de red y condiciones de restricción. La simulación de redes de tres y ocho nodos, implementadas en PyPSA, facilitó la observación detallada de los precios nodales y los flujos de potencia, así como la respuesta del sistema ante variaciones en la demanda, la generación y la capacidad de transmisión. La inclusión de un término que optimice la transmisión en la función objetivo aporta flexibilidad al modelo, al incentivar el uso eficiente de la infraestructura de transmisión. Además de cumplir su propósito como herramienta de análisis técnico, el modelo generó datos sintéticos consistentes que sirvieron como insumo para validar métodos de predicción basados en ML, consolidando así una base metodológica útil para estudios posteriores sobre el comportamiento del sistema eléctrico en escenarios de contingencia.
- Se demostró que los modelos de IA pueden predecir los resultados de un sistema de optimización de mercados eléctricos, el algoritmo de Random Forest siendo una clase de ML consiguió un aprendizaje del comportamiento de las salidas, obteniendo errores inferiores al 15% para los precios nodales en los sistemas de 3 y 8 nodos. Por lo que se considera que logra replicar el comportamiento de un despacho energético y mejora sus resultados a medida conoce más escenarios.
- En la evaluación del modelo de predicción aplicado al MER, las variables de energía transada mostraron errores absolutos relativamente altos; sin embargo, en

las variables vinculadas específicamente con El Salvador, los errores se mantuvieron en niveles moderados, con valores cercanos al 25 %, lo que indica que capta con fidelidad la tendencia de los despachos. Por su parte, las variables de precio registraron errores aún menores, siendo inferiores al 14%, lo que permitió una comprensión más precisa de su comportamiento.

- En la evaluación del modelo del mercado nacional, la predicción del CMO presentó un error muy bajo, cercano al 7%. No obstante, al depender una de las variables de entrada de los resultados del modelo previo, esta imprecisión puede trasladarse a las salidas del modelo nacional. A pesar de ello, el análisis indica que, para El Salvador, se proyectaría una menor cantidad de energía transada en el mercado regional, en los intercambios netos, se percibiría una disminución de al menos un 30%, y un incremento promedio por hora de 10.33\$/MWh del CMO en los despachos nacionales.

6.2 Recomendaciones

- Dado que el modelo de optimización demostró ser funcional y replicable en distintas configuraciones de red, se recomienda considerar su aplicación futura en análisis específicos del sistema eléctrico regional real. La estructura desarrollada permite ser escalada e integrada con topologías más complejas o con información operacional detallada, por lo que puede servir como base para estudios de planificación, evaluación de inversiones o análisis de confiabilidad en sistemas interconectados. Además, la generación controlada de escenarios mediante este enfoque puede enriquecer futuras investigaciones que combinen simulación técnica con predicción basada en datos históricos.
- En la evaluación preliminar para la elección del modelo de predicción pueden evaluarse más de dos modelos, en dado caso el tiempo del estudio lo permita. Para poder realizar una comparación más detallada de qué tipo de IA logre adecuarse mejor a las variables que buscan predecirse. También puede considerarse distintas combinaciones de las variables de entrada ya que para algunos algoritmos ofrecen un desempeño superior cuando las variables presentan un grado óptimo de correlación entre sí, mientras que aquellas con baja correlación, que podrían introducir ruido, es preferible descartarlas.
- La evaluación de este estudio está delimitada principalmente a consecuencias en el mercado eléctrico, se recomienda ampliar este análisis para consideraciones de otros ámbitos, como políticos, reglamentarios, económicos más allá del mercado eléctrico. Al igual que buscar mejorar las predicciones para el resto de países implicados en el MER y así poder trasladar las afectaciones a cada uno de ellos.
- En este estudio solo se evaluó la posibilidad de suspensión de transacciones de Guatemala en el MER, sin embargo se puede continuar esta evaluación considerando como posible escenario intercambios de energía entre Guatemala y El Salvador fuera del mercado regional, dado que son países vecinos que ya se

encuentran interconectados; se puede analizar desde distintos enfoques como políticos, económicos y energéticos.

REFERENCIAS

- [1] CRIE, «INFORME MENSUAL DEL MER», ago. 2021.
- [2] D. Kirschen y G. Strbac, *Fundamentals of Power System Economics*, 1.^a ed. Wiley, 2004. doi: 10.1002/0470020598.
- [3] N. Entezari y J. A. Fuinhas, «Quantifying the Impact of Risk on Market Volatility and Price: Evidence from the Wholesale Electricity Market in Portugal», *Sustainability*, vol. 16, n.º 7, Art. n.º 7, ene. 2024, doi: 10.3390/su16072691.
- [4] R. Weron, «Electricity price forecasting: A review of the state-of-the-art with a look into the future», *Int. J. Forecast.*, vol. 30, n.º 4, pp. 1030-1081, oct. 2014, doi: 10.1016/j.ijforecast.2014.08.008.
- [5] S. Albahli, M. Shiraz, y N. Ayub, «Electricity Price Forecasting for Cloud Computing Using an Enhanced Machine Learning Model», *IEEE Access*, vol. 8, pp. 200971-200981, 2020, doi: 10.1109/ACCESS.2020.3035328.
- [6] C. Echevarría, N. Jesurun-Clements, J. Mercado, y C. Trujillo, «CENTRAL AMERICAN ELECTRICITY INTEGRATION», 2017.
- [7] J. Mei, D. He, R. Harley, T. Habetler, y G. Qu, «A random forest method for real-time price forecasting in New York electricity market», en *2014 IEEE PES General Meeting | Conference & Exposition*, National Harbor, MD, USA: IEEE, jul. 2014, pp. 1-5. doi: 10.1109/PESGM.2014.6939932.
- [8] CRIE, «Reglamento del mercado eléctrico regional». 2023.
- [9] EOR, «Informe de evolución del EOR en el marco de la operación técnica y comercial del mercado eléctrico regional (MER)». 2019.
- [10] CRIE, «Evaluación del MER y del estado de competencia», 2023.
- [11] T. Brown, J. Hörsch, y D. Schlachtberger, «PyPSA: Python for Power System Analysis», *J. Open Res. Softw.*, vol. 6, n.º 1, p. 4, ene. 2018, doi: 10.5334/jors.188.
- [12] World Food Programme y Action Against Hunger, «EL NIÑO (2023-2024) Latin America and the Caribbean». 2022.
- [13] «Informe-Final-Experiencias-Comercio-Intenacional_2020».
- [14] A. Belegund y T. Chandrupatla, *Optimization Concepts and Applications in Engineering Second Edition*. New York. [En línea]. Disponible en: https://app-knovel-com.udb.idm.oclc.org/web/view/khtml/show.v/rcid:kpOCAEE00K/cid:kt008MI3G2/viewerType:khtml/root_slug:optimization-concepts/url_slug:front-matter?&b-toc-cid=kpOCAEE00K&b-toc-title=Optimization%20Concepts%20and%20Applications%20in%20Engineering%20%282nd%20Edition%29&b-toc-url-slug=prelimina

ry-concepts&view=collapsed&zoom=1&page=1

- [15] G. Dudek, P. Piotrowski, y D. Baczyński, «Intelligent Forecasting and Optimization in Electrical Power Systems: Advances in Models and Applications», *Energies*, vol. 16, n.º 7, p. 3024, mar. 2023, doi: 10.3390/en16073024.
- [16] «PyPSA-Basics.pdf». Accedido: 21 de marzo de 2025. [En línea]. Disponible en: <https://meridianeconomics.co.za/wp-content/uploads/2024/05/PyPSA-Basics.pdf>
- [17] «Visual Studio Code - Code Editing. Redefined». Accedido: 22 de junio de 2025. [En línea]. Disponible en: <https://code.visualstudio.com/>
- [18] «Download Python», Python.org. Accedido: 22 de junio de 2025. [En línea]. Disponible en: <https://www.python.org/downloads/>
- [19] «Components — PyPSA: Python for Power System Analysis». Accedido: 3 de abril de 2025. [En línea]. Disponible en: <https://pypsa.readthedocs.io/en/latest/user-guide/components.html>
- [20] S. Russell, «Inteligencia artificial».
- [21] N. V. Muñoz, «Previsión del Precio SPOT en el Mercado Eléctrico Español con Redes Neuronales».
- [22] P. Leal, R. Castro, y F. Lopes, «Influence of Increasing Renewable Power Penetration on the Long-Term Iberian Electricity Market Prices», *Energies*, vol. 16, n.º 3, Art. n.º 3, ene. 2023, doi: 10.3390/en16031054.
- [23] B. Magalhães, P. Bento, J. Pombo, M. D. R. Calado, y S. Mariano, «Short-Term Load Forecasting Based on Optimized Random Forest and Optimal Feature Selection», *Energies*, vol. 17, n.º 8, p. 1926, abr. 2024, doi: 10.3390/en17081926.

ANEXO A

Tabla A.1- Datos de entrada para sistema de 3 nodos

Escenario	Load 1 (MW)	Load 2 (MW)	Load 3 (MW)	Gen A p_nom (MW)	Coste A (\$/MWh)	Gen B p_nom (MW)	Coste B (\$/MWh)	Gen C p_nom (MW)	Coste C (\$/MWh)	Gen D p_nom (MW)	Coste D (\$/MWh)
Escenario 1	122	149	72	243	10.72	72	16.47	210	11.68	238	11.38
Escenario 2	199	72	79	54	21.79	112	18.93	65	26.97	73	21.54
Escenario 3	112	191	127	78	20.45	192	26.52	286	24.94	197	29.47
Escenario 4	34	179	24	214	13.95	274	18.38	219	21.46	86	14.36
Escenario 5	126	179	122	215	7.84	202	9.61	157	26.26	53	5.44
Escenario 6	91	87	25	132	21.79	194	12.49	175	26.68	269	11.10
Escenario 7	40	142	128	185	18.01	274	12.75	243	22.71	157	25.77
Escenario 8	122	164	135	289	24.31	288	14.93	104	25.93	175	26.62
Escenario 9	141	57	113	158	18.00	296	15.67	276	22.44	69	24.21
Escenario 10	94	43	66	114	26.30	243	24.99	219	22.00	237	7.83
Escenario 11	107	88	118	135	18.80	255	13.73	83	20.47	201	24.89
Escenario 12	136	135	74	293	19.02	102	16.71	207	23.82	99	27.97
Escenario 13	119	117	187	194	26.92	153	20.62	300	8.97	226	20.02
Escenario 14	123	158	71	120	15.09	153	14.44	296	27.02	228	28.52
Escenario 15	171	163	163	266	8.35	228	25.91	62	26.80	145	25.67
Escenario 16	150	116	32	94	5.72	88	19.69	190	5.73	154	21.67
Escenario 17	169	143	133	181	23.88	228	12.35	67	25.65	213	19.43
Escenario 18	72	89	143	85	20.51	247	22.85	209	8.22	299	13.71
Escenario 19	21	112	125	119	22.60	183	18.19	145	13.38	166	8.98
Escenario 20	107	22	177	208	10.32	116	18.36	276	23.59	147	20.12
Escenario 21	177	167	166	68	8.41	184	17.03	172	9.02	277	12.95
Escenario 22	57	183	164	238	5.36	228	17.43	88	25.45	115	26.66
Escenario 23	149	166	139	157	13.76	249	24.13	95	25.80	128	29.83
Escenario 24	40	109	82	231	19.75	91	7.57	293	17.69	211	23.81
Escenario 25	180	166	38	216	14.81	241	13.36	78	5.16	213	7.26
Escenario 26	77	167	111	140	15.94	293	6.89	239	12.18	55	12.22
Escenario 27	41	115	77	251	27.60	64	23.83	290	20.42	88	7.73
Escenario 28	108	71	109	139	13.71	160	11.81	270	29.53	219	21.26
Escenario 29	68	180	136	68	17.85	206	27.44	111	20.80	292	24.13
Escenario 30	78	187	81	88	24.59	82	18.16	294	11.50	164	28.14
Escenario 31	189	147	42	175	14.91	293	25.02	285	20.85	235	15.95
Escenario 32	34	58	146	244	20.55	271	29.47	234	18.50	295	27.53
Escenario 33	194	101	156	222	26.56	280	25.99	65	24.50	174	26.95
Escenario 34	70	123	159	190	28.74	204	26.67	233	7.67	61	12.93
Escenario 35	127	148	148	291	8.68	213	15.20	285	24.03	180	26.72
Escenario 36	74	30	77	269	28.16	206	18.79	288	18.53	286	14.39
Escenario 37	83	197	141	175	17.30	87	11.35	170	29.07	67	12.42
Escenario 38	150	170	20	107	11.46	234	9.90	59	13.55	89	21.23
Escenario 39	70	178	53	197	16.48	146	17.64	207	20.82	70	13.21
Escenario 40	154	61	115	269	29.50	278	19.88	202	28.30	192	20.76
Escenario 41	40	118	145	249	17.32	204	13.48	152	7.56	274	20.25
Escenario 42	92	26	137	110	13.22	232	19.24	133	28.43	148	19.09
Escenario 43	186	163	67	176	20.84	82	27.19	182	22.20	75	14.51
Escenario 44	37	109	108	154	11.00	245	18.92	114	6.70	57	18.71
Escenario 45	151	131	136	216	6.90	135	23.02	271	12.52	149	19.91
Escenario 46	108	79	148	50	8.22	115	25.13	226	22.70	289	18.64
Escenario 47	79	132	35	180	8.20	59	29.72	52	6.68	271	16.11
Escenario 48	33	21	88	254	8.80	54	20.08	222	19.55	136	5.37
Escenario 49	28	148	41	141	8.47	172	25.17	191	13.65	91	19.68
Escenario 50	109	67	112	239	21.02	123	29.07	169	20.52	221	9.21
Escenario 51	72	159	95	298	9.55	146	28.61	207	6.14	63	21.06
Escenario 52	149	56	173	240	13.64	167	8.53	291	26.79	127	23.98
Escenario 53	103	179	163	162	27.42	87	15.16	117	29.34	51	17.51
Escenario 54	111	28	198	202	16.85	190	13.10	195	29.22	168	18.56
Escenario 55	130	118	105	105	21.69	208	7.17	239	23.74	86	28.79
Escenario 56	191	166	48	210	9.31	96	20.83	86	8.25	118	26.18
Escenario 57	27	67	88	215	9.81	277	23.40	202	23.96	215	27.86
Escenario 58	194	150	66	166	6.02	158	26.20	225	5.61	286	25.34
Escenario 59	54	167	113	183	9.22	265	8.07	242	5.55	90	7.72
Escenario 60	100	171	163	107	11.96	229	26.91	230	13.09	111	8.72
Escenario 61	183	73	195	93	9.43	233	21.07	287	17.22	295	18.17
Escenario 62	69	139	104	222	7.22	64	22.60	256	24.26	109	11.15
Escenario 63	123	180	58	209	8.02	206	27.77	122	22.08	174	16.92
Escenario 64	151	171	119	222	16.52	185	20.62	192	16.15	160	14.86
Escenario 65	21	135	52	110	10.16	54	13.40	98	11.84	63	18.74

Tabla A.1-(Continuación)

Escenario	Load 1 (MW)	Load 2 (MW)	Load 3 (MW)	Gen A p_nom (MW)	Coste A (\$/MWh)	Gen B p_nom (MW)	Coste B (\$/MWh)	Gen C p_nom (MW)	Coste C (\$/MWh)	Gen D p_nom (MW)	Coste D (\$/MWh)
Escenario 66	153	94	120	96	14.11	206	25.63	170	29.93	297	23.67
Escenario 67	73	132	42	198	17.59	96	14.08	137	15.65	280	22.89
Escenario 68	125	183	29	129	22.26	117	5.86	245	16.28	266	18.03
Escenario 69	23	185	88	167	5.98	125	25.77	189	9.09	133	25.56
Escenario 70	73	123	119	262	24.99	222	13.63	236	24.87	179	15.77
Escenario 71	165	103	53	252	20.70	179	24.35	299	22.34	280	27.42
Escenario 72	63	131	199	278	7.04	204	14.07	86	10.52	119	6.78
Escenario 73	181	118	157	213	26.84	144	26.53	110	7.06	194	28.87
Escenario 74	33	172	166	276	28.02	164	10.49	278	22.01	172	21.37
Escenario 75	114	112	115	196	6.53	292	29.36	220	21.36	138	14.50
Escenario 76	67	165	20	69	11.92	213	24.49	173	11.83	298	9.93
Escenario 77	34	147	88	234	25.16	85	7.86	247	28.77	77	16.98
Escenario 78	59	129	23	195	23.71	75	19.14	88	8.78	115	9.86
Escenario 79	101	101	35	96	9.61	92	29.63	233	15.81	212	9.16
Escenario 80	130	73	43	282	10.23	76	16.78	112	28.59	278	20.43
Escenario 81	72	182	99	98	14.26	118	9.55	95	15.49	54	18.08
Escenario 82	43	188	21	63	17.11	197	17.12	137	20.96	242	21.75
Escenario 83	173	180	147	192	20.46	60	17.81	60	14.94	217	28.24
Escenario 84	143	87	179	208	14.22	123	23.54	111	11.86	253	18.31
Escenario 85	60	52	103	50	16.56	153	22.47	126	29.60	233	19.52
Escenario 86	176	161	171	166	23.69	87	15.06	275	15.23	213	7.24
Escenario 87	34	40	159	103	5.92	183	10.45	202	27.35	94	22.94
Escenario 88	64	67	197	167	11.31	249	21.13	248	10.75	200	15.00
Escenario 89	84	167	182	52	22.83	72	15.54	101	10.33	96	29.42
Escenario 90	108	147	143	193	27.38	96	8.31	53	5.78	80	25.58
Escenario 91	90	155	52	264	17.79	139	27.51	108	21.29	188	18.06
Escenario 92	28	154	180	234	18.30	95	22.28	121	14.21	59	8.08
Escenario 93	107	164	198	252	7.68	156	22.08	197	26.61	244	26.49
Escenario 94	148	147	190	61	16.19	189	25.56	142	16.83	167	24.99
Escenario 95	155	52	120	123	18.32	267	18.24	112	29.20	63	9.61
Escenario 96	82	195	31	273	11.06	190	25.38	103	9.64	129	12.38
Escenario 97	158	134	86	65	11.73	153	17.45	166	26.72	251	24.84
Escenario 98	100	138	84	249	14.43	239	6.68	292	24.41	142	9.63
Escenario 99	155	41	180	151	5.50	259	15.13	286	24.27	59	27.94
Escenario 100	182	177	187	253	13.05	266	17.44	159	26.12	125	15.61
Escenario 101	182	57	93	201	10.29	274	23.01	123	24.03	143	7.18
Escenario 102	52	128	62	205	13.19	160	7.66	156	20.66	154	25.39
Escenario 103	142	70	63	166	7.99	153	8.50	275	8.28	50	14.34
Escenario 104	24	27	48	57	27.26	109	11.59	106	5.81	182	18.16
Escenario 105	60	46	160	171	19.84	220	11.66	267	28.02	69	7.81
Escenario 106	47	46	31	141	21.98	253	23.30	218	20.42	57	5.06
Escenario 107	154	40	114	213	24.73	285	11.27	290	24.91	220	20.95
Escenario 108	91	49	65	139	17.46	149	20.83	299	17.04	253	17.88
Escenario 109	31	116	149	185	7.17	289	17.36	52	7.93	50	19.84
Escenario 110	181	47	54	235	18.43	117	19.33	169	8.13	106	24.84
Escenario 111	52	130	100	109	19.67	182	25.95	55	22.14	113	21.17
Escenario 112	67	80	109	227	23.64	169	15.11	54	15.76	167	9.37
Escenario 113	170	67	27	77	15.79	86	24.27	54	10.01	261	14.02
Escenario 114	81	166	112	269	8.19	121	15.55	103	17.29	77	27.65
Escenario 115	56	23	173	150	12.09	176	13.85	96	6.61	170	24.25
Escenario 116	118	54	109	90	14.08	155	28.97	264	19.55	156	18.92
Escenario 117	191	68	181	277	21.15	290	9.61	226	11.72	214	11.39
Escenario 118	123	36	134	241	19.27	141	7.26	58	24.94	224	12.55
Escenario 119	54	191	124	204	13.90	80	24.27	148	12.76	278	23.30
Escenario 120	120	177	154	295	29.66	171	6.71	69	16.38	253	26.28
Escenario 121	194	65	77	240	20.14	186	25.93	171	5.29	214	21.79
Escenario 122	150	136	133	194	10.93	295	15.93	290	6.81	98	25.24
Escenario 123	20	25	94	250	7.54	100	27.89	110	14.81	290	24.17
Escenario 124	24	118	176	210	8.82	78	23.04	172	17.00	169	8.74
Escenario 125	161	143	139	294	11.15	255	20.26	283	20.00	93	15.60
Escenario 126	122	56	183	261	9.02	89	28.73	212	12.29	105	8.82
Escenario 127	46	43	40	254	9.66	90	14.92	227	22.37	205	10.88
Escenario 128	156	112	183	269	12.13	263	28.85	131	26.50	160	26.73
Escenario 129	34	65	157	289	9.33	60	8.38	111	24.50	256	16.82
Escenario 130	109	200	120	206	27.42	200	17.09	194	5.99	183	18.38

Tabla A.1-(Continuación)

Escenario	Load 1 (MW)	Load 2 (MW)	Load 3 (MW)	Gen A p_nom (MW)	Coste A (\$/MWh)	Gen B p_nom (MW)	Coste B (\$/MWh)	Gen C p_nom (MW)	Coste C (\$/MWh)	Gen D p_nom (MW)	Coste D (\$/MWh)
Escenario 131	61	114	171	190	7.01	50	11.75	265	17.01	157	9.46
Escenario 132	143	118	196	95	18.11	95	18.50	52	7.62	300	12.81
Escenario 133	198	135	118	84	15.26	150	9.05	209	11.05	238	10.76
Escenario 134	82	179	55	183	29.56	198	26.04	276	29.67	197	10.15
Escenario 135	115	180	115	131	7.80	139	26.16	279	8.56	163	20.95
Escenario 136	71	86	171	164	14.95	159	28.88	62	17.47	127	11.42
Escenario 137	115	147	170	246	29.24	213	8.87	169	20.45	179	20.80
Escenario 138	151	37	56	96	26.64	231	20.58	174	22.56	250	6.46
Escenario 139	170	44	31	202	25.43	264	16.86	288	18.99	86	8.54
Escenario 140	162	73	132	243	11.45	106	13.61	138	5.24	69	11.86
Escenario 141	190	77	32	59	9.27	50	13.79	122	13.16	75	19.93
Escenario 142	48	86	42	105	21.72	112	15.32	117	17.94	78	21.90
Escenario 143	55	123	118	79	28.23	231	22.62	191	7.20	50	16.07
Escenario 144	32	193	124	291	18.92	104	19.96	150	13.77	168	16.14
Escenario 145	179	43	49	300	19.29	164	16.49	147	5.83	84	23.11
Escenario 146	90	133	36	158	12.00	217	6.90	60	6.96	247	5.40
Escenario 147	105	51	132	54	24.24	192	6.94	154	14.92	278	13.53
Escenario 148	47	194	81	168	9.68	198	5.06	233	8.32	294	25.47
Escenario 149	85	105	103	297	13.09	224	29.19	116	19.19	108	20.08
Escenario 150	189	170	131	82	15.64	250	5.13	172	22.24	118	13.43
Escenario 151	64	146	105	167	17.69	102	7.58	269	25.01	210	27.64
Escenario 152	81	174	160	114	11.06	186	12.86	78	10.00	290	24.32
Escenario 153	153	149	38	195	7.87	251	25.19	186	9.19	228	11.62
Escenario 154	47	36	196	273	20.27	229	29.05	244	7.61	255	21.13
Escenario 155	47	123	119	288	12.22	106	24.75	202	20.91	61	19.89
Escenario 156	127	180	159	226	19.53	166	22.26	275	22.66	283	15.03
Escenario 157	63	156	166	60	8.86	203	18.03	125	5.79	69	14.17
Escenario 158	103	62	95	134	17.03	218	7.17	219	28.41	230	13.59
Escenario 159	49	195	28	75	18.31	84	28.95	58	6.30	291	20.43
Escenario 160	94	58	47	112	6.30	112	23.96	256	18.53	265	16.06
Escenario 161	147	189	147	266	13.42	293	20.97	89	22.73	300	25.80
Escenario 162	111	45	71	135	8.36	74	23.98	74	26.77	92	21.74
Escenario 163	148	118	102	108	6.58	139	23.10	54	22.85	175	6.75
Escenario 164	140	69	130	76	29.75	124	20.93	188	25.04	275	21.00
Escenario 165	46	172	163	226	13.06	87	29.51	236	13.49	266	11.78
Escenario 166	140	171	136	254	25.25	179	27.58	275	25.37	99	19.82
Escenario 167	135	32	88	210	11.37	184	21.17	265	7.00	78	22.00
Escenario 168	22	79	118	147	22.04	259	22.33	173	27.37	234	10.77
Escenario 169	122	154	159	154	24.01	268	6.29	256	18.69	88	16.42
Escenario 170	174	76	44	148	19.89	211	21.75	87	25.43	272	9.76
Escenario 171	156	55	199	178	16.79	140	6.10	121	16.31	233	6.31
Escenario 172	81	192	142	198	15.30	66	19.71	300	21.09	288	14.46
Escenario 173	184	39	72	289	13.72	177	29.98	182	18.16	220	14.07
Escenario 174	70	84	170	104	28.24	220	18.90	225	23.29	227	29.89
Escenario 175	191	27	163	55	25.77	236	16.83	139	7.04	200	16.16
Escenario 176	171	163	76	269	29.13	157	12.82	195	6.51	221	13.34
Escenario 177	78	161	58	258	8.11	300	8.01	247	11.18	87	19.51
Escenario 178	137	134	128	246	23.27	228	23.28	86	8.99	133	7.22
Escenario 179	179	162	200	144	28.46	231	9.81	109	26.79	200	29.04
Escenario 180	115	111	61	182	9.53	201	7.88	225	10.48	177	20.87
Escenario 181	199	117	186	151	6.66	74	15.54	254	29.40	175	23.87
Escenario 182	132	85	161	52	23.53	248	24.88	77	13.42	94	9.26
Escenario 183	81	51	141	230	19.36	229	23.63	246	9.55	101	15.24
Escenario 184	71	105	152	72	26.05	247	6.37	254	24.74	129	15.57
Escenario 185	31	70	182	278	8.49	294	16.38	130	21.47	227	25.55
Escenario 186	58	172	94	102	24.88	137	18.06	163	17.45	283	5.03
Escenario 187	149	82	165	214	10.04	210	21.11	89	18.88	173	12.52
Escenario 188	150	144	95	251	9.09	226	21.25	94	22.98	168	29.53
Escenario 189	132	169	28	251	9.11	78	14.12	273	10.71	57	16.87
Escenario 190	120	77	93	132	25.36	112	19.02	111	29.91	291	14.56
Escenario 191	132	77	164	194	21.63	284	17.03	142	29.37	134	8.00
Escenario 192	100	105	26	134	18.08	199	27.12	164	21.26	178	29.35
Escenario 193	132	68	193	127	13.97	203	18.26	235	9.99	296	5.50
Escenario 194	21	199	160	250	26.93	205	16.03	116	22.01	57	23.43
Escenario 195	149	189	187	159	14.81	163	15.11	105	6.80	206	24.21
Escenario 196	73	89	189	50	25.41	262	19.31	89	5.77	145	11.09
Escenario 197	106	34	156	100	15.98	98	25.10	147	11.44	151	21.79
Escenario 198	148	73	197	222	14.42	248	18.46	89	16.57	54	7.32
Escenario 199	166	120	46	254	16.57	130	21.54	140	26.71	288	11.43
Escenario 200	145	27	141	53	12.53	133	23.45	254	23.18	135	24.70

Tabla A.2- Resultado para sistema de 3 nodos

Escenario	Despacho Gen A (MW)	Despacho Gen B (MW)	Despacho Gen C (MW)	Despacho Gen D (MW)	Carga servida 1 (MW)	Carga servida 2 (MW)	Carga servida 3 (MW)	Precio Bus 1 (\$/MWh)	Precio Bus 2 (\$/MWh)	Precio Bus 3 (\$/MWh)	Flujo L1-2 (MW)	Flujo L1-3 (MW)	Flujo L2-3 (MW)
Escenario 1	243	0	100	0	122	149	72	12.28	11.68	10.88	58.20	62.80	9.20
Escenario 2	54	112	65	73	153	72	79	30.00	29.40	28.60	6.60	6.40	-0.40
Escenario 3	78	66	286	0	112.0	191.0	127	26.52	25.92	25.12	-6.20	38.20	88.80
Escenario 4	214	0	0	23	34	179	24	15.76	15.16	14.36	107.80	72.20	-71.20
Escenario 5	215	159	0	53	126	179	122	9.61	9.01	8.21	135.00	113.00	-44.00
Escenario 6	0	194.0	0.0	9	91	87	25	12.50	11.90	11.10	58.60	44.40	-28.40
Escenario 7	36	274	0	0	40	142	128	18.01	17.41	16.61	136.40	133.60	-5.60
Escenario 8	133	288	0	0	122	164	135	24.31	23.71	22.91	152.40	146.60	-11.60
Escenario 9	15	296	0	0	141	57	113	18.00	17.40	16.60	79.40	90.60	22.40
Escenario 10	0	0	0	203	94	43	66	9.23	8.63	7.83	-29.00	-65.00	-72.00
Escenario 11	58	255	0	0	107	88	118	18.80	18.20	17.40	100.00	106.00	12.00
Escenario 12	243	102	0	0	136	135	74	19.02	18.42	17.62	110.60	98.40	-24.40
Escenario 13	0	123	300	0	119	117	187	20.62	20.02	19.22	-35.00	39.00	148.00
Escenario 14	120	153	79	0	123	158	71	27.62	27.02	26.22	-75.80	74.20	-3.20
Escenario 15	266	228	0	3	171	163	163	27.07	26.47	25.67	161.80	161.20	-1.20
Escenario 16	94	14	190	0	150	116	32	19.69	19.09	18.29	-31.60	-10.40	42.40
Escenario 17	4	228	0	213	169	143	133	23.88	23.28	22.48	53.80	9.20	-89.20
Escenario 18	0	0	209	95	72	89	143	15.11	14.51	13.71	-52.80	-19.20	67.20
Escenario 19	0	0	92	166	21	112	125	13.98	13.38	12.58	-4.40	-16.60	-24.40
Escenario 20	208	98	0	0	107	22	177	18.36	17.76	16.96	84.00	115.00	62.00
Escenario 21	68	0	172	270	177	167	166	14.35	13.75	12.95	-44.60	-64.40	-39.60
Escenario 22	238	166	0	0	57	183	164	17.43	16.83	16.03	175.40	171.60	-7.60
Escenario 23	157	249	48	0	149	166	139	26.40	25.80	25.00	126.40	130.60	8.40
Escenario 24	0	91	140	0	40	109	82	18.29	17.69	16.89	14.20	36.80	45.20
Escenario 25	0	93	78	213	180	166	38	13.36	12.76	11.96	-17.20	-69.80	-105.20
Escenario 26	0	293	62	0	77	167	111	12.78	12.18	11.38	107.40	108.60	2.40
Escenario 27	0	0	145	88	41	115	77	21.02	20.42	19.62	-22.40	-18.60	7.60
Escenario 28	128	160	0	0	108	71	109	13.71	13.11	12.31	86.20	93.80	15.20
Escenario 29	68	0	111	205	68	180	136	25.53	24.93	24.13	13.80	-13.80	-55.20
Escenario 30	0	52	294	0	78	187	81	18.16	17.56	16.76	-31.80	-5.80	75.20
Escenario 31	175	0	0	203	189	147	42	17.35	16.75	15.95	23.80	-37.80	-123.20
Escenario 32	4	0	234	0	34	58	146	20.55	19.95	19.15	-47.20	17.20	128.80
Escenario 33	106	280	65	0	194	101	156	26.56	25.96	25.16	84.00	108.00	48.00
Escenario 34	0	58	233	61	70	123	159	26.67	26.07	25.27	-26.80	14.80	83.20
Escenario 35	291	132	0	0	127	148	148	15.20	14.60	13.80	148.00	148.00	0.00
Escenario 36	0	0	0	181	74	30	77	15.79	15.19	14.39	-23.60	-50.40	-53.60
Escenario 37	175	87	92	67	83	197	141	29.67	29.07	28.27	92.60	86.40	-12.40
Escenario 38	106	234	0	0	150	170	20	11.46	10.86	10.06	110.00	80.00	-60.00
Escenario 39	197	34	0	70	70	178	53	17.64	17.04	16.24	100.00	61.00	-78.00
Escenario 40	0	278	0	52	154	61	115	22.16	21.56	20.76	61.80	62.20	0.80
Escenario 41	0	151	152	0	40	118	145	13.48	12.88	12.08	37.60	73.40	71.60
Escenario 42	110	145	0	0	92	26	137	19.24	18.64	17.84	70.40	92.60	44.40
Escenario 43	176	0	165	75	186	163	67	22.80	22.20	21.40	-4.40	-5.60	-2.40
Escenario 44	140	0	114	0	37	109	108	11.00	10.40	9.60	40.20	62.80	45.20
Escenario 45	216	0	202	0	151	131	136	13.12	12.52	11.72	11.80	53.20	82.80
Escenario 46	50	0	0	285	108	79	148	20.04	19.44	18.64	-7.40	-50.60	-86.40
Escenario 47	180	0	52	14	79	132	35	17.51	16.91	16.11	56.40	44.60	-23.60
Escenario 48	6	0	0	136	33	21	88	8.80	8.20	7.40	-6.60	-20.40	-27.60
Escenario 49	141	0	76	0	28	148	41	14.25	13.65	12.85	59.60	53.40	-12.40
Escenario 50	67	0	0	221	109	67	112	21.02	20.42	19.62	-3.40	-38.60	-70.40
Escenario 51	119	0	207	0	72	159	95	9.55	8.95	8.15	9.20	37.80	57.20
Escenario 52	211	167	0	0	149	56	173	13.64	13.04	12.24	102.80	126.20	46.80
Escenario 53	162	87	117	51	75	179	163	30.00	29.40	28.60	82.00	92.00	20.00
Escenario 54	147	190	0	0	111	28	198	16.85	16.25	15.45	96.00	130.00	68.00
Escenario 55	105	208	40	0	130	118	105	24.34	23.74	22.94	88.80	94.20	10.80
Escenario 56	210	96	86	13	191	166	48	27.58	26.98	26.18	62.00	53.00	-18.00
Escenario 57	182	0	0	0	27	67	88	9.81	9.21	8.41	75.40	79.60	8.40
Escenario 58	166	19	225	0	194	150	66	26.20	25.60	24.80	-18.60	9.60	56.40
Escenario 59	0	92	242	0	54	167	113	8.07	7.47	6.67	0.20	37.80	75.20
Escenario 60	107	0	216	111	100	171	163	13.69	13.09	12.29	-6.20	13.20	38.80
Escenario 61	93	0	287	71	183	73	195	19.57	18.97	18.17	-78.80	-11.20	135.20
Escenario 62	222	0	0	90	69	139	104	12.55	11.95	11.15	89.00	64.00	-50.00
Escenario 63	209	0	0	152	123	180	58	18.32	17.72	16.92	70.40	15.60	-109.60
Escenario 64	222	0	59	160	151	171	119	16.75	16.15	15.35	50.80	20.20	-61.20
Escenario 65	110	0	98	0	21	135	52	12.44	11.84	11.04	43.00	46.00	6.00

Tabla A.2- (Continuación)

Escenario	Despacho Gen A (MW)	Despacho Gen B (MW)	Despacho Gen C (MW)	Despacho Gen D (MW)	Carga servida 1 (MW)	Carga servida 2 (MW)	Carga servida 3 (MW)	Precio Bus 1 (\$/MWh)	Precio Bus 2 (\$/MWh)	Precio Bus 3 (\$/MWh)	Flujo L1-2 (MW)	Flujo L1-3 (MW)	Flujo L2-3 (MW)
Escenario 66	96	0	0	271	153	94	120	25.07	24.47	23.67	-4.00	-53.00	-98.00
Escenario 67	14	96	137	0	73	132	42	17.59	16.99	16.19	13.80	23.20	18.80
Escenario 68	0	117	220	0	125	183	29	16.88	16.28	15.48	-10.60	2.60	26.40
Escenario 69	167	0	129	0	23	185	88	9.69	9.09	8.29	68.80	75.20	12.80
Escenario 70	0	222	0	93	73	123	119	17.17	16.57	15.77	84.20	64.80	-38.80
Escenario 71	252	0	69	0	165	103	53	22.94	22.34	21.54	41.60	45.40	7.60
Escenario 72	278	0	0	115	63	131	199	8.18	7.58	6.78	112.20	102.80	-18.80
Escenario 73	202	144	110	0	181	118	157	26.84	26.24	25.44	67.60	97.40	59.60
Escenario 74	0	164	207	0	33	172	166	22.61	22.01	21.21	45.40	85.60	80.40
Escenario 75	196	0	7	138	114	112	115	21.96	21.36	20.56	53.80	28.20	-51.20
Escenario 76	0	0	0	252	67	165	20	11.33	10.73	9.93	6.20	-73.20	-158.80
Escenario 77	107	85	0	77	34	147	88	25.16	24.56	23.76	92.60	65.40	-54.40
Escenario 78	0	8	88	115	59	129	23	19.14	18.54	17.74	-12.20	-38.80	-53.20
Escenario 79	96	0	0	141	101	101	35	10.56	9.96	9.16	18.20	-23.20	-82.80
Escenario 80	246	0	0	0	130	73	43	10.23	9.63	8.83	61.00	55.00	-12.00
Escenario 81	98	118	95	42	72	182	99	19.48	18.88	18.08	75.00	69.00	-12.00
Escenario 82	63	189	0	0	43	188	21	17.12	16.52	15.72	121.20	87.80	-66.80
Escenario 83	192	60	60	188	173	180	147	29.64	29.04	28.24	55.60	23.40	-64.40
Escenario 84	208	0	111	90	143	87	179	19.71	19.11	18.31	21.20	43.80	45.20
Escenario 85	50	0	0	165	60	52	103	20.92	20.32	19.52	6.40	-16.40	-45.60
Escenario 86	0	87	208	213	176	161	171	15.83	15.23	14.43	-45.00	-44.00	2.00
Escenario 87	103	130	0	0	34	40	159	10.45	9.85	9.05	87.60	111.40	47.60
Escenario 88	167	0	161	0	64	67	197	11.35	10.75	9.95	22.40	80.60	116.40
Escenario 89	52	72	101	0	0	43	182	30.60	30.00	29.20	38.00	86.00	96.00
Escenario 90	169	96	53	80	108	147	143	27.38	26.78	25.98	81.60	75.40	-12.40
Escenario 91	264	0	0	33	90	155	52	19.46	18.86	18.06	100.60	73.40	-54.40
Escenario 92	182	0	121	59	28	154	180	18.30	17.70	16.90	68.20	85.80	35.20
Escenario 93	252	156	61	0	107	164	198	27.21	26.61	25.81	141.00	160.00	38.00
Escenario 94	61	189	142	93	148	147	190	26.39	25.79	24.99	41.80	60.20	36.80
Escenario 95	0	264	0	63	155	52	120	18.24	17.64	16.84	54.00	55.00	2.00
Escenario 96	205	0	103	0	82	195	31	11.06	10.46	9.66	67.60	55.40	-24.40
Escenario 97	65	153	0	160	158	134	86	26.24	25.64	24.84	50.80	9.20	-83.20
Escenario 98	0	239	0	83	100	138	84	11.03	10.43	9.63	83.20	55.80	-54.80
Escenario 99	151	225	0	0	155	41	180	15.13	14.53	13.73	96.60	124.40	55.60
Escenario 100	253	168	0	125	182	177	187	17.44	16.84	16.04	131.00	108.00	-46.00
Escenario 101	189	0	0	143	182	57	93	10.29	9.69	8.89	14.20	-7.20	-42.80
Escenario 102	82	160	0	0	52	128	62	13.19	12.59	11.79	101.60	88.40	-26.40
Escenario 103	166	109	0	0	142	70	63	8.50	7.90	7.10	67.20	65.80	-2.80
Escenario 104	0	0	99	0	24	27	48	6.41	5.81	5.01	-24.00	0.00	48.00
Escenario 105	0	197	0	69	60	46	160	11.66	11.06	10.26	64.00	73.00	18.00
Escenario 106	0	0	67	57	47	46	31	21.02	20.42	19.62	-23.00	-24.00	-2.00
Escenario 107	0	285	0	23	154	40	114	22.35	21.75	20.95	60.40	70.60	20.40
Escenario 108	139	0	66	0	91	49	65	17.64	17.04	16.24	15.80	32.20	32.80
Escenario 109	185	59	52	0	31	116	149	17.36	16.76	15.96	98.00	115.00	34.00
Escenario 110	113	0	169	0	181	47	54	18.43	17.83	17.03	-51.60	-16.40	70.40
Escenario 111	109	5	55	113	52	130	100	25.95	25.35	24.55	39.80	22.20	-35.20
Escenario 112	0	89	0	167	67	80	109	15.11	14.51	13.71	24.80	-2.80	-55.20
Escenario 113	0	0	54	210	170	67	27	15.42	14.82	14.02	-65.40	-104.60	-78.40
Escenario 114	269	90	0	0	81	166	112	15.55	14.95	14.15	144.40	133.60	-21.60
Escenario 115	150	6	96	0	56	23	173	13.85	13.25	12.45	25.40	74.60	98.40
Escenario 116	90	0	191	0	118	54	109	20.15	19.55	18.75	-38.60	10.60	98.40
Escenario 117	0	290	150	0	191	68	181	12.32	11.72	10.92	23.20	75.80	105.20
Escenario 118	0	141	0	152	123	36	134	13.95	13.35	12.55	14.40	3.60	-21.60
Escenario 119	204	17	148	0	54	191	124	24.27	23.67	22.87	75.40	91.60	32.40
Escenario 120	0	171	69	211	120	177	154	27.68	27.08	26.28	42.00	9.00	-66.00
Escenario 121	165	0	171	0	194	65	77	20.14	19.54	18.74	-32.80	3.80	73.20
Escenario 122	129	0	290	0	150	136	133	10.93	10.33	9.53	-39.20	18.20	114.80
Escenario 123	139	0	0	0	20	25	94	7.54	6.94	6.14	52.60	66.40	27.60
Escenario 124	210	0	0	108	24	118	176	10.14	9.54	8.74	98.00	88.00	-20.00
Escenario 125	294	56	0	93	161	143	139	20.26	19.66	18.86	104.20	84.80	-38.80
Escenario 126	261	0	0	100	122	56	183	10.22	9.62	8.82	66.80	72.20	10.80
Escenario 127	129	0	0	0	46	43	40	9.66	9.06	8.26	41.80	41.20	-1.20
Escenario 128	269	0	131	51	156	112	183	28.13	27.53	26.73	41.40	71.60	60.40
Escenario 129	196	60	0	0	34	65	157	9.33	8.73	7.93	101.80	120.20	36.80
Escenario 130	0	200	194	35	109	200	120	19.78	19.18	18.38	37.60	53.40	31.60

Tabla A.2- (Continuación)

Escenario	Despacho Gen A (MW)	Despacho Gen B (MW)	Despacho Gen C (MW)	Despacho Gen D (MW)	Carga servida 1 (MW)	Carga servida 2 (MW)	Carga servida 3 (MW)	Precio Bus 1 (\$/MWh)	Precio Bus 2 (\$/MWh)	Precio Bus 3 (\$/MWh)	Flujo L1-2 (MW)	Flujo L1-3 (MW)	Flujo L2-3 (MW)
Escenario 131	190	0	0	156	61	114	171	10.86	10.26	9.46	74.40	54.60	-39.60
Escenario 132	95	10	52	300	143	118	196	18.50	17.90	17.10	-2.00	-36.00	-68.00
Escenario 133	0	150	209	92	198	135	118	12.16	11.56	10.76	-34.00	-14.00	40.00
Escenario 134	0	119	0	197	82	179	55	26.04	25.44	24.64	50.60	-13.60	-128.40
Escenario 135	131	0	279	0	115	180	115	9.16	8.56	7.76	-13.40	29.40	85.60
Escenario 136	164	0	37	127	71	86	171	18.07	17.47	16.67	47.00	46.00	-2.00
Escenario 137	0	213	169	50	115	147	170	22.20	21.60	20.80	34.80	63.20	56.80
Escenario 138	0	0	0	244	151	37	56	7.86	7.26	6.46	-53.00	-98.00	-90.00
Escenario 139	0	159	0	86	170	44	31	16.86	16.26	15.46	4.40	-15.40	-39.60
Escenario 140	229	0	138	0	162	73	132	11.45	10.85	10.05	13.80	53.20	78.80
Escenario 141	59	50	122	68	190	77	32	21.33	20.73	19.93	-41.40	-39.60	3.60
Escenario 142	0	112	64	0	48	86	42	18.54	17.94	17.14	30.00	34.00	8.00
Escenario 143	0	55	191	50	55	123	118	22.62	22.02	21.22	-13.60	13.60	54.40
Escenario 144	31	0	150	168	32	193	124	18.92	18.32	17.52	8.20	-9.20	-34.80
Escenario 145	0	124	147	0	179	43	49	16.49	15.89	15.09	-42.80	-12.20	61.20
Escenario 146	0	12	0	247	90	133	36	6.90	6.30	5.50	-4.60	-73.40	-137.60
Escenario 147	0	192	0	96	105	51	132	14.93	14.33	13.53	45.00	42.00	-6.00
Escenario 148	0	198	124	0	47	194	81	8.92	8.32	7.52	74.40	76.60	4.40
Escenario 149	293	0	0	0	85	105	103	13.09	12.49	11.69	104.20	103.80	-0.80
Escenario 150	82	250	40	118	189	170	131	22.84	22.24	21.44	83.20	59.80	-46.80
Escenario 151	167	102	46	0	64	146	105	25.61	25.01	24.21	102.00	103.00	2.00
Escenario 152	114	186	78	37	81	174	160	25.72	25.12	24.32	106.80	112.20	10.80
Escenario 153	195	0	145	0	153	149	38	9.79	9.19	8.39	17.60	24.40	13.60
Escenario 154	35	0	244	0	47	36	196	20.27	19.67	18.87	-46.40	34.40	161.60
Escenario 155	288	0	0	1	47	123	119	21.29	20.69	19.89	121.00	120.00	-2.00
Escenario 156	183	0	0	283	127	180	159	19.53	18.93	18.13	58.40	-2.40	-121.60
Escenario 157	60	131	125	69	63	156	166	18.03	17.43	16.63	57.40	70.60	26.40
Escenario 158	0	218	0	42	103	62	95	14.99	14.39	13.59	58.40	56.60	-3.60
Escenario 159	75	0	58	139	49	195	28	21.83	21.23	20.43	37.80	-11.80	-99.20
Escenario 160	112	0	0	87	94	58	47	17.46	16.86	16.06	18.80	-0.80	-39.20
Escenario 161	266	217	0	0	147	189	147	20.97	20.37	19.57	172.20	163.80	-16.80
Escenario 162	135	0	0	92	111	45	71	23.14	22.54	21.74	18.60	5.40	-26.40
Escenario 163	108	85	0	175	148	118	102	23.10	22.50	21.70	41.60	3.40	-76.40
Escenario 164	0	124	0	215	140	69	130	22.40	21.80	21.00	7.40	-23.40	-61.60
Escenario 165	226	0	0	155	46	172	163	13.18	12.58	11.78	106.40	73.60	-65.60
Escenario 166	254	0	94	99	140	171	136	25.97	25.37	24.57	61.00	53.00	-16.00
Escenario 167	0	0	255	0	135	32	88	7.60	7.00	6.20	-98.60	-36.40	124.40
Escenario 168	0	0	0	219	22	79	118	12.17	11.57	10.77	7.00	-29.00	-72.00
Escenario 169	0	268	79	88	122	154	159	19.29	18.69	17.89	73.40	72.60	-1.60
Escenario 170	22	0	0	272	174	76	44	19.89	19.29	18.49	-45.60	-106.40	-121.60
Escenario 171	37	140	0	233	156	55	199	16.79	16.19	15.39	19.40	1.60	-35.60
Escenario 172	198	0	0	217	81	192	142	15.86	15.26	14.46	85.20	31.80	-106.80
Escenario 173	289	0	0	6	184	39	72	15.47	14.87	14.07	49.80	53.20	10.80
Escenario 174	0	220	104	0	70	84	170	23.89	23.29	22.49	56.00	94.00	76.00
Escenario 175	0	236	139	6	191	27	163	17.56	16.96	16.16	-4.40	49.40	107.60
Escenario 176	0	157	195	58	171	163	76	14.74	14.14	13.34	-12.00	-2.00	20.00
Escenario 177	0	297	0	0	78	161	58	8.01	7.41	6.61	119.80	99.20	-41.20
Escenario 178	180	0	86	133	137	134	128	23.27	22.67	21.87	26.80	16.20	-21.20
Escenario 179	144	231	109	0	122	162	200	30.00	29.40	28.60	111.80	141.20	58.80
Escenario 180	86	201	0	0	115	111	61	9.53	8.93	8.13	91.00	81.00	-20.00
Escenario 181	151	74	0	175	97	117	186	30.00	29.40	28.60	74.60	53.40	-42.40
Escenario 182	52	155	77	94	132	85	161	24.88	24.28	23.48	31.60	43.40	23.60
Escenario 183	0	0	246	27	81	51	141	16.64	16.04	15.24	-71.40	-9.60	123.60
Escenario 184	0	247	0	81	71	105	152	16.97	16.37	15.57	91.40	84.60	-13.60
Escenario 185	278	5	0	0	31	70	182	16.38	15.78	14.98	114.80	137.20	44.80
Escenario 186	0	0	41	283	58	172	94	18.05	17.45	16.65	3.00	-61.00	-128.00
Escenario 187	214	0	9	173	149	82	165	19.48	18.88	18.08	40.60	24.40	-32.40
Escenario 188	251	138	0	0	150	144	95	21.25	20.65	19.85	124.40	114.60	-19.60
Escenario 189	251	0	78	0	132	169	28	11.31	10.71	9.91	65.80	53.20	-25.20
Escenario 190	0	0	0	290	120	77	93	15.96	15.36	14.56	-32.60	-87.40	-109.60
Escenario 191	0	239	0	134	132	77	164	17.03	16.43	15.63	58.20	48.80	-18.80
Escenario 192	134	0	97	0	100	105	26	21.86	21.26	20.46	15.20	18.80	7.20
Escenario 193	0	0	97	296	132	68	193	10.59	9.99	9.19	-58.60	-73.40	-29.60
Escenario 194	2	205	116	57	21	199	160	26.93	26.33	25.53	91.00	95.00	8.00
Escenario 195	159	163	105	98	149	189	187	25.61	25.01	24.21	86.00	87.00	2.00
Escenario 196	0	117	89	145	73	89	189	19.31	18.71	17.91	17.60	26.40	17.60
Escenario 197	100	0	147	49	106	34	156	23.19	22.59	21.79	-25.00	19.00	88.00
Escenario 198	222	53	89	54	148	73	197	18.46	17.86	17.06	47.60	79.40	63.60
Escenario 199	44	0	0	288	166	120	46	16.57	15.97	15.17	-24.80	-97.20	-144.80
Escenario 200	53	133	127	0	145	27	141	23.78	23.18	22.38	-3.60	44.60	96.40

ANEXO B

Tabla B.1- Datos de entrada para sistema de 8 nodos

Escenario	Load 1 (MW)	Load 2 (MW)	Load 3 (MW)	Load 4 (MW)	Load 5 (MW)	Load 6 (MW)	Load 7 (MW)	Load 8 (MW)	Gen 1 (MW)	Coste 1 (\$/MWh)	Gen 2 (MW)	Coste 2 (\$/MWh)	Gen 3 (MW)	Coste 3 (\$/MWh)	Gen 4 (MW)	Coste 4 (\$/MWh)	Gen 5 (MW)	Coste 5 (\$/MWh)	Gen 6 (MW)	Coste 6 (\$/MWh)	Gen 7 (MW)	Coste 7 (\$/MWh)	Gen 8 (MW)	Coste 8 (\$/MWh)
Escenario 1	122	149	72	24	130	139	160	63	105	24.41	178	24.84	135	28.21	92	11.36	100	17.69	148	27.66	176	10.13	225	15.82
Escenario 2	199	72	79	48	170	156	198	68	89	24.27	296	9.63	182	21.90	218	25.48	124	21.93	96	9.10	137	17.68	288	27.70
Escenario 3	112	191	127	184	99	181	142	36	147	26.12	57	27.94	232	17.40	216	27.00	254	10.88	289	21.07	243	11.71	254	17.68
Escenario 4	34	179	74	185	114	92	81	82	89	24.03	206	15.61	179	5.32	135	18.14	59	25.77	195	26.25	163	12.19	97	9.70
Escenario 5	126	179	122	137	54	51	76	140	20.66	145	7.18	111	29.81	226	11.11	191	18.42	255	28.68	64	21.42	226	6.92	
Escenario 6	91	87	25	155	163	20	177	74	254	8.28	151	23.39	268	21.79	66	7.92	259	9.13	276	13.43	145	29.21	294	22.40
Escenario 7	40	142	128	128	27	59	48	66	286	5.81	54	14.34	198	12.92	147	7.18	100	19.57	285	23.12	216	20.09	113	13.57
Escenario 8	122	164	135	84	151	83	68	31	82	28.02	288	18.16	295	26.98	247	22.98	167	29.99	154	18.47	172	6.92	110	25.55
Escenario 9	141	57	113	105	103	169	192	81	55	20.42	155	7.81	279	11.46	287	15.50	250	8.76	173	6.52	247	6.89	206	21.49
Escenario 10	94	43	66	164	151	79	49	99	265	24.91	224	5.06	128	18.60	247	27.63	170	25.42	248	22.25	50	28.79	88	24.91
Escenario 11	107	88	118	90	44	83	163	102	196	17.04	83	20.95	198	20.90	147	23.49	88	10.18	282	25.25	288	12.43	177	11.80
Escenario 12	136	135	74	64	115	112	187	27	129	7.93	242	17.88	187	10.53	114	9.78	77	24.56	62	28.27	200	7.30	137	22.31
Escenario 13	119	117	187	151	174	91	38	168	217	8.13	104	19.84	264	29.46	123	20.34	52	23.36	259	17.43	171	19.98	75	11.60
Escenario 14	123	158	71	55	112	30	37	100	141	22.14	168	24.84	107	23.70	134	15.89	133	12.51	278	10.76	216	20.59	66	28.48
Escenario 15	171	163	163	89	179	124	20	137	146	15.76	267	21.17	169	18.95	54	19.43	247	13.15	190	6.11	175	21.21	120	20.91
Escenario 16	150	116	32	178	197	33	97	44	108	10.01	220	9.37	216	9.51	51	23.45	204	24.81	149	15.39	106	11.69	62	13.11
Escenario 17	169	143	133	38	80	79	134	108	108	17.29	251	14.02	182	6.35	71	25.15	166	16.54	80	12.55	130	5.38	118	11.74
Escenario 18	72	89	143	127	141	49	194	31	97	6.61	207	27.65	114	13.00	161	26.09	51	23.27	179	24.03	211	29.13	75	9.77
Escenario 19	21	112	125	186	70	54	132	162	218	19.55	163	24.25	62	23.83	106	11.35	142	8.70	65	13.86	300	11.27	98	22.37
Escenario 20	107	22	177	110	166	184	133	78	67	11.72	259	18.92	262	11.73	115	5.78	215	26.31	186	28.73	218	21.90	244	10.47
Escenario 21	177	167	166	109	40	24	185	173	156	24.94	194	11.39	267	18.49	123	23.48	180	22.77	122	29.06	270	22.67	56	19.88
Escenario 22	57	183	164	38	24	102	198	128	94	12.76	75	12.55	291	23.20	147	6.66	193	27.67	215	20.52	122	20.25	107	11.62
Escenario 23	149	166	139	58	111	142	82	45	138	16.38	185	23.30	286	7.70	193	12.87	143	8.31	252	28.23	190	13.82	99	21.55
Escenario 24	40	109	82	145	189	97	151	66	230	5.29	96	26.28	262	22.13	161	5.10	89	19.83	103	24.02	110	11.78	132	26.87
Escenario 25	180	166	88	192	80	173	148	51	219	6.81	281	21.79	230	7.39	228	22.04	51	19.98	239	18.67	55	19.94	102	24.45
Escenario 26	77	167	111	160	41	81	27	29	149	14.81	162	25.24	131	29.13	174	9.18	130	13.84	263	9.51	133	26.65	242	20.02
Escenario 27	41	115	77	145	168	151	176	35	240	17.00	125	24.17	278	17.21	216	21.38	218	16.46	274	16.46	101	28.67	90	9.69
Escenario 28	108	71	109	77	89	108	74	164	204	20.00	268	8.74	222	8.77	135	29.79	61	5.95	149	19.02	294	7.65	111	7.21
Escenario 29	68	180	136	167	20	61	122	170	215	12.29	121	15.60	209	13.56	125	6.82	212	23.65	158	26.60	52	8.87	66	22.47
Escenario 30	78	187	81	80	152	108	150	45	237	22.37	138	8.82	213	15.34	137	6.93	284	18.73	136	17.03	130	28.62	220	14.21
Escenario 31	189	147	42	146	31	165	51	105	56	26.50	95	10.88	258	23.95	288	13.51	114	6.44	222	27.44	112	23.41	74	15.81
Escenario 32	34	58	146	124	109	59	29	154	182	24.50	245	26.73	276	23.59	217	26.66	104	22.02	286	21.86	98	27.67	300	5.78
Escenario 33	194	101	156	186	65	91	129	33	284	5.99	82	16.82	290	20.30	87	10.39	94	16.67	211	8.42	125	10.07	180	11.49
Escenario 34	70	123	159	20	53	58	181	98	94	17.01	50	18.38	237	7.65	237	14.01	256	5.86	186	29.87	161	19.69	256	5.84
Escenario 35	127	148	148	150	196	123	143	136	107	7.62	196	9.46	188	8.79	108	6.71	267	29.24	265	18.18	224	22.53	78	26.98
Escenario 36	74	30	77	111	97	33	106	26	298	11.05	80	12.81	240	7.34	187	24.08	150	28.73	57	14.80	158	22.00	166	11.10
Escenario 37	83	197	141	132	64	51	74	156	292	29.67	257	10.76	198	19.43	148	15.21	262	17.82	56	21.48	232	15.20	284	18.93
Escenario 38	150	170	20	172	174	198	51	134	80	8.56	191	10.15	101	26.93	241	23.98	111	7.34	85	7.72	241	5.38	209	5.97
Escenario 39	70	178	53	75	92	144	197	195	72	17.47	102	20.95	232	15.85	292	27.59	98	23.87	67	20.91	114	19.57	75	21.67
Escenario 40	154	61	115	180	45	185	154	91	219	20.48	97	11.42	166	9.02	112	10.82	178	17.30	52	17.46	190	11.32	173	13.08
Escenario 41	40	118	145	182	66	116	112	78	187	22.56	118	20.80	75	18.95	98	25.18	272	12.56	77	15.17	244	16.28	199	27.45
Escenario 42	26	137	136	140	42	27	101	269	18.99	154	6.46	245	25.29	247	6.48	202	17.29	119	28.83	267	28.64	74	27.20	
Escenario 43	186	163	67	153	25	82	84	135	156	5.24	139	8.54	83	23.84	81	27.47	72	18.06	285	18.06	64	14.98	103	13.13
Escenario 44	37	109	108	77	113	162	76	186	230	13.16	239	11.86	101	27.04	184	21.27	201	19.07	221	10.48	149	26.00	205	27.52
Escenario 45	151	131	136	63	126	172	86	165	207	17.94	269	19.93	161	11.05	70	26.86	298	16.03	198	16.47	81	9.71	122	29.90
Escenario 46	108	79	148	192	82	164	91	122	88	7.20	243	21.90	131	9.85	69	5.00	87	20.14	77	27.98	145	21.81	169	25.64
Escenario 47	79	132	35	179	67	72	73	36	208	13.77	291	16.07	281	27.00	203	9.23	77	27.97	281	9.40	177	29.43	105	26.12
Escenario 48	33	21	88	192	80	123	86	33	131	5.83	241	16.14	276	21.44	176	14.74	70	14.06	103	10.35	245	7.55	114	11.23
Escenario 49	28	148	41	80	100	123	70	178	149	6.96	247	23.11	282	12.77	117	14.49	231	23.14	231	5.33	195	5.21	142	19.42
Escenario 50	109	67	112	66	45	198	116	171	51	14.92	112	5.40	270	23.56	159	10.67	156	27.36	114	5.35	162	15.84	298	6.88
Escenario 51	72	159	95	168	55	58	111	127	255	8.32	122	13.53	229	25.38	165	14.54	195	16.40	149	25.73	132	7.32	135	7.37
Escenario 52	149	56	173	99	20	198	27	64	126	10.19	210	25.47	206	20.37	263	8.22	213	16.09	70	23.30	92	23.71	129	29.97
Escenario 53	103	179	163	137	27	153	181	117	270	22.24	218	20.08	215	22.20	192	15.32	148	20.05	284	13.88	165	27.86	218	13.17
Escenario 54	111	28	198	183	132	86	54	150	61	25.01	138	13.43	91	14.38	169	25.06	222	19.79	276	22.46	221	15.85	292	23.70
Escenario 55	130	118	105	166	118	154	115	56	88	10.00	225	27.64	70	18.47	281	16.98	168	25.16	62	14.88	281	11.47	157	25.17
Escenario 56	191	166	48	39	199	1																		

Tabla B.1- (Continuación)

Escenario	Load 1 (A/W)	Load 2 (A/W)	Load 3 (A/W)	Load 4 (A/W)	Load 5 (A/W)	Load 6 (A/W)	Load 7 (A/W)	Load 8 (A/W)	Gen 1 (A/W)	Coste 1 (\$/MWh)	Gen 2 (A/W)	Coste 2 (\$/MWh)	Gen 3 (A/W)	Coste 3 (\$/MWh)	Gen 4 (A/W)	Coste 4 (\$/MWh)	Gen 5 (A/W)	Coste 5 (\$/MWh)	Gen 6 (A/W)	Coste 6 (\$/MWh)	Gen 7 (A/W)	Coste 7 (\$/MWh)	Gen 8 (A/W)	Coste 8 (\$/MWh)
Escenario 101	182	57	93	49	102	88	78	165	187	16.57	84	21.79	249	18.01	278	10.51	237	5.61	258	15.39	164	20.76	69	21.87
Escenario 102	52	128	62	128	61	167	147	56	167	26.71	221	7.32	298	14.34	134	17.21	195	12.65	153	26.18	106	11.21	241	21.94
Escenario 103	142	70	63	24	188	30	133	172	242	23.18	151	11.43	136	8.06	121	23.44	269	18.73	141	27.56	278	22.64	270	14.33
Escenario 104	24	27	48	138	120	93	134	195	71	23.57	267	24.70	92	23.39	104	18.13	212	20.80	235	26.93	121	15.69	172	28.54
Escenario 105	60	46	160	52	25	123	33	200	267	15.64	60	26.62	178	10.90	186	5.82	220	19.43	253	29.36	56	16.06	283	9.18
Escenario 106	47	46	31	137	199	57	28	92	169	13.65	148	20.21	158	14.29	96	26.71	288	22.44	76	5.69	255	21.23	270	17.51
Escenario 107	154	40	114	84	45	153	59	162	300	14.28	249	17.67	228	6.56	192	6.62	272	5.15	295	26.00	233	28.41	116	22.27
Escenario 108	91	49	65	165	83	42	44	68	259	29.69	159	8.98	201	25.03	225	28.90	268	7.52	230	23.79	168	6.60	132	22.43
Escenario 109	31	116	149	196	78	66	122	140	99	6.00	255	6.58	276	24.16	287	5.63	175	26.72	219	10.72	244	25.62	52	21.22
Escenario 110	181	47	54	30	128	109	41	107	63	26.68	123	7.94	201	23.34	153	22.36	188	22.04	236	28.91	163	12.31	231	11.88
Escenario 111	52	130	100	104	140	65	23	159	241	18.47	243	10.68	66	12.49	259	7.06	98	7.82	224	8.70	65	16.10	255	8.91
Escenario 112	67	80	109	45	52	126	173	56	224	15.97	223	13.54	182	9.34	91	27.77	162	26.05	271	21.99	296	5.55	113	20.90
Escenario 113	170	67	27	82	200	159	48	80	78	23.13	58	14.52	197	20.94	109	16.61	87	11.06	282	10.62	132	12.53	89	19.98
Escenario 114	81	166	112	105	169	160	128	190	253	17.17	52	13.66	70	17.40	261	8.44	113	16.96	211	15.78	228	17.57	108	9.48
Escenario 115	56	23	173	78	40	123	117	143	213	26.84	134	10.98	281	9.46	247	13.52	118	8.63	214	22.98	299	6.40	232	22.63
Escenario 116	118	54	109	46	89	130	56	58	300	27.52	75	17.74	107	22.15	61	9.12	185	22.75	183	19.08	293	17.28	111	16.38
Escenario 117	191	68	181	196	131	123	94	82	276	15.54	121	25.65	208	29.78	179	9.26	211	21.67	184	15.69	257	28.18	181	21.69
Escenario 118	123	36	134	180	23	79	89	65	229	11.92	97	11.99	159	23.68	56	28.70	225	10.28	273	13.16	121	7.63	300	25.93
Escenario 119	54	191	124	117	113	190	165	107	174	19.81	243	28.56	277	23.50	129	16.13	165	26.59	273	25.99	173	24.11	169	9.24
Escenario 120	120	177	154	124	94	119	147	30	253	27.81	247	26.83	188	28.76	180	24.72	233	15.03	294	8.60	274	15.24	165	5.48
Escenario 121	194	65	77	118	81	87	104	81	56	10.27	205	9.04	229	10.07	158	20.99	253	12.31	202	15.75	162	21.38	124	24.48
Escenario 122	150	136	133	148	113	152	61	96	78	20.57	166	24.66	192	19.14	52	21.91	279	8.81	82	27.59	61	11.51	171	20.24
Escenario 123	20	25	94	168	114	139	119	172	188	20.79	270	19.36	260	29.49	76	8.29	114	11.65	104	26.15	175	8.99	272	22.49
Escenario 124	24	118	176	74	171	56	60	71	82	23.33	203	19.16	184	9.13	163	10.85	80	5.55	235	15.02	102	9.01	156	25.95
Escenario 125	161	143	139	25	74	91	185	23	183	8.29	202	14.78	292	22.51	156	24.67	181	19.58	56	24.08	124	6.76	145	25.07
Escenario 126	122	56	183	114	156	145	53	78	160	22.90	61	17.53	77	19.65	89	29.27	162	26.06	293	25.58	182	9.64	140	29.02
Escenario 127	46	43	40	152	150	125	36	91	128	27.73	182	14.93	100	19.66	279	11.57	158	18.72	106	27.22	76	21.61	207	18.40
Escenario 128	156	112	183	121	50	111	184	167	209	9.49	275	18.49	284	22.44	210	11.79	227	10.48	175	18.61	189	27.04	284	17.21
Escenario 129	34	65	157	22	59	50	172	112	228	10.94	97	20.70	235	28.24	269	16.82	118	5.84	61	10.11	194	25.35	179	15.05
Escenario 130	109	200	120	200	55	141	141	82	252	29.28	86	21.86	54	24.56	178	29.60	207	10.37	65	11.58	183	22.13	111	8.84
Escenario 131	61	114	171	42	171	156	95	73	107	9.52	256	18.31	54	6.40	296	11.72	169	15.40	257	12.59	146	7.76	98	19.32
Escenario 132	143	118	196	72	25	70	106	136	264	26.36	93	20.04	143	26.32	57	15.17	137	23.99	92	19.85	54	12.23	186	11.93
Escenario 133	198	155	118	184	85	48	136	129	75	17.31	277	8.53	295	10.64	150	27.29	236	9.70	166	5.82	106	12.75	141	28.03
Escenario 134	82	179	55	102	94	59	125	93	275	11.18	64	10.30	145	14.42	269	5.07	116	22.99	277	20.90	252	11.25	208	19.58
Escenario 135	115	180	115	164	23	60	105	126	223	26.77	92	23.47	57	16.54	173	5.99	124	26.67	254	14.11	127	17.88	173	19.82
Escenario 136	71	86	171	104	98	30	46	76	275	16.13	225	13.06	113	17.02	225	20.10	94	16.35	184	12.58	118	18.39	275	13.87
Escenario 137	115	147	170	97	153	170	76	188	78	17.87	136	5.57	187	15.88	156	27.68	53	25.54	277	26.99	167	13.92	110	6.30
Escenario 138	151	37	56	129	137	20	50	22	53	13.98	119	8.84	87	28.43	150	10.97	203	18.87	160	16.50	169	13.84	297	5.79
Escenario 139	170	44	31	20	132	65	153	139	258	19.82	95	10.59	160	22.65	53	16.74	204	20.93	100	7.38	108	25.71	256	15.58
Escenario 140	162	72	132	70	113	120	187	25	148	9.09	291	28.92	273	20.78	271	16.26	223	18.16	250	25.67	82	24.73	97	7.11
Escenario 141	190	77	32	192	198	168	117	24	190	14.78	157	19.33	161	6.25	247	16.82	295	16.59	209	6.19	111	12.69	202	20.17
Escenario 142	48	86	42	23	81	109	31	24	283	29.24	172	28.32	269	27.60	159	20.56	156	10.87	124	23.17	99	27.84	213	27.02
Escenario 143	55	123	118	132	98	129	72	73	88	11.45	220	19.38	150	27.73	295	16.74	241	12.58	57	24.35	161	28.82	185	27.07
Escenario 144	32	193	124	51	155	183	157	66	64	21.42	286	16.98	272	24.51	68	16.19	268	12.25	274	13.82	292	13.17	250	21.48
Escenario 145	179	43	49	53	45	76	192	196	168	13.12	70	12.84	185	5.18	81	16.86	283	19.08	264	25.62	68	13.86	299	10.28
Escenario 146	90	133	36	111	198	20	164	28	78	24.24	200	20.16	153	6.43	186	19.77	100	8.00	266	17.89	263	17.64	107	26.57
Escenario 147	105	51	132	114	192	82	173	118	206	8.27	156	8.48	202	10.63	61	18.43	99	27.92	297	16.58	246	25.84	150	27.15
Escenario 148	47	194	81	91	63	74	141	39	124	29.25	296	27.46	122	8.28	188	26.35	55	23.02	249	6.14	172	26.91	161	9.92
Escenario 149	85	105	103	58	152	134	65	141	165	16.24	129	25.73	243	14.97	95	6.24	108	15.04	94	12.25	243	7.56	222	39.44
Escenario 150	189	170	131	173	89	187	83	80	81	10.90	96	12.84	256	28.07	169	25.83	174	8.97	263	28.28	271	14.82	111	12.16
Escenario 151	64	146	105	181	173	162	149	142	179	6.84	166	28.82	227	16.80	65	26.10	192	27.05	108	14.80	96	18.83	88	25.07
Escenario 152	81	174	160	137	168	73	182	224	9.24	173	25.63	244	5.34	178	12.12	294	25.59	181	18.67	216	17.58	273	29.93	
Escenario 153	153	149	38	22	87	194	126	197	255	17.99	192	21.66	98	12.07	112	16.57	79	23.04	153	18.30	245	9.85	107	5.75
Escenario 154	47	36	196	142	38	72	70	101	133	13.43	74	8.04	85	5.11	158	15.96	219	11.79	244	19.76	82	26.47	293	27.43
Escenario 155	47	123	119	69	39	156	200	81	71	25.72	85	16.96	175	5.91	168	10.46	278	15.06	206	6.53	190	21.92	258	20.57
Escenario 156	127	180	159																					

ANEXO C

Código de modelo de Random Forest aplicado a sistema de 8 nodos.

```
import pandas as pd
import numpy as np
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split,
RandomizedSearchCV
from sklearn.metrics import mean_squared_error,
mean_absolute_error
import joblib

# 1. Cargar datos de Excel
ruta = r"C:\Users\kpcampos\Desktop\Pruebas\Escenarios PYPSA -
MER.xlsx"
df_ent = pd.read_excel(ruta, sheet_name="Entradas-8nodos",
header=1)
df_sal = pd.read_excel(ruta, sheet_name="Resultados-8nodos",
header=1)

# 2. Definir función para filtrar columnas
def filter_cols(df, cols, name):
    present = [c for c in cols if c in df.columns]
    missing = [c for c in cols if c not in df.columns]
    if missing:
        print(f"Advertencia: en {name} faltan columnas:
{missing}")
    return present

# 3. Columnas esperadas
todas_X = [
    "Escenario",
    "Load 1 (MW)", "Load 2 (MW)", "Load 3 (MW)", "Load 4 (MW)",
    "Load 5 (MW)", "Load 6 (MW)", "Load 7 (MW)", "Load 8 (MW)",
    "Gen 1 p_nom (MW)", "Coste 1 ($/MWh)",
    "Gen 2 p_nom (MW)", "Coste 2 ($/MWh)",
    "Gen 3 p_nom (MW)", "Coste 3 ($/MWh)",
    "Gen 4 p_nom (MW)", "Coste 4 ($/MWh)",
    "Gen 5 p_nom (MW)", "Coste 5 ($/MWh)",
    "Gen 6 p_nom (MW)", "Coste 6 ($/MWh)",
    "Gen 7 p_nom (MW)", "Coste 7 ($/MWh)",
    "Gen 8 p_nom (MW)", "Coste 8 ($/MWh)"
]
todas_y = [
    "Escenario",
    "Despacho G1 (MW)", "Despacho G2 (MW)", "Despacho G3 (MW)",
    "Despacho G4 (MW)",
```

```

    "Despacho G5 (MW)", "Despacho G6 (MW)", "Despacho G7 (MW)",
    "Despacho G8 (MW)",
    "Carga servida 1 (MW)", "Carga servida 2 (MW)", "Carga
servida 3 (MW)", "Carga servida 4 (MW)",
    "Carga servida 5 (MW)", "Carga servida 6 (MW)", "Carga
servida 7 (MW)", "Carga servida 8 (MW)",
    "Precio N1 ($/MWh)", "Precio N2 ($/MWh)", "Precio N3
($/MWh)", "Precio N4 ($/MWh)",
    "Precio N5 ($/MWh)", "Precio N6 ($/MWh)", "Precio N7
($/MWh)", "Precio N8 ($/MWh)",
    "Precio NE1 ($/MWh)", "Precio NE2 ($/MWh)",
    "Flujo L1_N2 (MW)", "Flujo L3_N2 (MW)", "Flujo L2_NE1 (MW)",
"Flujo L4_NE1 (MW)",
    "Flujo L6_N7 (MW)", "Flujo L8_N7 (MW)", "Flujo L7_NE2 (MW)",
"Flujo L5_NE2 (MW)",
    "Flujo L_NE1_NE2 (MW)"
]

# 4. Filtrar columnas presentes
ent_cols = filter_cols(df_ent, todas_x, "Entradas")
sal_cols = filter_cols(df_sal, todas_y, "Salidas")

# 5. Unir tablas
merged = pd.merge(
    df_ent[ent_cols],
    df_sal[sal_cols],
    on="Escenario",
    how="inner"
)

# 6. Preparar X e y, y eliminar NAs
X = merged[[c for c in ent_cols if c != "Escenario"]]
y = merged[[c for c in sal_cols if c != "Escenario"]]
scenarios = merged["Escenario"]
mask = X.notna().all(axis=1) & y.notna().all(axis=1)
X = X[mask]
y = y[mask]
scenarios = scenarios[mask]

# 7. División entrenamiento/prueba
X_train, X_test, y_train, y_test, sc_train, sc_test =
train_test_split(
    X, y, scenarios, test_size=0.2, random_state=42
)

# 8. Definir hiperparámetros para RandomizedSearchCV
param_dist = {
    'n_estimators': [100, 200, 300, 500],

```

```

    'max_depth': [None, 10, 20, 30, 40],
    'min_samples_split': [2, 5, 10],
    'min_samples_leaf': [1, 2, 4],
    'max_features': ['auto', 'sqrt', 'log2']
}

# 9. Configurar y ejecutar búsqueda aleatoria
en_rf = RandomForestRegressor(random_state=42)
search = RandomizedSearchCV(
    estimator=en_rf,
    param_distributions=param_dist,
    n_iter=20,
    cv=3,
    scoring='neg_mean_squared_error',
    n_jobs=-1,
    random_state=42,
    verbose=1
)
search.fit(X_train, y_train)
best_rf = search.best_estimator_
print("Mejores hiperparámetros:", search.best_params_)

# 10. Evaluación
y_pred = best_rf.predict(X_test)
mse_vals = mean_squared_error(y_test, y_pred,
multioutput='raw_values')
rmse_vals = np.sqrt(mse_vals)
mae_vals = mean_absolute_error(y_test, y_pred,
multioutput='raw_values')
print("\nMétricas tras optimización:")
for col, rmse, mae in zip(y.columns, rmse_vals, mae_vals):
    print(f" - {col}: RMSE = {rmse:.3f}, MAE = {mae:.3f}")

# 11. Guardar resultados y modelo
results = pd.concat([
    sc_test.reset_index(drop=True).rename('Escenario'),
    y_test.reset_index(drop=True),
    pd.DataFrame(y_pred, columns=[f'Pred_{c}' for c in
y.columns])
], axis=1)
results.to_excel("resultados_comparacion_optimo.xlsx",
index=False)
print("Guardado: resultados_comparacion_optimo.xlsx")
joblib.dump(best_rf, "rf_multisalida_best.pkl")
print("Guardado modelo: rf_multisalida_best.pkl")

```

ANEXO D

Código de entrenamiento de modelo para predicción del MER

```
import os
import numpy as np
import pandas as pd
import joblib

from sklearn.ensemble import RandomForestRegressor
from sklearn.multioutput import MultiOutputRegressor
from sklearn.model_selection import TimeSeriesSplit,
RandomizedSearchCV
from sklearn.metrics import mean_squared_error,
mean_absolute_error

import lightgbm as lgb

# 1. Rutas
folder = r"C:\Users\kpcampos\Desktop\Pruebas\prediccionMER"
input_file = os.path.join(folder, "tablaMER.xlsx")
output_file = os.path.join(folder, "resultados_lag_franjas.xlsx")

# 2. Carga
df = pd.read_excel(input_file, sheet_name="tablaMER")

# 3. Variables calendario
df["fecha"] = pd.to_datetime(df["fecha"], dayfirst=True)
df["mes"] = df["fecha"].dt.month
df["día"] = df["fecha"].dt.day
df["hora"] = df["periodo"].astype(int)
df["weekday"] = df["fecha"].dt.weekday
df["dia_semana"] = df["weekday"] + 1

# ——— Definir franjas horarias ———
# Ajusta estas listas a tu criterio
peak_hours = list(range(6, 11)) + list(range(18, 23)) # 6-10h
y 18-22h
valley_hours = list(range(0, 6)) # 0-5h
# El resto (11-17h) será la franja "shoulder"

# Indicadores binarios
df["is_peak"] = df["hora"].isin(peak_hours).astype(int)
df["is_valley"] = df["hora"].isin(valley_hours).astype(int)
df["is_shoulder"] = (~df["hora"].isin(peak_hours +
valley_hours)).astype(int)

# (Opcional) columna categórica
def label_franja(h):
```

```

    if h in peak_hours:    return "peak"
    if h in valley_hours: return "valley"
    return "shoulder"

df["franja"] = df["hora"].apply(label_franja)

# Y si quieres pasarla a dummies:
df = pd.get_dummies(df, columns=["franja"], prefix="franja")

# 4. Listado de salidas
target_cols = [
    "01iMPred", "01rMPred", "01PEx",
    "02iMPred", "02rMPred", "02PEx",
    "03iMPred", "03rMPred", "03PEx",
    "04iMPred", "04rMPred", "04PEx",
    "05iMPred", "05rMPred", "05PEx",
    "06iMPred", "06rMPred", "06PEx"
]

# 5. Ingeniería de lags (solo 24h y 168h) y rolling (3h, 24h)
lags      = [1, 24, 168]
windows   = [3, 24]

for col in target_cols:
    for lag in lags:
        df[f"{col}_lag{lag}"] = df[col].shift(lag)
    for w in windows:
        df[f"{col}_roll{w}"] = df[col].rolling(w).mean().shift(1)

# 6. Eliminar filas con NaN creadas por los lags/rolling
df.dropna(inplace=True)

# 7. Split temporal: 2024 → train, 2025 → test
mask_train = df["fecha"].dt.year == 2024
mask_test  = df["fecha"].dt.year == 2025

# 8. Definir features (todo menos targets, fecha y periodo)
feature_cols = [c for c in df.columns
                 if c not in target_cols + ["fecha", "periodo"]]

X = df[feature_cols]
y = df[target_cols]

X_train, X_test = X[mask_train], X[mask_test]
y_train, y_test = y[mask_train], y[mask_test]

# 9. Búsqueda de hiperparámetros RF
tscv = TimeSeriesSplit(n_splits=5)

```

```

base_rf = MultiOutputRegressor(
    RandomForestRegressor(n_jobs=-1, random_state=42)
)
param_dist = {
    "estimator__n_estimators": [100, 200, 500],
    "estimator__max_depth": [None, 10, 20],
    "estimator__max_features": ["auto", "sqrt"],
    "estimator__min_samples_leaf": [1, 5, 10]
}
search = RandomizedSearchCV(
    base_rf, param_dist,
    n_iter=10, cv=tscv,
    scoring="neg_mean_squared_error",
    n_jobs=-1, random_state=0, verbose=1
)
search.fit(X_train, y_train)
best_rf = search.best_estimator_

# 10. Predicción con RF
y_pred_rf = pd.DataFrame(
    best_rf.predict(X_test),
    columns=target_cols,
    index=y_test.index
)

# 11. Predicción con LightGBM
base_lgb = MultiOutputRegressor(
    lgb.LGBMRegressor(
        n_estimators=500,
        learning_rate=0.05,
        num_leaves=31,
        n_jobs=-1,
        random_state=42
    )
)
base_lgb.fit(X_train, y_train)
y_pred_lgb = pd.DataFrame(
    base_lgb.predict(X_test),
    columns=target_cols,
    index=y_test.index
)

# 12. Función para métricas
def calc_metrics(y_true, y_pred):
    rows = []
    for c in target_cols:
        mse = mean_squared_error(y_true[c], y_pred[c])
        rmse = np.sqrt(mse)

```

```

    mae      = mean_absolute_error(y_true[c], y_pred[c])
    mean_v   = y_true[c].mean()
    rows.append({
        "variable":    c,
        "RMSE":        rmse,
        "MAE":         mae,
        "RMSE_rel_%":  (rmse/mean_v)*100 if mean_v else
np.nan,
        "MAE_rel_%":   (mae/mean_v)*100  if mean_v else np.nan
    })
    return pd.DataFrame(rows)

df_metrics_rf = calc_metrics(y_test, y_pred_rf)
df_metrics_lgb = calc_metrics(y_test, y_pred_lgb)

# 13. Guardar todo en Excel
with pd.ExcelWriter(output_file, engine="openpyxl") as writer:
    # Predicciones
    df_preds = pd.concat([
        df.loc[mask_test,
["fecha", "periodo"]].reset_index(drop=True),
        y_test.reset_index(drop=True),
        y_pred_rf.reset_index(drop=True).add_suffix("_rf"),
        y_pred_lgb.reset_index(drop=True).add_suffix("_lgb")
    ], axis=1)
    df_preds.to_excel(writer, sheet_name="predicciones",
index=False)

    # Métricas
    df_metrics_rf.to_excel(writer, sheet_name="metricas_rf",
index=False)
    df_metrics_lgb.to_excel(writer, sheet_name="metricas_lgb",
index=False)

print(f" Prueba sin lag1 completada.\n  Revisa {output_file}")

# 14. Guardar el modelo entrenado en un archivo .pkl
modelo_guardado_path = os.path.join(folder,
"modelo_randomforest_entrenado.pkl")
joblib.dump(best_rf, modelo_guardado_path)

print(f" Modelo guardado en: {modelo_guardado_path}")

# Guardar listado de columnas usadas en el entrenamiento
feature_cols_path = os.path.join(folder,
"columnas_entrenamiento.pkl")
joblib.dump(feature_cols, feature_cols_path)

```

ANEXO E

Código de entrenamiento de modelo para predicción del CMO.

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import StandardScaler
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, r2_score
import matplotlib.pyplot as plt

# === Cargar archivo y hoja base de datos ===
ruta_archivo =
r"C:\Users\kpcampos\Desktop\Pruebas\BD_redneu.xlsx"
df = pd.read_excel(ruta_archivo, sheet_name="Base de datos")

# Eliminar filas con valores nulos
df = df.dropna()

# === Definir variables de entrada y salida ===
columnas_entrada = [
    "Demanda nacional", "Intercambios guatemala", "Intercambios
honduras",
    "Potencia hidro inyectada", "Potencia GRNC inyectada",
    "Potencia geotermica inyectada", "Potencia biomasa
inyectada",
    "Potencia termica inyectada", "precio hidro", "precio GRNC",
    "precio geotermico", "Precio biomasa", "Precio termico"
]
columna_salida = "CMO [$/MWh]"

# === Preparar datos ===
X = df[columnas_entrada]
y = df[columna_salida].values
fechas = df["Fecha"].values

# === División de datos con fechas incluidas ===
X_train, X_test, y_train, y_test, fechas_train, fechas_test =
train_test_split(
    X, y, fechas, test_size=0.2, random_state=42
)

# === Escalar las variables de entrada ===
scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)
```

```

# === Entrenamiento del modelo ===
rf = RandomForestRegressor(n_estimators=100, max_depth=10,
random_state=42)
rf.fit(X_train_scaled, y_train)

# === Predicción y evaluación ===
y_pred = rf.predict(X_test_scaled)
mse = mean_squared_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)

print(f"MSE Random Forest: {mse:.2f}")
print(f"R2 Score: {r2:.4f}")

# === Guardar resultados en Excel por fecha ===
df_resultado = pd.DataFrame({
    "Fecha": fechas_test,
    "CMO real": y_test,
    "CMO predicho": y_pred
})
df_resultado.to_excel(r"C:\Users\kpcampos\Desktop\Pruebas\datos\resultados_rf.xlsx", index=False)
print(" Resultados guardados en resultados_rf.xlsx")

# === Gráfico de comparación ===
plt.figure(figsize=(10, 6))
plt.plot(np.sort(y_test), label="CMO real (ordenado)")
plt.plot(np.sort(y_pred), label="CMO predicho (ordenado)")
plt.title("Random Forest: CMO real vs. predicho")
plt.xlabel("Muestras ordenadas")
plt.ylabel("CMO [$/MWh]")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()

import joblib
# Guardar el modelo entrenado
joblib.dump(rf,
r"C:\Users\kpcampos\Desktop\Pruebas\modelo_rf_precio_energia.pkl"
)

# Guardar el escalador de entradas
joblib.dump(scaler,
r"C:\Users\kpcampos\Desktop\Pruebas\scaler_X_rf_precio_energia.pkl"
)

print(" Modelo y escalador guardados correctamente.")

```

ANEXO F

Código de modelo ya entrenado para predicción del MER

```
import os
import pandas as pd
import numpy as np
import joblib
import matplotlib.pyplot as plt
from openpyxl import load_workbook
from openpyxl.drawing.image import Image as XLImage

# 1. Rutas
folder = r"C:\Users\kpcampos\Desktop\Pruebas\prediccionMER"
modelo_path = os.path.join(folder,
"modelo_randomforest_entrenado.pkl")
features_path = os.path.join(folder,
"columnas_entrenamiento.pkl")
input_nuevos_datos = os.path.join(folder, "tablaMER.xlsx")
output_predicciones = os.path.join(folder,
"predicciones_nuevos_datos.xlsx")

# 2. Cargar modelo entrenado y columnas originales
modelo = joblib.load(modelo_path)
feature_cols = joblib.load(features_path)

# 3. Cargar nuevos datos
df = pd.read_excel(input_nuevos_datos, sheet_name="tablaMER")

# 4. Procesamiento igual al modelo original
df["fecha"] = pd.to_datetime(df["fecha"], dayfirst=True)
df["mes"] = df["fecha"].dt.month
df["día"] = df["fecha"].dt.day
df["hora"] = df["periodo"].astype(int)
df["weekday"] = df["fecha"].dt.weekday
df["dia_semana"] = df["weekday"] + 1

# Franjas horarias
peak_hours = list(range(6, 11)) + list(range(18, 23))
valley_hours = list(range(0, 6))

df["is_peak"] = df["hora"].isin(peak_hours).astype(int)
df["is_valley"] = df["hora"].isin(valley_hours).astype(int)
```

```

df["is_shoulder"] = (~df["hora"].isin(peak_hours +
valley_hours)).astype(int)

def label_franja(h):
    if h in peak_hours:    return "peak"
    if h in valley_hours: return "valley"
    return "shoulder"

df["franja"] = df["hora"].apply(label_franja)
df = pd.get_dummies(df, columns=["franja"], prefix="franja")

# 5. Variables objetivo y lags
target_cols = [
    "01iMPred", "01rMPred", "01PEx",
    "02iMPred", "02rMPred", "02PEx",
    "03iMPred", "03rMPred", "03PEx",
    "04iMPred", "04rMPred", "04PEx",
    "05iMPred", "05rMPred", "05PEx",
    "06iMPred", "06rMPred", "06PEx"
]

lags = [1, 24, 168]
windows = [3, 24]

for col in target_cols:
    for lag in lags:
        df[f"{col}_lag{lag}"] = df[col].shift(lag)
    for w in windows:
        df[f"{col}_roll{w}"] = df[col].rolling(w).mean().shift(1)

df.dropna(inplace=True)

# 6. Asegurar que estén todas las columnas del modelo
for col in feature_cols:
    if col not in df.columns:
        df[col] = 0 # columna faltante → la crea con ceros

X_nuevo = df[feature_cols]

# 7. Predicción
y_pred_nuevo = modelo.predict(X_nuevo)

# Forzar salidas del país 01 a cero (simulación de ausencia del
país 01)
#cols_pais01 = ["01iMPred", "01rMPred", "01PEx"]
#for i, col in enumerate(cols_pais01):
    # y_pred_nuevo[:, i] = 0

```

```

# 8. Crear DataFrame de comparación
df_resultado = pd.concat([
    df[["fecha", "periodo"]].reset_index(drop=True),
    df[target_cols].reset_index(drop=True).add_suffix("_real"),
    pd.DataFrame(y_pred_nuevo,
columns=target_cols).add_suffix("_pred")
], axis=1)

# 9. Guardar en Excel
df_resultado.to_excel(output_predicciones,
sheet_name="comparacion", index=False)

import os
import matplotlib.pyplot as plt
from openpyxl import load_workbook
from openpyxl.drawing.image import Image as XLImage

# Variables a graficar
variables_pais02 = ["02iMPred", "02rMPred", "02PEx"]

# Mapeo de variable → título personalizado
title_map = {
    "02iMPred": "Comparación de MW inyectados de El Salvador
(02iMPred)",
    "02rMPred": "Comparación de MW retirados de El Salvador
(02rMPred)",
    "02PEx": "Comparación de precio exante de El Salvador
(02PEx)"
}

graficas = []

for var in variables_pais02:
    data_real = df_resultado[var + "_real"]
    data_pred = df_resultado[var + "_pred"]

    plt.figure(figsize=(10, 4))
    # Línea "Real" en color por defecto (azul)
    plt.plot(data_real, label="Real")
    # Línea "Predicho" en color por defecto (naranja)
    plt.plot(data_pred, label="Predicho")

    plt.title(title_map[var])
    plt.xlabel("Índice por hora")
    if var in ["02iMPred", "02rMPred"]:
        plt.ylabel("[MWh]")
    else:

```

```

plt.ylabel("[$/MWh]")

plt.legend()
plt.tight_layout()

img_name = f"grafica_{var}.png"
img_path = os.path.join(folder, img_name)
plt.savefig(img_path)
plt.close()
graficas.append(img_path)

# Insertar todas las gráficas en una hoja de Excel nueva
book = load_workbook(output_predicciones)
sheet = book.create_sheet("graficas_pais02")

fila_actual = 1
for img_path in graficas:
    img = XLImage(img_path)
    img.anchor = f"A{fila_actual}"
    sheet.add_image(img)
    fila_actual += 25 # espacio vertical entre imágenes

book.save(output_predicciones)

# Eliminar las imágenes temporales
for img_path in graficas:
    if os.path.exists(img_path):
        os.remove(img_path)

print(f" Predicción completada y resultados guardados
en:\n{output_predicciones}")

```

ANEXO G

Código de modelo ya entrenado para predicción del CMO.

```
import pandas as pd
import joblib
from sklearn.preprocessing import StandardScaler
import matplotlib.pyplot as plt
from openpyxl import load_workbook
from openpyxl.drawing.image import Image as Img
import tempfile

# === Ruta de entrada del nuevo archivo ===
ruta_nuevo_excel =
r"C:\Users\kpcampos\Desktop\Pruebas\BD_redneu_2025.xlsx"
df_nuevo = pd.read_excel(ruta_nuevo_excel, sheet_name="Base de
datos")

# === Definir columnas de entrada (deben coincidir con las usadas
al entrenar) ===
columnas_entrada = [
    "Demanda nacional", "Intercambios guatemala", "Intercambios
honduras",
    "Potencia hidro inyectada", "Potencia GRNC inyectada",
    "Potencia geotermica inyectada", "Potencia biomasa
inyectada",
    "Potencia termica inyectada", "precio hidro", "precio GRNC",
    "precio geotermico", "Precio biomasa", "Precio termico"
]

# === Cargar modelo y escalador entrenado ===
modelo =
joblib.load(r"C:\Users\kpcampos\Desktop\Pruebas\modelo_rf_precio_
energia.pkl")
scaler =
joblib.load(r"C:\Users\kpcampos\Desktop\Pruebas\scaler_X_rf_precio_
energia.pkl")

# === Preparar datos de entrada ===
df_nuevo = df_nuevo.dropna(subset=columnas_entrada) # quitar
nulos si existen
X_nuevo = df_nuevo[columnas_entrada].values
X_nuevo_scaled = scaler.transform(X_nuevo)

# === Realizar predicciones ===
y_pred_nuevo = modelo.predict(X_nuevo_scaled)
```

```

# === Guardar resultados en un nuevo archivo Excel ===
df_resultado = df_nuevo.copy()
df_resultado["CMO predicho"] = y_pred_nuevo

# Ruta de salida
ruta_salida =
r"C:\Users\kpcampos\Desktop\Pruebas\datos\predicciones_rf.xlsx"
df_resultado.to_excel(ruta_salida, index=False)

# === Mostrar rango de fechas si existe ===
if "Fecha" in df_resultado.columns:
    print("Fechas mínimas y máximas en los datos procesados:")
    print(df_resultado["Fecha"].min())
    print(df_resultado["Fecha"].max())
else:
    print(" No se encontró una columna llamada 'Fecha' para
mostrar el rango.")

# === Generar gráfico de CMO real vs predicho con fechas si están
disponibles ===
if "CMO [$/MWh]" in df_resultado.columns:
    plt.figure(figsize=(12, 5))

    # Usar fechas si existen
    if "Fecha" in df_resultado.columns:
        x_vals = pd.to_datetime(df_resultado["Fecha"],
dayfirst=True, errors='coerce')
        plt.plot(x_vals, df_resultado["CMO [$/MWh]"], label="CMO
real")
        plt.plot(x_vals, df_resultado["CMO predicho"], label="CMO
predicho", linestyle='--')
        plt.xlabel("Fecha")
    else:
        x_vals = df_resultado.index
        plt.plot(x_vals, df_resultado["CMO [$/MWh]"], label="CMO
real")
        plt.plot(x_vals, df_resultado["CMO predicho"], label="CMO
predicho", linestyle='--')
        plt.xlabel("Índice")

    plt.title("CMO real vs CMO predicho")
    plt.ylabel("CMO [$/MWh]")
    plt.legend()
    plt.xticks(rotation=45)
    plt.tight_layout()

# Guardar imagen temporal

```

```

    temp_img1 = tempfile.NamedTemporaryFile(suffix=".png",
delete=False)
    plt.savefig(temp_img1.name, bbox_inches="tight")
    plt.close()

    # Cargar Excel y pegar imagen
    wb = load_workbook(ruta_salida)
    ws = wb.active
    img = Image(temp_img1.name)
    img.anchor = "O2"
    ws.add_image(img)

    wb.save(ruta_salida)
    wb.close()

    print(" Gráfico con fechas embebido en el Excel.")
else:
    print(" No se encontró la columna 'CMO [$/MWh]' para
comparar.")

    # === Calcular MAE y MAPE para CMO ===
if "CMO [$/MWh]" in df_resultado.columns:
    y_true = df_resultado["CMO [$/MWh]"].values
    y_pred = df_resultado["CMO predicho"].values
    mae = mean_absolute_error(y_true, y_pred)
    mape = np.mean(np.abs((y_true - y_pred) / y_true)) * 100
    print(f"MAE CMO: {mae:.2f} $/MWh")
    print(f"MAPE CMO: {mape:.2f}%")
else:
    print(" No se encontró la columna 'CMO [$/MWh]' para el
cálculo de métricas.")

```