

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS

Integración de Pronósticos Avanzados con Políticas de Despacho para
Apoyar Metas de Descarbonización: Un enfoque híbrido
LSTM–Programación Lineal aplicado al sistema eléctrico chileno

TESIS PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL Y MAGÍSTER
EN CIENCIAS DE LA INGENIERIA INDUSTRIAL

Autor

Felipe Carrasco Gomez

PROFESOR GUÍA

Fredy Kristjanpoller

PROFESOR CORREFERENTE

Ignacio Verdugo

Pablo Viveros

4 de agosto de 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

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

Título del trabajo: Integración de Pronósticos Avanzados con Políticas de Despacho para Apoyar Metas de Descarbonización: Un enfoque híbrido

LSTM–Programación Lineal aplicado al sistema eléctrico chileno

Nombre del candidato(a): Felipe Ignacio Carrasco Gomez

Carrera / Grado: Ingeniería civil industrial/Magister en ciencias de la ingeniería industrial

Campus: Casa Central Valparaíso ; **Departamento:** Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Fredy Kristjanpoller Rodríguez, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

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

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

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

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

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

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

4.- FIRMAS

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

Fecha: 04-08-2025

; Firma:

Estudiante o Candidato(a):

Fecha: 04-08-2025

; Firma:

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



Tabla de Contenidos

| | |
|--|-----------|
| 1. Resumen Ejecutivo | 4 |
| 2. Introducción | 6 |
| 3. Objetivos | 10 |
| 3.1. Objetivo General | 10 |
| 3.2. Objetivos Específicos | 11 |
| 4. Alcance | 13 |
| 5. Marco teórico | 15 |
| 5.1. Contexto y Transición Energética | 15 |
| 5.2. Mercados Eléctricos y Políticas de Flexibilidad | 17 |
| 5.3. Despacho Energético a Corto Plazo | 19 |
| 5.4. Modelos de Pronóstico en Energía | 21 |
| 5.4.1. Redes LSTM (Long Short-Term Memory) | 21 |
| 5.4.2. GRU (Gated Recurrent Unit) | 22 |
| 5.4.3. Transformer | 22 |
| 5.4.4. TCN (Temporal Convolutional Networks) | 23 |
| 5.5. Optimización del Despacho Energético | 24 |
| 5.6. Integración Pronóstico–Optimización | 27 |
| 5.7. Modelos bajo Incertidumbre | 29 |
| 5.8. Brechas Metodológicas y Motivación del Estudio | 32 |



| | |
|--|-----------|
| 6. Metodología | 36 |
| 6.1. Preparación de Datos: Preprocesamiento, Ingeniería de Características y Partición del Conjunto de Datos | 36 |
| 6.2. Optimización de Hiperparámetros | 39 |
| 6.3. Entrenamiento y Evaluación del Modelo | 41 |
| 6.4. Métricas de Desempeño en el Pronóstico | 43 |
| 6.5. Evaluación Comparativa de Modelos de Pronóstico | 44 |
| 6.6. Modelo de Optimización | 45 |
| 6.7. Integración del Marco de Pronóstico y Optimización | 47 |
| 7. Case Study Application | 51 |
| 7.1. Recolección y Preprocesamiento de Datos | 51 |
| 7.2. Implementación del Módulo de Pronóstico | 54 |
| 7.3. Implementación del Módulo de Optimización | 56 |
| 8. Resultados | 58 |
| 8.1. Selección del Modelo de Pronóstico | 58 |
| 8.1.1. Supuestos y Metodología | 74 |
| 8.1.2. Resultados y Discusión | 75 |
| 8.1.3. Conclusiones Críticas | 78 |
| 8.2. Análisis de Sensibilidad ante Errores de Pronóstico | 79 |
| 9. Conclusiones y Recomendaciones de Política | 83 |
| 10. Discusión | 85 |



11. Limitaciones

91

1. Resumen Ejecutivo

El despacho eficiente de energía a corto plazo es fundamental para garantizar la estabilidad del sistema eléctrico y el cumplimiento de las metas de descarbonización en escenarios con alta penetración de energías renovables. Este trabajo propone un marco de decisión basado en pronósticos que integra modelos de aprendizaje profundo para la predicción de demanda con una optimización multiobjetivo orientada a la operación confiable y el alineamiento regulatorio.

En la etapa de pronóstico, se evalúan y comparan cuatro arquitecturas avanzadas de aprendizaje profundo: GRU, LSTM, Transformer y TCN. Los resultados demuestran que la red LSTM, optimizada mediante metaheurísticas, ofrece el mejor desempeño predictivo. Los pronósticos generados se incorporan a un modelo de programación lineal multiobjetivo, diseñado para minimizar simultáneamente los costos operativos, las emisiones de CO₂ y la dependencia de generación térmica, asegurando a su vez la suficiencia de reservas.

El marco propuesto se aplica al sistema eléctrico chileno, considerando datos históricos del período 2016–2023. Los resultados evidencian reducciones significativas en comparación con un esquema de despacho ingenuo: 22 % en costos operativos, 42 % en emisiones de CO₂ y 22,9 % en dependencia térmica. Además, se realiza un análisis de sensibilidad que revela que los errores de pronóstico afectan linealmente los costos, mientras que su impacto sobre las emisiones es no lineal y varía según la región, lo que subraya la necesidad de estándares de flexibilidad adaptativos.

Los hallazgos de este estudio aportan evidencia relevante para la formulación de políticas energéticas, destacando la importancia de integrar esquemas de despacho basados en pronósticos en el diseño de mercado, con el fin de estabilizar señales de precio del carbono, fortalecer la seguridad energética y acelerar la transición hacia sistemas eléctricos más sostenibles bajo condiciones



de alta incertidumbre renovable.

2. Introducción

El sector energético global atraviesa una profunda transición impulsada por el cambio climático, los objetivos de sostenibilidad y la rápida incorporación de fuentes renovables (58). Marcos internacionales como los Objetivos de Desarrollo Sostenible de las Naciones Unidas (particularmente el ODS 7) y las políticas nacionales de descarbonización han posicionado la planificación energética como un instrumento crítico para alcanzar transiciones hacia economías bajas en carbono (59; 60). Una planificación efectiva permite alinear la asignación de recursos con los objetivos climáticos, apoyando las estrategias de reducción de emisiones y fortaleciendo la seguridad energética (61). La evidencia proveniente de países de la OCDE demuestra que la planificación coordinada acelera la integración renovable, mejora la estabilidad del mercado y desacopla el crecimiento económico del uso de combustibles fósiles (64; 65).

Sin embargo, la incertidumbre regulatoria y la volatilidad en el precio del carbono afectan significativamente la planificación operativa y los requerimientos de reserva, introduciendo complejidades adicionales para operadores y reguladores (12). Estas dificultades subrayan la necesidad de marcos de despacho anticipativos basados en pronósticos, que actúen como herramientas estratégicas para garantizar el cumplimiento de los objetivos de descarbonización, estabilizar los mercados eléctricos y reforzar la seguridad energética frente a la incertidumbre renovable. Dichos enfoques están alineados con iniciativas globales como el *European Green Deal*, el Acuerdo de París y las Contribuciones Nacionalmente Determinadas (NDC), las cuales operacionalizan las rutas de descarbonización mediante estrategias de despacho accionables, en coherencia con evidencia reciente sobre políticas de sostenibilidad para la reducción de emisiones en los sectores de energía y residuos (25).

Instrumentos basados en el mercado, como el Sistema de Comercio de Emisiones de la Unión Europea (EU ETS) y su Reserva de Estabilidad del Mercado (MSR), han sido introducidos para estabilizar los precios del carbono y proporcionar señales de inversión de largo plazo bajo escenarios de variabilidad renovable (3). No obstante, estudios evidencian que parámetros mal calibrados pueden amplificar la volatilidad, incrementando el riesgo regulatorio. Esto refuerza la importancia de estrategias operativas complementarias que integren pronósticos avanzados con la planificación del despacho, permitiendo a los reguladores cumplir con los límites de emisiones sin comprometer la estabilidad del mercado. Al reducir la exposición a la volatilidad del carbono y optimizar el respaldo térmico bajo incertidumbre, estas estrategias pueden complementar la dinámica del ETS, los estándares de flexibilidad adoptados en mercados de la UE y la OCDE, y el cumplimiento de los NDC.

A pesar de los avances normativos, los enfoques tradicionales de despacho —basados en promedios históricos, pronósticos deterministas o reglas heurísticas— resultan insuficientes para gestionar la variabilidad inherente a la generación renovable (5). Una brecha metodológica persistente radica en la desconexión entre el pronóstico y la optimización operativa, lo que limita la efectividad de los mecanismos actuales para la programación con un día de anticipación, la planificación de reservas y el cumplimiento normativo (21; 15). Estudios recientes también destacan el papel del diseño regulatorio —como los requisitos de transparencia en mercados locales de flexibilidad— en la efectividad de estrategias operativas basadas en pronósticos (55). Cerrar esta brecha es fundamental para mantener la confiabilidad del sistema, reducir emisiones y garantizar eficiencia de costos, en coherencia con los compromisos de neutralidad de carbono.

En este escenario, la Inteligencia Artificial (IA), y en particular las técnicas de Aprendizaje Automático (ML) y Aprendizaje Profundo (DL), han emergido como habilitadores clave para

mejorar la precisión predictiva y respaldar operaciones de mercado adaptativas (1; 4; 6). Modelos basados en IA han demostrado un desempeño robusto en la predicción de demanda a corto plazo, pronóstico de generación renovable y optimización de respuesta a la demanda, facilitando diseños de mercado más flexibles y estrategias regulatorias más efectivas (23; 47). Entre estas arquitecturas, los enfoques híbridos que combinan modelos estadísticos y redes neuronales profundas, como las Long Short-Term Memory (LSTM), han mostrado alta eficacia para capturar dinámicas no lineales y variabilidad estacional (73; 50; 16). Estos enfoques son cada vez más reconocidos en políticas energéticas nacionales para mejorar la confiabilidad del sistema, reducir costos y acelerar la descarbonización (51; 31). Sin embargo, su integración operativa en esquemas de despacho y marcos regulatorios sigue siendo limitada, lo que crea una brecha crítica entre la analítica predictiva y la planificación normativa (18; 33; 39).

Para abordar esta brecha, este trabajo propone un marco integrado de apoyo a la decisión que combina pronósticos basados en LSTM, técnicas avanzadas de IA para mejorar el desempeño predictivo y un modelo de Programación Lineal (LP) multiobjetivo para la optimización del despacho a corto plazo. El enfoque propuesto ofrece información operativa y de valor regulatorio, complementando instrumentos como el ETS y la MSR al mejorar la programación basada en pronósticos y reducir la volatilidad asociada al costo del carbono. Aplicado al sistema eléctrico chileno un contexto alineado con la hoja de ruta hacia la carbono neutralidad al 2050 y las políticas de retiro del carbón, este marco demuestra alta transferibilidad a otros mercados con desafíos similares de integración renovable.

Las contribuciones principales de este estudio son las siguientes:

- Propone un marco híbrido LSTM–LP que vincula el pronóstico de demanda con políticas de despacho para sistemas eléctricos dominados por renovables.

- Demuestra que la programación informada por pronósticos reduce costos, dependencia térmica y emisiones de CO₂, al tiempo que mejora la confiabilidad del sistema.
- Proporciona lineamientos prácticos para reguladores y operadores orientados a fortalecer la seguridad energética, la estabilidad del mercado y las estrategias de descarbonización bajo incertidumbre renovable.

Al cerrar la brecha entre la analítica predictiva y la gobernanza operativa, este estudio ofrece un marco escalable diseñado no solo para lograr eficiencia técnica, sino también para mejorar el cumplimiento normativo y la resiliencia regulatoria. El resto de este documento se organiza de la siguiente manera: la Sección [5](#) revisa la literatura relacionada y las bases metodológicas; la Sección [6](#) describe el marco propuesto; la Sección [7](#) presenta el caso de estudio y el conjunto de datos; la Sección [8](#) reporta los resultados y el análisis comparativo; la Sección [10](#) discute las implicaciones regulatorias; y la Sección [9](#) resume las conclusiones y plantea líneas para futuras investigaciones.

3. Objetivos

La transición hacia sistemas eléctricos con alta penetración de energías renovables plantea importantes desafíos para la operación a corto plazo, particularmente en lo que respecta a la estabilidad del sistema, la seguridad del suministro y el cumplimiento de los compromisos de descarbonización. Los enfoques tradicionales de despacho, basados en promedios históricos o reglas heurísticas, no son suficientes para gestionar la variabilidad e incertidumbre inherente a las fuentes renovables. En este contexto, surge la necesidad de desarrollar marcos de decisión integrados que incorporen herramientas predictivas avanzadas y modelos de optimización capaces de equilibrar criterios técnicos, económicos y ambientales.

En respuesta a esta problemática, el presente trabajo formula un objetivo general y un conjunto de objetivos específicos orientados a cubrir la brecha metodológica existente entre el pronóstico y la optimización del despacho energético, asegurando así una operación más eficiente, confiable y alineada con las metas regulatorias de sostenibilidad.

3.1. Objetivo General

Desarrollar e implementar un marco integrado de pronóstico y optimización para el despacho energético a corto plazo en sistemas eléctricos con alta penetración renovable, que permita mejorar la confiabilidad operativa, reducir costos y emisiones de CO₂, y contribuir al cumplimiento de metas de descarbonización mediante la integración de modelos avanzados de aprendizaje profundo y programación lineal multiobjetivo.

Este objetivo busca no solo ofrecer una solución técnica, sino también aportar una herramienta con relevancia estratégica para operadores y reguladores, en coherencia con políticas internacionales como los Objetivos de Desarrollo Sostenible (ODS), el Acuerdo de París y las

Contribuciones Nacionalmente Determinadas (NDC). El marco propuesto se diseñará bajo principios de escalabilidad y transparencia, de modo que pueda aplicarse tanto en entornos industriales como en planificación a nivel nacional.

3.2. Objetivos Específicos

Para alcanzar el objetivo general, se establecen los siguientes objetivos específicos:

1. Analizar el estado del arte sobre pronóstico de demanda energética, despacho operativo y estrategias que integren predicción y optimización en contextos con alta penetración renovable, identificando las principales brechas metodológicas y regulatorias.
2. Diseñar y evaluar un modelo de pronóstico basado en redes neuronales Long Short-Term Memory (LSTM), comparándolo con arquitecturas alternativas como GRU, Transformer y TCN, mediante métricas de desempeño estándar aplicadas a condiciones operativas heterogéneas.
3. Optimizar los hiperparámetros del modelo LSTM utilizando algoritmos metaheurísticos, tales como Optimización Bayesiana, Algoritmo Genético y Particle Swarm Optimization, con el fin de mejorar su robustez y adaptabilidad frente a la variabilidad temporal y regional.
4. Integrar los pronósticos generados en un modelo de Programación Lineal Multiobjetivo (LP) orientado a la minimización simultánea del costo operativo, las emisiones de CO₂ y la dependencia térmica, considerando restricciones técnicas y requerimientos de reserva.
5. Validar el marco propuesto mediante un caso de estudio aplicado al sistema eléctrico chileno, utilizando datos históricos del período 2016–2023, evaluando su impacto en indicadores

- clave (costos, emisiones y respaldo térmico) frente a esquemas convencionales de despacho.
6. Realizar un análisis de sensibilidad que permita cuantificar el efecto de los errores de pronóstico sobre las variables de decisión y los indicadores de desempeño, identificando su relevancia para la definición de estándares de flexibilidad y políticas regulatorias.
 7. Formular lineamientos y recomendaciones orientadas a la incorporación de esquemas de despacho informados por pronósticos en la planificación energética y en el diseño de mercados eléctricos, promoviendo la estabilidad, la seguridad del suministro y la reducción de emisiones en entornos con alta incertidumbre renovable.

4. Alcance

El presente trabajo se orienta al diseño, desarrollo e implementación de un marco metodológico integral que combina técnicas avanzadas de pronóstico con un modelo de optimización multiobjetivo para la planificación del despacho eléctrico a corto plazo, en el contexto de sistemas eléctricos con alta penetración de energías renovables. La propuesta busca fortalecer la confiabilidad operativa, reducir costos y emisiones, y contribuir al cumplimiento de metas de descarbonización, asegurando coherencia con estándares regulatorios y políticas energéticas vigentes.

El alcance de la investigación considera:

- La elaboración de modelos de pronóstico de demanda eléctrica a corto plazo mediante arquitecturas de aprendizaje profundo (GRU, LSTM, Transformer y TCN), seleccionando el modelo con mejor desempeño en términos de precisión predictiva.
- La optimización de los hiperparámetros del modelo seleccionado (LSTM) mediante algoritmos metaheurísticos, específicamente Optimización Bayesiana, Particle Swarm Optimization (PSO) y Algoritmo Genético (GA), con el objetivo de mejorar su robustez y adaptabilidad.
- La integración de las previsiones generadas en un modelo de Programación Lineal Multiobjetivo (LP) diseñado para minimizar simultáneamente costos operativos, emisiones de CO₂ y dependencia térmica, considerando restricciones de oferta, demanda y suficiencia de reservas.
- La validación del marco metodológico en el sistema eléctrico chileno, empleando datos históricos del período 2016–2023 y abarcando la programación diaria en 14 regiones y siete

tecnologías de generación.

- La comparación del desempeño del marco propuesto frente a un esquema convencional de despacho sin integración de pronósticos, evaluando indicadores económicos, ambientales y de confiabilidad.
- La realización de un análisis de sensibilidad para determinar el impacto de errores de pronóstico sobre los costos y las emisiones, identificando implicancias para la formulación de estándares de flexibilidad y políticas regulatorias.

Este estudio se plantea bajo un enfoque determinista con horizonte diario, priorizando la aplicabilidad práctica, la transparencia metodológica y la replicabilidad en entornos reales bajo escenarios de alta penetración renovable.

5. Marco teórico

Este capítulo presenta los fundamentos conceptuales y técnicos que sustentan la presente investigación. Se abordan el contexto energético global, los desafíos derivados de la integración masiva de energías renovables, las metodologías de pronóstico y optimización aplicadas al despacho eléctrico, así como los avances y limitaciones identificadas en la literatura.

5.1. Contexto y Transición Energética

La transición hacia sistemas energéticos sostenibles constituye uno de los principales desafíos del siglo XXI, impulsada por la urgencia de mitigar el cambio climático y cumplir con los compromisos internacionales en materia de descarbonización. A nivel global, el *Objetivo de Desarrollo Sostenible (ODS) 7* promueve el acceso a energía asequible, segura y limpia, mientras que el Acuerdo de París y las Contribuciones Nacionalmente Determinadas (NDC) establecen metas concretas de reducción de emisiones para limitar el aumento de la temperatura media global a menos de 2°C respecto de los niveles preindustriales (58; 25).

En este escenario, la planificación energética se ha convertido en una herramienta clave para operacionalizar estas metas, mediante estrategias que permitan integrar grandes volúmenes de generación renovable intermitente sin comprometer la seguridad del suministro (59; 60). Países miembros de la OCDE y la Unión Europea han implementado políticas orientadas a incrementar la participación renovable y reducir la dependencia de combustibles fósiles, logrando avances en la desvinculación entre crecimiento económico y emisiones (64; 65).

No obstante, esta transición también introduce desafíos significativos para la planificación operativa. La alta penetración de fuentes renovables como la solar y la eólica genera una varia-

bilidad e incertidumbre sin precedentes en la oferta eléctrica, lo que complica la programación diaria, la asignación de reservas y la determinación de estrategias de respaldo térmico (12). Estas condiciones requieren esquemas de despacho más dinámicos, capaces de anticipar escenarios y adaptarse a cambios abruptos en la generación renovable.

A nivel regulatorio, la tendencia global apunta a la implementación de mecanismos que promuevan la flexibilidad del sistema y reduzcan la exposición a riesgos asociados a la volatilidad de los precios del carbono. Instrumentos como el *European Union Emission Trading System (EU ETS)* y su *Market Stability Reserve (MSR)* han sido adoptados para estabilizar señales de precio y fomentar inversiones en tecnologías bajas en carbono (3). Sin embargo, estudios recientes evidencian que una calibración inadecuada de estos mecanismos puede amplificar la volatilidad, afectando tanto la estabilidad del mercado como la planificación de la operación (21). Esto resalta la necesidad de estrategias complementarias, basadas en pronósticos precisos y modelos de optimización que aseguren la coordinación entre objetivos económicos, ambientales y de seguridad del suministro.

En síntesis, la transición energética global no solo redefine los objetivos estratégicos del sector eléctrico, sino que también exige la adopción de herramientas analíticas avanzadas que permitan integrar la previsión y la optimización en entornos caracterizados por incertidumbre y variabilidad, en coherencia con los compromisos de descarbonización y las políticas regulatorias emergentes.

5.2. Mercados Eléctricos y Políticas de Flexibilidad

La creciente participación de energías renovables variables (ERV), como la solar y la eólica, ha impulsado transformaciones significativas en el diseño y la regulación de los mercados eléctricos. La variabilidad y la incertidumbre asociadas a estas tecnologías imponen la necesidad de instrumentos que garanticen la estabilidad operativa y la sostenibilidad económica del sistema (21; 12). En este contexto, los mecanismos regulatorios orientados a la reducción de emisiones y la promoción de flexibilidad han adquirido un rol estratégico.

Mecanismos regulatorios: EU ETS y Market Stability Reserve

Uno de los instrumentos más relevantes en los mercados eléctricos europeos es el *European Union Emission Trading System (EU ETS)*, diseñado para establecer un límite global de emisiones y permitir la transacción de derechos entre agentes, fomentando la reducción de gases de efecto invernadero de manera costo-efectiva (3). Sin embargo, la experiencia evidencia que la volatilidad en el precio del carbono puede comprometer la predictibilidad de las señales económicas, afectando la planificación de generación y la inversión en tecnologías limpias. Para mitigar estas fluctuaciones, se creó la *Market Stability Reserve (MSR)*, cuyo objetivo es ajustar el volumen de derechos en circulación y estabilizar el precio del carbono frente a choques de oferta y demanda.

A pesar de estos mecanismos, estudios recientes señalan que una calibración inadecuada del MSR puede amplificar la volatilidad en lugar de reducirla, incrementando el riesgo regulatorio y dificultando la programación del despacho y las decisiones de respaldo térmico (21). Estas limitaciones subrayan la necesidad de estrategias operativas complementarias que integren pronósticos precisos y optimización multiobjetivo, a fin de reducir la exposición a la volatilidad del carbono en

escenarios de alta incertidumbre renovable.

Volatilidad del precio del carbono y su impacto en la planificación

El precio del carbono se ha consolidado como un factor determinante en las decisiones de despacho y en la estructura de costos de generación térmica. Fluctuaciones abruptas pueden alterar los costos marginales y modificar el orden económico de mérito, afectando la competitividad de tecnologías renovables y la utilización de combustibles fósiles (12). En mercados donde la penetración renovable es elevada, estas variaciones impactan la definición de estrategias de respaldo y la estimación de reservas, generando incertidumbre adicional en la programación operativa.

Estándares de confiabilidad y políticas de flexibilidad

Frente a la creciente variabilidad del sistema, las políticas de flexibilidad han cobrado especial relevancia. Estas incluyen requerimientos como el criterio *N-1*, que establece la capacidad del sistema para soportar la falla del elemento más crítico sin comprometer la operación, y la asignación de reservas girantes y no girantes para cubrir desviaciones imprevistas (55). Sin embargo, la eficacia de estos mecanismos depende en gran medida de la capacidad para anticipar condiciones de operación a través de pronósticos robustos, reforzando la necesidad de modelos que vinculen predicción y optimización en la toma de decisiones operativas.

En síntesis, la evolución de los mercados eléctricos hacia esquemas más dinámicos y la adopción de políticas orientadas a la flexibilidad y la estabilidad ambiental demandan herramientas analíticas avanzadas que permitan gestionar la incertidumbre, optimizar recursos y garantizar la seguridad del suministro en entornos con alta penetración renovable.

5.3. Despacho Energético a Corto Plazo

El despacho energético a corto plazo consiste en la asignación óptima de la generación eléctrica para satisfacer la demanda prevista en horizontes temporales reducidos, típicamente diarios o intradiarios (13; 32). Su relevancia radica en que determina la operación real del sistema, afectando directamente la estabilidad del mercado eléctrico, la seguridad del suministro y el cumplimiento de compromisos regulatorios relacionados con la reducción de emisiones (21).

En entornos con alta penetración de energías renovables intermitentes, como la solar y la eólica, este problema adquiere especial complejidad debido a la variabilidad y la incertidumbre inherentes a dichas fuentes. Estas características impactan la programación térmica, la asignación de reservas y la gestión del almacenamiento, generando riesgos operativos y económicos que pueden comprometer los estándares de confiabilidad del sistema (5; 12).

Métodos tradicionales para despacho

Históricamente, la programación del despacho se ha basado en enfoques deterministas sustentados en pronósticos simples, promedios históricos y reglas heurísticas. Estos métodos buscan minimizar el costo operativo bajo un conjunto fijo de restricciones, suponiendo que las previsiones de demanda y generación renovable se cumplen con exactitud (13). Entre los enfoques más comunes se encuentran:

- **Despacho basado en costos marginales:** prioriza la asignación de recursos por orden económico de mérito, sin considerar explícitamente la incertidumbre ni los impactos ambientales.
- **Heurísticas y reglas fijas:** empleadas principalmente en entornos industriales, donde las

decisiones se apoyan en experiencias pasadas o en condiciones nominales de operación.

- **Modelos deterministas clásicos:** formulados como problemas de Programación Lineal, los cuales asumen pronósticos perfectos y omiten variabilidad en la oferta renovable (32).

Si bien estos enfoques ofrecen simplicidad computacional y son ampliamente utilizados en entornos regulados, presentan limitaciones importantes en contextos de alta penetración renovable, donde la incertidumbre impacta significativamente la operación y los costos.

Limitaciones frente a escenarios con incertidumbre

La principal desventaja de los métodos tradicionales radica en su incapacidad para anticipar y gestionar las desviaciones entre la generación planificada y la generación real, especialmente cuando la variabilidad renovable y la volatilidad del precio del carbono son elevadas (21; 12). Este sesgo puede conducir a:

- Incremento en los costos por despacho fuera de mérito.
- Mayor dependencia de generación térmica de respaldo.
- Dificultades para cumplir con estándares regulatorios y metas de descarbonización.

En este contexto, surge la necesidad de modelos avanzados que integren pronósticos robustos con la optimización del despacho, incorporando objetivos múltiples (costo, emisiones, confiabilidad) y herramientas que reduzcan la exposición a la incertidumbre (39; 40). Esta integración, conocida como *forecast-informed dispatch*, representa un cambio de paradigma frente a los esquemas reactivistas, permitiendo una operación más eficiente, predecible y alineada con las políticas climáticas.

5.4. Modelos de Pronóstico en Energía

El pronóstico preciso constituye un componente fundamental para la operación segura y eficiente de sistemas eléctricos, especialmente en entornos con alta penetración de energías renovables variables. La volatilidad inherente a estas fuentes, sumada a las fluctuaciones en la demanda y los precios del carbono, exige modelos capaces de capturar dependencias temporales complejas y patrones no lineales (1; 5). En este contexto, el aprendizaje profundo se ha consolidado como una herramienta poderosa para abordar problemas de series temporales en energía, ofreciendo mejoras significativas frente a métodos tradicionales basados en regresión estadística o modelos ARIMA.

Fundamentos del aprendizaje profundo aplicado a series temporales

Las arquitecturas de aprendizaje profundo, en particular las redes neuronales recurrentes (RNN) y sus variantes, han demostrado gran eficacia en la predicción de demanda eléctrica, generación renovable y comportamiento industrial (4; 16). A diferencia de modelos lineales, estas arquitecturas aprenden representaciones jerárquicas y capturan relaciones no triviales entre múltiples variables, integrando información histórica y exógena. Además, pueden adaptarse a dinámicas complejas, como estacionalidades múltiples, eventos abruptos y señales con ruido (2).

5.4.1. Redes LSTM (Long Short-Term Memory)

Las redes LSTM son una de las arquitecturas más utilizadas para el pronóstico energético debido a su capacidad para modelar dependencias de largo plazo y atenuar el problema del *vanishing gradient* característico de las RNN tradicionales (1). Introducidas por Hochreiter y Schmidhuber, incorporan un mecanismo de puertas (entrada, olvido y salida) que regula el flujo de información en la celda de memoria, permitiendo retener patrones relevantes durante largos ho-

rizontes temporales (4). Estudios recientes evidencian que las LSTM alcanzan altos niveles de precisión en tareas como la predicción de demanda diaria, generación solar y eólica, y series multivariadas en entornos industriales (21; 7). Además, su desempeño puede mejorarse mediante técnicas de ajuste de hiperparámetros basadas en metaheurísticas, optimizando la generalización y reduciendo el costo computacional (8).

5.4.2. GRU (Gated Recurrent Unit)

Las GRU constituyen una alternativa simplificada a las LSTM, fusionando las compuertas de entrada y olvido en un único mecanismo denominado *update gate*. Esta estructura reduce la complejidad computacional sin comprometer la capacidad de modelar dependencias temporales significativas (6). Las GRU han demostrado un rendimiento comparable, e incluso superior, al de las LSTM en escenarios de pronóstico de corto plazo, con la ventaja adicional de un menor tiempo de entrenamiento, lo que las hace atractivas para sistemas que requieren recalibración continua (1; 11). Su eficiencia las posiciona como candidatas ideales para aplicaciones en tiempo casi real.

5.4.3. Transformer

La arquitectura Transformer, originalmente desarrollada para procesamiento de lenguaje natural, ha sido recientemente adaptada al pronóstico energético por su capacidad para capturar dependencias de largo alcance mediante mecanismos de autoatención (4). A diferencia de las redes recurrentes, el Transformer procesa secuencias completas en paralelo, lo que reduce las limitaciones asociadas a la propagación secuencial y facilita el manejo de variables multivariadas con interacciones complejas (2). Variantes especializadas como *Informer* y *Temporal Fusion Transformer (TFT)* han alcanzado resultados sobresalientes en entornos con alta estacionalidad, aunque

su elevado costo computacional representa un desafío para aplicaciones industriales que requieren decisiones en ventanas de tiempo reducidas (8).

5.4.4. TCN (Temporal Convolutional Networks)

Las TCN introducen un enfoque basado en convoluciones causales y dilatadas, que permite ampliar el campo receptivo y capturar patrones temporales sin recurrencia (7). Esta característica posibilita el entrenamiento en paralelo, reduciendo significativamente los tiempos de cómputo frente a modelos recurrentes. La literatura confirma que las TCN son robustas ante series con ruido y datos irregulares, lo que las convierte en una alternativa viable para aplicaciones energéticas y de mantenimiento predictivo (2; 6). Su incorporación en procesos de *benchmarking* aporta diversidad arquitectónica, fortaleciendo la validez comparativa del marco metodológico.

Importancia del ajuste de hiperparámetros y metaheurísticas

El desempeño de las arquitecturas de aprendizaje profundo depende en gran medida de la correcta selección de hiperparámetros (número de capas, tamaño de las celdas, tasa de aprendizaje, etc.). Debido a la naturaleza no convexa del espacio de búsqueda, las técnicas de optimización metaheurística han ganado popularidad para este propósito (8; 14). Algoritmos como la Optimización Bayesiana, el Algoritmo Genético (GA) y el *Particle Swarm Optimization* (PSO) han mostrado resultados efectivos para acelerar la convergencia y mejorar la capacidad de generalización de los modelos, reduciendo la carga computacional en sistemas a gran escala (33; 16).

Revisión de trabajos previos

Diversos estudios han explorado la integración de arquitecturas avanzadas y técnicas de optimización en el contexto del pronóstico energético. Abbasimehr et al. (11) demostraron la efectividad del ajuste de hiperparámetros en LSTM para la mejora de la precisión. Gu et al. (4) propusieron un enfoque híbrido que combina LSTM con mecanismos de atención, mientras que Caroprese et al. (2) desarrollaron la arquitectura DL2F, orientada a integrar pronóstico con decisiones operativas. Sin embargo, gran parte de la literatura se concentra exclusivamente en la fase predictiva, sin incorporar explícitamente estos modelos en esquemas de optimización del despacho, lo que refuerza la brecha metodológica abordada en este trabajo.

5.5. Optimización del Despacho Energético

La optimización del despacho eléctrico a corto plazo consiste en asignar de manera eficiente los recursos de generación para satisfacer la demanda prevista, cumpliendo con restricciones técnicas y alineando los objetivos estratégicos de costo, confiabilidad y sostenibilidad ambiental (13; 33). Esta tarea se vuelve crítica en sistemas con alta penetración de energías renovables, donde la variabilidad y la incertidumbre asociadas a la generación impactan la estabilidad operativa y el costo del suministro (21).

Fundamentos y enfoque adoptado

El presente trabajo utiliza un modelo determinista basado en Programación Lineal (LP) con un enfoque multiobjetivo. Esta técnica es ampliamente reconocida en el ámbito energético por su capacidad de modelar relaciones lineales entre variables y restricciones, asegurando soluciones

eficientes en tiempos de cómputo reducidos. El objetivo del modelo es minimizar de manera conjunta el costo operativo total y las emisiones de CO₂, respondiendo a la necesidad de equilibrar eficiencia económica y metas regulatorias de descarbonización (21; 13).

Variables y restricciones principales

Las variables de decisión corresponden a la generación diaria por tecnología (térmica, hidráulica, solar, eólica) y a las operaciones de carga y descarga de sistemas de almacenamiento (BESS). Entre las restricciones más relevantes se incluyen:

- El balance energético, que asegura que la generación total iguale la demanda pronosticada.
- Límites de capacidad por tecnología, definidos por la infraestructura instalada.
- Condiciones operativas de almacenamiento, considerando eficiencia, capacidad máxima y consistencia del estado de carga (51; 54).

Ventajas del uso de Programación Lineal

El empleo de Programación Lineal se justifica por tres ventajas fundamentales:

- **Tractabilidad computacional:** permite resolver problemas complejos en segundos, incluso para múltiples regiones, garantizando aplicabilidad en entornos operativos (11).
- **Escalabilidad:** la estructura modular facilita su extensión hacia diferentes horizontes temporales o tecnologías.
- **Transparencia:** la simplicidad matemática favorece auditorías y cumplimiento regulatorio (18).

Aunque el modelo no incorpora explícitamente la incertidumbre, su diseño modular admite futuras extensiones hacia enfoques robustos o estocásticos (21; 27).

Aplicación y validación

La formulación fue implementada para el sistema eléctrico chileno en sus 14 regiones administrativas, considerando datos históricos del período 2016–2023. La herramienta se desarrolló en Python utilizando la librería PuLP y el solver abierto CBC, alcanzando tiempos de ejecución de pocos segundos por región. Al compararlo con un esquema de despacho basado en promedios históricos, el modelo propuesto redujo en 22 % los costos operativos, en 42 % las emisiones y en 22,9 % la dependencia térmica (39; 40).

Implicancias y proyecciones

Este modelo no solo constituye un aporte metodológico, sino que también habilita decisiones estratégicas en programación térmica, planificación de combustibles y gestión de reservas, contribuyendo a la estabilidad del mercado y al cumplimiento de metas climáticas. Como líneas futuras, destacan:

- Integración de modelos robustos para gestionar explícitamente la incertidumbre.
- Incorporación de comportamiento de mercado y señales de precio.
- Programación conjunta con mantenimiento preventivo y métricas de confiabilidad (72; 74).

5.6. Integración Pronóstico–Optimización

En sistemas eléctricos con alta penetración de energías renovables, la relación entre predicción y planificación operativa es crítica. El concepto de *Forecast-informed Dispatch* se refiere a la integración explícita de pronósticos avanzados dentro del proceso de optimización del despacho energético, con el fin de mejorar la toma de decisiones en horizontes cortos de planificación (18; 2). A diferencia de los enfoques tradicionales que tratan la previsión y la optimización como procesos independientes, esta estrategia busca reducir la brecha entre la estimación de variables futuras (demanda, generación renovable) y la ejecución de acciones operativas (asignación de recursos, planificación térmica), favoreciendo una operación proactiva y resiliente.

Concepto y motivación

El *Forecast-informed Dispatch* surge como respuesta a la creciente variabilidad e incertidumbre que introduce la generación renovable intermitente, la cual compromete la estabilidad del sistema y eleva el riesgo de desviaciones costosas respecto al plan de despacho (4). Bajo un esquema tradicional, las decisiones se basan en valores esperados o promedios históricos, ignorando las fluctuaciones de corto plazo y, por tanto, incrementando la necesidad de correcciones reactivas mediante generación de respaldo. Este comportamiento reactivo incrementa los costos marginales y la dependencia térmica, además de dificultar el cumplimiento de metas de descarbonización (21; 12).

En contraste, un modelo integrado utiliza pronósticos robustos como insumo directo para la optimización, permitiendo ajustar el despacho de manera anticipada, asignar reservas adecuadas y reducir la exposición a la volatilidad del mercado y a sanciones regulatorias. Este enfoque también es coherente con políticas emergentes que incentivan la flexibilidad y la estabilidad en entornos

descarbonizados (55).

Avances y limitaciones en la literatura

Diversos estudios han explorado la predicción energética con redes neuronales y la optimización operativa mediante modelos deterministas o estocásticos; sin embargo, la mayoría trata ambas dimensiones como procesos aislados. Por ejemplo, Abbasimehr et al. (1) lograron mejoras sustanciales en precisión de pronóstico mediante optimización de hiperparámetros en LSTM, pero sin integrarlo a la programación del despacho. De forma similar, trabajos en optimización multiobjetivo, como los de Aghdam et al. (33) y Castelli et al. (21), han abordado la reducción de emisiones mediante modelos LP o robustos, sin incorporar previsiones avanzadas como variable exógena clave.

Existen aproximaciones híbridas, como las propuestas por Gu et al. (4) y Caroprese et al. (2), que enlazan pronósticos con decisiones operativas en sistemas específicos (edificios inteligentes, microredes), pero su aplicación en contextos industriales o a nivel nacional sigue siendo limitada. Asimismo, la mayoría de los modelos que integran pronósticos lo hacen bajo supuestos deterministas con error cero, sin evaluar formalmente el impacto de la incertidumbre sobre costos y emisiones (39). Este vacío constituye uno de los principales **GAPs** identificados en la literatura: la falta de marcos unificados que vinculen forecasting avanzado y optimización del despacho bajo criterios regulatorios y escenarios de variabilidad renovable.

Relevancia para la seguridad del sistema y el cumplimiento normativo

La integración entre pronóstico y optimización no es solo una mejora técnica, sino un componente estratégico para:

- **Seguridad del suministro:** al anticipar la disponibilidad renovable y ajustar reservas preventivas, se reduce el riesgo de fallas y desastres.
- **Estabilidad del mercado:** al disminuir el despacho fuera de mérito, se atenúan los picos de precio y la volatilidad en mercados spot.
- **Cumplimiento regulatorio:** permite cumplir metas de emisiones y estándares de flexibilidad (ej. reservas N-1) exigidos por políticas como los compromisos NDC y esquemas de precios al carbono (3; 12).

Además, esta integración facilita la coordinación entre generación térmica, almacenamiento y renovables, alineando la planificación operativa con instrumentos regulatorios como sistemas de comercio de emisiones (*ETS*) y reservas de estabilidad de mercado (*Market Stability Reserve*) (3). En síntesis, la conexión pronóstico–optimización constituye la base para habilitar estrategias proactivas, mejorar la resiliencia del sistema y avanzar en el cumplimiento de las metas de descarbonización en entornos de alta incertidumbre.

5.7. Modelos bajo Incertidumbre

La operación de sistemas eléctricos con alta penetración de energías renovables introduce un nivel significativo de incertidumbre, principalmente asociado a la variabilidad climática, la inexactitud en los pronósticos y la volatilidad de precios en los mercados eléctricos. Esta incertidumbre afecta decisiones críticas en la programación del despacho, la asignación de reservas y el cumplimiento de restricciones regulatorias, lo que ha motivado el desarrollo de modelos avanzados orientados a su gestión explícita (21; 23; 36).

Enfoques robustos y estocásticos

Los enfoques de **optimización robusta** buscan garantizar soluciones factibles ante el peor escenario dentro de un conjunto definido de incertidumbre, reduciendo el riesgo operativo aunque, en algunos casos, a costa de decisiones más conservadoras y costos más altos (21). Este tipo de modelos es ampliamente utilizado en la planificación de redes y sistemas multi-energía, donde la resiliencia es prioritaria.

Por otro lado, la **optimización estocástica** formula el problema bajo múltiples escenarios probabilísticos, ponderando costos y riesgos en función de distribuciones de probabilidad de las variables inciertas (23). Aunque este enfoque permite una representación más realista de la incertidumbre, su aplicación en el despacho diario presenta desafíos importantes:

- Incremento significativo en la complejidad computacional, especialmente en sistemas grandes.
- Dependencia de información estadística confiable para generar escenarios, lo cual no siempre es factible en entornos industriales.
- Dificultades para su implementación en procesos regulatorios que requieren trazabilidad y tiempos de respuesta reducidos.

Estudios recientes han propuesto enfoques híbridos que combinan optimización robusta y técnicas probabilísticas para el despacho bajo incertidumbre (36; 27). Sin embargo, estas metodologías, si bien teóricamente sólidas, siguen siendo poco adoptadas en aplicaciones operativas por las restricciones mencionadas.

Justificación del enfoque determinista en este trabajo

El presente estudio adopta un **enfoque determinista**, integrando pronósticos avanzados con un modelo de Programación Lineal Multiobjetivo. Esta decisión se fundamenta en tres razones clave:

- **Tractabilidad computacional:** los modelos deterministas permiten resolver el problema en tiempos del orden de segundos, lo cual es crítico para aplicaciones industriales y contextos donde la planificación diaria debe realizarse de manera recurrente (11).
- **Transparencia regulatoria:** la simplicidad estructural de los modelos lineales facilita auditorías, verificaciones y la incorporación en procesos normativos, algo complejo de lograr con formulaciones estocásticas.
- **Flexibilidad metodológica:** el modelo propuesto es modular, lo que permite su futura extensión hacia formulaciones robustas o estocásticas sin modificar la estructura central del marco propuesto (21; 27).

Para mitigar los riesgos derivados de no modelar la incertidumbre explícitamente, se incorpora un **análisis de sensibilidad** que evalúa el impacto de errores de pronóstico sobre los costos y las emisiones. Esta aproximación proporciona información relevante sobre la resiliencia del modelo frente a condiciones de variabilidad, sin comprometer su aplicabilidad práctica en entornos con limitaciones computacionales y regulatorias.

Tabla 1: Síntesis sistemática de literatura sobre despacho energético industrial informado por pronósticos.

| Referencia | Contribución | Métodos y técnicas | Dominio | Fortalezas (F) / Debilidades (D) |
|--------------------------------|---|--|--|--|
| Abbasimehr et al. (2020) [1] | Optimización de hiperparámetros para LSTM en pronóstico | Grid Search + LSTM | Pronóstico de demanda (industria del mueble) | F: Metodología de ajuste LSTM; D: sin integración con optimización, serie única |
| Alvarez et al. (2020) [13] | Optimización integrada para compra de combustibles y despacho energético | Programación Lineal (LP), modelo determinista | Despacho térmico industrial | F: Planificación térmica de largo plazo; D: sin integración de pronósticos |
| Aghdam et al. (2023) [33] | Programación industrial considerando emisiones | LP multiobjetivo + minimización de emisiones | Operaciones industriales | F: Reducción de CO ₂ ; D: sin módulo predictivo |
| Castelli et al. (2023) [21] | Optimización robusta con modelado de incertidumbre en pronósticos | LP robusto, conjuntos estocásticos | Sistemas renovables | F: Modelado de incertidumbre; D: sin pronóstico basado en DL |
| González et al. (2023) [40] | Corrección de sesgo y limpieza de residuales en pronósticos | Análisis de sesgo, corrección residual | Pronóstico industrial | F: Control robusto de error; D: sin optimización de despacho |
| Gu et al. (2024) [4] | Arquitectura híbrida LSTM-Transformer para pronóstico multivariable | Transformer, LSTM, atención | Pronóstico renovable | F: Alta precisión multivariable; D: sin integración con despacho |
| Caroprese et al. (2024) [2] | Pronóstico DL integrado con despacho operativo | LSTM, DL2F, acoplamiento pronóstico+optimización | Despacho energético (edificios) | F: Vinculación pronóstico-optimización; D: enfoque en edificios, no en térmico industrial |
| Zinsmeister et al. (2024) [39] | Benchmarking de optimización informada por pronósticos | Carga pronosticada vs modelos clásicos | Operación de sistemas eléctricos | F: Evaluación explícita; D: limitado a redes eléctricas |
| Zhu et al. (2025) [8] | Optimización de hiperparámetros para DL considerando restricciones | Optimización Bayesiana, GA, LSTM | Pronóstico industrial | F: Optimización metaheurística; D: pronóstico independiente, sin integración operacional |
| Ren et al. (2024) [32] | Planificación determinista para plantas industriales multi-energía | LP determinista | Sistemas multi-energía industrial | F: Escala industrial en optimización; D: sin integración de pronósticos |
| Este trabajo | Despacho informado por pronósticos para planificación térmica con implicancias regulatorias | Pronóstico LSTM + LP multiobjetivo para costo, emisiones y seguridad | Sistemas industriales bajo incertidumbre renovable | F: Integración completa pronóstico+optimización, benchmarking empírico, aportes regulatorios; D: modelo determinista sin modelado explícito de incertidumbre |

5.8. Brechas Metodológicas y Motivación del Estudio

Una revisión exhaustiva de la literatura evidencia importantes avances en tres áreas: (i) modelos de pronóstico para sistemas energéticos, (ii) optimización operativa informada por pronósticos y (iii) metodologías que consideran incertidumbre, como la optimización robusta y estocástica ([1]; [4]; [21]; [23]). Sin embargo, persisten brechas significativas en la intersección de estos dominios, especialmente en el contexto del despacho térmico industrial bajo altos niveles de variabilidad renovable. A continuación, se presentan los principales vacíos metodológicos identificados:

- **GAP 1: Falta de integración entre pronóstico y optimización.** La mayoría de los estudios

sobre pronóstico energético basados en aprendizaje profundo (LSTM, GRU, Transformer, TCN) se centran en mejorar la precisión predictiva, sin incorporar estas previsiones en la toma de decisiones operativas (1; 4). Esta desconexión limita la capacidad para anticipar la programación térmica y gestionar riesgos asociados a la volatilidad renovable y de precios.

- **GAP 2: Escasez de modelos de optimización informados por pronósticos.** Si bien existen formulaciones robustas y estocásticas aplicadas a la planificación energética (21; 23), pocas investigaciones abordan la integración forecast–dispatch en el despacho diario, especialmente en entornos industriales. Además, los enfoques existentes suelen asumir pronósticos perfectos, reduciendo su aplicabilidad frente a condiciones reales de incertidumbre (39).
- **GAP 3: Ausencia de evaluación empírica y benchmarking sistemático.** La literatura carece de estudios que comparen formalmente el desempeño de estrategias informadas por pronósticos frente a métodos clásicos basados en reglas heurísticas o promedios históricos, dificultando la validación regulatoria y la adopción de estas herramientas en la práctica (40; 39).

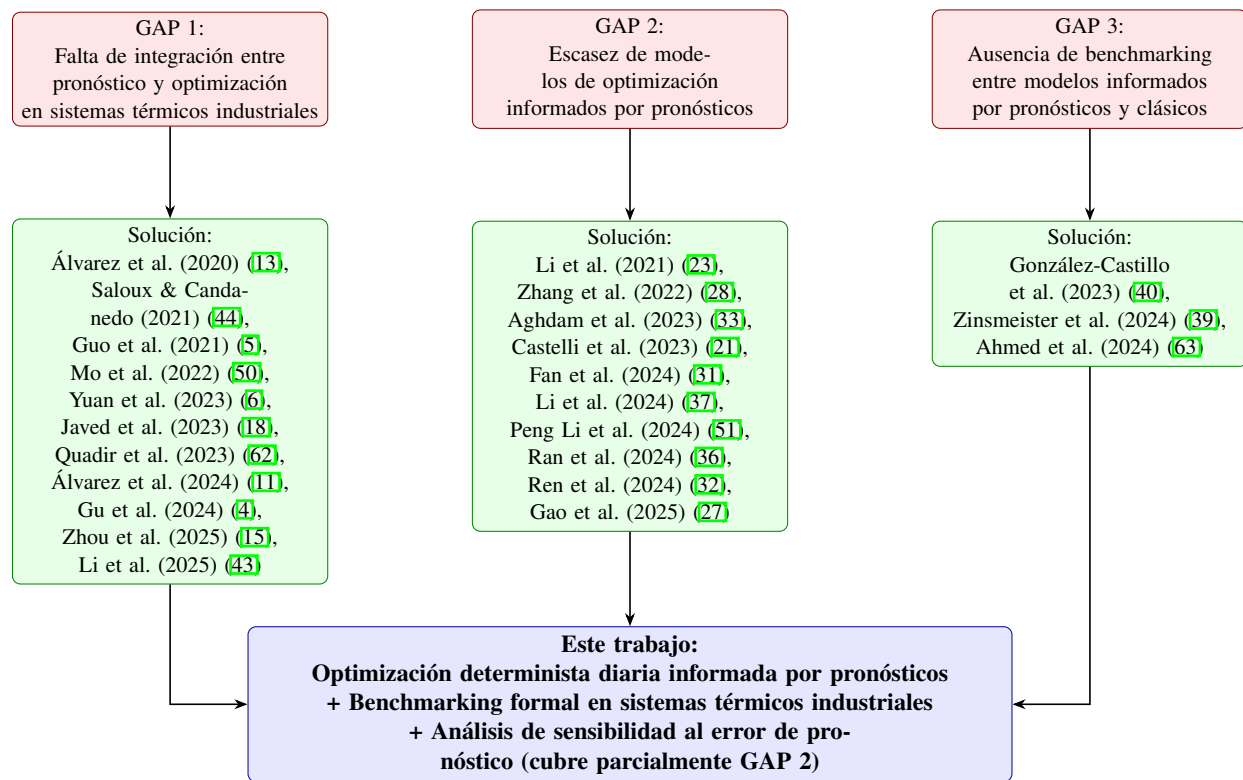


Figura 1: Mapa lógico de brechas identificadas, soluciones existentes y contribución propuesta. El trabajo aborda el GAP 1 y GAP 3 mediante la integración pronóstico–optimización y benchmarking empírico, y parcialmente el GAP 2 con análisis de sensibilidad, sin incluir optimización robusta o estocástica.

Justificación del marco propuesto

Para abordar estas brechas, el presente trabajo propone un **marco metodológico integrado** que combina:

1. Pronósticos de alta precisión mediante modelos LSTM optimizados con metaheurísticas (Optimización Bayesiana, PSO, GA).
2. Un modelo de Programación Lineal multiobjetivo para despacho diario, orientado a minimizar costos y emisiones, asegurando factibilidad y escalabilidad computacional.
3. Un análisis comparativo (benchmarking) frente a métodos tradicionales, complementado con



análisis de sensibilidad para evaluar la resiliencia del modelo frente a errores de pronóstico.

Este enfoque prioriza la aplicabilidad en entornos reales, la transparencia regulatoria y la replicabilidad, contribuyendo a la estabilidad del mercado, la seguridad energética y el cumplimiento de compromisos de descarbonización en sistemas con alta penetración renovable.

6. Metodología

Esta sección presenta el marco metodológico integrado desarrollado para incorporar pronósticos de generación renovable en un modelo de optimización operativa del despacho energético para sistemas industriales. El proceso propuesto comprende cuatro etapas principales: adquisición de datos, preprocesamiento, modelado predictivo y su integración en un modelo de optimización multiobjetivo bajo restricciones económicas y ambientales. Para mejorar la claridad y coherencia, se han agrupado etapas estrechamente relacionadas.

6.1. Preparación de Datos: Preprocesamiento, Ingeniería de Características y Partición del Conjunto de Datos

El marco metodológico inicia con la recopilación de datos históricos de generación energética, desagregados por tecnología (hidráulica, solar, eólica y térmica) y posteriormente agregados en totales diarios, con el fin de equilibrar la resolución temporal con la factibilidad computacional. Esta decisión responde al horizonte operativo considerado en la planificación industrial (escala diaria), evitando la complejidad adicional que implicaría una resolución horaria.

En concordancia con la práctica habitual en entornos industriales, se excluyen variables exógenas como precios de la electricidad, pronósticos meteorológicos o consumos en tiempo real. Esta exclusión se fundamenta en dos razones: (i) la disponibilidad limitada de información externa en entornos industriales, y (ii) la necesidad de validar la aplicabilidad del modelo bajo condiciones de datos restringidos.

Etapas de preprocesamiento

El preprocesamiento de datos comprende las siguientes etapas secuenciales:

- **Imputación de datos faltantes:** Para pequeños vacíos temporales se aplica interpolación lineal, garantizando la continuidad de la serie. En casos de brechas extensas, los registros se eliminan para preservar la integridad del conjunto de datos.
- **Agregación temporal:** Datos horarios o subdiarios se consolidan en totales diarios, alineando la granularidad de los datos con el horizonte de planificación del despacho.
- **Normalización:** Todas las series temporales se escalan al rango $[0, 1]$ mediante la técnica *Min-Max Scaling*, optimizando la estabilidad numérica durante el entrenamiento de redes neuronales y manteniendo la interpretabilidad del modelo (II).

Partición del conjunto de datos

Finalmente, el conjunto de datos se divide en tres subconjuntos:

1. **Entrenamiento:** utilizado para ajustar los parámetros del modelo predictivo.
2. **Validación:** empleado en la optimización de hiperparámetros mediante técnicas metaheurísticas (Optimización Bayesiana, PSO y Algoritmos Genéticos).
3. **Prueba:** reservado para la evaluación final de desempeño y benchmarking.

Esta estructura garantiza la separación entre calibración y validación del modelo, evitando sesgos y sobreajuste.

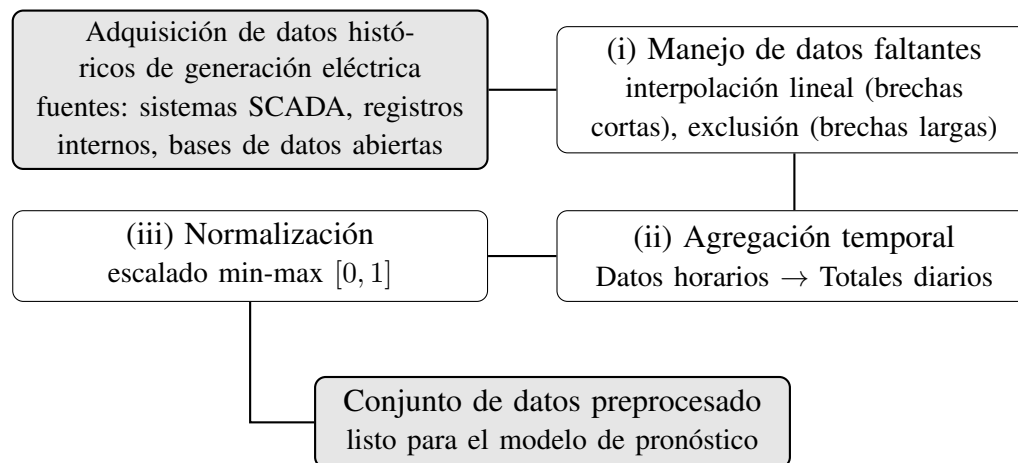


Figura 2: Flujo general de adquisición y preprocesamiento de datos previo al pronóstico.

Transformación a instancias supervisadas y partición temporal

Posteriormente al preprocesamiento, las series temporales se transforman en instancias de aprendizaje supervisado mediante un enfoque de *ventana deslizante*. Cada instancia de entrada está compuesta por una ventana de 30 días consecutivos con valores diarios de generación, mientras que la variable objetivo corresponde a la generación del día siguiente. La elección de una ventana de 30 días se fundamenta en tres criterios: (i) relevancia para la planificación mensual, (ii) preservación de las estructuras empíricas de autocorrelación y (iii) eficiencia computacional durante el entrenamiento del modelo, lo cual fue validado mediante un proceso interno de *benchmarking*.

Para el desarrollo del modelo, el conjunto de datos se divide cronológicamente en tres subconjuntos:

- **Entrenamiento:** años 2016–2021.
- **Validación:** año 2022, utilizado para optimización de hiperparámetros.
- **Prueba:** año 2023, reservado para evaluación final.

Esta segmentación temporal evita fugas de información (*data leakage*) y asegura condiciones realistas de pronóstico, emulando escenarios prospectivos en los que los datos futuros no están disponibles durante el entrenamiento. Asimismo, preserva la estacionalidad intraanual y la variabilidad interanual, características esenciales de los patrones de generación renovable.

El flujo completo desde los datos crudos hasta la generación de instancias supervisadas se muestra en la Figura 2, mientras que la partición temporal del conjunto de datos se ilustra en la Figura 3.




Figura 3: División temporal del conjunto de datos en entrenamiento, validación y prueba para el desarrollo del modelo de pronóstico.

6.2. Optimización de Hiperparámetros

Previo a la implementación de cualquier modelo de pronóstico, el marco metodológico aplica un proceso sistemático de optimización de hiperparámetros con el fin de garantizar equidad en las evaluaciones posteriores (1; 4; 8). Esta etapa se realizó para todas las arquitecturas consideradas (LSTM, GRU, Transformer y Temporal Convolutional Networks - TCN), evitando comparaciones sesgadas y asegurando que cada modelo opere bajo condiciones óptimas.

Metaheurísticas empleadas

Para la búsqueda de configuraciones óptimas, se utilizaron en paralelo tres algoritmos metaheurísticos ampliamente aplicados en pronóstico energético (30):

- **Optimización Bayesiana (BO):** utiliza modelos probabilísticos sustitutos (como Procesos Gaussianos) para balancear exploración y explotación en el espacio de búsqueda (8).
- **Particle Swarm Optimization (PSO):** se basa en dinámicas de enjambre, ajustando las soluciones a través de interacciones cooperativas entre partículas (18).
- **Algoritmo Genético (GA):** aplica operadores evolutivos como selección, cruce y mutación para generar nuevas soluciones (16).

Este enfoque multi-algoritmo permite explorar de manera robusta configuraciones arquitectónicas en condiciones diversas (33; 7), mitigando el riesgo de converger en óptimos locales.

Parámetros y criterios de búsqueda

Los objetivos de búsqueda incluyeron parámetros estructurales y de entrenamiento críticos, tales como:

- Número de capas y unidades ocultas.
- Tasa de aprendizaje (*learning rate*).
- Proporción de abandono (*dropout*) para regularización.

Los rangos de búsqueda se definieron conforme a evidencia en la literatura y prácticas industriales (4; 46; 32). Cada candidato fue entrenado por un número fijo de épocas, monitoreando la función de pérdida en el conjunto de validación para asegurar comparabilidad entre configuraciones.

Selección del modelo final

El modelo definitivo se eligió considerando tres criterios:

1. Precisión predictiva (métricas de error).
2. Costo computacional (tiempo y recursos requeridos).
3. Estabilidad del error frente a variabilidad en los datos.

Este procedimiento asegura neutralidad metodológica y evita sesgos de selección que pudieran impactar la etapa de optimización operativa (ver Sección [8](#)).

6.3. Entrenamiento y Evaluación del Modelo

Una vez identificados los hiperparámetros óptimos para cada arquitectura de pronóstico (LSTM, GRU, Transformer y TCN), cada modelo fue reentrenado utilizando la totalidad del conjunto de entrenamiento, maximizando así la información disponible antes de la evaluación ([1](#); [4](#)). Todas las arquitecturas operan bajo un esquema de *ventana deslizante* de longitud fija, en el cual se emplean secuencias de generación diaria para predecir la producción del día siguiente. Este enfoque permite capturar tanto dependencias temporales de corto plazo como patrones de mediano plazo, esenciales para la planificación operativa de energía ([5](#); [2](#); [46](#)).

Configuración de entrenamiento

El proceso de entrenamiento se llevó a cabo utilizando la función de pérdida **Error Cuadrático Medio (MSE)**, definida como:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

donde y_i es el valor real y \hat{y}_i el valor pronosticado. Esta métrica fue optimizada mediante el algoritmo **Adam**, seleccionado por su capacidad de ajustar tasas de aprendizaje adaptativas y lograr una convergencia eficiente en series secuenciales (7; 41).

El número de épocas de entrenamiento se fijó de acuerdo con los valores determinados durante la etapa de optimización de hiperparámetros, garantizando la comparabilidad entre algoritmos y arquitecturas (6).

Estandarización y evaluación comparativa

La estandarización del procedimiento de entrenamiento en todas las arquitecturas asegura condiciones equitativas para la posterior evaluación comparativa (Sección 8). Esta evaluación considera tres dimensiones clave:

1. Precisión del pronóstico mediante métricas de error.
2. Costo computacional asociado al entrenamiento.
3. Robustez de la estructura del error frente a la variabilidad en los datos.

El modelo con el mejor desempeño global será incorporado al módulo de optimización para el despacho energético informado por pronósticos.

6.4. Métricas de Desempeño en el Pronóstico

Para garantizar una evaluación integral del desempeño de los modelos, la precisión del pronóstico se analizó mediante múltiples métricas que capturan tanto errores absolutos como relativos en diferentes regiones y escalas temporales (21; 39). Las métricas consideradas son:

- **Error Cuadrático Medio (MSE):**

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

Esta métrica penaliza con mayor severidad los errores grandes, resultando útil para escenarios donde las desviaciones significativas afectan la estabilidad operativa.

- **Raíz del Error Cuadrático Medio (RMSE):**

$$\text{RMSE} = \sqrt{\text{MSE}} \quad (2)$$

El RMSE facilita la interpretación en las mismas unidades que la variable objetivo, permitiendo comparar el error promedio con la magnitud de la serie.

- **Error Porcentual Absoluto Medio (MAPE):**

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3)$$

Esta métrica expresa el error relativo en términos porcentuales, siendo especialmente útil para evaluar la proporcionalidad del error respecto al valor real.

■ **Error Porcentual Absoluto Medio por Cuantiles (Q-MAPE):**

$$\text{Q-MAPE}_q = \text{Quantile}_q \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \% \right) \quad (4)$$

El Q-MAPE permite analizar la distribución de los errores en diferentes cuantiles, proporcionando información robusta frente a valores atípicos.

Análisis de residuales

Además de las métricas anteriores, se realizaron diagnósticos de residuales para identificar sesgos sistemáticos, asimetrías y posibles patrones de heterocedasticidad. Estos análisis son fundamentales para asegurar que los errores sean aleatorios y no comprometan la integración posterior en el módulo de optimización, garantizando estabilidad y robustez en la planificación operativa (40).

6.5. Evaluación Comparativa de Modelos de Pronóstico

Para garantizar una selección objetiva del modelo de pronóstico a integrar en el marco de optimización, se diseñó un proceso de evaluación comparativa entre cuatro arquitecturas de aprendizaje profundo: *Long Short-Term Memory* (LSTM), *Gated Recurrent Units* (GRU), modelos basados en *Transformer* y *Temporal Convolutional Networks* (TCN).

Diseño experimental

Todos los modelos fueron entrenados bajo condiciones estandarizadas:

- Conjunto de datos preprocesado común.
- Estructuración de entradas mediante ventanas deslizantes de 30 días.

- Optimización de hiperparámetros independiente para cada arquitectura.
- Protocolos homogéneos de entrenamiento y validación.

Criterios de comparación

El análisis de desempeño consideró tanto métricas de precisión como indicadores operativos:

- **Precisión predictiva:** evaluada mediante MSE, RMSE, MAPE y Q-MAPE.
- **Eficiencia computacional:** tiempo total de entrenamiento y latencia de inferencia.
- **Robustez temporal:** estabilidad del error frente a variaciones estacionales y condiciones regionales.

Este enfoque integral busca reflejar las restricciones y requerimientos reales de sistemas energéticos industriales, donde la exactitud debe equilibrarse con la viabilidad computacional. Los resultados detallados de esta comparación se presentan en la Sección [8](#).

6.6. Modelo de Optimización

Conjuntos

- T : Conjunto de períodos de tiempo.
- E : Conjunto de tecnologías de generación de energía.

Parámetros

- C_e : Capacidad instalada de la tecnología e [MW].

- G_e : Costo de generación de la tecnología e [USD/MWh].
- D_t : Demanda de energía pronosticada en el período t [MWh].
- CO_{2e} : Emisiones de CO_2 por MWh para la tecnología e [ton/MWh].
- CapBESS : Capacidad de almacenamiento del BESS [MWh].
- $\eta_{\text{charge}}, \eta_{\text{discharge}}$: Eficiencia de carga/descarga.
- G_{BESS} : Costo operativo del BESS [USD/MWh].
- S_0 : Estado inicial del BESS.

Variables de Decisión

- $P_{e,t}$: Energía generada por la tecnología e en el período t [MWh].
- S_t : Energía almacenada en el BESS al final del período t [MWh].
- C_t : Energía cargada al BESS en el período t [MWh].
- R_t : Energía descargada del BESS en el período t [MWh].

Funciones Objetivo

$$f_1 = \sum_{t \in T} \left(\sum_{e \in E} G_e \cdot P_{e,t} + G_{\text{BESS}} \cdot (C_t + R_t) \right) \quad (5)$$

$$f_2 = \sum_{t \in T} \sum_{e \in E} \text{CO}_{2e} \cdot P_{e,t} \quad (6)$$

Restricciones

$$\sum_{e \in E} P_{e,t} + R_t = D_t + C_t \quad \forall t \in T \quad (7)$$

$$0 \leq P_{e,t} \leq C_e \quad \forall e \in E, t \in T \quad (8)$$

$$0 \leq S_t \leq \text{CapBESS} \quad \forall t \in T \quad (9)$$

$$S_t = S_{t-1} + \eta_{\text{charge}} \cdot C_t - \eta_{\text{discharge}} \cdot R_t \quad \forall t \in T \quad (10)$$

$$0 \leq C_t \leq \text{CapBESS} \quad \forall t \in T \quad (11)$$

$$0 \leq R_t \leq \text{CapBESS} \quad \forall t \in T \quad (12)$$

Agregación Multiobjetivo

$$\text{mín } Z = \alpha \cdot f_1 + \beta \cdot f_2 \quad \text{con } \alpha + \beta = 1, \alpha, \beta \in [0, 1] \quad (13)$$

6.7. Integración del Marco de Pronóstico y Optimización

La metodología propuesta integra modelos de pronóstico basados en aprendizaje profundo con un modelo de Programación Lineal Multiobjetivo (PL) para la optimización del despacho energético (5; 4; 2). A diferencia de los enfoques tradicionales que tratan el pronóstico y la optimi-

zación como etapas independientes, este marco conecta explícitamente ambos componentes para respaldar decisiones anticipativas y basadas en datos bajo restricciones industriales (21; 18; 8), inspirándose en avances recientes de modelos híbridos (50; 38).

Como se detalló previamente, se evaluaron múltiples arquitecturas de pronóstico (LSTM, GRU, Transformer y TCN) bajo esquemas consistentes de preprocesamiento y ajuste de hiperparámetros. El modelo seleccionado para la integración fue el que mostró mejor desempeño comparativo en términos de precisión, estabilidad y costo computacional. Este procedimiento asegura rigor metodológico y reduce la propagación de errores del pronóstico hacia el módulo de optimización.

El marco aprovecha la capacidad de LSTM para modelar dependencias temporales y la estructura eficiente de la programación lineal para optimización, alineándose con prácticas industriales que priorizan escalabilidad y tiempos de cómputo reducidos (17). Los perfiles diarios de demanda pronosticados (D_t), obtenidos mediante el modelo LSTM, se consideran entradas deterministas para el modelo PL (6; 46). Aunque la incertidumbre de los pronósticos no se modela explícitamente, esta formulación refleja prácticas reales donde la programación de generación, logística de combustibles y compras se basa en pronósticos puntuales con días o semanas de anticipación (15; 13).

El modelo de optimización determina los niveles diarios de despacho para cada tecnología de generación y sistema de almacenamiento, minimizando simultáneamente el costo total y las emisiones de CO_2 . La formulación es escalable y computacionalmente eficiente, permitiendo incorporar parámetros específicos como costos de generación (G_e), factores de emisión (CO_{2e}), capacidades instaladas (C_e) y dinámicas de sistemas BESS (33; 40; 32).

El proceso integrado se desarrolla en tres etapas principales:

1. El modelo de pronóstico genera las predicciones diarias de demanda $\{D_t\}_{t \in T}$ a partir de datos históricos (5; 4; 6).
2. Estas predicciones se incorporan al modelo PL junto con parámetros tecnológicos: costos, capacidades, emisiones y restricciones de almacenamiento (23; 33).
3. El solver del modelo PL calcula las decisiones óptimas de despacho diario para cada tecnología y estado de carga del BESS a lo largo del horizonte de planificación.

La arquitectura modular del marco propuesto permite futuras extensiones hacia horizontes horarios, incorporación de restricciones adicionales (p.ej., rampas de generación, reservas girantes) y formulaciones que consideren incertidumbre, como optimización robusta o estocástica (51; 52; 48). El flujo general se ilustra en la Figura 4, que muestra la secuencia de etapas desde el preprocesamiento de datos hasta la optimización del despacho energético.

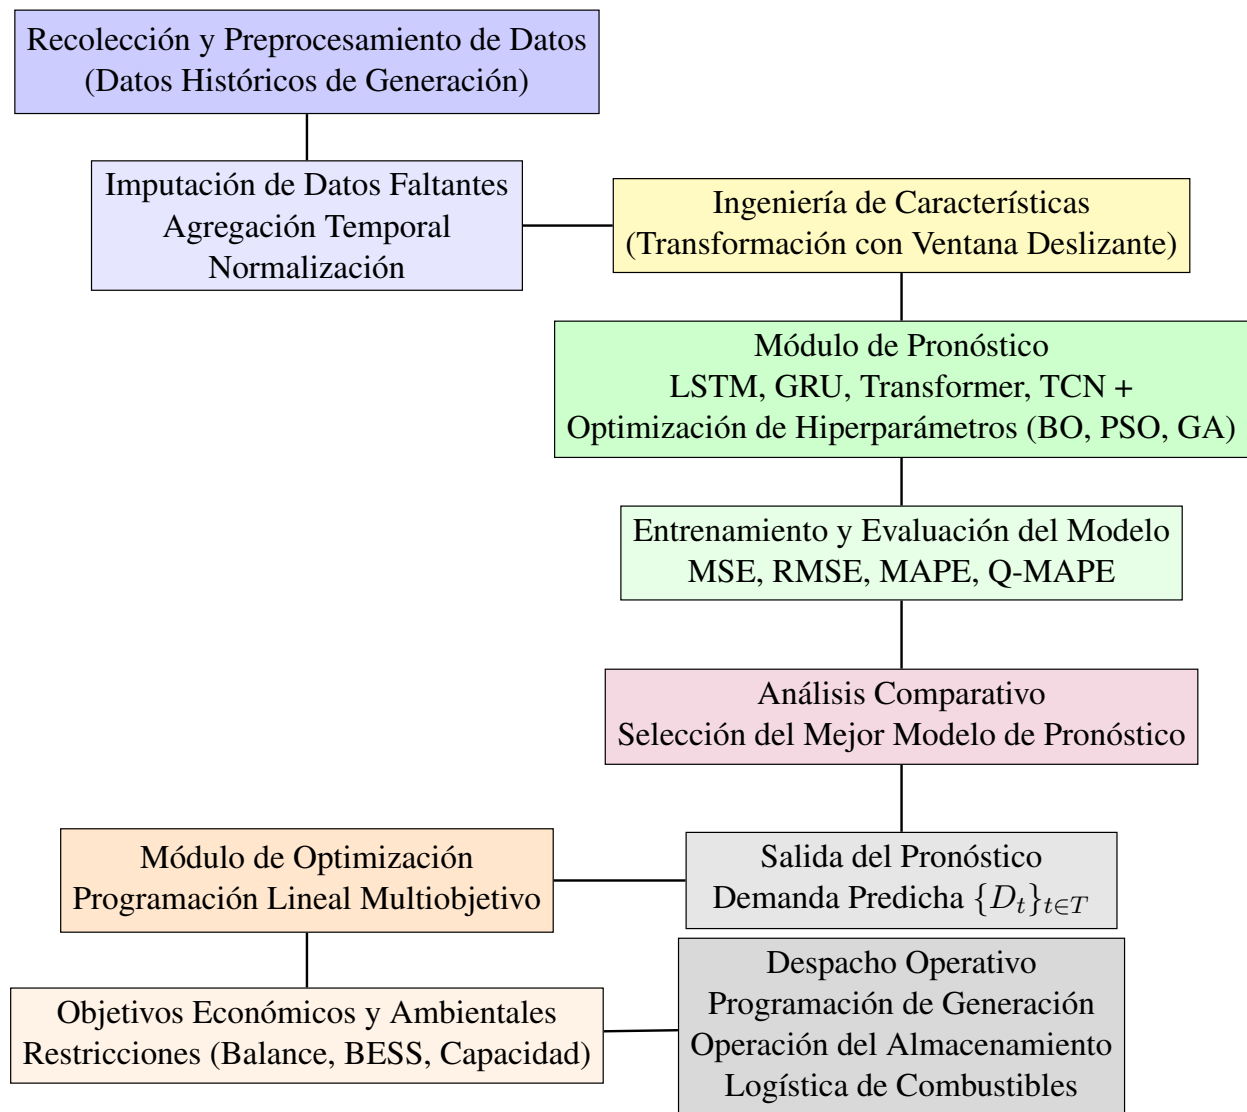


Figura 4: Marco metodológico general que integra pronóstico y optimización para la planificación energética. El proceso comienza con la preparación y transformación de datos, continúa con el entrenamiento y evaluación de modelos de pronóstico basados en aprendizaje profundo y, tras la selección del mejor modelo, incorpora los resultados al módulo de optimización para determinar el despacho energético óptimo.

7. Case Study Application

7.1. Recolección y Preprocesamiento de Datos

El marco integrado de pronóstico y optimización propuesto se valida mediante un caso de estudio a escala nacional, correspondiente al sistema eléctrico interconectado de Chile, desagregado en 14 regiones administrativas para capturar la heterogeneidad espacial. El análisis cubre el período 2016–2023, asegurando un horizonte temporal amplio que permita reflejar tanto la variabilidad a corto plazo como tendencias estructurales.

Se modelan siete tecnologías de generación: hidráulica, solar fotovoltaica, eólica, térmica (fósil), biomasa, geotermia y termosolar. Adicionalmente, se incluye un sistema representativo de almacenamiento mediante baterías (BESS) en cada región, con el fin de evaluar la flexibilidad operativa que aporta el almacenamiento en el balance diario bajo un esquema de despacho informado por pronósticos.

El sistema eléctrico chileno constituye un entorno ideal para la validación del modelo debido a su alta penetración de energías renovables, marcada variabilidad interanual y diversidad tecnológica. Los datos históricos fueron obtenidos desde plataformas gubernamentales de acceso abierto, proporcionando información horaria de generación por tecnología y región. Tras una limpieza mínima (menos de 10 observaciones faltantes, corregidas mediante interpolación lineal), los datos fueron agregados a valores diarios para alinearse con el horizonte de planificación utilizado en los módulos de pronóstico y optimización.

La Figura 5 presenta la generación agregada diaria, evidenciando los ciclos estacionales y la variabilidad de largo plazo. Posteriormente, el conjunto de datos se dividió cronológicamente en

subconjuntos de entrenamiento, validación y prueba, garantizando una evaluación *out-of-sample* consistente con las prácticas operativas reales en pronósticos.




Figura 5: Generación diaria de energía entre 2016 y 2023, segmentada en periodos de entrenamiento (2016–2021), validación (2022) y prueba (2023).

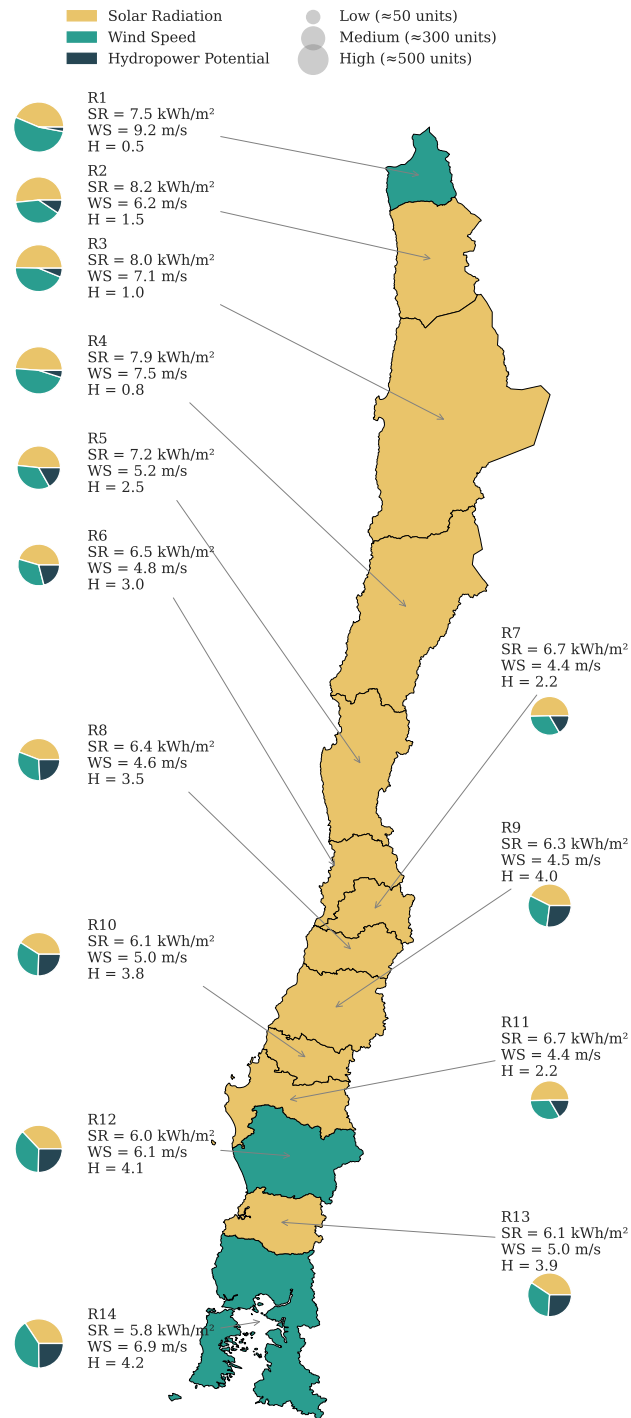


Figura 6: Distribución regional de los recursos de energía renovable en Chile. Los gráficos circulares muestran la proporción relativa de radiación solar (SR), velocidad del viento (WS) y potencial hidroeléctrico (H) para cada región (R1–R14). El tamaño del gráfico refleja la magnitud global del potencial renovable: bajo, medio o alto.

La Figura 6 proporciona una visión sintética de la disponibilidad de recursos energéticos renovables a lo largo del territorio chileno. La figura integra tres variables clave: radiación solar (SR), velocidad del viento (WS) y potencial hidroeléctrico (H), cada una representada como un segmento coloreado en los gráficos circulares regionales.

Los valores de SR, expresados en kilovatios-hora por metro cuadrado por día (kWh/m^2), indican la energía solar promedio disponible para conversión; los valores de WS, en metros por segundo (m/s), representan la velocidad media anual del viento a 10 metros de altura; y H corresponde a un índice adimensional que captura el potencial hidroeléctrico relativo, derivado de parámetros hidrológicos y topográficos.

El tamaño de cada gráfico circular refleja la magnitud total de los recursos renovables en la región, categorizada cualitativamente como baja, media o alta. Esta representación gráfica facilita la comparación de fortalezas y complementariedades regionales en la oferta renovable, aportando información relevante para la formulación de políticas energéticas, el despliegue de infraestructura y la planificación territorial.

7.2. Implementación del Módulo de Pronóstico

El componente de pronóstico del marco propuesto fue implementado mediante redes neuronales *Long Short-Term Memory* (LSTM), entrenadas sobre datos históricos de generación energética. El conjunto de datos se particionó cronológicamente para preservar la estructura temporal inherente a las tareas de pronóstico, asegurando una separación estricta entre los periodos de entrenamiento, validación y prueba. Específicamente, los datos de 2016 a 2021 se asignaron al conjunto de entrenamiento, el año 2022 al conjunto de validación y el año 2023 al conjunto de prueba. Esta

estrategia refleja las condiciones reales de pronóstico, donde las observaciones futuras no están disponibles durante la fase de desarrollo del modelo.

Los datos fueron transformados al formato de aprendizaje supervisado mediante un esquema de ventana deslizante (33; 28). Cada instancia de entrenamiento se construyó utilizando 30 días consecutivos de generación histórica como entrada para predecir la generación total del día siguiente, lo que permite capturar dependencias temporales de corto y mediano plazo presentes en el sistema eléctrico.

La optimización de hiperparámetros se realizó utilizando tres algoritmos metaheurísticos complementarios: *Bayesian Optimization* (BO), *Particle Swarm Optimization* (PSO) y *Genetic Algorithm* (GA). El diseño del proceso de búsqueda garantizó equidad en la comparación entre métodos, asignando presupuestos idénticos en términos de número de iteraciones para cada algoritmo. Los hiperparámetros explorados y sus respectivos rangos fueron los siguientes:

- **Unidades ocultas:** 32 a 256
- **Número de capas:** 1 a 4
- **Tasa de dropout:** 0.1 a 0.5
- **Tasa de aprendizaje:** 10^{-5} a 10^{-2}

Para cada configuración candidata propuesta por los algoritmos, el modelo LSTM se entrenó durante un número fijo de 40 épocas en la fase de búsqueda, controlando así el costo computacional y garantizando una convergencia adecuada. Una vez identificada la configuración óptima, los modelos finales fueron reentrenados utilizando todo el conjunto de entrenamiento, incrementando el número de épocas a 100 con el fin de explotar al máximo la información disponible para

su implementación operativa.

El entrenamiento se llevó a cabo empleando el optimizador *Adam* y la función de pérdida *Mean Squared Error* (MSE), en concordancia con las mejores prácticas en pronóstico secuencial (7; 40; 41). Esta configuración garantiza un balance entre eficiencia computacional, estabilidad en la convergencia y precisión predictiva frente a patrones de generación diversos, tanto a nivel regional como temporal.

7.3. Implementación del Módulo de Optimización

El módulo de optimización fue implementado a partir de la formulación de programación lineal (PL) multiobjetivo descrita previamente (21; 15; 13).

Los parámetros de costo de generación (G_e), factores de emisión (CO_2e) y capacidades instaladas (C_e) se definieron con valores fijos por tecnología, a partir de una síntesis de reportes públicos y fuentes estadísticas relevantes para el contexto chileno (67; 69; 68; 70). La Tabla 2 presenta los valores adoptados, representativos de las condiciones operativas del sistema eléctrico nacional.

Tabla 2: Parámetros tecnológicos utilizados en el modelo de optimización.

| Tecnología | Capacidad Instalada (MW) | Costo de Generación (USD/MWh) | Emisiones CO_2e (kg/MWh) |
|-----------------|--------------------------|-------------------------------|----------------------------|
| Hidroeléctrica | 2,500 | 70 | 24 |
| Solar | 5,000 | 35 | 41 |
| Eólica | 4,500 | 45 | 11 |
| Térmica (Fósil) | 12,600 | 100 | 900 |
| Biomasa | 800 | 75 | 0 |
| Geotermia | 100 | 70 | 45 |
| BESS | 2,500 | 12 | 0 |

Las entradas del modelo de optimización consistieron exclusivamente en:

1. Los pronósticos diarios de demanda (D_t) generados por el módulo LSTM, y

2. Los parámetros tecnológicos listados en la Tabla 2

Estos insumos fueron específicos por región, dado que el módulo de pronóstico se entrenó y aplicó de forma independiente para cada conjunto de datos regional. Las salidas del modelo LSTM, correspondientes a 365 valores diarios de demanda por región, se incorporaron directamente como restricciones en el modelo PL, que posteriormente calculó el despacho óptimo diario entre tecnologías y almacenamiento.

El modelo minimiza conjuntamente el costo total de generación y las emisiones de CO₂, respetando las restricciones operativas y físicas asociadas a la generación, almacenamiento y balance de demanda. Cada problema se resolvió de manera independiente para las 14 regiones, considerando un horizonte de planificación diaria de 365 días consecutivos, lo que permite capturar la variabilidad estacional con alta resolución temporal y compatibilidad con ciclos anuales de aprovisionamiento industrial.

Los parámetros del sistema de almacenamiento mediante baterías (BESS) —incluyendo capacidad de almacenamiento (Cap_{BESS}), eficiencia de carga (η_{charge}), eficiencia de descarga ($\eta_{discharge}$) y costo operativo (G_{BESS}) se asignaron de manera uniforme en todas las regiones, asegurando consistencia en el modelado y habilitando flexibilidad operativa en todo el sistema.

Todos los problemas de optimización fueron formulados y resueltos utilizando el solver *CBC*, disponible en la librería open-source PuLP para Python (71). Esta configuración computacional asegura escalabilidad, reproducibilidad y adaptabilidad del marco metodológico a sistemas más extensos o estudios alternativos.

8. Resultados

8.1. Selección del Modelo de Pronóstico

Esta sección resume la evaluación comparativa de cuatro arquitecturas de redes neuronales profundas: LSTM, GRU, Transformer y TCN, aplicadas bajo un esquema de preprocesamiento uniforme que asegura una comparación justa entre modelos. El desempeño se midió utilizando métricas estándar en pronóstico energético, incluyendo RMSE, MAE, MAPE y la estadística D, ampliamente reconocidas por su relevancia en la optimización del despacho (1; 4; 2).

El análisis visual confirmó que todos los modelos lograron capturar tanto la volatilidad de corto plazo como las dinámicas estacionales a nivel regional, lo que respalda la solidez de los insumos de pronóstico utilizados en el módulo de optimización y garantiza la pertinencia de las estrategias de despacho bajo escenarios de alta penetración renovable (51; 31).




Figura 7: Comparación de predicciones diarias de demanda energética generadas por cuatro modelos de redes neuronales: LSTM (morado), GRU (azul), TCN (rojo) y Transformer (amarillo), en relación con las observaciones reales (negro). El modelo TCN utiliza ahora una línea roja sólida para mejorar la visibilidad. La notación en el eje vertical corresponde a escala científica. Todos los modelos fueron entrenados bajo condiciones idénticas de preprocesamiento e insumos.

Tabla 3: Métricas de desempeño para diferentes arquitecturas de redes neuronales. La fila en verde corresponde al modelo con mejor rendimiento (LSTM) y en rojo al modelo menos preciso (TCN).

| Modelo | RMSE | MAE | MAPE (%) | Estadístico D | Tiempo (s) |
|-------------|-----------|----------|----------|---------------|------------|
| LSTM | 5,077.11 | 3,519.99 | 1.5581 | 0.0042 | 171.6 |
| GRU | 5,128.26 | 3,801.76 | 1.6775 | -0.0003 | 165.6 |
| Transformer | 6,060.26 | 4,346.42 | 1.9325 | 0.0133 | 2400.4 |
| TCN | 10,556.78 | 7,858.86 | 3.4465 | -0.0103 | 44.9 |

Para comparar los modelos de pronóstico en el contexto de integración con el despacho, se entrenaron las arquitecturas LSTM, GRU, Transformer y TCN bajo condiciones homogéneas de preprocesamiento y optimización de hiperparámetros, utilizando datos multi-regionales de demanda energética.

La Figura 7 muestra que todos los modelos lograron capturar patrones estacionales, aunque LSTM se ajustó con mayor precisión a la demanda real, especialmente durante los meses de alta variabilidad.

La Tabla 3 confirma la superioridad del modelo LSTM, que alcanzó los menores errores absolutos y relativos: RMSE = 5.077, MAE = 3.520 y MAPE = 1,56 %, junto con un sesgo mínimo ($D = 0,0042$) y un tiempo de cómputo moderado (172 s). El modelo GRU mostró errores ligeramente superiores, manteniendo una buena eficiencia computacional. El Transformer logró una precisión aceptable, pero a costa de un tiempo de ejecución casi diez veces mayor. Finalmente, TCN, aunque el más rápido, fue el modelo menos preciso.

El equilibrio entre exactitud y eficiencia del LSTM respalda su selección como el modelo base para el módulo de optimización propuesto, garantizando que las decisiones de despacho se fundamenten en pronósticos robustos y computacionalmente viables.




Figura 8: Valores reales versus predicciones generadas por el modelo. La gráfica ilustra la capacidad del modelo para seguir la dinámica observada.

La Figura 8 compara la generación energética real con la pronosticada por el modelo LSTM durante el año 2023, el más reciente en el conjunto de datos. Las curvas muestran una alta concordancia, capturando adecuadamente tanto la dinámica estacional como la variabilidad de corto plazo, factores críticos para la planificación anticipativa del despacho bajo escenarios de alta penetración renovable.

La banda sombreada representa la incertidumbre del pronóstico, calculada a partir de la desviación estándar de los residuales sobre el conjunto de validación. Su estrecha amplitud durante la mayor parte del año confirma una baja dispersión y una calibración robusta del modelo. No se detectaron sesgos sistemáticos, validando la idoneidad del modelo como insumo para la planificación operativa, incluyendo la programación térmica y la gestión de abastecimiento de combustible. Estos resultados refuerzan el rol del LSTM como puente entre el pronóstico y la optimización, abordando las brechas metodológicas **GAP 1** y **GAP 2**.

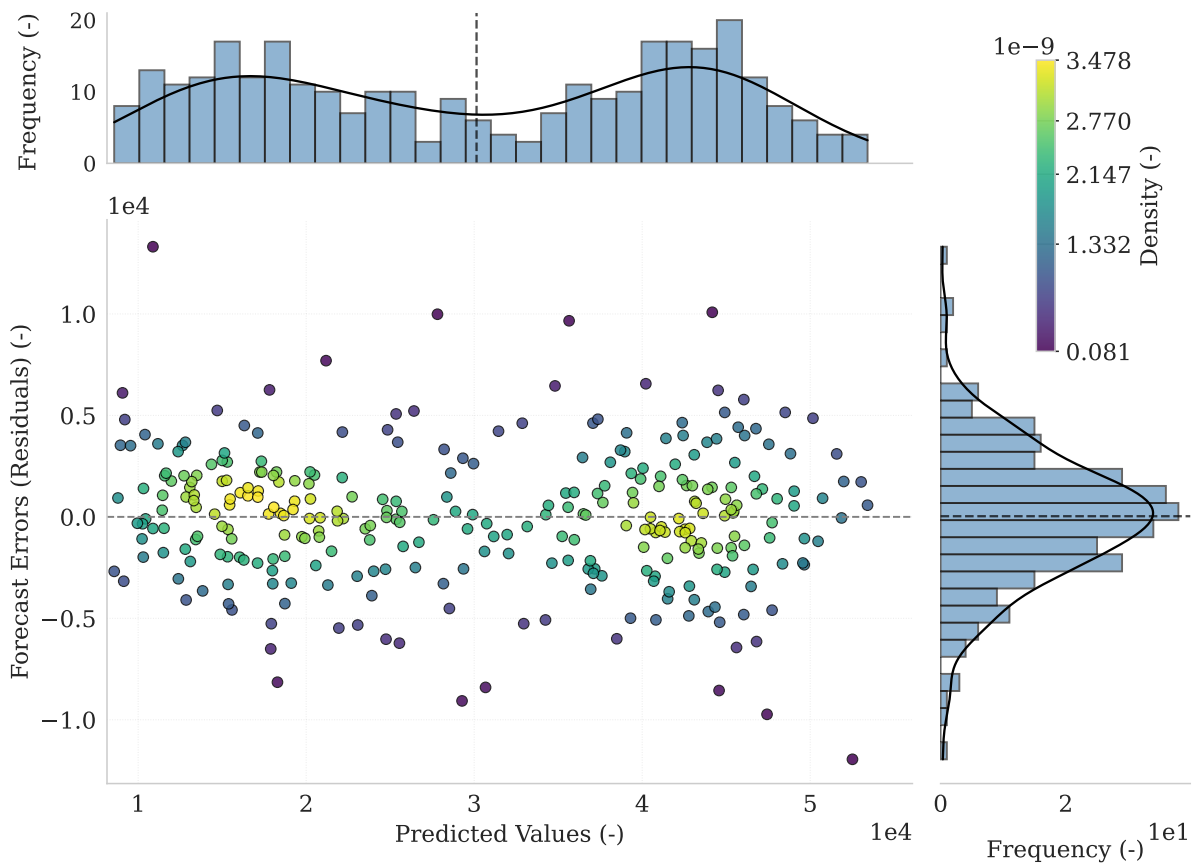


Figura 9: Residuales frente a valores predichos, coloreados según densidad mediante Kernel Density Estimation (KDE). La distribución muestra dispersión simétrica alrededor de cero, sin estructura aparente, lo que sugiere una calibración adecuada del modelo.

La Figura 9 presenta la relación entre residuales y valores predichos, incorporando sombreado por densidad mediante KDE. Los residuales se concentran simétricamente alrededor de cero, sin evidencias de forma embudo ni curvaturas, lo que confirma homocedasticidad y ausencia de sesgo sistemático a lo largo del rango de predicciones (40; 7).

Los histogramas asociados validan esta consistencia: la distribución de los residuales se aproxima a una normal centrada en cero, mientras que los valores predichos muestran un patrón bimodal, reflejando los regímenes estacionales de la demanda. De manera relevante, la precisión

del pronóstico se mantiene estable tanto en escenarios de baja como de alta demanda, garantizando confiabilidad uniforme.

Esta robustez estadística minimiza el riesgo de sesgos en la toma de decisiones de despacho cuando los pronósticos alimentan la optimización determinista, reforzando la credibilidad del marco propuesto para la planificación con relevancia regulatoria y contribuyendo a cerrar las brechas **GAP 1** y **GAP 2** (21; 15).

Tabla 4: Resumen compacto de las configuraciones óptimas de hiperparámetros para LSTM por región y algoritmo de optimización. Neu = Neuronas, Capas = Layers, Drp = Dropout, LR = Tasa de Aprendizaje.

| Región | PSO | | | | Algoritmo Genético | | | | Optimización Bayesiana | | | |
|--------------|-----|-------|-------|--------|--------------------|-------|-------|--------|------------------------|-------|-------|--------|
| | Neu | Capas | Drp | LR | Neu | Capas | Drp | LR | Neu | Capas | Drp | LR |
| R1 | 127 | 2 | 0.385 | 0.0047 | 35 | 2 | 0.163 | 0.0089 | 47 | 4 | 0.302 | 0.0027 |
| R2 | 256 | 4 | 0.308 | 0.0086 | 245 | 1 | 0.236 | 0.0042 | 43 | 1 | 0.380 | 0.0001 |
| R3 | 194 | 4 | 0.352 | 0.0004 | 84 | 2 | 0.434 | 0.0024 | 136 | 2 | 0.496 | 0.0007 |
| R4 | 97 | 2 | 0.166 | 0.0065 | 130 | 1 | 0.410 | 0.0087 | 200 | 4 | 0.481 | 0.0030 |
| R5 | 34 | 2 | 0.168 | 0.0006 | 152 | 3 | 0.345 | 0.0083 | 33 | 1 | 0.394 | 0.0004 |
| R6 | 89 | 2 | 0.211 | 0.0100 | 181 | 3 | 0.326 | 0.0073 | 186 | 2 | 0.305 | 0.0025 |
| R7 | 204 | 1 | 0.222 | 0.0025 | 256 | 1 | 0.265 | 0.0100 | 247 | 4 | 0.375 | 0.0025 |
| R8 | 99 | 1 | 0.446 | 0.0052 | 135 | 2 | 0.435 | 0.0017 | 173 | 2 | 0.431 | 0.0012 |
| R9 | 32 | 3 | 0.188 | 0.0056 | 68 | 1 | 0.339 | 0.0030 | 240 | 2 | 0.214 | 0.0039 |
| R10 | 159 | 1 | 0.400 | 0.0015 | 104 | 1 | 0.162 | 0.0072 | 225 | 3 | 0.248 | 0.0009 |
| R11 | 128 | 1 | 0.173 | 0.0091 | 146 | 2 | 0.328 | 0.0099 | 38 | 2 | 0.123 | 0.0068 |
| R12 | 164 | 3 | 0.334 | 0.0010 | 186 | 2 | 0.416 | 0.0076 | 129 | 3 | 0.194 | 0.0008 |
| R13 | 78 | 3 | 0.100 | 0.0012 | 96 | 2 | 0.251 | 0.0010 | 75 | 1 | 0.242 | 0.0034 |
| R14 | 256 | 2 | 0.401 | 0.0081 | 237 | 2 | 0.368 | 0.0065 | 215 | 3 | 0.364 | 0.0031 |
| Total | 251 | 2 | 0.229 | 0.0028 | 152 | 4 | 0.398 | 0.0016 | 164 | 2 | 0.104 | 0.0041 |

Table 4 resume las configuraciones óptimas de hiperparámetros para las redes LSTM, ob-

tenidas mediante PSO, Algoritmo Genético y Optimización Bayesiana en las diferentes regiones del sistema eléctrico chileno. Cada algoritmo generó arquitecturas distintas, reflejando cómo la volatilidad de la demanda regional influye en la complejidad del modelo y en las necesidades de regularización. En regiones con mayor variabilidad, se observaron redes más profundas y con tasas de *dropout* más altas, mientras que las regiones con patrones más estables convergieron en configuraciones simples. Esta heterogeneidad confirma la importancia de realizar ajustes específicos por región, ya que no se identificó una única configuración que generalizara de forma robusta en todos los casos.

Asimismo, la diversidad en las configuraciones obtenidas por cada método evidencia la sensibilidad del desempeño de LSTM a la estrategia de optimización empleada. Este hallazgo refuerza la necesidad de esquemas adaptativos y robustos para el ajuste de hiperparámetros en entornos industriales heterogéneos y bajo incertidumbre. En conjunto, estos resultados contribuyen directamente al cierre del **GAP 2**, al demostrar que la integración metodológica propuesta soporta escenarios con características operativas diversas.




Figura 10: Comparación entre valores reales y pronosticados en la generación total y cinco regiones seleccionadas. Cada panel muestra las predicciones obtenidas mediante modelos LSTM ajustados con tres algoritmos de optimización: Algoritmo Genético (AGO), PSO y Optimización Bayesiana. La línea negra indica los valores observados.

La Figura 10 compara la generación real y la pronosticada para el total del sistema y cinco regiones. Cada subgráfico muestra el efecto del algoritmo de ajuste sobre la alineación predictiva respecto a la demanda real. En regiones dinámicas, como R7 y R12, las diferencias entre algoritmos son más pronunciadas, lo que refleja la complejidad de capturar comportamientos no lineales. En contraste, regiones más estables, como R2 y R5, presentan desviaciones mínimas entre métodos, lo que sugiere una mayor facilidad de aprendizaje. Estos resultados subrayan la necesidad de un ajuste sensible al contexto geográfico y a la estrategia de optimización, validando la adaptabilidad del marco metodológico propuesto. Adicionalmente, la modularidad del enfoque lo convierte en una solución escalable y replicable para sistemas energéticos distribuidos con perfiles operativos heterogéneos.




Figura 11: Comparación del desempeño de los algoritmos de optimización de hiperparámetros en diferentes regiones. Todas las métricas de error se expresan como porcentajes relativos al valor promedio real. Los subgráficos presentan RMSE (%), MAPE (%), MAE (%) y la estadística D, proporcionando una evaluación integral de la precisión predictiva y la consistencia de cada modelo en distintos contextos regionales.

La Figura 11 muestra la comparación del desempeño predictivo de los tres algoritmos empleados para la optimización de hiperparámetros (Algoritmo Genético, PSO y Optimización Bayesiana) en todas las regiones, considerando las métricas RMSE, MAPE, MAE y la estadística D. Los errores se presentan normalizados como porcentaje, salvo la estadística D, que mide la concordancia entre las distribuciones pronosticadas y observadas.

Los resultados revelan una marcada variabilidad regional y la existencia de compromisos

(*trade-offs*) entre métodos. La Optimización Bayesiana presentó, en varias regiones, los menores valores de MAPE y MAE, lo que indica mayor precisión puntual. Por su parte, PSO destacó en la estadística D, lo que sugiere una mejor fidelidad en la reproducción de la estructura estadística global de la serie, aspecto crítico cuando los pronósticos se integran en modelos de optimización.

Estos hallazgos confirman que no existe un único algoritmo dominante en todos los escenarios. En consecuencia, la adopción de un enfoque multi-algoritmo incrementa la robustez del marco propuesto y justifica la necesidad de ajustes específicos por región. Este resultado refuerza el cierre del **GAP 2**, asegurando confiabilidad en la planificación operativa informada por pronósticos bajo condiciones de incertidumbre.

Tabla 5: Comparación compacta del desempeño de pronóstico entre algoritmos y regiones. D = Estadístico D, MAE = Error Absoluto Medio, MAPE = Error Porcentual Absoluto Medio, RMSE = Raíz del Error Cuadrático Medio. Todos los valores se expresan como porcentaje, excepto D.

| Región | Algoritmo PSO | | | | Optimización Bayesiana | | | | Algoritmo Genético | | | |
|--------|---------------|--------|--------|--------|------------------------|--------|--------|--------|--------------------|--------|--------|--------|
| | D | MAE | MAPE | RMSE | D | MAE | MAPE | RMSE | D | MAE | MAPE | RMSE |
| R1 | 0.671 | 40.739 | 22.580 | 76.285 | 0.373 | 47.081 | 26.374 | 86.127 | 0.954 | 38.957 | 21.750 | 72.718 |
| R2 | 0.954 | 15.915 | 17.583 | 21.308 | 0.905 | 14.841 | 17.119 | 19.570 | 0.748 | 14.943 | 17.248 | 20.918 |
| R3 | 0.428 | 6.515 | 6.710 | 8.431 | 0.530 | 6.549 | 6.666 | 8.423 | 0.601 | 6.425 | 6.662 | 8.310 |
| R4 | 0.801 | 13.232 | 14.050 | 16.628 | 0.611 | 13.920 | 14.421 | 17.749 | 0.636 | 12.232 | 13.040 | 15.572 |
| R5 | 0.974 | 33.088 | 42.292 | 41.952 | 0.633 | 32.733 | 41.405 | 41.769 | 0.497 | 38.418 | 48.742 | 48.908 |
| R6 | 0.755 | 8.852 | 11.735 | 11.506 | 0.373 | 8.249 | 10.375 | 10.949 | 0.464 | 8.548 | 11.299 | 11.271 |
| R7 | 0.377 | 10.029 | 12.801 | 14.674 | 0.954 | 11.432 | 13.558 | 15.474 | 0.540 | 12.014 | 13.232 | 16.066 |
| R8 | 0.312 | 10.409 | 11.564 | 13.204 | 0.864 | 10.405 | 11.675 | 13.197 | 0.927 | 10.714 | 12.148 | 13.694 |
| R9 | 0.441 | 9.440 | 10.370 | 11.814 | 0.739 | 8.183 | 9.974 | 10.395 | 0.512 | 8.761 | 10.232 | 11.198 |
| R10 | 0.561 | 14.515 | 15.530 | 18.822 | 0.453 | 12.663 | 15.180 | 17.297 | 0.635 | 12.907 | 14.667 | 17.455 |
| R11 | 0.337 | 6.715 | 7.038 | 8.621 | 0.595 | 6.429 | 6.689 | 8.507 | 0.819 | 7.905 | 7.653 | 10.456 |
| R12 | 0.388 | 37.167 | 44.064 | 48.112 | 0.630 | 38.148 | 46.120 | 48.756 | 0.637 | 41.087 | 51.646 | 52.683 |
| R13 | 0.352 | 8.323 | 12.049 | 10.806 | 0.883 | 7.520 | 10.407 | 10.296 | 0.538 | 8.299 | 11.397 | 10.819 |
| R14 | 0.555 | 17.619 | 17.374 | 23.463 | 0.982 | 17.654 | 17.321 | 23.244 | 0.965 | 18.877 | 18.065 | 25.176 |
| Total | 0.302 | 1.536 | 1.558 | 2.216 | 0.610 | 1.988 | 1.985 | 2.520 | 0.877 | 2.226 | 2.222 | 3.052 |

La Tabla 5 compara el desempeño de pronóstico de PSO, Optimización Bayesiana (BO) y

Algoritmo Genético (GA) a través de cuatro métricas clave: estadístico D, MAE, MAPE y RMSE. Todos los valores están expresados como porcentajes, excepto el estadístico D, que mide la alineación entre la distribución predicha y la real.

Los resultados muestran que BO obtuvo consistentemente los valores más bajos de MAE y MAPE, lo que indica una mayor precisión puntual, mientras que PSO presentó mejores valores del estadístico D, reflejando una superior fidelidad distribucional, aspecto crucial para la integración posterior en modelos deterministas de optimización. Sin embargo, ningún algoritmo dominó en todas las regiones o métricas.

Esta heterogeneidad confirma el valor de una estrategia multi-algoritmo, aprovechando las fortalezas específicas de cada método: la exploración colectiva de PSO, la búsqueda probabilística guiada de BO y la adaptabilidad evolutiva de GA. Este enfoque incrementa la robustez del sistema frente a perfiles regionales heterogéneos y condiciones de alta variabilidad.

En conjunto, este análisis comparativo respalda el GAP 2, al reforzar la necesidad de ajustes adaptativos y dependientes del contexto para garantizar pronósticos confiables y escalables en sistemas energéticos industriales.

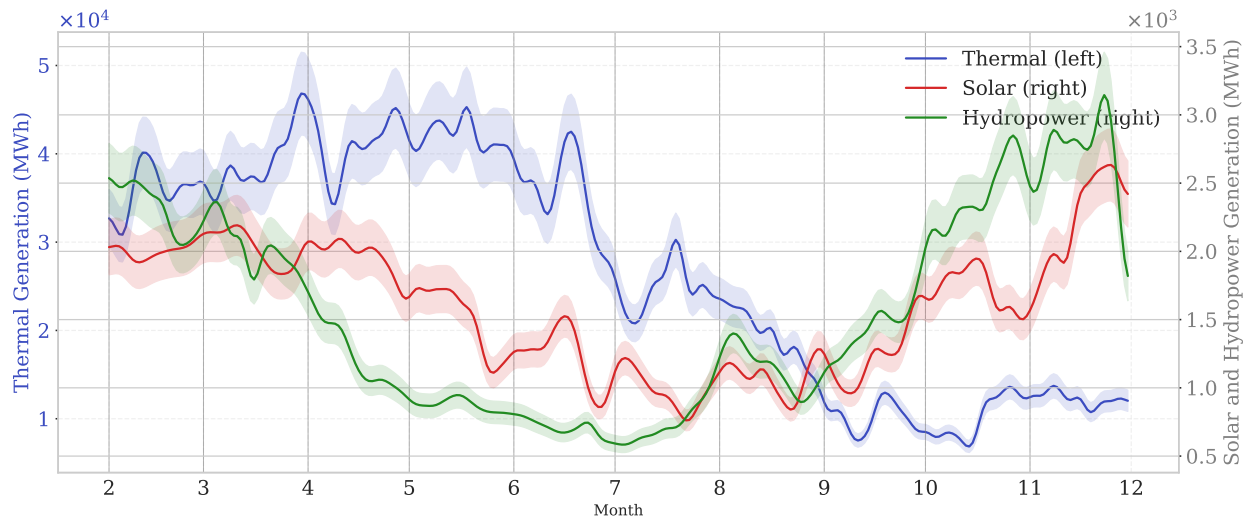


Figura 12: Generación de energía por tecnología durante el horizonte de optimización. Los resultados corresponden a la salida del modelo de programación lineal, detallando la generación programada para fuentes hidráulicas, solares y térmicas.

La Figura [12](#) ilustra el despacho energético informado por pronósticos para las tecnologías térmica, solar e hidráulica durante 2023, el último año completo disponible. El modelo de optimización asigna la generación diaria con el objetivo de minimizar simultáneamente los costos y las emisiones de CO_2 , cumpliendo las restricciones de capacidad y disponibilidad establecidas.

Tal como se esperaba, las fuentes renovables predominan cuando se encuentran disponibles, mientras que la generación térmica actúa como respaldo flexible para garantizar la confiabilidad del sistema. Un elemento distintivo del enfoque propuesto es la **cuantificación anticipativa de los requerimientos térmicos**, lo que permite planificar con antelación la logística de combustible y las reservas operativas. Este aspecto aborda directamente el **GAP 1** (programación proactiva) y el **GAP 2** (incertidumbre renovable).

Las bandas sombreadas representan la incertidumbre asociada a los pronósticos, calculada a partir de la desviación estándar residual del modelo LSTM, lo que proporciona un rango operativo para la gestión del riesgo. Las mayores amplitudes observadas entre abril y junio reflejan la



necesidad de estrategias conservadoras de despacho en escenarios con alta variabilidad estacional.

En síntesis, la integración de analítica predictiva y optimización convierte los pronósticos en decisiones operativas concretas, mejorando la confiabilidad del sistema, reduciendo costos y alineando la operación con objetivos regulatorios y climáticos bajo condiciones de alta penetración renovable.

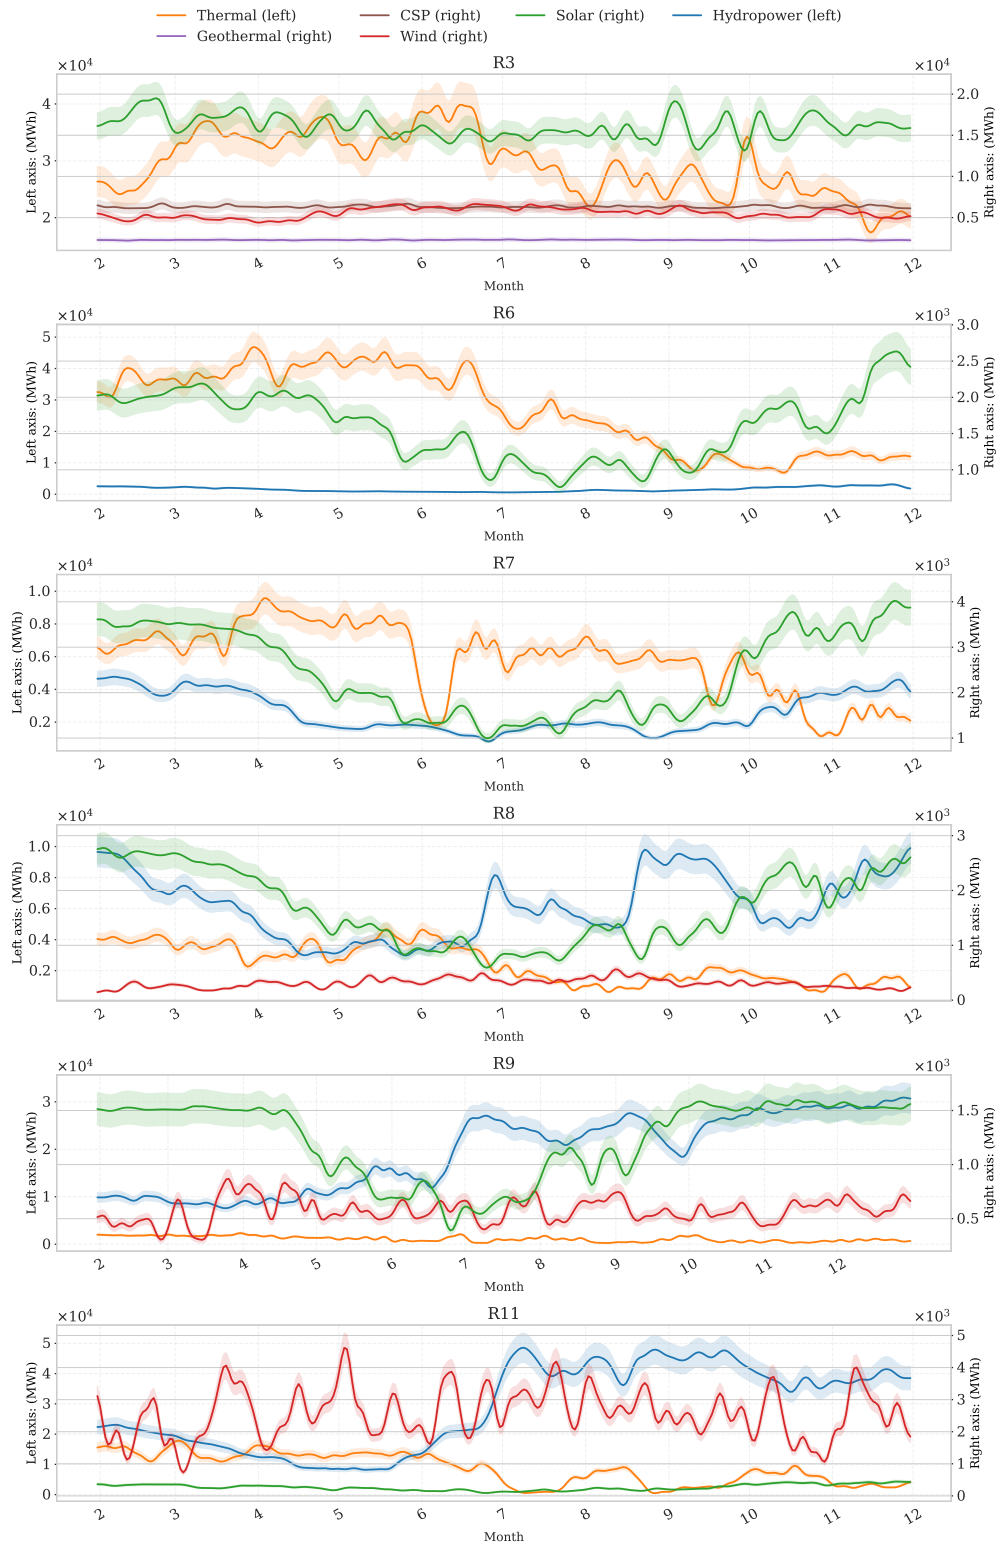


Figura 13: Perfiles regionales de generación de energía por tecnología durante el horizonte optimización. La figura ilustra la mezcla de energía despachada por región, destacando la variabilidad en la generación renovable y térmica entre las distintas regiones.

La Figura **13** muestra la variabilidad regional en el despacho óptimo para el año 2023, agrupada en tres zonas: **norte (R3, R6)**, **centro (R7, R8)** y **sur (R9, R11)**. Las bandas sombreadas representan la incertidumbre asociada a los pronósticos, estimada a partir de los residuos del modelo LSTM.

Zona norte (R3, R6): Predomina la energía solar, complementada por la generación eólica. El respaldo térmico aparece principalmente durante los meses de invierno (mayo–julio), coincidiendo con reducciones significativas en la irradiancia. Las bandas de incertidumbre son estrechas, lo que indica alta confiabilidad en las previsiones renovables.

Zona central (R7, R8): Se observa una cartera más equilibrada. R7 depende de generación térmica durante todo el año, reflejando alta demanda y capacidad de almacenamiento limitada. R8 prioriza el uso de hidroelectricidad; sin embargo, las sequías estacionales inducen un aumento en el despacho térmico. Las bandas de incertidumbre se amplían en meses con alta dependencia hídrica, señalando sensibilidad ante variaciones hidrológicas.

Zona sur (R9, R11): La hidroelectricidad domina el suministro. R9 presenta un comportamiento estable, mientras que R11 exhibe alta volatilidad debido a cargas industriales, lo que demanda ajustes térmicos frecuentes. Las bandas más amplias en esta región reflejan la dificultad de pronosticar picos inesperados.

El periodo invernal (junio–agosto) se confirma como el más crítico, por déficit renovable en todas las zonas, lo que resalta la importancia del despacho térmico anticipado para garantizar la resiliencia y cumplir con los estándares de flexibilidad. Estos resultados refuerzan los aportes frente a **GAP 1** (planificación proactiva), **GAP 2** (gestión de incertidumbre) y **GAP 3** (diferenciación regional).

8.1.1. Supuestos y Metodología

El análisis comparativo se realizó bajo los siguientes supuestos:

- Ambos modelos operan bajo las mismas restricciones técnicas, incluyendo límites de capacidad de generación, dinámica de BESS y satisfacción de demanda.
- El modelo de programación base (*naive*) asigna la generación suponiendo un perfil de demanda plano derivado de promedios históricos, ignorando la variabilidad temporal.
- El modelo *forecast-driven* utiliza pronósticos diarios obtenidos mediante LSTM, mejorando la capacidad de planificación anticipada.
- La generación renovable (solar, eólica, hidráulica) se consideró como entrada exógena, enfocando la optimización en tecnologías despachables (térmica y BESS).

Los indicadores clave (KPI) evaluados incluyen:

- **Reducción de Costos Totales (%):** Ahorros en costos operativos obtenidos mediante despacho optimizado basado en pronósticos.
- **Reducción de Emisiones (%):** Disminución de emisiones de CO₂ derivada de decisiones de despacho más eficientes.
- **Reducción en Uso de Combustibles Fósiles (%):** Reducción en el consumo de combustibles, reflejando mejoras en eficiencia y sustitución renovable.

8.1.2. Resultados y Discusión




Figura 14: Impacto de la integración de pronósticos sobre costos, emisiones y uso de combustible por región (% de mejora respecto al despacho *naive*).

La Figura 14 compara el despacho informado por pronósticos frente a un modelo *naive* en tres KPIs: costos operativos, emisiones de CO₂ y uso de combustibles fósiles. Los resultados evidencian una marcada heterogeneidad entre las 14 regiones analizadas.

Las regiones con alta variabilidad renovable (R1, R4, R5) muestran las mayores mejoras, con ahorros de combustible superiores al 90 % y reducciones significativas en costos y emisiones. Del mismo modo, las zonas centrales (R7, R8) se benefician de portafolios balanceados que permiten maximizar la participación renovable. En contraste, regiones con baja variabilidad o restricciones estructurales (p. ej., R6, R10) presentan mejoras limitadas (inferiores al 15 % en algunos KPIs), reflejando menor flexibilidad para estrategias predictivas.

Estas disparidades confirman que el valor agregado de la predicción es mayor donde la incertidumbre y la intermitencia son más pronunciadas, reforzando su rol como herramienta estratégica para reducir dependencia fósil y emisiones. Estos hallazgos abordan directamente **GAP 1** (despacho anticipativo), **GAP 2** (planificación bajo incertidumbre) y aportan evidencia para **GAP 3** al mostrar asimetrías regionales relevantes para la suficiencia de recursos y el diseño de mercados.

Tabla 6: KPIs operacionales: Optimización basada en pronósticos vs. programación *naive*.

| Región | Ahorro de Costos (%) | Reducción de Emisiones (%) | Reducción de Combustible (%) |
|-----------------|----------------------|----------------------------|------------------------------|
| R1 | 97.17 | 43.46 | 97.17 |
| R2 | 10.56 | 4.95 | 14.31 |
| R3 | 35.99 | 21.73 | 42.50 |
| R4 | 73.29 | 46.91 | 97.46 |
| R5 | 95.19 | 62.81 | 90.79 |
| R6 | 10.56 | 4.95 | 14.31 |
| R7 | 47.14 | 30.70 | 90.77 |
| R8 | 76.10 | 45.07 | 90.03 |
| R9 | 94.95 | 39.96 | 99.58 |
| R10 | 38.85 | 13.99 | 38.85 |
| R11 | 78.54 | 26.34 | 93.38 |
| R12 | 57.17 | 51.74 | 25.39 |
| R13 | 84.96 | 1.87 | 84.72 |
| R14 | 90.97 | 50.86 | 82.23 |
| Promedio | 63.7 | 31.8 | 68.7 |

La Tabla 6 resume los porcentajes de mejora logrados mediante la integración de pronósticos en la optimización del despacho, en comparación con una programación basada en perfiles históricos (*naive*). Los principales hallazgos son los siguientes:

- **Ahorros significativos:** El promedio nacional alcanza **63.7 %** de reducción en costos y **68.7 %** en uso de combustibles fósiles, validando el impacto económico del enfoque propuesto.
- **Impacto ambiental relevante:** Las emisiones de CO₂ se reducen en promedio un **31.8 %**, con máximos superiores al 60 % (caso de R5), lo que refuerza la contribución a objetivos de descarbonización.
- **Alta heterogeneidad regional:** Regiones con alta variabilidad y flexibilidad renovable (R1, R4, R5, R9) muestran mejoras superiores al 90 % en combustible y costos, confirmando la hipótesis de que el valor del pronóstico se incrementa en entornos inciertos.
- **Casos de baja ganancia:** Zonas con recursos renovables más estables o con restricciones estructurales (e.g., R2, R6) presentan beneficios menores (<15 %), lo que evidencia que la adaptabilidad del modelo debe considerarse al diseñar políticas regionales.

Estos resultados respaldan los **GAP 1** (planificación anticipativa) y **GAP 2** (manejo de incertidumbre) identificados en la literatura, al demostrar que la integración pronóstico–optimización no solo reduce costos y emisiones, sino que también aporta resiliencia frente a la variabilidad renovable.

8.1.3. Conclusiones Críticas

El análisis comparativo entre la optimización basada en pronósticos y la programación ingenua revela varias conclusiones fundamentales:

- **Superioridad consistente de la integración de pronósticos:** En todas las regiones y KPIs evaluados, el modelo informado por pronósticos supera a la planificación ingenua, confirmando que la programación anticipativa mejora significativamente el desempeño operativo y ambiental.
- **Alta heterogeneidad regional:** La magnitud de la mejora depende fuertemente de la región, reflejando variaciones en la penetración renovable, la volatilidad de la demanda y la disponibilidad de recursos flexibles. Regiones con alta incertidumbre (p. ej., R1, R4, R5, R9) lograron reducciones en costos y consumo de combustible superiores al 90 %, mientras que zonas estructuralmente limitadas (p. ej., R2, R6) registraron mejoras modestas (<15 %).
- **Beneficios residuales en escenarios de baja variabilidad:** Incluso en regiones estables, la integración de pronósticos reduce el consumo de combustibles fósiles y los costos operativos, demostrando que la planificación predictiva genera valor más allá de contextos con alta intermitencia.

Estos hallazgos validan la premisa central de este estudio: *la optimización anticipativa basada en datos es crítica para una planificación energética confiable y sostenible*. Los resultados aportan evidencia empírica para cerrar el **GAP 1** (necesidad de programación proactiva) y el **GAP 2** (gestión de incertidumbre informada por pronósticos), reforzando la transición desde despachos estáticos basados en heurísticas hacia estrategias dinámicas y adaptativas.

8.2. Análisis de Sensibilidad ante Errores de Pronóstico

Para evaluar la robustez del marco propuesto frente a predicciones imperfectas, se realizó un análisis de sensibilidad perturbando la demanda pronosticada con errores sistemáticos del 5 %, 10 %, 15 % y 20 %. Este análisis cuantifica el impacto de las inexactitudes del pronóstico sobre dos indicadores clave de desempeño:

- **Costo Operativo Total (% de cambio):** Mide el impacto económico derivado de desviaciones respecto al despacho óptimo debido a errores de pronóstico.
- **Emisiones de CO₂ (% de cambio):** Captura las implicaciones ambientales de la incertidumbre del pronóstico, especialmente bajo ajustes en el despacho térmico.

Las perturbaciones se aplicaron de manera uniforme en todas las regiones para emular escenarios de sesgo sistemático, preservando la estructura temporal de la demanda. Posteriormente, el modelo de optimización se resolvió nuevamente para cada nivel de error, permitiendo una comparación directa frente a la línea base (pronóstico sin sesgo). Este procedimiento refleja condiciones reales de operación, donde los pronósticos puntuales suelen contener desviaciones sistemáticas, y proporciona información sobre la resiliencia de los marcos deterministas de programación en entornos con alta penetración renovable.

Tabla 7: Impacto del error de pronóstico en los indicadores operativos por región.

| Región | Variación en Costo Total (%) | | | | Variación en Emisiones (%) | | | |
|--------|-------------------------------|-------|-------|-------|-----------------------------|-------|-------|--------|
| | 5 % | 10 % | 15 % | 20 % | 5 % | 10 % | 15 % | 20 % |
| R1 | 5.00 | 10.00 | 15.00 | 20.00 | 5.00 | 10.00 | 15.00 | 20.00 |
| R2 | 5.00 | 10.00 | 15.00 | 20.00 | 5.00 | 10.00 | 15.00 | 20.00 |
| R3 | 4.71 | 9.43 | 14.14 | 18.86 | 6.57 | 13.14 | 19.71 | 26.29 |
| R4 | 5.25 | 10.45 | 15.57 | 20.63 | 27.17 | 58.61 | 95.07 | 135.99 |
| R5 | 5.01 | 10.02 | 15.03 | 20.05 | 4.93 | 9.83 | 14.72 | 19.52 |
| R6 | 4.62 | 9.23 | 13.83 | 18.42 | 7.36 | 14.77 | 22.21 | 29.67 |
| R7 | 5.77 | 11.43 | 16.98 | 22.44 | 14.89 | 42.08 | 82.94 | 135.62 |
| R8 | 5.65 | 11.33 | 17.04 | 22.76 | 2.70 | 5.27 | 7.77 | 10.21 |
| R9 | 5.06 | 10.13 | 15.21 | 20.31 | 4.22 | 8.27 | 12.10 | 15.80 |
| R10 | 5.00 | 10.00 | 15.00 | 20.00 | 5.00 | 10.00 | 15.00 | 20.00 |
| R11 | 4.89 | 9.78 | 14.65 | 19.50 | 15.89 | 32.28 | 49.04 | 66.21 |
| R12 | 5.94 | 11.78 | 17.54 | 23.21 | 17.23 | 41.48 | 70.45 | 106.15 |
| R13 | 5.00 | 10.00 | 15.00 | 20.00 | 5.00 | 10.00 | 15.00 | 20.00 |
| R14 | 5.02 | 10.03 | 15.05 | 20.09 | 4.90 | 9.79 | 14.66 | 19.44 |

La **Tabla 7** presenta la sensibilidad al error de pronóstico en las 14 regiones analizadas. El **Costo Total** muestra una respuesta casi lineal, aumentando moderadamente desde un 4.7–5.9 % con un error del 5 % hasta aproximadamente 18–23 % con un error del 20 %. En contraste, los impactos sobre las **emisiones** son altamente no lineales y dependientes de la región: las áreas con alta dependencia térmica (R4, R7) experimentan incrementos superiores al 130 % bajo un error del 20 %, mientras que otras (R12, R11) registran aumentos por encima del 60 %. En cambio, las regiones con alta penetración renovable o portafolios diversificados (R5, R9, R13, R14) mantienen cambios en las emisiones por debajo del 20 %, incluso bajo escenarios de incertidumbre severa.

Esta asimetría destaca dos hallazgos clave:

1. Los riesgos económicos asociados a errores de pronóstico son **predecibles y manejables**.

2. Los riesgos ambientales escalan de manera **desproporcionada en regiones dependientes de combustibles fósiles**, poniendo en riesgo el cumplimiento de los objetivos de descarbonización.

Estos resultados validan la relevancia regulatoria de contar con pronósticos precisos para sostener la integridad de los esquemas de comercio de emisiones (ETS) y orientar estándares diferenciados de flexibilidad entre regiones, reforzando la motivación detrás de los **GAP 1** y **GAP 2**.

2.




Figura 15: Sensibilidad agregada del Costo Total y las Emisiones de CO₂ frente al error de pronóstico en todas las regiones. Visualización ampliada para mejorar la interpretabilidad.

La **Figura 15** muestra una visualización agregada de las tendencias de sensibilidad. Mientras que el **Costo Total** mantiene un crecimiento lineal constante, la sensibilidad de las **emisiones** se acelera de forma pronunciada, enfatizando el impacto ambiental desproporcionado de los errores de pronóstico. Es evidente la capacidad del modelo para mitigar aumentos en los costos mediante un despacho optimizado; sin embargo, las emisiones permanecen vulnerables a las imprecisiones en la predicción de la demanda. Estos hallazgos subrayan la importancia crítica de contar con pro-

nósticos precisos en las estrategias de descarbonización, reforzando la relevancia del modelo para la planificación operativa bajo incertidumbre.

Tabla 8: Resumen de hallazgos clave, implicancias operativas y contribuciones que abordan las brechas identificadas.

| Hallazgo | Implicancia Operativa | Brecha Abordada |
|---|---|--|
| Pronóstico robusto y preciso de necesidades diarias de generación controlable (LSTM + BO/PSO/GA) | Permite a las industrias anticipar requerimientos de generación térmica con meses de antelación, apoyando una planificación precisa de abastecimiento y logística de combustibles | GAP 1: Integración del pronóstico en la planificación operativa |
| Análisis de residuos confirma ausencia de sesgo sistemático o heterocedasticidad | Garantiza la fiabilidad de los pronósticos como insumo para modelos deterministas de optimización, reduciendo el riesgo de sobre/subestimación en los planes de despacho | GAP 2: Integración robusta/estocástica mediante optimización informada por pronósticos estables |
| Comparación de algoritmos (BO, PSO, GA) muestra que no existe un método universalmente superior en todas las regiones | Valida la necesidad de estrategias adaptativas y específicas por región para asegurar la robustez del pronóstico bajo perfiles energéticos heterogéneos | GAP 2: Necesidad de ajuste adaptable y contextualizado de modelos |
| Los perfiles de despacho regionales revelan fuertes vulnerabilidades estacionales y dependencia térmica en invierno | Destaca el rol crítico de la planificación proactiva, el despliegue de almacenamiento y la respuesta de demanda para mitigar riesgos de suministro durante déficits renovables | GAP 1 y 2: Despacho robusto informado por pronósticos bajo variabilidad estacional |
| La cuantificación térmica permite una planificación de abastecimiento con alta resolución temporal | Favorece la alineación de operaciones con estrategias de compra, logística y reducción de emisiones; reduce sobrestock y exposición a volatilidad del mercado | GAP 1 y GAP 3: Desde el pronóstico hacia decisiones operativas accionables |
| Las disparidades regionales confirman la necesidad de marcos de planificación descentralizados y específicos por ubicación | Incentiva a industrias y reguladores a adoptar enfoques flexibles y modulares que consideren heterogeneidad de recursos y demanda regional | GAP 1, 2 y 3: Refuerzo de la planificación localizada y el benchmarking en sistemas energéticos industriales |

9. Conclusiones y Recomendaciones de Política

Este estudio aborda un desafío crítico de política energética: garantizar la confiabilidad y la eficiencia de costos en sistemas eléctricos dominados por energías renovables, en coherencia con los compromisos de descarbonización. El marco propuesto constituye una herramienta práctica, transparente y alineada con la gobernanza, orientada a que reguladores y operadores del sistema puedan integrar decisiones operativas con objetivos climáticos y de mercado, reduciendo la exposición a riesgos derivados de la incertidumbre.

Aplicado al sistema eléctrico chileno, el enfoque demostró beneficios sustanciales en la disminución de la dependencia térmica, habilitando una programación anticipativa del despacho. Estos resultados se alinean directamente con la Estrategia de Carbono Neutralidad 2050 y el plan de retiro del carbón, constituyendo evidencia empírica transferible a países de la OCDE y mercados emergentes que enfrentan retos similares de integración renovable.

Más allá de la eficiencia operativa, el marco refuerza la credibilidad de los instrumentos regulatorios al complementar mecanismos de fijación de precios de carbono, como el *EU Emissions Trading System (ETS)* y su *Market Stability Reserve (MSR)*, mitigando la volatilidad en el valor de los permisos. Esta integración contribuye a la estabilidad del mercado, fortalece los estándares de flexibilidad y reduce riesgos asociados a la incertidumbre regulatoria. Adicionalmente, la utilización de programación lineal asegura interpretabilidad y compatibilidad con marcos normativos, posicionando el enfoque como una solución apta para auditorías y monitoreo en sistemas energéticos digitalizados.

En un contexto donde los mercados aceleran su transición hacia la neutralidad de carbono, la integración del despacho basado en pronósticos deja de ser opcional para convertirse en una ne-

cesidad estratégica. Este estudio demuestra que la combinación de analítica predictiva con imperativos regulatorios no sólo incrementa la resiliencia del sistema, sino que mejora la confiabilidad en el cumplimiento normativo, ofreciendo un marco replicable y alineado con políticas para fortalecer la gobernanza energética.

Recomendaciones de Política:

- **Incorporar requisitos de despacho basado en pronósticos en los estándares de flexibilidad y códigos operativos**, con el objetivo de mejorar la planificación de corto plazo y reducir la dependencia de generación térmica de emergencia.
- **Complementar los esquemas de precios de carbono (por ejemplo, EU ETS, MSR) con herramientas de predictibilidad operativa**, para estabilizar las señales de precios de permisos y mejorar el cumplimiento de los topes de emisiones.
- **Impulsar entornos regulatorios experimentales y programas piloto en mercados de flexibilidad**, que permitan validar estrategias de despacho anticipativo bajo condiciones controladas, reduciendo riesgos de adopción y acelerando su implementación.

10. Discusión

Los hallazgos de este estudio evidencian que los marcos de despacho basados en pronósticos pueden desempeñar un rol estratégico como instrumentos regulatorios para fortalecer la estabilidad del mercado, garantizar el cumplimiento de objetivos de descarbonización y mejorar la resiliencia operativa frente a la incertidumbre asociada a la penetración de energías renovables. La integración de pronósticos avanzados con modelos de programación lineal determinista permite habilitar una programación anticipativa de recursos controlables —en particular, generación térmica— reduciendo costos y emisiones en comparación con métodos convencionales que dependen de promedios históricos o heurísticas estáticas. Esta capacidad no solo disminuye los costos operativos y las emisiones de CO₂, sino que además refuerza la eficacia de esquemas de comercio de emisiones (*Emissions Trading Systems, ETS*) al mitigar la exposición a la volatilidad del precio del carbono y complementar mecanismos como la *Market Stability Reserve (MSR)*, reduciendo episodios de alzas abruptas en el valor de los permisos. Con ello, se impulsa la implementación de marcos robustos de fijación de precios de carbono y estándares de flexibilidad, adoptados de manera creciente en mercados de la OCDE (55). Estas contribuciones se alinean con iniciativas globales tales como el *European Green Deal*, el Acuerdo de París y las Contribuciones Nacionalmente Determinadas (NDCs), materializando trayectorias de descarbonización mediante estrategias de despacho accionables.

La evidencia empírica reciente destaca la necesidad de mecanismos complementarios que estabilicen los marcos de precios de carbono en contextos de alta penetración renovable. Estudios confirman que parámetros bien calibrados en la MSR mejoran la estabilidad del mercado al amortiguar la volatilidad en los precios de los permisos (19), mientras que un diseño robusto del ETS

sigue siendo esencial para alinear las operaciones de corto plazo con los objetivos climáticos de largo plazo (20). Los resultados de este trabajo demuestran que el despacho informado por pronósticos actúa como una palanca operativa que fortalece dichos instrumentos regulatorios, reduciendo la dependencia de generación térmica de emergencia y disminuyendo la exposición a fluctuaciones en los mercados de carbono. De esta manera, se mejora la calidad de la gobernanza y la confiabilidad del cumplimiento normativo, otorgando un doble beneficio: mayor predictibilidad en los ingresos por carbono y marcos regulatorios más creíbles en mercados eléctricos volátiles.

Desde una perspectiva de gobernanza, el marco propuesto entrega información clara y accionable para operadores del sistema y reguladores, complementando la evidencia reciente sobre los desafíos regulatorios y de diseño de mercado asociados a las plataformas de flexibilidad en sistemas energéticos emergentes (9). Este enfoque contribuye a la estabilidad del mercado, reduce los costos de balance y habilita un cumplimiento predictivo de las metas ambientales. Para facilitar su adopción, se recomienda que los formuladores de política prioricen las siguientes acciones, considerando los retos observados en mercados europeos en relación con la participación de agregadores, procesos de precalificación y requerimientos de tecnologías de información y comunicación (TIC) (10):

Recomendaciones de Política:

Los resultados de este estudio demuestran que la integración de despacho basado en pronósticos constituye una herramienta estratégica para fortalecer la resiliencia operativa, estabilizar los mercados eléctricos y cumplir con los compromisos de descarbonización en entornos dominados por energías renovables. Para facilitar su implementación y maximizar su impacto regulatorio, se proponen las siguientes recomendaciones:

- **Incorporar requisitos de programación basada en pronósticos en los estándares de flexibilidad y códigos operativos**, garantizando la resiliencia del sistema ante escenarios de alta variabilidad renovable.
- **Integrar herramientas híbridas de optimización en los mecanismos de capacidad y planificación de reservas**, con el objetivo de mejorar la confiabilidad operativa y la eficiencia económica.
- **Impulsar entornos regulatorios experimentales (*regulatory sandboxes*) y programas piloto**, que permitan validar la implementación bajo condiciones controladas, reducir el riesgo de adopción y asegurar transparencia en los procesos.

Relevancia práctica y política del caso chileno:

El caso de estudio aplicado al sistema eléctrico chileno evidencia la relevancia práctica y regulatoria del marco propuesto. La metodología permitió reducir los costos operativos en un **22 %**, las emisiones de CO₂ en un **42 %** y la dependencia térmica en un **22,9 %**, contribuyendo de manera directa a la Estrategia de Carbono Neutralidad 2050 y al plan de retiro del carbón, manteniendo al mismo tiempo la confiabilidad del sistema. Aunque este marco se desarrolló específicamente para Chile, su aplicabilidad es transferible a mercados de la OCDE y economías emergentes que implementan esquemas de precios de carbono o mecanismos de flexibilidad, ofreciendo una vía replicable para alinear la toma de decisiones operativas con objetivos regulatorios. Esta alineación es consistente con las tendencias observadas en mercados europeos, donde la integración de servicios de flexibilidad ha sido clave para la estabilidad y sostenibilidad del sector eléctrico (10).

Limitaciones y líneas futuras de investigación:

Pese a sus beneficios, este estudio presenta limitaciones que deben reconocerse:

- La formulación determinista asume la realización perfecta de los pronósticos, sin modelar explícitamente la incertidumbre, lo que puede reducir la robustez del despacho en escenarios de alta variabilidad.
- La resolución diaria utilizada excluye restricciones intradiarias, como rampas de generación y requerimientos de reserva giratoria, lo que limita su aplicabilidad directa en operación en tiempo real.

Para superar estas limitaciones, se identifican las siguientes líneas de investigación futura:

- Extender el marco hacia formulaciones robustas o estocásticas que integren la incertidumbre asociada a la generación renovable.
- Incorporar señales dinámicas de precios y mercados intradiarios que permitan una respuesta adaptativa y eficiente.
- Evaluar la integración del enfoque propuesto en mercados locales de flexibilidad y mecanismos de capacidad, validando su viabilidad en entornos regulatorios mediante *regulatory sandboxes* o pilotos industriales.

Implicancias globales y potencial de gobernanza:

Este estudio trasciende la contribución metodológica al ofrecer una herramienta práctica para operacionalizar estrategias de descarbonización, fortalecer la estabilidad del mercado y mejorar la confiabilidad del cumplimiento normativo. Al vincular la analítica predictiva con la gobernanza operativa, el marco propuesto proporciona a reguladores y operadores una solución escalable, transparente y alineada con las políticas, capaz de gestionar sistemas eléctricos dominados por renovables.

Más allá del contexto chileno, este enfoque complementa reformas de mercado orientadas a la integración de servicios de flexibilidad y la consecución de la neutralidad de carbono. Al alinear estrategias operativas con políticas de sostenibilidad y esquemas de precios de carbono, aborda objetivos regulatorios ampliamente discutidos en la literatura reciente sobre transición energética y reducción de emisiones (25). Además, entrega insumos concretos para el diseño de mercados de flexibilidad regionales, favoreciendo estructuras de gobernanza que incentiven la participación eficiente de recursos, asegurando transparencia y asequibilidad (29). Esta relevancia transversal posiciona al marco propuesto como una herramienta regulatoria clave para jurisdicciones que buscan descarbonización y resiliencia bajo alta penetración renovable.

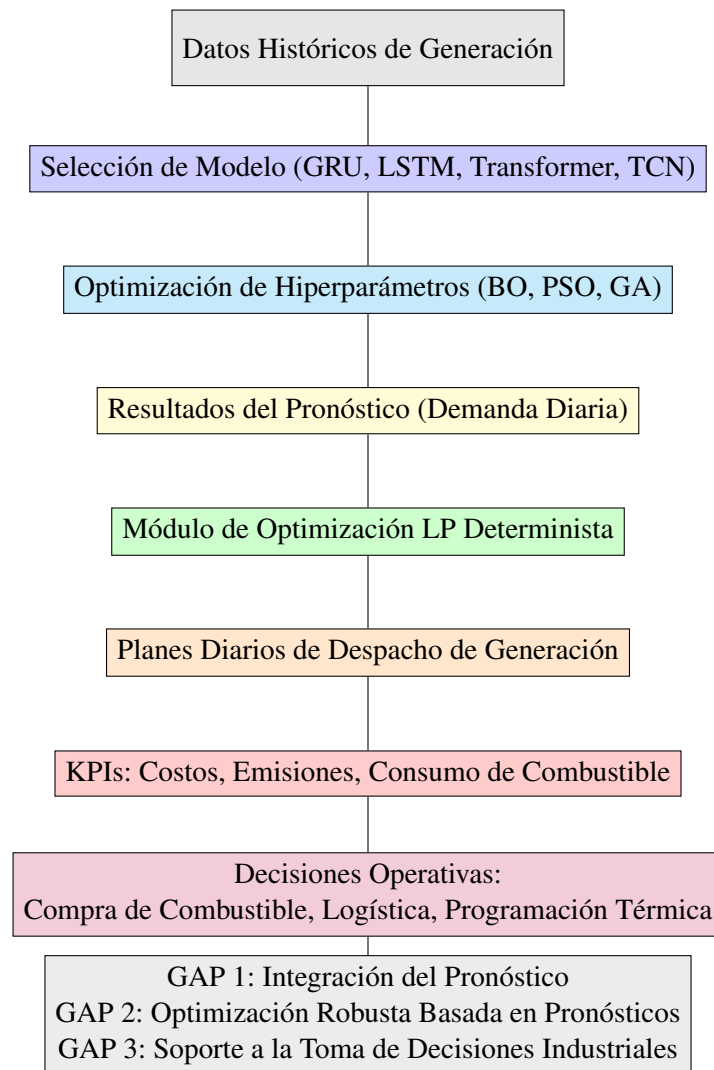


Figura 16: Esquema del marco de Pronóstico–Optimización y su contribución para abordar GAP 1, GAP 2 y GAP 3.

11. Limitaciones

A pesar de los avances y beneficios demostrados por el marco metodológico propuesto, este estudio presenta varias limitaciones que deben ser reconocidas para contextualizar su alcance y guiar futuras investigaciones:

1. Formulación determinista sin modelación explícita de incertidumbre: El modelo de optimización desarrollado asume que los pronósticos de demanda se cumplen de forma perfecta, sin incorporar explícitamente escenarios de incertidumbre ni distribuciones probabilísticas. Si bien esta aproximación responde a la necesidad de tractabilidad computacional y rapidez en entornos industriales, puede comprometer la robustez del despacho bajo condiciones extremas de variabilidad renovable. La ausencia de formulaciones robustas o estocásticas implica que el marco actual no captura de manera completa los riesgos asociados a errores de pronóstico, lo que representa una limitación importante para su aplicación en contextos donde la variabilidad y la incertidumbre son críticas.

2. Resolución temporal diaria y exclusión de restricciones intradiarias: La optimización se ejecuta en un horizonte diario, omitiendo consideraciones asociadas a la operación en tiempo real, como rampas de generación, reserva giratoria, tiempos de arranque y dinámicas intradiarias de la oferta renovable. Esto restringe la aplicabilidad directa del modelo en mercados de despacho horario o sub-horario, donde la flexibilidad operativa es esencial para la integración masiva de energías renovables y el cumplimiento de normas técnicas de seguridad.

3. No inclusión de precios dinámicos y mecanismos de respuesta de la demanda: El modelo se basa en parámetros de costo y emisiones fijos, sin considerar señales dinámicas de precios o la interacción con mercados spot e intradiarios. Tampoco se incorpora la respuesta de

la demanda (demand response), que constituye un mecanismo clave para flexibilizar el sistema y reducir los costos de balance. La omisión de estas dinámicas limita el realismo económico del modelo frente a escenarios de alta participación renovable y volatilidad de precios.

4. Dependencia de datos históricos y supuestos simplificados: El desempeño del modelo depende de la calidad y completitud de los datos históricos empleados para entrenar las redes neuronales (LSTM). Aunque se aplicaron procedimientos de imputación y normalización, la falta de variables exógenas relevantes (como precios de combustibles, condiciones meteorológicas o restricciones de red) puede restringir la capacidad predictiva en situaciones extremas no observadas en el historial. Además, se adoptaron supuestos simplificados sobre disponibilidad de tecnologías, costos constantes y desempeño uniforme de los sistemas de almacenamiento, lo cual puede diferir de la realidad operativa.

5. Exclusión de mercados y comportamiento estratégico: El enfoque actual no modela las interacciones estratégicas entre agentes del mercado, procesos de subasta, ni mecanismos de clearing propios de mercados eléctricos competitivos. Esta limitación implica que el marco propuesto se orienta principalmente a contextos regulados o de planeación centralizada, reduciendo su aplicabilidad directa a entornos de mercado liberalizados sin ajustes adicionales.

6. Validación restringida a un único caso de estudio: La validación empírica se circunscribe al sistema eléctrico chileno. Aunque este presenta alta penetración renovable y diversidad tecnológica, lo que lo convierte en un escenario representativo, la extrapolación a otros mercados requiere ajustes en parámetros, estructuras de costos, normas técnicas y mecanismos regulatorios locales. Esta restricción limita la generalización inmediata del marco, si bien su diseño modular favorece la transferencia a otros contextos mediante calibración y adaptación normativa.

7. Exclusión de impactos en confiabilidad y estabilidad de red: El modelo no evalúa

métricas asociadas a estabilidad de frecuencia, control de tensión o confiabilidad bajo contingencias, elementos críticos para la operación segura de sistemas eléctricos. Esto implica que, aunque el marco optimiza costos y emisiones, no aborda de manera integral la seguridad del sistema frente a perturbaciones dinámicas.

En conjunto, estas limitaciones no invalidan los aportes del estudio, pero sí delimitan su alcance. Abordan aspectos metodológicos (supuestos deterministas), temporales (resolución diaria), económicos (no inclusión de precios dinámicos), y regulatorios (ausencia de modelado de mercado), los cuales deben ser considerados en futuras investigaciones orientadas a robustecer el marco y ampliar su aplicabilidad en entornos con alta penetración renovable y alta incertidumbre operativa.

Referencias

- [1] H. Abbasimehr, M. Shabani, M. Yousefi, An optimized model using lstm network for demand forecasting, *Computers & Industrial Engineering* 143 (2020) 106435.
- [2] C. Caroprese, et al., D12f: A deep learning model for the local forecasting of renewable sources, *Computers & Industrial Engineering* 186 (2024) 109255.
- [3] J. C. Richstein, É. J. Chappin, L. J. de Vries, The market (in-)stability reserve for eu carbon emission trading: Why it might fail and how to improve it, *Utilities Policy* 35 (2015) 1–18.
- [4] Y. Gu, et al., A combined system based on data preprocessing and optimization algorithm for electricity load forecasting, *Computers & Industrial Engineering* 185 (2024) 109112.
- [5] L. Guo, et al., The hybrid prophet-svr approach for forecasting product time series demand with seasonality, *Computers & Industrial Engineering* 153 (2021) 107079.
- [6] X. Yuan, et al., Research on real-time prediction of completion time based on ae-cnn-lstm, *Computers & Industrial Engineering* 180 (2023) 108987.
- [7] A. Sharma, et al., Data driven predictive maintenance applications for industrial systems with temporal convolutional networks, *Computers & Industrial Engineering* 165 (2022) 107933.
- [8] X. Zhu, et al., Constraint first, shrinking next: A hybrid photovoltaic generation forecasting framework based on ensemble learning and multi-strategy improved optimizer, *Computers & Industrial Engineering* 192 (2025) 109500.
- [9] O. Rebenaque, C. Schmitt, K. Schumann, T. Dronne, F. Roques, Success of local flexibility market implementation: A review of current projects, *Utilities Policy* 80 (2023) 101491.

- [10] A. Pedro, M. Krutnik, V. M. Yadack, L. Pereira, H. Morais, Opportunities and challenges for small-scale flexibility in european electricity markets, *Utilities Policy* 80 (2023) 101477.
- [11] V. Alvarez, et al., A data-driven model for the operation and management of prosumer markets in electric smart grids, *Computers & Industrial Engineering* 181 (2024) 109079.
- [12] W. Lu, Q. Liu, J. Wang, Effect of electricity policy uncertainty and carbon emission prices on electricity demand in china based on mixed-frequency data models, *Utilities Policy* 91 (2024) 101825.
- [13] V. Alvarez, et al., Optimization of the integration among traditional fossil fuels, clean energies and natural gas for smart energy scheduling in smart grids, *Energy* 211 (2020) 118587.
- [14] M. S. Bakay, M. S. Basarslan, Forecasting of türkiye's net electricity consumption with metaheuristic algorithms, *Utilities Policy* 95 (2025) 101929. [doi:10.1016/j.jup.2025.101929](https://doi.org/10.1016/j.jup.2025.101929).
- [15] L. Zhou, et al., Optimization method for load aggregation scheduling in industrial parks considering multiple interests of virtual power plants and load users, *Applied Energy* 350 (2025) 121771.
- [16] M. K. Suddle, M. Bashir, Metaheuristics based long short term memory optimization for sentiment analysis, *Applied Soft Computing* 131 (2022) 109794.
- [17] L. Zhao, X. Zhang, X. Peng, Power fluctuation mitigation strategy for microgrids based on an lstm-based power forecasting method, *Applied Soft Computing* 127 (2022) 109370.
- [18] A. Javed, et al., Green manufacturing facilities – meeting co2 emission targets considering

- operation scheduling of multi-energy systems under flexibility and emission control strategies, *Journal of Cleaner Production* 389 (2023) 136141.
- [19] M. Hintermayer, F. Holz, The market stability reserve in the eu ets: Effects on price volatility and allowance supply under renewable expansion, *Energy Policy* 176 (2023) 113491.
- [20] P. Linares, J. Abrell, Carbon price dynamics and dispatch strategies under high renewable penetration: A policy perspective, *Utilities Policy* 87 (2024) 101581.
- [21] L. Castelli, et al., Robust optimization of seasonal, day-ahead and real-time operation of multi-energy systems under uncertainty, *Applied Energy* 332 (2023) 120236.
- [22] K. Lindberg, P. Seljom, H. Madsen, D. Fischer, M. Korpås, Long-term electricity load forecasting: Current and future trends, *Utilities Policy* 58 (2019) 102–119.
- [23] X. Li, et al., A robust chance-constrained programming approach for short-term operational scheduling of product pipelines under demand uncertainty, *Journal of Cleaner Production* 297 (2021) 126711.
- [24] T. Jia, H. Chen, X. Zeng, Y. Zhu, H. Qin, Mitigating risk and emissions in power systems: A two-stage robust dispatch model with carbon trading, *Processes* 12 (11) (2024) 2497.
- [25] M. Simionescu, J. Cifuentes-Faura, Sustainability policies to reduce pollution in energy supply and waste sectors in the v4 countries, *Utilities Policy* 82 (2023) 101551.
- [26] W. Bank, I. C. A. Partnership, Carbon pricing in the power sector, Tech. rep., World Bank (2024).

- [27] M. Gao, et al., Optimization of renewable energy-based integrated energy systems: A three-stage stochastic robust model, *Energy Conversion and Management* 295 (2025) 117438.
- [28] X. Zhang, et al., Chance-constrained co-optimization for day-ahead generation and reserve scheduling of cascade hydropower–variable renewable energy hybrid systems, *Renewable Energy* 182 (2022) 753–766.
- [29] K. Heilmann, Wetzel, Design of regional flexibility markets for electricity: A product classification framework for and application to german pilot projects, *Utilities Policy* 67 (2020) 101133.
- [30] V. Suresh, P. Janik, M. Jasinski, J. M. Guerrero, Z. Leonowicz, Microgrid energy management using metaheuristic optimization algorithms, *Applied Soft Computing* 134 (2023) 109981.
- [31] J. Fan, et al., Short-term stochastic multi-objective optimization scheduling of wind-solar-hydro hybrid system considering source-load uncertainties, *Renewable Energy* 209 (2024) 1300–1315.
- [32] W. Ren, et al., Deterministic scenarios guided k-adaptability in multistage robust optimization for energy management and cleaning scheduling of heat transfer process, *Energy* 263 (2024) 125312.
- [33] E. Aghdam, et al., Optimal stochastic operation of technical virtual power plants in reconfigurable distribution networks considering contingencies, *Journal of Cleaner Production* 385 (2023) 135729.
- [34] S. Borghesi, M. Pahle, G. Perino, S. Quemin, M. Willner, The market stability reserve in the

- eu emissions trading system: A critical review, *Annual Review of Resource Economics* 15 (1) (2023) 131–152.
- [35] A. Dechezleprêtre, D. Nachtigall, F. Venmans, The joint impact of the european union emissions trading system on carbon emissions and economic performance, *Journal of Environmental Economics and Management* 116 (2023) 102628.
- [36] X. Ran, et al., A bi-level optimization method for regional integrated energy system considering uncertainty and load prediction under climate change, *Energy Conversion and Management* 293 (2024) 117263.
- [37] P. Li, et al., Optimal planning for hybrid renewable energy systems under limited information based on uncertainty quantification, *Energy* 288 (2024) 126566.
- [38] S. Khan, Y. Muhammad, I. Jadoon, S. E. Awan, M. A. Z. Raja, Leveraging lstm-smi and arima architecture for robust wind power plant forecasting, *Applied Soft Computing* 170 (2025) 112765.
- [39] N. Zinsmeister, et al., A benchmarking framework for energy management systems with different levels of control sophistication and forecast utilization, *Applied Energy* 354 (2024) 121529.
- [40] J. González-Castillo, et al., Cleaning scheduling in photovoltaic solar farms with deterministic and stochastic optimization, *Renewable Energy* 205 (2023) 330–343.
- [41] W. Dong, et al., A data-driven intelligent predictive maintenance decision framework for mechanical systems integrating transformer and kernel density estimation, *Computers & Industrial Engineering* (2025).

- [42] D. W. Komala, et al., Storage placement in low voltage networks: A multi-objective optimization approach considering uncertainty of load and generation profiles, *Applied Energy* 298 (2021) 117197.
- [43] J.-C. Li, L.-P. Sun, X. Wu, C. Tao, Enhancing financial time series forecasting with hybrid deep learning: Ceemdan-informer-lstm model, *Applied Soft Computing* 177 (2025) 113241.
- [44] E. Saloux, J. A. Candanedo, Model-based predictive control to minimize primary energy use in a solar district heating system with long-term thermal storage, *Energy* 223 (2021) 120058.
- [45] X. Li, et al., Adaptive scenario generation for robust optimization under uncertainty of renewable energy, *Energy* 266 (2023) 125256.
- [46] Q. Wang, et al., Energy consumption forecasting of electric vehicle charging station based on multi-feature fusion long short-term memory network, *Journal of Cleaner Production* 350 (2022) 131484.
- [47] I. Ben Slama, et al., Reinforcement learning-based hierarchical multi-agent energy management for industrial cluster with renewable energy and hybrid energy storage system, *Energy Conversion and Management* 287 (2025) 117122.
- [48] D. Coronado, et al., Resilience-based preventive maintenance policy for complex systems under shock loads and dependent competing risks, *Reliability Engineering & System Safety* 237 (2023) 109347.
- [49] G. Gharehpetian, et al., Forecasting of photovoltaic power generation using integrated attention and convolutional neural network, *Energy Conversion and Management* 290 (2024) 117201.

- [50] J. Mo, R. Gao, J. Liu, L. Du, K. F. Yuen, Annual dilated convolutional lstm network for time charter rate forecasting, *Applied Soft Computing* 126 (2022) 109259.
- [51] X. Peng, et al., Optimal scheduling of integrated energy system considering the interaction of electric-hydrogen multi-energy, *Energy* 282 (2024) 127390.
- [52] Q. Liang, et al., Robust scheduling of integrated heat and power system considering demand-side response and renewable energy uncertainty, *Energy* 289 (2024) 117039.
- [53] K. Wang, M. Yu, D. Niu, Y. Liang, S. Peng, X. Xu, Short-term electricity price forecasting based on similarity day screening, two-layer decomposition technique and bi-lstm neural network, *Applied Soft Computing* 136 (2023) 110018.
- [54] W. Xu, et al., Multi-objective optimal planning of multi-energy microgrid considering demand-side response and electric-thermal coupling, *Energy Conversion and Management* 284 (2023) 116955.
- [55] E. Heilmann, The impact of transparency policies on local flexibility markets in electric distribution networks, *Utilities Policy* 83 (2023) 101592.
- [56] C. Zhang, et al., Multi-objective optimal dispatch of integrated electricity-hydrogen system considering deep coupling of power and hydrogen storage, *Journal of Cleaner Production* 408 (2024) 137255.
- [57] J. Liu, et al., Stochastic multi-objective optimization of integrated energy system considering carbon emission trading and hydrogen storage system, *Journal of Cleaner Production* 371 (2022) 133668.

- [58] Q. Hassan, P. Viktor, T. J. Al-Musawi, B. M. Ali, S. Algburi, H. M. Alzoubi, A. K. Al-Jiboory, A. Z. Sameen, H. M. Salman, M. Jaszczur, The renewable energy role in the global energy transformations, *Renewable Energy Focus* 48 (2024) 100545.
- [59] N. Balta-Ozkan, T. Watson, E. Mocca, Spatially uneven development and low carbon transitions: Insights from urban and regional planning, *Energy Policy* 85 (2015) 500–510.
- [60] B.-O. Linnér, P. Mickwitz, M. Román, Reducing greenhouse gas emissions through development policies: a framework for analysing policy interventions, *Climate and Development* 4 (3) (2012) 175–186.
- [61] M. R. Pasimeni, I. Petrosillo, R. Aretano, T. Semeraro, A. De Marco, N. Zaccarelli, G. Zurlini, Scales, strategies and actions for effective energy planning: A review, *Energy Policy* 65 (2014) 165–174.
- [62] A. Quadir, S. Kapoor, C. A. Junni, A. K. Sivaraman, K. F. Tee, H. Sabireen, N. Janakiraman, Novel optimization approach for stock price forecasting using multi-layered sequential lstm, *Applied Soft Computing* 134 (2023) 109830.
- [63] U. Ahmed, A. R. Khan, A. Mahmood, I. Rafiq, R. Ghannam, A. Zoha, Short-term global horizontal irradiance forecasting using weather classified categorical boosting, *Applied Soft Computing* 155 (2024) 111441.
- [64] International Energy Agency, *World energy outlook 2021*, Tech. rep., IEA, Paris, technical report (2021).
- [65] H. Lund, P. A. Østergaard, D. Connolly, B. V. Mathiesen, *Review of energy system flexibility*

measures to enable high levels of variable renewable electricity, *Renewable and Sustainable Energy Reviews* 39 (2014) 525–536.

[66] W. Yu, Y. Dai, T. Ren, M. Leng, Short-time photovoltaic power forecasting based on informer model integrating attention mechanism, *Applied Soft Computing* 178 (2025) 113345.

[67] I. M. Fund, Chile's energy transition: Cost of renewables vs fossil fuels, accessed: 2025-06-25 (2024).

[68] I. E. Agency, *Projected costs of generating electricity 2020* (2020).

[69] I. P. on Climate Change, *Fifth assessment report (ar5): Mitigation of climate change – annex iii: Technology-specific cost and performance parameters* (2014).

[70] I. P. on Climate Change, *Life cycle greenhouse gas emissions from electricity supply technologies* (2014).

[71] S. Mitchell, contributors, *Pulp: A linear programming toolkit for python* (2024).

[72] P. Viveros, M. Espinoza, R. Mena, F. Kristjanpoller, Extended framework for preventive maintenance planning: Risk and behaviour analysis of a proposed optimization model, *Complexity* 2023 (2023) 1–22.

[73] B. Kumar, Sunil, N. Yadav, A novel hybrid model combining β sarma and lstm for time series forecasting, *Applied Soft Computing* 134 (2023) 110019.

[74] M. Coronado, B. Kadoch, J. Contreras, F. Kristjanpoller, Reliability and availability modelling of a retrofitted diesel-based cogeneration system for heat and hot water demand of an



isolated antarctic base, *Eksploatacja i Niezawodność – Maintenance and Reliability* 25 (3)
(2023).