

# Aceleración de la resolución del problema de Unit Commitment mediante técnicas de Inteligencia Artificial

---


Fernando Esteban Rosenthal Miqueles

---

2026

Requisito parcial para obtener el título de:  
Ingeniero Civil Eléctricista  
Profesor Guía: Dr. Ricardo Álvarez (UTFSM)  
Co-referente: Ing. Eugenio Palacios (EDF power solutions)

Santiago, Julio 1



# Aceleración de la resolución del problema de Unit Commitment mediante técnicas de Inteligencia Artificial

---

Fernando Esteban Rosenthal Miqueles

---

2026



## 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: Aceleración de la resolución del problema de Unit Commitment mediante técnicas de Inteligencia Artificial

Nombre del candidato(a): Fernando Esteban Rosenthal Miqueles

Carrera / Grado: Ingeniería Civil Eléctrica

Campus: San Joaquín

Departamento: Departamento de Ingeniería Eléctrica

### 2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, **Ricardo Álvarez** 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 (marcar una opción)

☒ 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 (**marcar una opción**):

☐ 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: 05/08/2026

Firma: 

Estudiante o Candidato(a):

Fecha: 05/08/2026

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.*

*Per Audacia Ad Astra*

# Agradecimientos

Culminar este enriquecedor trabajo de memoria representa no solo el cierre de una etapa, sino también un hito invaluable en mi desarrollo profesional. En este contexto, deseo expresar mi más profundo y sincero agradecimiento a mis guías: al profesor Dr. Ricardo Álvarez y a mi co-referente Eugenio Palacios. Ambos me acompañaron de cerca en este riguroso proceso, brindándome las herramientas técnicas y los consejos precisos en los momentos de mayor complejidad. Su paciencia, disposición y experiencia han moldeado profundamente el curso de esta investigación. Sus aportes y visiones, tanto en la formulación preliminar como en el análisis de las fases finales, resultaron verdaderamente decisivos, elevando la calidad de los resultados obtenidos. Sin su mentoría, este estudio no habría alcanzado la profundidad ni el rigor que hoy lo caracterizan. Asimismo, quisiera extender mi agradecimiento al Laboratorio Nacional de Computación de Alto Rendimiento (NLHPC) de Chile por permitirme el uso de su infraestructura supercomputacional, recurso que fue fundamental para llevar a cabo las simulaciones masivas requeridas en este estudio.

En un ámbito más íntimo, sobre la exigente aventura que ha significado mi formación en esta carrera universitaria, mi gratitud se dirige hacia mi familia, el pilar fundamental de todo este esfuerzo. Deseo agradecer infinitamente a mis padres, quienes me entregaron su ejemplo y los mejores valores que podría pedir, en especial la perseverancia como el motor para superar cualquier obstáculo. Gracias por su confianza inquebrantable en mí, por ser mi contención en cada paso de este largo camino y por recordarme siempre, con su orgullo y amor, el propósito de este esfuerzo. Su apoyo incondicional hizo posible que hoy esté aquí. A mis hermanas, gracias por ser mi refugio constante, por escucharme, acompañarme en las largas jornadas y por darme el aliento necesario para continuar, sobre todo en aquellos momentos donde los desafíos parecían superarme.

Finalmente, quiero dedicar unas palabras a mis amigos. Gracias por aligerar la carga, por hacerme reír en los momentos más difíciles y por estar siempre dispuestos a tender una mano o compartir una pausa cuando más lo necesitaba. A todas aquellas personas que creyeron en mis capacidades y aportaron a este logro, les estaré eternamente agradecido. Este trabajo es tanto suyo como mío.

# Índice de Contenidos

|                                                                                       |          |
|---------------------------------------------------------------------------------------|----------|
| Índice de Contenidos                                                                  | III      |
| Índice de Figuras                                                                     | V        |
| Índice de Tablas                                                                      | VIII     |
| Resumen                                                                               | 1        |
| <b>1. Introducción</b>                                                                | <b>2</b> |
| 1.1. Motivación . . . . .                                                             | 2        |
| 1.2. Objetivos . . . . .                                                              | 3        |
| 1.2.1. Objetivo General . . . . .                                                     | 3        |
| 1.2.2. Objetivos Específicos . . . . .                                                | 3        |
| <b>2. Marco Teórico</b>                                                               | <b>4</b> |
| 2.1. Sistemas Eléctricos de Potencia y el Desafío Operativo . . . . .                 | 4        |
| 2.1.1. El Sistema Eléctrico y la Congestión . . . . .                                 | 4        |
| 2.1.2. Despacho Económico vs. Seguridad . . . . .                                     | 5        |
| 2.1.3. Integración de ERV y la “Curva del Pato” . . . . .                             | 5        |
| 2.2. El Problema de Unit Commitment (UC) . . . . .                                    | 6        |
| 2.2.1. Formulación Primal del UC y Función Objetivo . . . . .                         | 6        |
| 2.2.2. Restricciones de Acoplamiento Temporal . . . . .                               | 7        |
| 2.2.3. Restricciones de Red y Topología (DC-OPF) . . . . .                            | 8        |
| 2.3. Optimización Matemática (MILP) y Relajación Lineal . . . . .                     | 9        |
| 2.3.1. Programación Lineal Entera Mixta (MILP) y Complejidad Computacional . . . . .  | 10       |
| 2.3.2. Algoritmos de Resolución: Branch-and-Bound y Planos de Corte . . . . .         | 10       |
| 2.3.3. Relajación Lineal y la Brecha de Integridad . . . . .                          | 11       |
| 2.4. Inteligencia Artificial y Machine Learning en Optimización . . . . .             | 12       |
| 2.4.1. Aprendizaje Supervisado para Clasificación de Decisiones . . . . .             | 12       |
| 2.4.2. Arquitecturas de Redes Neuronales Profundas . . . . .                          | 13       |
| 2.4.3. IA Guiada por la Física ( <i>Physics-Informed Machine Learning</i> ) . . . . . | 14       |
| 2.4.4. Modelos de Ensamble y Gradient Boosting (GBDT) . . . . .                       | 16       |
| 2.5. Modelos Sustitutos y Estrategias Híbridas de Optimización . . . . .              | 16       |
| 2.5.1. Concepto de Modelo Sustituto en Sistemas de Potencia . . . . .                 | 16       |
| 2.5.2. Estrategias Híbridas IA-Optimización . . . . .                                 | 17       |

|                                                                                 |           |
|---------------------------------------------------------------------------------|-----------|
| 2.6. Métricas de Evaluación y Desempeño . . . . .                               | 18        |
| 2.6.1. Métricas de Clasificación Estadística . . . . .                          | 18        |
| 2.6.2. Métricas de Factibilidad Física y Aceleración Computacional . . . . .    | 20        |
| 2.6.3. Métricas de Impacto Económico . . . . .                                  | 20        |
| <b>3. Metodología</b>                                                           | <b>22</b> |
| 3.1. Caracterización del Sistema y Modelación Base . . . . .                    | 22        |
| 3.1.1. Elementos del Sistema Modelados . . . . .                                | 23        |
| 3.1.2. Restricciones Físicas y de Red Relevantes . . . . .                      | 23        |
| 3.2. Generación de la Base de Datos . . . . .                                   | 25        |
| 3.2.1. Bucle de Monte Carlo Jerárquico y Modelación Hidrológica . . . . .       | 25        |
| 3.2.2. Extracción de Datos Híbridos: Etiquetas y Señales Relajadas . . . . .    | 25        |
| 3.3. Diseño y Entrenamiento del Modelo de Inteligencia Artificial . . . . .     | 29        |
| 3.3.1. Selección del Algoritmo Predictivo . . . . .                             | 29        |
| 3.3.2. Arquitectura y Estructura Matemática de los Ensamblados . . . . .        | 30        |
| 3.3.3. Calibración de Probabilidades mediante Regresión Isotónica . . . . .     | 30        |
| 3.4. Implementación de la Estrategia de Optimización Híbrida . . . . .          | 32        |
| 3.4.1. Acoplamiento Heurístico mediante Triage de Tres Zonas . . . . .          | 32        |
| 3.4.2. Resolución del Despacho y Post-procesamiento . . . . .                   | 33        |
| 3.5. Protocolo de Evaluación de Resultados . . . . .                            | 34        |
| 3.5.1. Métricas de Desempeño Estadístico de la IA . . . . .                     | 34        |
| 3.5.2. Cuantificación del Desempeño Técnico-Económico y Computacional . . . . . | 34        |
| 3.5.3. Análisis de Robustez mediante Sensibilidades . . . . .                   | 34        |
| <b>4. Resultados</b>                                                            | <b>36</b> |
| 4.1. Evaluación Estadística de Modelos Clasificadores (ML) . . . . .            | 36        |
| 4.1.1. Comparación de Modelos: Random Forest vs. XGBoost vs. LightGBM . . . . . | 36        |
| 4.2. Análisis de Importancia de Variables (Feature Engineering) . . . . .       | 37        |
| 4.3. Calibración de Umbrales de Fijación . . . . .                              | 38        |
| 4.4. Caso de Referencia y Análisis del Impacto de la Calibración . . . . .      | 40        |
| 4.4.1. Resultados de la Semana Base (Modelo Híbrido Calibrado) . . . . .        | 40        |
| 4.4.2. Impacto de la Calibración de Probabilidades . . . . .                    | 43        |
| 4.5. Análisis de Sensibilidades Avanzadas (Pruebas de Robustez) . . . . .       | 44        |
| 4.5.1. Sensibilidad a la Escala del Sistema . . . . .                           | 44        |
| 4.5.2. Sensibilidad a la Penetración de Energías Renovables (ERNC) . . . . .    | 47        |
| 4.5.3. Sensibilidad al Tamaño del Bloque de Optimización (Chunk Size) . . . . . | 49        |
| 4.5.4. Sensibilidad a Congestionamientos . . . . .                              | 52        |
| <b>5. Conclusiones</b>                                                          | <b>55</b> |
| <b>Apéndices</b>                                                                | <b>58</b> |

---

|                                                                       |           |
|-----------------------------------------------------------------------|-----------|
| <b>A.</b>                                                             | <b>58</b> |
| A.1. Resultados . . . . .                                             | 58        |
| A.1.1. Análisis de Importancia de Variables . . . . .                 | 58        |
| A.1.2. Semana Base . . . . .                                          | 59        |
| A.1.3. Sensibilidad a Escala del Sistema . . . . .                    | 61        |
| A.1.4. Sensibilidad a la Penetración de Energías Renovables . . . . . | 62        |
| A.1.5. Sensibilidad al Tamaño del Bloque de Optimización . . . . .    | 64        |
| A.1.6. Sensibilidad a Congestionamientos . . . . .                    | 66        |
| <b>Referencias</b>                                                    | <b>67</b> |

# Índice de Figuras

|      |                                                                                                                                                                  |    |
|------|------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 2.1. | Ilustración del fenómeno de la “Curva del Pato” en el SEN. <i>Fuente: Elaboración propia, con datos extraídos de [1].</i> . . . . .                              | 6  |
| 2.2. | Perfil operativo dinámico de una unidad térmica convencional. <i>Fuente: Elaboración propia, con datos extraídos de [1].</i> . . . . .                           | 8  |
| 2.3. | Representación geométrica de la Brecha de Integridad en un espacio bidimensional. <i>Fuente: Elaboración propia, basado en [2].</i> . . . . .                    | 12 |
| 2.4. | Diagrama de flujo del aprendizaje supervisado aplicado a las decisiones del Unit Commitment. <i>Fuente: Elaboración propia.</i> . . . . .                        | 13 |
| 2.5. | Arquitectura conceptual de un enfoque PIML aplicado al despacho eléctrico. <i>Fuente: Elaboración propia.</i> . . . . .                                          | 15 |
| 2.6. | Diagrama de la estrategia de optimización híbrida propuesta. <i>Fuente: Elaboración propia.</i> . . . . .                                                        | 18 |
| 2.7. | Matriz de confusión contextualizada para la evaluación del modelo de Inteligencia Artificial en el Unit Commitment. <i>Fuente: Elaboración propia.</i> . . . . . | 19 |
| 3.1. | Estructura Tabular plana de la Base de datos. <i>Fuente: Elaboración propia.</i> . . . . .                                                                       | 28 |
| 3.2. | Flujo de procesamiento y arquitectura del modelo predictivo. <i>Fuente: Elaboración propia.</i> . . . . .                                                        | 31 |
| 3.3. | Flujo de decisión y fijación de variables mediante <i>Triage</i> en 3 zonas. <i>Fuente: Elaboración propia.</i> . . . . .                                        | 33 |
| 4.1. | Importancia relativa de las variables de entrada ( <i>Feature Importance</i> ) en las decisiones de encendido de la IA. . . . .                                  | 37 |
| 4.2. | Distribución de errores, total de predicciones y zonas de <i>Triage</i> para Calibración de Umbrales (XGBoost). . . . .                                          | 39 |
| 4.3. | Distribución de errores, total de predicciones y zonas de <i>Triage</i> para Calibración de Umbrales (LightGBM). . . . .                                         | 39 |
| 4.4. | Evolución del tiempo de cómputo y desviación de costo a lo largo de una semana para horizonte diario. . . . .                                                    | 41 |
| 4.5. | Evolución de la cantidad de variables fijadas y el índice de coincidencia a lo largo de una semana para horizonte diario. . . . .                                | 42 |
| 4.6. | Evolución del tiempo de cómputo y desviación de costo para un escalamiento x2 (Base vs. Híbrido). . . . .                                                        | 44 |

|                                                                                                                                                                       |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 4.7. Evolución de la cantidad de variables fijadas y el índice de coincidencia para un escalamiento x2 (Base vs. Híbrido). . . . .                                    | 45 |
| 4.8. Evolución del tiempo de cómputo y desviación de costo para un escalamiento x3 (Base vs. Híbrido). . . . .                                                        | 45 |
| 4.9. Evolución de la cantidad de variables fijadas y el índice de coincidencia para un escalamiento x3 (Base vs. Híbrido). . . . .                                    | 46 |
| 4.10. Impacto de la Penetración ERNC en el Speedup y Riesgo Económico. . . . .                                                                                        | 47 |
| 4.11. Impacto de la Penetración ERNC en el Deesempeño Predictivo. . . . .                                                                                             | 47 |
| 4.12. Evolución del tiempo de cómputo y desviación de costo a lo largo de un mes para horizonte semanal. . . . .                                                      | 49 |
| 4.13. Evolución de la cantidad de variables fijadas y el índice de coincidencia a lo largo de un mes para horizonte semanal. . . . .                                  | 49 |
| 4.14. Evolución del tiempo de cómputo y desviación de costo a lo largo del horizonte mensual. . . . .                                                                 | 50 |
| 4.15. Evolución de la cantidad de variables fijadas y el índice de coincidencia a lo largo del horizonte mensual. . . . .                                             | 51 |
| 4.16. Evolución del tiempo de cómputo y desviación de costo a lo largo de una semana sensibilizando la cantidad de líneas congestionadas. . . . .                     | 53 |
| 4.17. Evolución de la cantidad de variables fijadas y el índice de coincidencia a lo largo de una semana sensibilizando la cantidad de líneas congestionadas. . . . . | 54 |

# Índice de Tablas

|                                                                                                                                                              |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 4.1. Comparación de desempeño estadístico y tiempo de entrenamiento entre modelos clasificadores. . . . .                                                    | 36 |
| 4.2. Resumen de factibilidad física y rendimiento computacional promedio (Modelos Híbridos vs. Heurísticas de Redondeo) durante la semana base. . . . .      | 40 |
| 4.3. Impacto del uso de probabilidades sin calibrar en la factibilidad y velocidad del acoplamiento híbrido. . . . .                                         | 43 |
| 4.4. Desempeño del enfoque híbrido XGBoost frente a expansiones en la escala del horizonte temporal de resolución (mejores soluciones encontradas). . . . .  | 51 |
| 4.5. Desempeño del enfoque híbrido LightGBM frente a expansiones en la escala del horizonte temporal de resolución (mejores soluciones encontradas). . . . . | 52 |
| 4.6. Desempeño estadístico predictivo y validación de factibilidad (Energía No Suministrada) para el modelo XGBoost ante contingencias. . . . .              | 52 |
| 4.7. Desempeño estadístico predictivo y validación de factibilidad (Energía No Suministrada) para el modelo LightGBM ante contingencias. . . . .             | 53 |
|                                                                                                                                                              |    |
| A.1. Importancia de variables del modelo clasificador XGBoost en el proceso de Triage. . . . .                                                               | 58 |
| A.2. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la semana base. . . . .            | 59 |
| A.3. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la semana base. . . . .             | 59 |
| A.4. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Benchmark Heurístico: Redondeo Simple LP) durante la semana base. . . . .     | 59 |
| A.5. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Benchmark Heurístico: Umbrales LP) durante la semana base. . . . .            | 60 |
| A.6. Desempeño estadístico predictivo (Variables Fijadas y Coincidencia) para los modelos LightGBM y XGBoost en la semana base. . . . .                      | 60 |

|                                                                                                                                                                      |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| A.7. Desempeño estadístico predictivo (Variables Fijadas y Coincidencia) para los modelos Heurísticos Benchmark (Redondeo LP) en la semana base. . . . .             | 60 |
| A.8. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) - Sensibilidad a escala (20 Generadores). . . . .  | 61 |
| A.9. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) - Sensibilidad a escala (20 Generadores). . . . .   | 61 |
| A.10. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) - Sensibilidad a escala (30 Generadores). . . . . | 61 |
| A.11. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) - Sensibilidad a escala (30 Generadores). . . . .  | 62 |
| A.12. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la sensibilidad a 25 % de ERNC. . . . .    | 62 |
| A.13. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la sensibilidad a 25 % de ERNC. . . . .   | 62 |
| A.14. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la sensibilidad a 50 % de ERNC. . . . .    | 63 |
| A.15. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la sensibilidad a 50 % de ERNC. . . . .   | 63 |
| A.16. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la sensibilidad a 150 % de ERNC. . . . .   | 63 |
| A.17. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la sensibilidad a 150 % de ERNC. . . . .  | 64 |
| A.18. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante el horizonte semanal. . . . .              | 64 |
| A.19. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante el horizonte semanal. . . . .             | 64 |
| A.20. Desempeño estadístico predictivo (Variables Fijadas y Coincidencia) para los modelos LightGBM y XGBoost en simulación de horizonte semanal. . . . .            | 65 |
| A.21. Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante el horizonte mensual. . . . .              | 65 |

---

|                                                                                                                                                                    |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| A.22.Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante el horizonte mensual. . . . .            | 65 |
| A.23.Desempeño estadístico predictivo y Gap de convergencia (Gurobi Base vs Modelo Híbrido LightGBM) en simulación de horizonte mensual.                           | 65 |
| A.24.Desempeño estadístico predictivo y Gap de convergencia (Gurobi Base vs Modelo Híbrido XGBoost) en simulación de horizonte mensual.                            | 66 |
| A.25.Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la sensibilidad a contingencias. . . . .  | 66 |
| A.26.Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la sensibilidad a contingencias. . . . . | 66 |

# Nomenclatura

## Conjuntos e Índices

|               |                                                                  |
|---------------|------------------------------------------------------------------|
| $\mathcal{G}$ | : Conjunto de unidades generadoras térmicas.                     |
| $\mathcal{L}$ | : Conjunto de líneas de transmisión del sistema.                 |
| $\mathcal{N}$ | : Conjunto de nodos del sistema eléctrico.                       |
| $\mathcal{T}$ | : Conjunto de periodos de tiempo del horizonte de evaluación.    |
| $g$           | : Índice asociado a una unidad generadora térmica específica.    |
| $l$           | : Índice asociado a una línea de transmisión específica.         |
| $n$           | : Índice asociado a un nodo específico de la red.                |
| $t$           | : Índice asociado a un periodo de tiempo (generalmente horas).   |
| $GR$          | : Subconjunto de plantas generadoras de ERNC.                    |
| $HE$          | : Subconjunto de centrales hidroeléctricas de embalse.           |
| $HP$          | : Subconjunto de centrales hidroeléctricas de pasada.            |
| $S$           | : Subconjunto de sistemas de almacenamiento por baterías (BESS). |

## Parámetros del Sistema

|                  |                                                                                 |
|------------------|---------------------------------------------------------------------------------|
| $C_g(P)$         | : Función de costo variable de producción de la unidad $g$ .                    |
| $C_{g,t}^{SD}$   | : Costo de apagado (Shut-down cost) de la unidad $g$ en el periodo $t$ .        |
| $C_{g,t}^{SU}$   | : Costo de encendido (Start-up cost) de la unidad $g$ en el periodo $t$ .       |
| $DT_g$           | : Tiempo mínimo de apagado o enfriamiento (Down-Time) de la unidad $g$ .        |
| $D_t$            | : Demanda de energía proyectada a satisfacer en el periodo $t$ .                |
| $F_l^{max}$      | : Capacidad máxima nominal de flujo de transporte de la línea $l$ .             |
| $P_g^{max}$      | : Capacidad máxima neta de potencia activa de la unidad $g$ .                   |
| $P_g^{min}$      | : Mínimo técnico de potencia activa para combustión estable de la unidad $g$ .  |
| $RD_g$           | : Límite de rampa de bajada (Ramp-Down) de la unidad $g$ .                      |
| $RU_g$           | : Límite de rampa de subida (Ramp-Up) de la unidad $g$ .                        |
| $R_t$            | : Margen de seguridad sistémico o Reserva en Giro requerida en el periodo $t$ . |
| $SD_g$           | : Límite de rampa transitoria asociada al proceso de desconexión de $g$ .       |
| $SF_{l,n}$       | : Factor de distribución (Shift Factor) de la línea $l$ respecto al nodo $n$ .  |
| $SU_g$           | : Límite de rampa transitoria de sincronización inicial de la unidad $g$ .      |
| $UT_g$           | : Tiempo mínimo de operación ininterrumpida (Up-Time) de la unidad $g$ .        |
| $\lambda$        | : Hiperparámetro de ponderación de penalización física (PIML).                  |
| $B_{bus}$        | : Matriz de susceptancia nodal del sistema.                                     |
| $B_f$            | : Matriz de susceptancia de las ramas o líneas de transmisión.                  |
| $C_g^{op}$       | : Costo operativo nominal de la unidad $g$ .                                    |
| $C_{ENS}$        | : Costo de falla o penalización económica por Energía No Suministrada.          |
| $C_g^{rel}$      | : Costo relativo de la unidad térmica $g$ en el análisis de competitividad.     |
| $C_t^{agua,rel}$ | : Costo de oportunidad relativo del agua en el periodo $t$ .                    |
| $H_g$            | : Constante de inercia física del generador $g$ .                               |
| $M$              | : Número total de árboles de decisión en el modelo.                             |
| $rp_g^{max}$     | : Capacidad máxima de provisión de reserva primaria rápida de la unidad $g$ .   |
| $\epsilon$       | : Constante matemática de regularización para evitar divisiones por cero.       |
| $\eta$           | : Eficiencia global del ciclo de ida y vuelta del sistema de almacenamiento.    |

## Variables de Decisión y Estado

|                    |                                                                                      |
|--------------------|--------------------------------------------------------------------------------------|
| $ENS$              | : Energía No Suministrada (variable de holgura y penalización).                      |
| $f_{l,t}$          | : Flujo de potencia activa que transita por la línea $l$ en el periodo $t$ .         |
| $P_{g,t}$          | : Variable continua de la potencia activa despachada por la unidad $g$ en $t$ .      |
| $P_{n,t}^{neta}$   | : Inyección neta de potencia (generación menos carga) en el nodo $n$ en $t$ .        |
| $P_{W,t}$          | : Aporte de potencia inyectada por energías renovables variables en el periodo $t$ . |
| $sd_{g,t}$         | : Variable binaria de decisión de parada de la unidad $g$ en el periodo $t$ .        |
| $su_{g,t}$         | : Variable binaria de decisión de arranque de la unidad $g$ en el periodo $t$ .      |
| $u_{g,t}$          | : Variable binaria de estado lógico (encendido/apagado) de la unidad $g$ en $t$ .    |
| $\hat{sd}_{g,t}$   | : Versión continua o relajada de la variable de decisión de parada $sd_{g,t}$ .      |
| $\hat{su}_{g,t}$   | : Versión continua o relajada de la variable de decisión de arranque $su_{g,t}$ .    |
| $\hat{u}_{g,t}$    | : Versión continua o relajada de la variable de estado $u_{g,t}$ .                   |
| $\tilde{sd}_{g,t}$ | : Predicción heurística de la decisión de parada emitida por el modelo sustituto.    |
| $\tilde{su}_{g,t}$ | : Predicción heurística de la decisión de arranque emitida por el modelo sustituto.  |
| $\tilde{u}_{g,t}$  | : Predicción heurística del estado operativo propagado por el modelo sustituto.      |
| $C_g^{Pond}$       | : Competitividad Operativa Ponderada de la unidad térmica $g$ .                      |
| $LMP_{g,t}^{rel}$  | : Precio Marginal Local relativo en el nodo de la unidad $g$ en $t$ .                |
| $MR_t$             | : Margen de Reserva Sistemico global en el periodo $t$ .                             |
| $ROI_{g,t}$        | : Retorno de Inversión Esperado normalizado de la máquina $g$ en $t$ .               |
| $T_{g,t}^{BE}$     | : Horas de amortización o <i>Break-Even</i> de la unidad $g$ encendida en $t$ .      |

|                          |   |                                                                                                                           |
|--------------------------|---|---------------------------------------------------------------------------------------------------------------------------|
| $X_{\text{prev}}$        | : | Señal de inercia temporal continua adyacente anterior ( $\hat{u}_{g,t-1}$ ).                                              |
| $X_{\text{act}}$         | : | Señal de inercia temporal continua actual ( $\hat{u}_{g,t}$ ).                                                            |
| $X_{\text{next}}$        | : | Señal de inercia temporal continua adyacente posterior ( $\hat{u}_{g,t+1}$ ).                                             |
| $f_m(x)$                 | : | Estimador base o árbol de decisión discreto en la iteración $m$ .                                                         |
| $lb, ub$                 | : | Límites matemáticos inferior ( <i>lower bound</i> ) y superior ( <i>upper bound</i> ) de una variable en el solucionador. |
| $m(\hat{y})$             | : | Función monótona no decreciente ajustada por Regresión Isotónica.                                                         |
| $rp f_{g,t}$             | : | Variable continua de reserva primaria de frecuencia despachada por $g$ en $t$ .                                           |
| $rs_{g,t}$               | : | Variable continua de reserva en giro despachada por $g$ en $t$ .                                                          |
| $\Pi_g(t, k)$            | : | Flujo de caja operativo acumulado proyectado desde el periodo $t$ hasta $k$ .                                             |
| $\lambda_{n,t}$          | : | Precio Marginal Local (LMP) en el nodo $n$ durante el periodo $t$ .                                                       |
| $\bar{\lambda}_t$        | : | Promedio del costo marginal sistémico en el periodo $t$ .                                                                 |
| $\mu_{g,t}^{Pmax}$       | : | Precio sombra o dual asociado a la restricción de capacidad máxima de $g$ .                                               |
| $\mu_{g,t}^{Pmin}$       | : | Precio sombra o dual asociado a la restricción de mínimo técnico de $g$ .                                                 |
| $\mu_t^{\text{inercia}}$ | : | Precio sombra sistémico asociado a la restricción de inercia mínima en $t$ .                                              |
| $\mu_t^{\text{rpf}}$     | : | Precio sombra sistémico asociado a la restricción de reserva primaria en $t$ .                                            |
| $\hat{y}$                | : | Predicción probabilística cruda emitida por el modelo de IA.                                                              |
| $\tilde{y}$              | : | Predicción probabilística empíricamente calibrada mediante regresión isotónica.                                           |

# Resumen

La transición energética ha introducido una alta variabilidad en la operación de sistemas eléctricos de potencia. En este contexto, el problema de *Unit Commitment* (UC) enfrenta severos cuellos de botella computacionales al escalar el sistema o proyectar planificaciones a largo plazo. Esta memoria desarrolla y valida una estrategia de optimización híbrida que utiliza Inteligencia Artificial (IA) para estimar el estado de las unidades generadoras, reduciendo drásticamente los tiempos de resolución de los modelos entero-mixtos (MILP) sin comprometer la factibilidad técnica ni la optimalidad económica.

La metodología abarca la simulación de despachos económicos para construir un dataset robusto, el entrenamiento de modelos de *Machine Learning* y la resolución del modelo final con variables binarias pre-fijadas heurísticamente. Los resultados demuestran que las arquitecturas de *Gradient Boosting* con probabilidades calibradas mediante Regresión Isotónica ofrecen un desempeño superior, garantizando la seguridad del sistema al evitar paradas forzadas y alcanzando factores de aceleración (*speedups*) de hasta 9.6x en horizontes semanales.

El análisis de sensibilidad ante contingencias y alta penetración renovable ratifica la resiliencia del modelo, manteniendo desviaciones de costo menores al 1 %. Destaca especialmente su desempeño en planificaciones mensuales, donde supera la maldición de la dimensionalidad: mientras el método clásico es truncado por tiempo sin lograr converger, la IA guía al *solver* hacia soluciones económicamente superiores en menos del 20 % del tiempo base. Finalmente, se propone como trabajo futuro la integración de *Graph Neural Networks* (GNN) y el uso de datasets más vastos para proyectar el potencial de esta técnica en sistemas a gran escala o de altísima volatilidad.

**Keywords:** Sistemas Eléctricos de Potencia, Unit Commitment, Inteligencia Artificial, Optimización Híbrida, Despacho Económico, Unidades Generadoras, Machine Learning.

# Capítulo 1

## Introducción

### 1.1. Motivación

El sector eléctrico a nivel global, y particularmente en Chile, atraviesa una transformación sin precedentes hacia la descarbonización, marcada por una alta penetración de energías renovables y el retiro programado de unidades convencionales. Esta masiva integración de Energías Renovables Variables (ERV), como la solar y la eólica, ha introducido un nivel de incertidumbre y variabilidad que el Sistema Eléctrico Nacional (SEN) debe gestionar con herramientas cada vez más sofisticadas [3]. En este nuevo escenario, la red de transmisión se vuelve más dinámica y compleja, exigiendo una coordinación del parque generador que sea capaz de responder a cambios bruscos en la disponibilidad de recursos naturales y la creciente demanda [4].

El núcleo matemático de esta coordinación es el problema de *Unit Commitment* (UC). Este desafío consiste en determinar, con antelación, qué unidades generadoras deben estar encendidas, apagadas o en estado de reserva para satisfacer la demanda al mínimo costo posible, respetando siempre las restricciones físicas de las máquinas y de la red de transmisión. Debido a la naturaleza discreta de las decisiones —donde una central debe estar operando o no— el UC se clasifica como un problema de optimización entero-mixto (MILP), el cual es inherentemente complejo de resolver computacionalmente, especialmente cuando la dimensionalidad aumenta ante sistemas de gran escala [5].

Actualmente, la industria utiliza herramientas de alto nivel para resolver estos problemas. Sin embargo, a medida que se busca representar el sistema con mayor detalle o realizar estudios de planificación a largo plazo con múltiples escenarios de incertidumbre, los tiempos de cómputo se vuelven una barrera crítica. Esta dificultad implica que, en muchas ocasiones, se deben sacrificar detalles técnicos o precisión para obtener resultados en tiempos útiles para la operación o la toma de decisiones regulatorias.

Es aquí donde surge la motivación de esta memoria. La Inteligencia Artificial (IA) ha demostrado una capacidad sobresaliente para identificar patrones en sistemas complejos y acelerar la toma de decisiones en problemas de ingeniería [6]. Al combinar la potencia de los modelos de aprendizaje automático con la estructura clásica de la optimización matemática, es posible guiar a los solvers tradicionales ha-

cia soluciones óptimas de manera mucho más eficiente. El objetivo de este trabajo no es reemplazar la física del sistema, sino utilizar la IA como una herramienta de aceleración para estimar el estado de las unidades y resolver un problema simplificado que mantenga la factibilidad económica y técnica del SEN [7].

## 1.2. Objetivos

### 1.2.1. Objetivo General

Desarrollar y validar una estrategia de optimización para resolver el problema de *Unit Commitment* basada en técnicas de Inteligencia Artificial, con el fin de reducir los tiempos de resolución manteniendo la calidad de la solución y la factibilidad operativa en el Sistema Eléctrico Nacional.

### 1.2.2. Objetivos Específicos

- **Identificación de variables y restricciones:** Analizar las variables operacionales y restricciones técnicas (tiempos mínimos, rampas, reservas) que impactan la decisión de encendido y apagado de las unidades en el SEN, determinando el conjunto de unidades cuya decisión debe ser tomada de manera conjunta.
- **Generación de base de entrenamiento:** Construir un dataset robusto que permita al modelo de IA aprender el comportamiento óptimo del despacho a partir de simulaciones previas y la resolución del modelo MILP relajado.
- **Diseño y entrenamiento del modelo de IA:** Implementar una arquitectura de aprendizaje automático capaz de estimar el encendido óptimo de las unidades de generación basándose en las características del sistema.
- **Validación y comparación de resultados:** Evaluar el rendimiento del modelo propuesto en términos de tiempo de cómputo y calidad económica de la solución, utilizando como referencia (*benchmark*) las soluciones obtenidas mediante herramientas tradicionales de optimización.

# Capítulo 2

## Marco Teórico

En este capítulo se presentan los fundamentos conceptuales y matemáticos que sustentan el desarrollo de esta memoria. Se aborda la estructura operativa de los sistemas de potencia, la formulación clásica del *Unit Commitment*, los principios de optimización matemática y, finalmente, las técnicas de Inteligencia Artificial aplicadas a la aceleración de estos problemas.

### 2.1. Sistemas Eléctricos de Potencia y el Desafío Operativo

El estudio de la operación óptima de un sistema eléctrico requiere una comprensión profunda de su topología, sus normativas regulatorias y la naturaleza física de sus componentes. En esta sección se detallan las características operativas fundamentales de los sistemas de potencia, con especial énfasis en el contexto y los desafíos actuales del sistema chileno.

#### 2.1.1. El Sistema Eléctrico y la Congestión

El Sistema Eléctrico Nacional (SEN) posee una topología marcadamente longitudinal y radial, caracterizada por distancias de transmisión extremadamente largas entre los principales polos de generación y los grandes centros de consumo [1].

Esta configuración física introduce desafíos operacionales significativos, siendo la congestión en las líneas de transmisión uno de los más críticos. Cuando la capacidad térmica o de estabilidad de una línea se satura, el sistema se desacopla eléctricamente. Esto genera diferencias sustanciales en los precios locales de la energía (Costos Marginales Nodales) a lo largo del país y obliga al Coordinador Eléctrico Nacional (CEN) a despachar unidades térmicas locales subóptimas y más costosas estrictamente por razones de seguridad de red [1].

### 2.1.2. Despacho Económico vs. Seguridad

El principio rector teórico de la operación de un sistema de potencia es el despacho económico basado en el estricto orden de mérito. Bajo este paradigma, para satisfacer la demanda se despachan primero las centrales con menor costo variable (como las Energías Renovables No Convencionales, de costo marginal cercano a cero), seguidas por las unidades termoelectricas ordenadas según su eficiencia. La central más costosa requerida para cubrir el último megawatt determina el Costo Marginal del sistema [8].

Sin embargo, en la práctica, este despacho puramente económico se encuentra fuertemente restringido por la seguridad operativa. Para garantizar la resiliencia del sistema ante contingencias, como la falla imprevista de una central o la desconexión de una línea de extra alta tensión (criterio de seguridad N-1), el CEN debe mantener Reservas en Giro (*Spinning Reserves*). Esto implica que ciertas unidades generadoras deben operar por debajo de su capacidad máxima técnica, o mantenerse encendidas aun cuando no sean económicamente eficientes, para proveer inercia y soporte de red [8]. La necesidad de proyectar dinámicamente qué máquinas deben estar operando para cumplir con este delicado equilibrio entre seguridad física y economía es lo que da origen al problema de *Unit Commitment*.

### 2.1.3. Integración de ERV y la “Curva del Pato”

Durante la última década, la inserción masiva de Energías Renovables Variables (ERV) ha desplazado drásticamente a la generación térmica convencional [3]. Aunque esta transición reduce los costos operativos y las emisiones, introduce externalidades técnicas severas debido a la variabilidad e incertidumbre inherente del recurso primario.

El impacto físico más notable de esta integración es la aparición de la “Curva del Pato” (*Duck Curve*) (Ver Figura 2.1). Durante las horas de máxima radiación solar, la inyección masiva de energía solar deprime la demanda neta, forzando a las centrales convencionales a operar a sus mínimos técnicos o induciendo vertimientos de energía limpia (*curtailment*). Al atardecer, la generación fotovoltaica cae abruptamente casi en sincronía con el *peak* de demanda residencial diaria. Para mantener el balance del sistema, el parque generador remanente debe incrementar su producción a tasas extremadamente rápidas (altos requerimientos de rampas de subida o *Ramp-up*) [4].

Esta dinámica fuerza a las unidades térmicas de base a realizar ciclos de encendido y apagado frecuentes, operando bajo un severo estrés mecánico. Este contexto de alta exigencia dinámica es el que hace imperativo contar con herramientas de *Unit Commitment* de alta velocidad, que superen los tiempos de cómputo de los optimizadores tradicionales y permitan simular miles de escenarios estocásticos para evaluar la resiliencia de la red.




Figura 2.1: Ilustración del fenómeno de la “Curva del Pato” en el SEN.

*Fuente: Elaboración propia, con datos extraídos de [1].*

## 2.2. El Problema de Unit Commitment (UC)

El problema de *Unit Commitment* (UC) es fundamental en la operación de sistemas de potencia. Su objetivo principal es determinar la programación óptima de encendido y apagado de las unidades generadoras disponibles, así como su nivel de despacho continuo, para satisfacer la demanda de energía proyectada al mínimo costo posible durante un horizonte de tiempo determinado. Dada la naturaleza de las decisiones operativas, que incluyen estados discretos y variables continuas (potencia inyectada), el UC se formula matemáticamente como un problema de Programación Lineal Entera Mixta (MILP).

### 2.2.1. Formulación Primal del UC y Función Objetivo

La formulación primal busca minimizar el costo total de operación del sistema. Este costo se compone típicamente de tres elementos principales: el costo variable de producción (combustible), el costo de encendido (*Start-up cost*) y el costo de apagado (*Shut-down cost*).

La función objetivo se expresa de la siguiente manera:

$$\min \sum_{t \in \mathcal{T}} \sum_{g \in \mathcal{G}} [C_g(P_{g,t}) + C_{g,t}^{SU} su_{g,t} + C_{g,t}^{SD} sd_{g,t}] \quad (2.1)$$

Donde  $\mathcal{T}$  es el conjunto de periodos de tiempo (generalmente horas) y  $\mathcal{G}$  es el conjunto de unidades generadoras térmicas. Las variables principales del problema son:

- $P_{g,t}$ : Variable continua que representa la potencia activa despachada por la unidad  $g$  en el periodo  $t$ .

- $u_{g,t} \in \{0, 1\}$ : Variable binaria de **estado**, donde 1 indica que la unidad está encendida y sincronizada a la red, y 0 que está apagada.
- $su_{g,t}, sd_{g,t} \in \{0, 1\}$ : Variables binarias de **decisión** que indican si la unidad  $g$  ejecuta una orden de arranque ( $su_{g,t} = 1$ ) o una orden de detención ( $sd_{g,t} = 1$ ) en el periodo  $t$ .

Es fundamental establecer la distinción matemática y operativa entre los estados ( $u$ ) y las decisiones de transición ( $su, sd$ ). Mientras el estado indica la condición estática de la máquina durante la hora, las decisiones representan acciones dinámicas puntuales. En el contexto de modelos predictivos y de Inteligencia Artificial, predecir las decisiones ( $su, sd$ ) resulta en matrices dispersas (*sparse*) que son computacionalmente más eficientes de inferir y menos propensas a generar violaciones físicas en secuencias temporales que la predicción directa de la matriz de estados completa ( $u$ ).

La coherencia física entre el estado estático de la máquina y sus transiciones dinámicas se asegura mediante la siguiente restricción de balance lógico:

$$u_{g,t} - u_{g,t-1} = su_{g,t} - sd_{g,t} \quad (2.2)$$

Además, el despacho físico de la unidad está restringido por sus límites técnicos de operación, los cuales dependen directamente de su estado:

$$u_{g,t}P_g^{min} \leq P_{g,t} \leq u_{g,t}P_g^{max} \quad (2.3)$$

Donde  $P_g^{min}$  representa el mínimo técnico de la central (el nivel más bajo de potencia para una combustión estable) y  $P_g^{max}$  su capacidad máxima neta.

### 2.2.2. Restricciones de Acoplamiento Temporal

Lo que convierte al UC en un problema computacionalmente NP-Hard no es únicamente la presencia de variables binarias, sino su fuerte acoplamiento intertemporal [5, 9]. Una decisión de arranque o parada ejecutada en la hora  $t$  condiciona irrevocablemente el espacio de soluciones factibles en las horas futuras.

#### Tiempos mínimos de operación y apagado ( $UT/DT$ )

Para evitar la fatiga térmica de componentes críticos como turbinas y calderas, las plantas convencionales no pueden ciclar su estado de manera instantánea [5]. Si una unidad recibe una orden de arranque, debe permanecer operando por un tiempo mínimo  $UT_g$  (*Up-Time*). De manera análoga, tras una orden de parada, debe permanecer inactiva por un tiempo mínimo de enfriamiento  $DT_g$  (*Down-Time*). Matemáticamente:

$$\sum_{k=t-UT_g+1}^t su_{g,k} \leq u_{g,t} \quad \forall t \in \mathcal{T} \quad (2.4)$$

$$\sum_{k=t-DT_g+1}^t sd_{g,k} \leq 1 - u_{g,t} \quad \forall t \in \mathcal{T} \quad (2.5)$$

### Límites de rampa (*Ramp rates*)

Las unidades térmicas poseen inercias mecánicas que limitan la velocidad a la que pueden modificar su potencia inyectada [9]. Se definen las rampas de subida ( $RU_g$ ), de bajada ( $RD_g$ ), y las rampas transitorias asociadas a los procesos de sincronización inicial ( $SU_g$ ) y desconexión ( $SD_g$ ):

$$P_{g,t} - P_{g,t-1} \leq RU_g u_{g,t-1} + SU_g s u_{g,t} \quad (2.6)$$

$$P_{g,t-1} - P_{g,t} \leq RD_g u_{g,t} + SD_g s d_{g,t} \quad (2.7)$$

Para ilustrar de manera integral cómo estas restricciones de acoplamiento temporal condicionan el despacho físico, la Figura 2.2 presenta el perfil operativo típico de una unidad térmica, evidenciando el respeto estricto a las rampas de subida/bajada y los periodos de latencia de los tiempos mínimos.




Figura 2.2: Perfil operativo dinámico de una unidad térmica convencional.

*Fuente: Elaboración propia, con datos extraídos de [1].*

### 2.2.3. Restricciones de Red y Topología (DC-OPF)

La operación de las unidades generadoras no ocurre en un nodo aislado, sino que debe enmarcarse dentro de las capacidades físicas de la red de transmisión mallada.

### Balance Nodal y Reservas en Giro

El balance de energía debe cumplirse estrictamente. La generación térmica, sumada a los aportes de energías renovables ( $P_{W,t}$ ), debe igualar a la demanda más las pérdidas de red en cada instante. Adicionalmente, para asegurar el criterio N-1, la suma de la capacidad máxima de las unidades sincronizadas debe superar la demanda por un margen de seguridad sistémico  $R_t$ :

$$\sum_{g \in \mathcal{G}} u_{g,t} P_g^{max} \geq D_t + R_t \quad \forall t \in \mathcal{T} \quad (2.8)$$

### Límites de Transmisión (Shift Factors)

En redes malladas como el SEN o el sistema IEEE de 39 barras, el despacho debe respetar los límites térmicos de transporte. Para integrar estas restricciones manteniendo la linealidad del modelo MILP y reduciendo los tiempos de cómputo, se emplea una aproximación de Flujo de Potencia Óptimo en Corriente Continua (DC-OPF) basada en Factores de Distribución (*Shift Factors* o *SF*).

Esta formulación matricial permite calcular el flujo de potencia activa  $f_{l,t}$  por cualquier línea  $l$  como una combinación lineal directa de las inyecciones netas de potencia en cada nodo  $n$  del sistema, sin requerir el cálculo explícito de los ángulos de fase de voltaje:

$$f_{l,t} = \sum_{n \in \mathcal{N}} SF_{l,n} P_{n,t}^{neta} \quad (2.9)$$

Donde  $P_{n,t}^{neta}$  representa la diferencia entre la generación y la carga en el nodo  $n$ . Posteriormente, se impone una restricción dura para garantizar que ningún flujo exceda la capacidad máxima nominal de la línea ( $F_l^{max}$ ):

$$-F_l^{max} \leq f_{l,t} \leq F_l^{max} \quad \forall l \in \mathcal{L}, \forall t \in \mathcal{T} \quad (2.10)$$

Esta formulación topológica asegura que la solución matemática del Unit Commitment sea físicamente inyectable y transportable a través de la infraestructura real de la red eléctrica.

## 2.3. Optimización Matemática (MILP) y Relajación Lineal

Para resolver el problema de *Unit Commitment* (UC) de manera exacta y garantizar la factibilidad técnica del despacho económico, la industria eléctrica recurre a técnicas avanzadas de optimización matemática. Sin embargo, la exigencia contemporánea de evaluar múltiples escenarios operativos, especialmente en la planificación estocástica a largo plazo con alta incertidumbre renovable, impone límites computacionales severos a estos métodos tradicionales.

### 2.3.1. Programación Lineal Entera Mixta (MILP) y Complejidad Computacional

El UC, en su formulación clásica presentada en la sección anterior, pertenece a la familia de problemas de Programación Lineal Entera Mixta (MILP, por sus siglas en inglés). Un problema MILP se caracteriza por poseer una función objetivo lineal (o cuadrática linealizada mediante aproximaciones a tramos) y un conjunto de restricciones lineales, pero con la particularidad fundamental de que un subconjunto de sus variables de decisión debe tomar valores enteros o binarios [2].

En el contexto del despacho eléctrico, las variables continuas representan la inyección de potencia de las máquinas y los flujos por las líneas  $(P_{g,t}, f_{l,t})$ , mientras que las variables discretas (específicamente binarias) representan los estados lógicos del sistema y sus transiciones dinámicas: el encendido, el arranque y la parada de las unidades térmicas  $(u_{g,t}, su_{g,t}, sd_{g,t})$ . La presencia de estas variables binarias transforma el espacio de soluciones factibles de un conjunto continuo y convexo (fácil de optimizar) a un conjunto combinatorio discreto y no convexo.

Esta naturaleza combinatoria implica que el problema se clasifique como NP-Hard (*Non-deterministic Polynomial-time hard*). En términos prácticos, el tiempo computacional requerido para encontrar y certificar la solución óptima global crece de manera exponencial a medida que aumenta la dimensionalidad del problema. Para un sistema con  $N$  unidades térmicas, en una sola hora existen teóricamente  $2^N$  combinaciones posibles de estados, lo que evidencia la “maldición de la dimensionalidad” que enfrenta la operación del SEN [9].

### 2.3.2. Algoritmos de Resolución: Branch-and-Bound y Planos de Corte

Dado que no existe un algoritmo de tiempo polinomial capaz de resolver problemas MILP de forma exacta, los *solvers* comerciales de alto rendimiento (tales como Gurobi o CPLEX) utilizan métodos de enumeración implícita, siendo el más predominante el algoritmo de *Branch-and-Bound* (Ramificación y Acotamiento), frecuentemente potenciado con *Cutting Planes* (Planos de Corte) para formar el método *Branch-and-Cut* [10].

El algoritmo de *Branch-and-Bound* opera dividiendo sistemáticamente el espacio de búsqueda discreto en subproblemas más pequeños (nodos), construyendo un árbol de decisiones. En cada nodo, el algoritmo resuelve una versión continua del problema para obtener una cota inferior (*Bound*) del costo óptimo. Si la solución de un nodo presenta variables binarias con valores fraccionarios (por ejemplo,  $\hat{u}_{g,t} = 0,5$ ), el algoritmo “ramifica” (*Branch*) el problema creando dos nuevos nodos, forzando a la variable a tomar el valor de 0 en una rama y 1 en la otra [2].

Simultáneamente, los algoritmos de planos de corte identifican desigualdades matemáticas válidas que “recortan” las áreas fraccionarias del espacio de soluciones sin eliminar ninguna solución entera factible. No obstante, para simulaciones de planificación que requieren evaluar escenarios anuales (8760 horas) o bucles de Monte Carlo masivos, el árbol de ramificación crece de forma tan masiva que los tiempos de

convergencia se vuelven prohibitivos, haciendo inviable la evaluación probabilística ágil del sistema eléctrico [9].

### 2.3.3. Relajación Lineal y la Brecha de Integridad

Frente a la barrera computacional impuesta por el modelo MILP completo, una técnica matemática fundamental para obtener aproximaciones ultra-rápidas es la *Relajación Lineal* (*LP Relaxation*). Este enfoque consiste en eliminar la restricción estricta de integralidad impuesta sobre las variables discretas, permitiendo que estas asuman valores continuos dentro del intervalo cerrado  $[0, 1]$  [2].

Matemáticamente, las restricciones originales  $u_{g,t}, su_{g,t}, sd_{g,t} \in \{0, 1\}$  se relajan a  $0 \leq \hat{u}_{g,t}, \hat{su}_{g,t}, \hat{sd}_{g,t} \leq 1$ . Al realizar esta transformación, el problema MILP se convierte en un problema de Programación Lineal (LP) estándar. Dado que los problemas LP son puramente continuos y convexos, pueden resolverse eficientemente en tiempo polinomial (milisegundos) utilizando algoritmos de Punto Interior.

La diferencia porcentual entre el valor de la función objetivo del modelo MILP original (costo real) y el modelo LP relajado (costo idealizado) se denomina *Brecha de Integridad* (*Integrity Gap*). Es crucial entender que, si bien la solución del problema relajado es matemáticamente óptima para su formulación continua, carece de viabilidad física directa: una turbina no puede ejecutar un arranque fraccionario ( $\hat{su}_{g,t} = 0,6$ ).

Sin embargo, desde la perspectiva de la **física del sistema**, la solución relajada es portadora de un inmenso valor analítico. Debido a que el problema LP mantiene absolutamente intactas todas las restricciones topológicas de la red (flujos DC-OPF, *Shift Factors*, límites térmicos y balances nodales), los valores fraccionarios capturan la “presión económica y física” del sistema. Indican la probabilidad implícita o la necesidad del sistema por contar con esa unidad generadora en ese instante específico para mitigar restricciones activas de transmisión o suplir rampas críticas.

Esta característica es el pilar de la estrategia propuesta en esta memoria. En lugar de descartar la solución relajada por ser físicamente inviable, se propone utilizar la información latente contenida en las variables continuas ( $\hat{u}_{g,t}, \hat{su}_{g,t}$ ) como el **espacio de características (*feature space*) de un modelo de Inteligencia Artificial Guiado por la Física**. Este modelo aprenderá a mapear las señales continuas de la relajación lineal hacia decisiones binarias factibles, puenteando la brecha entre la velocidad del modelo LP y la viabilidad física del modelo MILP [7].

Para ilustrar geométricamente la naturaleza de la relajación lineal, la Figura 2.3 presenta el espacio de soluciones de un problema simplificado. El polígono convexo ( $P_{LP}$ ) delimita el espacio continuo, permitiendo alcanzar rápidamente el óptimo fraccionario ( $x_{LP}^*$ ). Por otro lado, los puntos discretos ( $X_{IP}$ ) representan las soluciones enteras estrictamente factibles del modelo MILP. La diferencia entre el óptimo continuo y el óptimo entero ( $x_{IP}^*$ ) materializa visualmente la Brecha de Integridad. Esta representación confirma que, si bien la solución relajada no es operativa, su ubicación contiene información estructural sumamente valiosa que puede ser decodificada mediante técnicas de *Machine Learning* para estimar con alta precisión el óptimo entero verdadero.




Figura 2.3: Representación geométrica de la Brecha de Integridad en un espacio bidimensional.

*Fuente: Elaboración propia, basado en [2].*

## 2.4. Inteligencia Artificial y Machine Learning en Optimización

La aplicación de técnicas de Inteligencia Artificial (IA), y específicamente de *Machine Learning* (ML), en la optimización de sistemas de potencia ha surgido como una respuesta directa a la intratabilidad computacional de los modelos MILP a gran escala. En lugar de explorar exhaustivamente el árbol de ramificación del espacio de soluciones, los modelos de aprendizaje automático buscan aproximar la función de mapeo óptima basándose en la experiencia acumulada de despachos históricos o resoluciones previas [7].

### 2.4.1. Aprendizaje Supervisado para Clasificación de Decisiones

En la metodología propuesta para el *Unit Commitment*, el objetivo del modelo estadístico no es predecir el valor continuo de potencia, ni predecir la matriz estática

y densa de los estados operativos ( $u_{g,t}$ ). Por el contrario, el problema se enmarca como un **Aprendizaje Supervisado para Clasificación Binaria de Secuencias**, donde la red neuronal debe inferir exclusivamente el momento exacto de las transiciones operativas: el arranque ( $su_{g,t}$ ) y la parada ( $sd_{g,t}$ ).

En el aprendizaje supervisado, se entrena a un modelo utilizando un conjunto de datos etiquetados conformado por pares de entrada-salida ( $X, Y$ ). Para esta investigación, el tensor de características o *features* ( $X$ ) incluye parámetros dinámicos con fuerte significado físico: la demanda neta proyectada, los gradientes de rampa horarios ( $\Delta$  MW/h), contadores de inercia térmica y, de manera fundamental, los valores continuos extraídos de la resolución ultra-rápida del modelo LP relajado ( $\hat{su}_{g,t}, \hat{sd}_{g,t}$ ). La etiqueta objetivo (*label* o  $Y$ ) corresponde a la matriz dispersa (*sparse*) de las decisiones óptimas reales ( $su_{g,t}^*, sd_{g,t}^* \in \{0, 1\}$ ), obtenida de ejecuciones exhaustivas previas del modelo MILP en Gurobi [11].

Durante el entrenamiento, el algoritmo ajusta sus parámetros internos para minimizar una función de pérdida (*Loss Function*), típicamente una variante asimétrica de la Entropía Cruzada Binaria (*Binary Cross-Entropy*), penalizando con mayor severidad las divergencias que puedan poner en riesgo la seguridad del sistema eléctrico (falsos negativos en encendidos críticos). Para visualizar la estructura de este proceso, la Figura 2.4 presenta el diagrama de flujo conceptual.




Figura 2.4: Diagrama de flujo del aprendizaje supervisado aplicado a las decisiones del Unit Commitment.

*Fuente: Elaboración propia.*

### 2.4.2. Arquitecturas de Redes Neuronales Profundas

Dado el comportamiento dinámico del parque generador, la elección de la arquitectura de la red es determinante para capturar tanto las relaciones espaciales (topología) como las temporales (restricciones de rampa y tiempos mínimos).

## Perceptrón Multicapa (MLP)

El Perceptrón Multicapa (*Multilayer Perceptron*) procesa cada vector de entrada de forma independiente [11]. En el UC, un MLP estándar carece de “memoria” secuencial, por lo que podría recomendar apagar una central térmica en la hora  $t$  sin ser consciente de que la máquina recién se encendió en la hora  $t - 1$ , violando irremediablemente su tiempo mínimo de operación si no se estructuran los datos de entrada con ventanas de contexto.

## Redes Recurrentes (RNN) y LSTM

Para superar las limitaciones del MLP frente a datos secuenciales, se emplean las Redes Neuronales Recurrentes (RNN). Estas redes poseen bucles de retroalimentación que les permiten mantener un “estado oculto”, transmitiendo información de instantes de tiempo pasados hacia el presente.

Dentro de esta familia, la arquitectura de Memoria a Corto y Largo Plazo (*Long Short-Term Memory*, LSTM) es particularmente efectiva para el UC. Mediante un sistema de compuertas matemáticas que regulan qué información se recuerda y cuál se olvida, las LSTM modelan dependencias a largo plazo [4]. Esta característica las hace intrínsecamente aptas para inferir matrices dispersas de decisiones lógicas de encendido y apagado, internalizando empíricamente las restricciones de acoplamiento intertemporal del despacho eléctrico, como los  $DT_g$  y las inercias térmicas.

## Redes Neuronales Convolucionales (CNN)

Aunque tradicionalmente asociadas a imágenes, las Redes Convolucionales unidimensionales (1D-CNN) se utilizan en series de tiempo como filtros extractores de características. En el contexto eléctrico, pueden identificar rápidamente la presencia de rampas pronunciadas en la demanda neta (como la caída vespertina de la curva del pato) comprimiendo esta información estructural antes de alimentarla a una capa LSTM [11].

### 2.4.3. IA Guiada por la Física (*Physics-Informed Machine Learning*)

El desafío académico más profundo al aplicar IA “ciega” (basada puramente en datos) a los sistemas de potencia es que los modelos estadísticos pueden emitir predicciones que, aunque probabilísticamente cercanas a la realidad, son físicamente infactibles [6]. Por ejemplo, predecir el arranque simultáneo de múltiples unidades en un mismo nodo, ignorando la saturación de los límites térmicos de las líneas de transmisión adyacentes.

Para mitigar este riesgo crónico, emerge el paradigma del *Physics-Informed Machine Learning* (PIML), el cual busca coaccionar al modelo estadístico para que respete las leyes de la física. En la literatura reciente, este enfoque se ha materializado a través de dos vertientes principales, ambas aplicadas en esta investigación:

**1. Ingeniería de Características Guiada por la Física (*Physics-Informed Feature Engineering*):** En lugar de esperar que la red deduzca la topología del sistema desde cero, se inyecta conocimiento explícito en sus entradas. Al incluir la solución LP relajada como *feature* principal, la IA hereda la evaluación de una red eléctrica en corriente continua (DC-OPF). Los valores fraccionarios del modelo relajado ya contemplan las leyes de Kirchhoff y los *Shift Factors*, entregando a la red neuronal un “borrador” que garantiza el respeto previo a la congestión de transmisión.

**2. Redes Informadas por la Física (PINNs):** Esta técnica altera el proceso de aprendizaje al incorporar las ecuaciones del sistema directamente dentro de la función de pérdida del modelo [6]. En el contexto del UC combinatorio, la función de pérdida total ( $\mathcal{L}_{total}$ ) se descompone:

$$\mathcal{L}_{total} = \mathcal{L}_{datos} + \lambda \cdot \mathcal{L}_{física} \quad (2.11)$$

Donde  $\mathcal{L}_{datos}$  evalúa el error de clasificación binaria tradicional, y  $\mathcal{L}_{física}$  actúa como un término de penalización asimétrica severa que castiga exponencialmente a la red si sus predicciones inducen a déficits de generación (Energía No Suministrada - ENS) o violaciones topológicas al evaluar el modelo matemático post-procesado. El hiperparámetro  $\lambda$  pondera la severidad de esta penalización operativa.

Esta regularización física, ilustrada en la Figura 2.5, subraya cómo el modelo es coaccionado matemáticamente a converger hacia un espacio de soluciones que no solo minimiza el error estadístico, sino que garantiza una alta calidad de factibilidad física para el parque generador.

Esquema de Aprendizaje Supervisado para el Unit Commitment




Figura 2.5: Arquitectura conceptual de un enfoque PIML aplicado al despacho eléctrico.

Fuente: Elaboración propia.

### 2.4.4. Modelos de Ensamble y Gradient Boosting (GBDT)

En paralelo a las arquitecturas de aprendizaje profundo (*Deep Learning*), el estado del arte actual para el procesamiento de datos tabulares y fronteras de decisión físicas en sistemas de potencia contempla el uso de modelos de ensamble basados en **Gradient Boosting Decision Trees (GBDT)**, tales como *XGBoost* [12] y *LightGBM* [13].

A diferencia de las redes neuronales que aproximan funciones mediante capas densas o recurrentes, los métodos GBDT construyen un ensamble de  $M$  árboles de decisión de forma aditiva y secuencial. En cada iteración  $m$ , se añade un nuevo árbol  $f_m(x)$  diseñado para minimizar el gradiente negativo de la función de pérdida logística respecto a las predicciones previas del modelo acumulado  $F_{m-1}(x)$ :

$$F_m(x) = F_{m-1}(x) + \gamma_m f_m(x) \quad (2.12)$$

Al optimizar directamente el gradiente de la pérdida residual (*log-loss*), estos algoritmos concentran su capacidad de aprendizaje en ajustar con extrema precisión fronteras no lineales nítidas (condicionadas por límites térmicos o costos de arranque), empujando las probabilidades hacia los extremos mediante la función sigmoide  $\hat{y} = \sigma(F(x))$ . No obstante, el estado del arte advierte que estos modelos suelen sufrir de sesgos de sobreconfianza, requiriendo módulos de postprocesamiento como la **Regresión Isotónica** [11].

## 2.5. Modelos Sustitutos y Estrategias Híbridas de Optimización

La aplicación directa de algoritmos de *Machine Learning* para predecir variables en sistemas de potencia ha demostrado un gran potencial, pero enfrenta la barrera de la confiabilidad operativa. Para conciliar la velocidad de la Inteligencia Artificial con la rigurosidad física de la optimización matemática, la literatura reciente ha consolidado el uso de Modelos Sustitutos (*Surrogate Models*) y enfoques híbridos [14].

### 2.5.1. Concepto de Modelo Sustituto en Sistemas de Potencia

En el ámbito de la ingeniería computacional y la optimización, un Modelo Sustituto —también conocido como modelo *proxy* o emulador— es un modelo estadístico o de aprendizaje automático diseñado para aproximar el comportamiento de una función o simulación subyacente que es computacionalmente prohibitiva de evaluar [14].

Matemáticamente, si el proceso de resolver el problema de *Unit Commitment* mediante un algoritmo *Branch-and-Bound* se define como una función compleja  $f(x)$  que mapea las condiciones del sistema ( $x$ ) a un programa de despacho óptimo, su evaluación exacta requiere un tiempo computacional  $t_{MILP}$  inasumible para la

simulación masiva de escenarios. El objetivo del aprendizaje automático es construir una función aproximada  $\hat{f}(x)$ , tal que  $\hat{f}(x) \approx f(x)$ , pero cuyo tiempo de inferencia  $t_{IA}$  sea órdenes de magnitud menor ( $t_{IA} \ll t_{MILP}$ ).

En el diseño tradicional de modelos sustitutos, la red neuronal intenta predecir directamente todas las variables operativas (matrices densas de estados de encendido  $u$  y potencia inyectada  $P$ ). Sin embargo, este enfoque puramente basado en datos (*data-driven*) es propenso a generar soluciones con pequeñas discrepancias matemáticas que, en un sistema de potencia, se traducen en infactibilidades severas, como violaciones de los tiempos mínimos de operación, del balance nodal o de los límites de transmisión [7].

### 2.5.2. Estrategias Híbridas IA-Optimización

Para sortear las limitaciones de un modelo sustituto puro, esta memoria propone una **estrategia de optimización híbrida en dos etapas**. En lugar de delegar toda la responsabilidad matemática a la red neuronal, la IA se emplea exclusivamente como un emulador de las decisiones estratégicas discretas (las órdenes de arranque y parada), devolviendo la resolución de la física continua y topológica al *solver* matemático tradicional [7].

Esta metodología híbrida se fundamenta en la siguiente secuencia de procesos:

1. **Exploración Relajada (LP):** Ante un nuevo escenario operativo, se formula el modelo del sistema eléctrico y se resuelve aplicando la relajación lineal de todas sus variables lógicas ( $0 \leq \hat{u}_{g,t}, \hat{s}u_{g,t}, \hat{s}d_{g,t} \leq 1$ ). Esta fase es extremadamente rápida al tratarse de un problema continuo, y su solución captura las restricciones de red (DC-OPF) y la presión económica del despacho.
2. **Inferencia del Modelo Sustituto (IA):** El vector de variables continuas  $(\hat{u}, \hat{s}u, \hat{s}d)$ , junto con los parámetros físicos dinámicos, alimenta al modelo de IA pre-entrenado. La red neuronal actúa como un clasificador de alta velocidad, estimando exclusivamente la matriz dispersa de estado.
3. **Despacho Lineal Restringido y Verificación Física:** Las predicciones binarias emitidas por la IA se inyectan en el modelo MILP original como límites fijos (*bounds*). Al estar predefinidas las decisiones, las ecuaciones lógicas del *solver* ( $u_{g,t} - u_{g,t-1} = su_{g,t} - sd_{g,t}$ ) propagan automáticamente el estado de las máquinas respetando sus inercias. El problema pierde así su naturaleza combinatoria y colapsa en un problema LP continuo. El *solver* (ej. Gurobi) calcula el despacho económico exacto ( $P_{g,t}$ ) garantizando el cumplimiento estricto del balance de red. Si la IA comete un error físico grave que impida el balance, el *solver* no diverge, sino que activa variables de holgura (Energía No Suministrada - ENS), permitiendo cuantificar y penalizar la falla del modelo estadístico.

Este enfoque híbrido garantiza que la Inteligencia Artificial acelere dramáticamente la resolución de la frontera combinatoria (el *Unit Commitment*), mientras que

la Programación Lineal tradicional certifica la factibilidad operativa y la seguridad económica de la solución final (el Despacho Económico).

Para visualizar la arquitectura de esta metodología, la Figura 2.6 presenta el diagrama de bloques de la estrategia híbrida propuesta, detallando el flujo de información desde la caracterización del parque generador hasta la resolución del modelo lineal final.




Figura 2.6: Diagrama de la estrategia de optimización híbrida propuesta.

*Fuente: Elaboración propia.*

## 2.6. Métricas de Evaluación y Desempeño

La validación de un modelo sustituto basado en Inteligencia Artificial aplicado al *Unit Commitment* requiere un enfoque de evaluación dual. Por un lado, es necesario medir la capacidad estadística de la red neuronal para clasificar correctamente las transiciones operativas de las unidades. Por otro lado, y de mayor relevancia para la ingeniería eléctrica, es imperativo cuantificar la factibilidad física de la solución y su impacto económico sobre el mercado eléctrico [7].

### 2.6.1. Métricas de Clasificación Estadística

Dado que la salida de la red neuronal predice decisiones discretas de arranque y parada ( $\tilde{s}u_{g,t}, \tilde{s}d_{g,t} \in \{0, 1\}$ ) que propagan el estado final de la unidad ( $\tilde{u}_{g,t}$ ), el rendimiento del modelo se evalúa inicialmente mediante una Matriz de Confusión sobre los estados resultantes. En el contexto del despacho de energía, los cuadrantes de esta matriz adquieren un significado físico y económico crítico [14]:

- **Verdadero Positivo (TP):** La IA decide mantener/encender la unidad ( $\tilde{u}_{g,t} = 1$ ) y el modelo MILP óptimo lo confirma ( $u_{g,t}^* = 1$ ). Operación correcta.
- **Verdadero Negativo (TN):** La IA decide mantener/apagar la unidad ( $\tilde{u}_{g,t} = 0$ ) y el modelo óptimo lo confirma ( $u_{g,t}^* = 0$ ). Ahorro de combustible y cumplimiento de tiempos de detención correctos.
- **Falso Positivo (FP):** La IA arranca o mantiene encendida una unidad que debía estar apagada. Esto introduce **sobrecostos operativos** (*Overcommitment*), ya que el sistema incurre en costos de partida innecesarios, forzando a las máquinas a operar en sus mínimos técnicos y, frecuentemente, desplazando energía renovable gratuita.

- **Falso Negativo (FN):** La IA omite una orden de arranque necesaria, dejando apagada una unidad que el modelo óptimo requería. Este es el **error operativo más crítico** (*Undercommitment*), ya que provoca déficits de inercia, congestión de redes y pérdida de carga.

Para sintetizar la asimetría del riesgo operativo, la Figura 2.7 presenta la Matriz de Confusión contextualizada. Mientras un *FP* penaliza la economía del sistema, un *FN* compromete severamente su seguridad física.

**Matriz de Confusión Contextualizada:  
Impacto Eléctrico en el Unit Commitment**

|                             |               | Predicción de la Inteligencia Artificial                                                                   |                                                                                             |
|-----------------------------|---------------|------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------|
|                             |               | Encendido (1)                                                                                              | Apagado (0)                                                                                 |
| Decisión Óptima Real (MILP) | Encendido (1) | <b>Verdadero Positivo (TP)</b><br><br>Decisión Correcta:<br>La unidad se enciende<br>como estaba previsto. | <b>Falso Negativo (FN)</b><br><br><b>Riesgo de Déficit /<br/>Inviabilidad Física</b>        |
|                             | Apagado (0)   | <b>Falso Positivo (FP)</b><br><br><b>Sobrecosto Operativo /<br/>Desplazamiento ERNC</b>                    | <b>Verdadero Negativo (TN)</b><br><br>Decisión Correcta:<br>La unidad permanece<br>apagada. |

Figura 2.7: Matriz de confusión contextualizada para la evaluación del modelo de Inteligencia Artificial en el Unit Commitment.

*Fuente: Elaboración propia.*

A partir de esta matriz, se calculan las métricas estadísticas estándar [11]: Exactitud (*Accuracy*), Precisión (*Precision*) y Sensibilidad (*Recall*). Debido a la asimetría en los costos de los errores, la métrica *F1-Score* resulta ser el indicador estadístico más robusto para evaluar el entrenamiento del modelo:

$$F1-Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (2.13)$$

### 2.6.2. Métricas de Factibilidad Física y Aceleración Computacional

Independientemente del rendimiento estadístico (*F1-Score*), la validación ingenieril recae en el comportamiento de la red eléctrica al simular las decisiones de la IA en la etapa de *post-procesamiento híbrido*.

#### Energía No Suministrada (ENS)

Si el modelo de IA comete errores severos de tipo Falso Negativo (*Undercommitment*), el modelo lineal final no encontrará una combinación de flujos factible para satisfacer la demanda. Para evitar la divergencia matemática, los *solvers* incorporan variables de holgura penalizadas, siendo la más crítica la generación de falla o Energía No Suministrada (*ENS*). Un modelo sustituto exitoso debe garantizar que el ENS inducido por sus predicciones sea cero (o marginal), demostrando que la solución propuesta es 100 % factible de inyectar en la red de transmisión.

#### Aceleración Computacional (*Speed-up Factor*)

El propósito central de esta memoria es viabilizar el análisis estocástico masivo reduciendo la barrera computacional del MILP. Esto se cuantifica mediante el factor de aceleración:

$$Speedup = \frac{t_{MILP}}{t_{LP\_relajado} + t_{IA} + t_{LP\_final}} \quad (2.14)$$

Donde  $t_{MILP}$  es el tiempo de convergencia del modelo exacto combinatorio (Branch-and-Bound), mientras que el denominador representa el tiempo fraccionado de la estrategia híbrida propuesta.

### 2.6.3. Métricas de Impacto Económico

Finalmente, es imperativo evaluar si las decisiones heurísticas de la IA generan distorsiones inaceptables en el mercado eléctrico a corto plazo.

#### Pérdida de Optimalidad (Sobrecostos)

Teóricamente, al restringir el espacio de búsqueda fijando las decisiones de arranque predichas por la IA, el costo operativo del despacho resultante ( $C_{híbrido}$ ) debería ser siempre mayor o igual al óptimo global absoluto. Sin embargo, en la práctica computacional, el solucionador estricto (MILP) no busca el óptimo absoluto, sino que detiene su ejecución al alcanzar una tolerancia predefinida (*MIPGap*).

Debido a esto, el modelo híbrido —al podar drásticamente el árbol de decisiones— puede guiar al solucionador hacia una solución entera de alta calidad que resulte incidentalmente menor (mejor) que el costo reportado por el MILP base ( $C_{MILP}^*$ ).

antes de abortar su búsqueda. Esta diferencia relativa, que empíricamente puede tomar valores levemente negativos, se denomina Pérdida de Optimalidad (*Optimality Gap*):

$$\Delta Costo(\%) = \frac{C_{híbrido} - C_{MILP}^*}{C_{MILP}^*} \cdot 100 \quad (2.15)$$

Un modelo sustituto industrialmente viable debe mantener este  $\Delta Costo$  por debajo del 1 %, garantizando que la aceleración computacional no comprometa la economía del sistema.

# Capítulo 3

## Metodología

La presente sección detalla el marco metodológico diseñado para abordar el problema de *Unit Commitment* (UC) mediante la implementación de una estrategia de optimización híbrida. El desarrollo computacional se estructura en cuatro etapas secuenciales fundamentales: (i) la caracterización del parque generador y resolución de un modelo de programación lineal continuo (UC Relajado), (ii) la generación y estructuración de la base de entrenamiento a partir de simulaciones históricas, (iii) el diseño y entrenamiento del modelo de Inteligencia Artificial (IA) como clasificador de estados operativos, y (iv) la resolución del modelo de despacho lineal final fijando las decisiones combinatorias.

### 3.1. Caracterización del Sistema y Modelación Base

Para que un modelo de Inteligencia Artificial logre internalizar el comportamiento físico de un sistema de potencia y no se limite a ser un mero reconocedor de patrones estadísticos, es imperativo establecer un entorno de simulación riguroso. Este entorno debe presentar la complejidad topológica y de fenómenos suficiente para desafiar al optimizador computacional, pero al mismo tiempo permitir una validación matemática controlada y transparente.

Por este motivo, la presente metodología plantea la modelación de un problema de **Unit Commitment Hidrotérmico (HTUC)** enriquecido. Si bien la topología base toma inspiración del sistema de prueba **IEEE 39-Bus System** (conocido como el sistema de Nueva Inglaterra o *Case 39*) compuesto por 39 nodos, 46 líneas de transmisión y 10 unidades generadoras térmicas, para garantizar la representatividad de la congestión de red y el acoplamiento temporal, el modelo se expande para capturar la realidad operativa de un sistema moderno con alta penetración renovable, análogo al Sistema Eléctrico Nacional (SEN). Esto exige la inclusión explícita de sistemas de almacenamiento, variabilidad hidrológica y estrictas restricciones de estabilidad de frecuencia.

### 3.1.1. Elementos del Sistema Modelados

El modelo matemático integra diversas tecnologías de generación y almacenamiento, cada una caracterizada computacionalmente mediante restricciones lógicas, físicas y económicas [15, 9]:

- **Generadores Térmicos ( $G$ ):** Representan la inercia física y la generación base/punta del sistema. Se modelan mediante funciones de costo de combustible cuadráticas o lineales por tramos, e incurren en costos discretos de arranque ( $C_g^{SU}$ ). Su dinámica operativa se acota mediante tiempos mínimos de encendido ( $UT_g$ ) y apagado ( $DT_g$ ). Además, están sujetos a límites de capacidad ( $P_g^{min}, P_g^{max}$ ), tasas de rampa de subida y bajada ( $RU_g, RD_g$ ) y a la provisión de reserva primaria rápida ( $rp_g^{max}$ ) [5].
- **Energías Renovables No Convencionales (ERN,  $GR$ ):** Las plantas solares y eólicas son modeladas como inyecciones de potencia dependientes del recurso primario, representadas a través de perfiles horarios estocásticos. Actúan como modificadores directos de la demanda neta, exigiendo mayor flexibilidad y capacidad de rampa al parque termoeléctrico.
- **Almacenamiento por Baterías (BESS,  $S$ ):** Se modelan con límites simétricos o asimétricos de potencia de carga y descarga. Incluyen ecuaciones de balance de energía para rastrear el Estado de Carga (SOC) en todo momento. Se penaliza el ciclo de ida y vuelta mediante una eficiencia global ( $\eta$ ), capturando adecuadamente las mermas del arbitraje temporal de energía.
- **Hidroeléctricas de Pasada ( $HP$ ):** Su inyección está sujeta estrictamente a perfiles horarios de caudales afluentes, sin capacidad de regulación intrínseca volumétrica.
- **Hidroeléctricas de Embalse ( $HE$ ):** Introducen el acoplamiento temporal interdiario al despacho. Se modelan considerando la dinámica de volumen del embalse (sujeto a cotas máximas y mínimas operativas), caudales afluentes estocásticos ( $\text{Hm}^3/\text{h}$ ) y condiciones de borde de volumen inicial y final. La potencia eléctrica inyectada se relaciona con el caudal turbinado mediante un factor de conversión o rendimiento hidrológico ( $\text{MW}/(\text{Hm}^3/\text{h})$ ).

### 3.1.2. Restricciones Físicas y de Red Relevantes

Para asegurar que el espacio de características (*Feature Space*) proyecte estados operacionales factibles para el aprendizaje de la red neuronal, el motor HTUC incorpora un conjunto avanzado de restricciones de transmisión y seguridad sistémica:

#### Balance de Potencia Nodal y Flujos DC

El transporte de energía se formula bajo el paradigma de Flujo de Potencia Óptimo en Corriente Continua (DC-OPF) [8]. La topología de la red se condensa

matemáticamente mediante matrices de Factores de Distribución (*Shift Factors*,  $SF$ ) o matrices de susceptancia nodal ( $B_{bus}, B_f$ ). Esto permite evaluar de forma matricial la primera ley de Kirchhoff en cada nodo y restringir los flujos de potencia activa a los límites térmicos de las líneas de transmisión ( $F_l^{max}$ ).

### Modelación de Pérdidas de Transmisión

Dado que en redes extensas las pérdidas óhmicas alteran de manera no despreciable el despacho económico y los Precios Marginales Locales (LMP), la metodología implementa tres enfoques seleccionables para su tratamiento en el motor de optimización:

1. **Aproximación Lineal por Tramos ( $QL = 1$ ):** Las pérdidas se dividen en intervalos lineales controlados por variables binarias de adyacencia. Garantiza un modelo MILP estricto, mitigando el error de aproximación, aunque incrementa la dimensionalidad combinatoria del problema.
2. **Envolvente Convexa ( $QL = 2$ ):** Utiliza un conjunto de desigualdades lineales para limitar el espacio factible superior. Constituye una relajación continua altamente eficiente, ideal para la extracción rápida de características en la fase de inferencia de la IA.
3. **Pérdidas Cuadráticas Exactas ( $QL = 3$ ):** Se imponen restricciones de la forma  $P_{loss} \propto f^2$ , transformando el modelo matemático original en un problema cuadrático mixto-entero (MIQCP).

### Requerimientos de Control de Frecuencia e Inercia

La alta penetración de ERNC basada en inversores desplaza a la generación sincrónica clásica, reduciendo la inercia natural del sistema. Por consiguiente, es necesario acoplar las restricciones de estabilidad directamente a las variables binarias del Unit Commitment [16]:

- **Reserva Primaria de Frecuencia (RPF):** Se exige que la suma de las reservas primarias efectivas de las máquinas térmicas encendidas sea igual o superior a un requerimiento de seguridad global, protegiendo al sistema ante la contingencia más severa (criterio  $N - 1$ ).
- **Inercia Mínima del Sistema:** Se garantiza que la inercia rotacional combinada supere un límite preestablecido. Esta inercia es aportada en función de las constantes de inercia ( $H_g$ ) de los generadores, su capacidad aparente instalada y su estado lógico de operación en el instante  $t$  ( $u_{g,t}$ ). Restringir la inercia despachada es crítico para limitar la Tasa de Cambio de Frecuencia (RoCoF) en los primeros milisegundos posteriores a una falla de desbalance, previniendo el colapso del sistema.

## 3.2. Generación de la Base de Datos

Una vez definido el modelo matemático base, el siguiente paso es generar y estructurar la información necesaria para entrenar el modelo de Inteligencia Artificial (IA). La calidad de las predicciones dependerá directamente de la coherencia física y la representatividad estadística de los datos simulados [11].

### 3.2.1. Bucle de Monte Carlo Jerárquico y Modelación Hidrológica

Para construir un conjunto de datos robusto, esta metodología genera miles de escenarios operativos mediante un **Bucle de Monte Carlo jerárquico**. Este proceso se estructura en tres niveles secuenciales:

1. **Topología de Red:** Se define el estado de disponibilidad de las líneas de transmisión y generadores.
2. **Escenario Anual:** Se proyectan perfiles anuales de demanda y disponibilidad de radiación solar y viento.
3. **Horizonte Rodante Diario:** Se resuelve el despacho en ventanas con resolución horaria.

Para capturar la incertidumbre en sistemas hidrotérmicos, los caudales de afluencia diaria de las centrales de embalse se modelan utilizando un proceso autorregresivo de media móvil **ARMA(2,1)**. Este modelo matemático genera caudales sintéticos a partir de anomalías históricas, permitiendo calcular dinámicamente el **Costo de Oportunidad del Agua** (en USD/Hm<sup>3</sup>) en función del nivel de llenado del embalse, penalizando el uso del recurso cuando las reservas se acercan a su volumen mínimo operativo [15].

### 3.2.2. Extracción de Datos Híbridos: Etiquetas y Señales Relajadas

La metodología presente implementa una técnica de **aplanamiento tabular** (*tabular flattening*). Cada instancia del *dataset* se define como una combinación única de generador y hora ( $g, t$ ) para un escenario específico. De este modo, para un horizonte de  $H$  horas y un sistema con  $N_{\text{gen}}$  generadores térmicos, el número de observaciones generadas por iteración es exactamente  $N_{\text{registros}} = N_{\text{gen}} \times H$ .

La clave del éxito del modelo sustituto radica en la **Ingeniería de Características Guiada por la Física** (*Physics-Informed Feature Engineering*) [6]. En lugar de forzar a la Inteligencia Artificial a deducir las leyes de Kirchhoff o el acoplamiento económico temporal desde cero, el espacio de entrada ( $X$ ) se construye de forma agnóstica combinando información estructural estática con variables duales (precios sombra) extraídas de la resolución previa del modelo lineal relajado (LP).

Cada registro vectorial plano en el archivo .CSV se compone de los siguientes bloques de información:

## 1. Identificadores y Etiqueta Objetivo

- **Metadatos:** Índices de referenciación espacial y temporal (*caso\_red*, *escenario*, *maquina\_id*  $\equiv g$ , *hora\_global*  $\equiv t$ ).
- **Etiqueta Objetivo ( $Y$ ):** La decisión binaria de encendido óptima ( $u_{g,t}^* \in \{0, 1\}$ ) determinada por el modelo MILP estricto. Esta es la “Verdad Terreno” que el clasificador buscará replicar.

## 2. Variables Predictivas de Estado de Red e Inercia

Estas variables proporcionan al modelo el contexto operativo inmediato del sistema:

- **Señales de Inercia Temporal Continua ( $X_{\text{prev}}, X_{\text{act}}, X_{\text{next}}$ ):** Representan la decisión del solucionador LP en el entorno temporal adyacente a la hora  $t$ :

$$X_{\text{prev}} = \hat{u}_{g,t-1}, \quad X_{\text{act}} = \hat{u}_{g,t}, \quad X_{\text{next}} = \hat{u}_{g,t+1} \quad (3.1)$$

Actúan como un filtro analítico de alta calidad. Dado que el modelo LP ya resuelve las condiciones KKT del problema continuo, estas señales pre-evalúan el impacto topológico de la máquina. La inclusión de  $t - 1$  y  $t + 1$  ayuda a la IA a detectar trayectorias lógicas de encendido/apagado.

- **Margen de Reserva Sistémico ( $MR_t$ ):** Mide el nivel de estrés de capacidad del parque generador frente a la carga:

$$MR_t = \frac{\sum_{g \in G} P_g^{\max} + \sum_{r \in GR} (P_r^{\max} \cdot f_{r,t}) + \sum_{h \in HE} P_h^{\max}}{D_t} \quad (3.2)$$

Donde  $P^{\max}$  representa la capacidad máxima instalada de unidades térmicas ( $G$ ), renovables ( $GR$ ) e hidráulicas de embalse ( $HE$ ),  $f_{r,t}$  es el factor de planta proyectado para la energía eólica/solar, y  $D_t$  es la demanda. Un margen bajo obliga matemáticamente a encender unidades de punta. Esta variable centraliza el estrés global para que la IA no tenga que inferirlo leyendo todas las demandas nodales por separado.

- **Multiplicadores Duales de Capacidad Operativa ( $\mu_{g,t}^{\max}, \mu_{g,t}^{\min}$ ):** Representan los precios sombra (multiplicadores de Lagrange) extraídos directamente de las restricciones físicas de generación máxima y mínima en la solución del modelo relajado (LP). Se formalizan como:

$$\mu_{g,t}^{\max} \leftarrow \text{Dual de } (P_{g,t} + rs_{g,t} + rpf_{g,t} \leq P_g^{\max} \cdot \hat{u}_{g,t}) \quad (3.3)$$

$$\mu_{g,t}^{\min} \leftarrow \text{Dual de } (P_{g,t} \geq P_g^{\min} \cdot \hat{u}_{g,t}) \quad (3.4)$$

Estas variables actúan como detectores microscópicos de eficiencia y saturación marginal. Un valor de  $\mu_{g,t}^{\max} > 0$  indica que la máquina está operando a su máxima capacidad permitida y el sistema se beneficiaría económicamente

si esta pudiera inyectar aún más energía; esto proporciona a la IA una señal inequívoca de que la unidad es estructuralmente indispensable en esa hora, fortaleciendo drásticamente la probabilidad de predecir un encendido ( $u = 1$ ). Por el contrario, un valor de  $\mu_{g,t}^{Pmin} > 0$  revela que la unidad está arrinconada en su mínimo técnico (su costo marginal supera el precio nodal), operando de manera ineficiente frente al mercado. Esta señal entrena a la IA para identificar unidades económicamente vulnerables que el solucionador estricto (MILP) tenderá a apagar ( $u = 0$ ), a menos que la inercia temporal u otros requerimientos sistémicos obliguen su permanencia.

### 3. Heurísticas de Coordinación Económica Prospectiva

El mayor desafío para una IA sin memoria recurrente explícita es predecir decisiones que dependen de costos intertemporales (como los costos de arranque). Para resolver esto, se construyen heurísticas financieras proyectadas hacia el futuro:

- **Retorno de Inversión Esperado ( $ROI_{g,t}$ ):** Mide la ganancia neta máxima esperada que la máquina podría obtener si se enciende en la hora  $t$  y se mantiene operando hasta un horizonte  $k$ . Primero, se calcula el flujo de caja operativo acumulado ( $\Pi$ ):

$$\Pi_g(t, k) = \sum_{\tau=t}^k [\lambda_{g,\tau} P_g^{max} + \mu_{\tau}^{inercia} H_g P_g^{max} + \mu_{\tau}^{rpf} r p_g^{max} - C_g^{op}] \quad (3.5)$$

Luego, el ROI normalizado se define como:

$$ROI_{g,t} = \frac{\max_{k \geq t} \{\Pi_g(t, k) - C_g^{SU}\}}{C_g^{SU} + \epsilon} \quad (3.6)$$

Donde  $\lambda_{g,\tau}$  es el Precio Marginal Local (LMP) en el nodo de la máquina, y  $\mu_{\tau}^{inercia}$  y  $\mu_{\tau}^{rpf}$  son los precios sombra extraídos de las restricciones de inercia y reserva del modelo LP.  $H_g$  es la constante de inercia,  $r p_g^{max}$  la capacidad de reserva primaria,  $C_g^{op}$  el costo operativo nominal y  $C_g^{SU}$  el costo de arranque. Emula la racionalidad del despacho económico evaluando si los ingresos por inyección de energía y venta de servicios complementarios (inercia y reserva) superan los costos de arranque intertemporales, informando a la IA sobre la rentabilidad real de la máquina [2].

- **Horas de Amortización o Break-Even ( $T_{g,t}^{BE}$ ):** Representa el tiempo mínimo requerido para que la máquina recupere su costo de partida:

$$T_{g,t}^{BE} = \min \{\tau - t \mid \Pi_g(t, \tau) \geq C_g^{SU}\} \quad (3.7)$$

Internaliza indirectamente la restricción de tiempos mínimos de encendido ( $UT_g$ ). Si la recuperación financiera excede el horizonte de planificación temporal, se asigna un valor de penalización (ej. 999.0), enseñándole al modelo a evitar encendidos miopes de corto plazo.

■ **LMP Relativo** ( $LMP_{g,t}^{rel}$ ):

$$LMP_{g,t}^{rel} = \frac{\lambda_{g,t}}{\bar{\lambda}_t + \epsilon} \quad (3.8)$$

Donde  $\bar{\lambda}_t$  es el promedio del costo marginal sistémico.

Cuantifica el nivel de congestión de la red de transmisión en el bus de la máquina. Un valor alto alerta a la IA de que la unidad debe encenderse para aliviar un cuello de botella local, independientemente de si su costo operativo es poco competitivo.

■ **Competitividad Operativa Ponderada** ( $C_g^{Pond}$ ):

$$C_g^{Pond} = \frac{C_g^{rel} \times (N_{gen} + 1)}{N_{gen} + C_t^{agua,rel}} \quad (3.9)$$

Esta fórmula de acoplamiento modela la coordinación hidrotérmica. Al ponderar el costo relativo térmico ( $C_g^{rel}$ ) con el costo de oportunidad del agua ( $C_t^{agua,rel}$ ), la IA comprende que la competitividad térmica es dinámica: en escenarios de año húmedo (agua barata), la prioridad de las máquinas térmicas disminuye drásticamente, mientras que en años secos, su encendido se vuelve imperativo.

El conjunto de datos final es exportado directamente como un archivo estructurado bidimensional plano (.CSV). Este formato elimina la necesidad de realizar transformaciones densas de alta dimensionalidad y es consumido de forma nativa mediante la biblioteca *Pandas* por algoritmos basados en árboles de decisión potenciados por gradiente, como **XGBoost** [12] y **LightGBM** [13], agilizando drásticamente el tiempo de entrenamiento.

**ESTRUCTURA TABULAR PLANA (TABULAR FLATTENING) DE LA BASE DE DATOS**




Figura 3.1: Estructura Tabular plana de la Base de datos.

*Fuente: Elaboración propia.*

### 3.3. Diseño y Entrenamiento del Modelo de Inteligencia Artificial

Con la base de datos tabular estructurada y enriquecida mediante las características propuestas, la siguiente etapa metodológica consiste en el diseño, configuración y entrenamiento del modelo de Inteligencia Artificial. El objetivo de este modelo no es reemplazar el solucionador matemático, sino actuar como un *Surrogate Model* (modelo sustituto) de alta fidelidad que logre predecir las decisiones combinatorias del *Unit Commitment* ( $u_{g,t}$ ) de forma ultrarrápida.

Para comprender la estructura de la Inteligencia Artificial implementada, es fundamental aclarar que no se utiliza una red neuronal profunda, sino una arquitectura basada en **Árboles de Decisión**. En términos sencillos, un árbol de decisión es un algoritmo que crea una serie de reglas lógicas secuenciales (por ejemplo: “¿Es el margen de reserva menor a 1.05? Si es sí, ¿es el ROI mayor al 50 %?”) para clasificar si una máquina debe encenderse o apagarse. Sin embargo, un solo árbol es propenso a cometer errores. Por ello, la arquitectura del modelo se estructura como un **Ensamble** (*Ensemble Learning*), es decir, una asamblea de múltiples árboles que combinan sus conocimientos para emitir una única predicción robusta.

Computacionalmente, esta arquitectura se estructura como una tubería secuencial (*Pipeline*) implementada mediante librerías estandarizadas de alto rendimiento en Python (`scikit-learn`, `xgboost`, `lightgbm`).

#### 3.3.1. Selección del Algoritmo Predictivo

Para abordar la tarea de clasificación binaria (máquina térmica encendida o apagada), la experimentación inicial contempló algoritmos basados en la agregación por *Bootstrap* (*Bagging*), específicamente el **Random Forest convencional**. En este modelo base, se construyen cientos de árboles de forma independiente y, al final, todos “votan” para promediar el resultado.

Sin embargo, este enfoque fue descartado a favor de métodos basados en **Gradient Boosting Decision Trees (GBDT)**, concretamente **XGBoost** [12] y **LightGBM** [13]. A diferencia del bosque aleatorio, el *Boosting* construye los árboles de forma secuencial: cada nuevo árbol tiene como único objetivo corregir el error residual (*log-loss*) del árbol anterior. Esta evolución arquitectónica se justifica por tres ventajas estructurales críticas para el mercado eléctrico:

1. **Gestión de Fronteras de Decisión:** En problemas de optimización física, las fronteras de decisión suelen ser extremadamente nítidas (condicionadas por límites estrictos de potencia o costos de arranque). El promedio del Random Forest tiende a suavizar y distorsionar estas fronteras, aumentando el error en los generadores marginales. El ensamble de *Gradient Boosting*, al minimizar el error paso a paso, permite un ajuste de extrema precisión sobre fronteras complejas y no lineales.
2. **Distribución de Probabilidades para *Triage* Operativo:** El éxito de este método híbrido requiere clasificar decisiones con un nivel de confianza absolu-

to (*Hard Fixing*). El promedio de predicciones del Random Forest agrupa las probabilidades en el centro del intervalo  $[0, 1]$ , haciendo muy inusual obtener valores extremos ( $\geq 0,99$  o  $\leq 0,01$ ). En contraste, al optimizar directamente el gradiente de la función logística, los algoritmos *Boosting* empujan naturalmente las predicciones seguras hacia los márgenes, maximizando la cantidad de variables binarias que pueden fijarse de forma estricta.

3. **Eficiencia Computacional:** La evaluación estocástica de Monte Carlo genera conjuntos de datos masivos. *LightGBM* utiliza agrupamiento de datos por histogramas, logrando entrenar a una velocidad notablemente superior que las implementaciones clásicas de Random Forest o XGBoost estándar, agilizando la iteración del modelo [13].

### 3.3.2. Arquitectura y Estructura Matemática de los Ensamblados

Para evitar el sobreajuste (*overfitting*) de la red a los datos de entrenamiento y asegurar la generalización de la IA en diferentes topologías de red, el ensamble se limita algorítmicamente. Se configura un tamaño máximo de  $M = 200$  estimadores base (árboles), con una profundidad máxima restringida (`max_depth = 8`) y una tasa de aprendizaje conservadora (`learning_rate = 0,1`).

La construcción topológica de estos árboles difiere según la librería implementada:

- **XGBoost (*Level-wise*):** Desarrolla los árboles nivel por nivel de manera simétrica. Esto facilita el control global de la estructura algorítmica y previene la creación de ramas innecesariamente profundas que capten ruido estadístico en lugar de heurísticas reales.
- **LightGBM (*Leaf-wise*):** Expande el árbol seleccionando sistemáticamente la hoja con la mayor pérdida estimada, ignorando la simetría geométrica de las ramas. Esto produce topologías asimétricas de mayor profundidad local, las cuales son excelentes para capturar la compleja interacción jerárquica entre las restricciones del sistema de potencia y las decisiones del óptimo global [13].

### 3.3.3. Calibración de Probabilidades mediante Regresión Isotónica

Como se mencionó anteriormente, los algoritmos de *Boosting* son excelentes clasificadores, pero sufren de un sesgo matemático intrínseco: empujan excesivamente las probabilidades hacia los extremos. Esto implica que si el modelo indica un valor crudo ( $\hat{y}$ ) del 99 % de certeza, la frecuencia real estadística de ese estado en el MILP podría ser significativamente menor.

Dado que el modelo híbrido propuesto utilizará estas probabilidades para forzar variables estrictas dentro del solucionador Gurobi, una falsa confianza resultaría inevitablemente en la infactibilidad de la red eléctrica. Por ello, se incorpora un

paso de postprocesamiento mediante **Regresión Isotónica** [11] como última capa del *Pipeline*. Utilizando validación cruzada de 3 pliegues ( $cv = 3$ ), se ajusta una función monótona no decreciente  $m(\hat{y})$  por tramos de mínimos cuadrados. Esta técnica corrige los sesgos y transforma la predicción cruda en una probabilidad empíricamente calibrada  $\tilde{y}$ :

$$\tilde{y} = m(\hat{y}) \quad (3.10)$$

Este vector de probabilidades rigurosamente calibradas ( $\tilde{y}$ ) se convierte en el insumo de transición definitivo, permitiendo que el algoritmo decida con justificación estadística qué variables fijar y cuáles derivar a la inspección matemática.

**Diagrama de Arquitectura de Predicción y Calibración GBDT**




Figura 3.2: Flujo de procesamiento y arquitectura del modelo predictivo.

*Fuente: Elaboración propia.*

### 3.4. Implementación de la Estrategia de Optimización Híbrida

Una vez entrenado y calibrado el modelo de Inteligencia Artificial (IA), la metodología contempla su integración funcional dentro del flujo de resolución. A diferencia de los modelos sustitutos puros que buscan reemplazar por completo la optimización matemática, esta propuesta implementa un enfoque híbrido. Las predicciones del algoritmo predictivo se utilizan para acotar drásticamente el espacio de búsqueda del solucionador Gurobi, manteniendo la rigurosidad topológica y física del Despacho Económico [15].

#### 3.4.1. Acoplamiento Heurístico mediante Triage de Tres Zonas

El acoplamiento de las predicciones probabilísticas de la IA con el modelo MILP de Gurobi es el paso más crítico de la metodología. En lugar de utilizar una simple umbralización (*thresholding*) binaria en 0.5, la cual podría forzar decisiones erróneas e infactibles debido al estrecho margen de error en sistemas intertemporales, se implementa una estrategia de **Triage en Tres Zonas**:

- **Zona 1: Fijación Dura (*Hard Fixing*):** Aplica a las predicciones donde el modelo tiene certeza casi absoluta. Las variables binarias de la máquina se convierten en constantes obligatorias para el solucionador fijando sus límites matemáticos inferior (*lb*) y superior (*ub*):

$$\text{Si } \tilde{y}_{g,t} \geq 0,99 \rightarrow u_{g,t} = 1 \quad (lb = 1, ub = 1) \quad (3.11)$$

$$\text{Si } \tilde{y}_{g,t} \leq 0,01 \rightarrow u_{g,t} = 0 \quad (lb = 0, ub = 0) \quad (3.12)$$

- **Zona 2: Guía de Búsqueda (*VarHint*):** Aplica a predicciones con un alto nivel de confianza, pero que habitan en la zona marginal de error. En lugar de forzar la variable, se le sugiere el valor a Gurobi como una heurística o “pista” (*VarHintVal*), dándole una alta prioridad (*VarHintPri*). Si la secuencia sugerida viola tiempos mínimos de encendido o rampa, Gurobi tiene la libertad de ignorarla y reparar la solución automáticamente [10]:

$$\text{Si } 0,90 \leq \tilde{y}_{g,t} < 0,99 \rightarrow \text{VarHintVal}_{g,t} = 1, \text{ Pri} = 100 \quad (3.13)$$

$$\text{Si } 0,01 < \tilde{y}_{g,t} \leq 0,10 \rightarrow \text{VarHintVal}_{g,t} = 0, \text{ Pri} = 100 \quad (3.14)$$

La elección de *VarHint* por sobre un inicio en caliente tradicional (*Warm Start*) radica en que, si un *Warm Start* contiene una sola variable infactible, el solucionador desecha la solución completa. Con *VarHint*, Gurobi utiliza las pistas individuales para acelerar sus heurísticas de ramificación locales (ej. RINS), manteniendo una aceleración de cómputo robusta frente a pequeños errores de la IA.

- **Zona 3: Búsqueda Libre (*Free Search*):** Para la zona de incertidumbre ( $0,10 < \tilde{y}_{g,t} < 0,90$ ), Gurobi conserva el control absoluto para optimizar libremente. Esto elimina el riesgo de que predicciones ambiguas en generadores marginales fueren la infactibilidad del modelo o disparen los sobre costos de operación.




Figura 3.3: Flujo de decisión y fijación de variables mediante *Triage* en 3 zonas.

*Fuente: Elaboración propia.*

### 3.4.2. Resolución del Despacho y Post-procesamiento

Una vez que el espacio de variables combinatorias  $u_{g,t}$  ha sido severamente podado mediante el Triage, el árbol de *Branch-and-Bound* se minimiza de forma exponencial.

En esta fase final, el modelo se resuelve a una velocidad excepcionalmente alta. Gurobi calcula la inyección óptima de potencia continua ( $P_{g,t}$ ), el uso de recursos hidroeléctricos turbinados y los flujos por las líneas de transmisión ( $f_{l,t}$ ), de acuerdo a la aproximación DC-OPF. La función objetivo minimiza el costo variable total:

$$\min \sum_{t \in \mathcal{T}} \sum_{g \in \mathcal{G}} [C_g(P_{g,t}) + C_{g,t}^{SU} su_{g,t} + C_{g,t}^{SD} sd_{g,t} + C_{ENS} \cdot ENS_t] \quad (3.15)$$

Este post-procesamiento actúa como el filtro de seguridad definitivo de la metodología. Si la red cometiese un error crítico no interceptado por las zonas del Triage, el solucionador activará la variable de holgura de Energía No Suministrada ( $ENS_t > 0$ ), penalizando fuertemente la función objetivo mediante el costo de falla ( $C_{ENS}$ ). Finalmente, este paso continuo de cierre asegura la correcta extracción teórica de las Variables Duales asociadas al balance de energía, habilitando el cálculo exacto de los Precios Marginales Locales (LMP) bajo la nueva política de encendidos propuesta por la inteligencia artificial.

### 3.5. Protocolo de Evaluación de Resultados

La validación de la estrategia de optimización híbrida propuesta no puede recaer exclusivamente en métricas tradicionales de aprendizaje automático. Al tratarse de un problema crítico para la seguridad y economía de un sistema de potencia, el desempeño del modelo sustituto debe evaluarse de forma integral a través de dos frentes: la precisión estadística de sus predicciones binarias y la aceleración computacional conseguida.

#### 3.5.1. Métricas de Desempeño Estadístico de la IA

La primera fase del protocolo evalúa la capacidad intrínseca del ensamble de árboles de decisión (LightGBM/XGBoost) para clasificar correctamente el estado operativo de las unidades térmicas. Para ello, las predicciones probabilísticas calibradas y umbralizadas se contrastan directamente contra las etiquetas reales obtenidas del modelo MILP exacto de Gurobi.

El análisis se estructura en torno a la matriz de confusión. Dado que en los sistemas de potencia existe una profunda asimetría en el impacto de los errores (donde un Falso Negativo puede causar Energía No Suministrada y un Falso Positivo solo un sobre costo transitorio), el rendimiento estadístico se evalúa mediante la exactitud (*Accuracy*), la Precisión, Recall y F1-score (2.13).

#### 3.5.2. Cuantificación del Desempeño Técnico-Económico y Computacional

La segunda fase del protocolo evalúa el comportamiento del sistema eléctrico cuando las decisiones guiadas por la IA son inyectadas en el optimizador. El éxito metodológico del acoplamiento híbrido se determina mediante dos indicadores:

1. **Aceleración Computacional (*Speedup*):** Se registra el tiempo de reloj en el que Gurobi resuelve el modelo MILP exacto ( $T_{\text{MILP Base}}$ ) y se compara contra el tiempo total acumulado por la estrategia propuesta (2.14). Para viabilizar estudios estocásticos masivos, se busca que  $\text{Speedup} \gg 1$ .
2. **Desviación del Costo Operativo y Factibilidad (*Costo Gap*):** Se mide el sobre costo porcentual provocado por las desviaciones del Triage respecto al óptimo global (2.15). El objetivo es mantener esta brecha por debajo del 1 %. Es fundamental que la variable de holgura de Energía No Suministrada ( $\text{ENS}_t$ ) se mantenga en cero. Cualquier  $\text{ENS} > 0$  es penalizada mediante el costo de falla ( $C_{\text{ENS}}$ ), arruinando el desempeño económico y alertando de una infactibilidad física provocada por un falso negativo crítico de la IA.

#### 3.5.3. Análisis de Robustez mediante Sensibilidades

Para garantizar que el modelo de Inteligencia Artificial mantenga su precisión predictiva y no sufra de sobreajuste ante cambios en las condiciones del sistema de

potencia, el protocolo de evaluación incorpora cinco análisis de sensibilidad en las simulaciones de prueba:

1. **Sensibilidad a la Penetración de Energías Renovables (ERNc):** Evalúa el comportamiento del clasificador bajo diferentes niveles de capacidad instalada solar y eólica. El aumento de ERNC estresa los márgenes de reserva y desplaza la generación sincrónica, reduciendo la inercia natural del sistema y forzando a la IA a predecir bajo perfiles de red altamente volátiles.
2. **Sensibilidad a Contingencias en Líneas de Transmisión:** Introduce fallas aleatorias en líneas clave de la red (reducciones forzadas de capacidad térmica). Esto altera los flujos de potencia y genera congestión con variaciones bruscas en los LMPs, permitiendo verificar si la característica `lmp_relativo` le entrega a la IA la capacidad de generalizar adecuadamente ante estados de emergencia o anomalías de red.
3. **Sensibilidad a la Escala del Horizonte Temporal (*Chunk Size*):** Evalúa el comportamiento y robustez del modelo cuando la ventana temporal de resolución del horizonte rodante se expande desde el bloque base diario (24 horas) hacia bloques de simulación acoplados de una semana o un mes completo. Esta sensibilidad es crucial para verificar si la IA puede sostener su precisión clasificatoria a medida que crece exponencialmente la dimensionalidad del problema y se complejizan las restricciones de almacenamiento hídrico interdiario.

# Capítulo 4

## Resultados

En el presente capítulo se detallan los resultados obtenidos al aplicar la metodología propuesta sobre el sistema de estudio. El objetivo es demostrar empíricamente la efectividad del enfoque híbrido, validando primero la capacidad estadística del modelo de aprendizaje automático, para luego evaluar el desempeño técnico, económico y computacional del acoplamiento con el solucionador matemático bajo múltiples escenarios estocásticos.

### 4.1. Evaluación Estadística de Modelos Clasificadores (ML)

Antes de acoplar la Inteligencia Artificial con el optimizador Gurobi, es imperativo validar su capacidad puramente predictiva como clasificador del estado de encendido de las unidades térmicas ( $u_{g,t} \in \{0, 1\}$ ). En esta sección se contextualiza el rendimiento de la red a través de la matriz de confusión y las métricas detalladas en la sección anterior.

#### 4.1.1. Comparación de Modelos: Random Forest vs. XGBoost vs. LightGBM

Se comparan algoritmos basados en ensambles de árboles de decisión (Random Forest, XGBoost y LightGBM) para justificar la elección de la arquitectura final. La Tabla 4.1 resume el desempeño de cada modelo sobre un conjunto de prueba independiente.

Cuadro 4.1: Comparación de desempeño estadístico y tiempo de entrenamiento entre modelos clasificadores.

| Modelo        | Accuracy | Precision | Recall  | F1-Score | Tiempo (s) |
|---------------|----------|-----------|---------|----------|------------|
| Random Forest | 88.76 %  | 91.54 %   | 91.51 % | 91.53 %  | 124.90     |
| XGBoost       | 92.79 %  | 93.75 %   | 95.49 % | 94.61 %  | 8.24       |
| LightGBM      | 92.23 %  | 93.35 %   | 95.06 % | 94.20 %  | 5.41       |

Los resultados presentados en la Tabla 4.1 justifican la preselección de las arquitecturas de potenciación del gradiente (XGBoost y LightGBM) por sobre los bosques aleatorios tradicionales (Random Forest). En términos de capacidad predictiva, XGBoost alcanza el mejor desempeño general con un Accuracy del 92,79 % y un F1-Score del 94,61 %, seguido muy de cerca por LightGBM con 92,23 % y 94,20 % respectivamente. Ambos modelos superan significativamente a Random Forest, el cual se sitúa por debajo del 89 % de exactitud.

Sin embargo, la diferencia más determinante radica en la eficiencia computacional de entrenamiento: mientras que Random Forest requiere 124,90 s para converger, XGBoost se entrena en 8,24 s y LightGBM en apenas 5,41 s (siendo aproximadamente 23 veces más rápido que Random Forest). Dada la mínima brecha de rendimiento entre los dos algoritmos de boosting, la sobresaliente velocidad y menor demanda de memoria de LightGBM lo posicionan como la alternativa óptima para la arquitectura final del acoplamiento híbrido, facilitando potenciales reentrenamientos en línea ante la llegada de nuevos datos históricos del sistema eléctrico

## 4.2. Análisis de Importancia de Variables (Feature Engineering)

Para dotar al modelo de explicabilidad e interpretar la lógica física detrás de sus decisiones, se analiza la contribución individual de las características. La Figura 4.1 expone las variables más determinantes del clasificador.




Figura 4.1: Importancia relativa de las variables de entrada (*Feature Importance*) en las decisiones de encendido de la IA.

El análisis de importancia de variables del modelo clasificador (representado en la Figura 4.1 de importancia de variables) revela que la decisión de fijación de variables

del Unit Commitment está fuertemente determinada por el estado de las variables continuas en la relajación lineal (LP). Específicamente, el estado relajado de la hora previa (`u_lp_t_prev`) domina el comportamiento predictivo con un 63,98 % de la importancia, seguido por el estado de la hora actual (`u_lp_t_act`) con un 11,38 % y el de la hora siguiente (`u_lp_t_next`) con un 6,02 %. Esto es consistente con la física del problema de Unit Commitment, donde el encendido de una máquina está fuertemente acoplado a la continuidad temporal y a las restricciones de tiempos mínimos de operación y detención.

Por otro lado, variables económicas y de frontera física como la variable `costo_operativo_ponderado` (4,38 %) y los multiplicadores de Lagrange asociados a los límites de capacidad (`mu_pmin_relativo` con 3,89 % y `mu_pmax_relativo` con 3,30 %) aportan el contexto necesario para que la IA identifique cuándo una unidad opera al límite de sus restricciones de potencia o si su costo operativo relativo la desplaza de la base de despacho. El resto de las métricas financieras (como el ROI esperado y el tiempo de recuperación de costos de partida) actúan como indicadores secundarios que refinan la probabilidad de encendido ante variaciones de precios de mercado.

### 4.3. Calibración de Umbrales de Fijación

Para justificar empíricamente la configuración del algoritmo de *Triage* y la selección de los umbrales de decisión, se analizó la distribución de los errores predictivos de los modelos (LightGBM y XGBoost) a lo largo de todo el espectro de probabilidades.

El objetivo de este análisis es evaluar la calibración real de la Inteligencia Artificial, identificando en qué rangos de probabilidad el modelo presenta una certeza absoluta y en cuáles se concentra la incertidumbre. Esto resulta fundamental para definir zonas de acción seguras que maximicen la aceleración computacional sin poner en riesgo la factibilidad del sistema eléctrico.




Figura 4.2: Distribución de errores, total de predicciones y zonas de *Triage* para Calibración de Umbrales (XGBoost).




Figura 4.3: Distribución de errores, total de predicciones y zonas de *Triage* para Calibración de Umbrales (LightGBM).

Las Figuras 4.2 y 4.3 evidencian un comportamiento altamente polarizado en las predicciones, característico de un clasificador bien calibrado. La inmensa mayoría del volumen de decisiones se agrupa en los extremos del espectro (probabilidades  $\leq 0,01$  y  $\geq 0,99$ ), zonas donde la tasa de error es matemáticamente marginal (inferior al 0,4% para ambos modelos). A medida que las probabilidades se alejan de estos extremos, la tasa de error crece progresivamente hasta alcanzar un pico crítico

cercano al 40 % en el rango central (0,3 a 0,7). Esta distribución justifica de manera concluyente la arquitectura del *Triage* propuesto: aplicar una fijación estricta (zona verde) únicamente en los extremos de altísima fiabilidad, utilizar sugerencias o *VarHints* (zona amarilla) en las áreas de transición donde el error es moderado (entre 1 % y 7 %), y delegar la decisión absoluta al *solver* matemático (zona roja) en el centro de la distribución, donde la alta estocasticidad del modelo volvería insegura cualquier decisión pre-fijada.

## 4.4. Caso de Referencia y Análisis del Impacto de la Calibración

En esta sección se evalúa el desempeño del sistema híbrido completo durante una semana operativa estándar (168 horas), resolviendo iterativamente bloques de 24 horas. Este análisis permite contrastar el costo computacional frente al *solver* matemático tradicional y evidenciar la importancia de utilizar probabilidades calibradas.

### 4.4.1. Resultados de la Semana Base (Modelo Híbrido Calibrado)

Las Tablas A.3, A.2, A.6 y A.7 y las Figuras 4.4 y 4.5 detallan la comparación del desempeño de Gurobi Base y del método de redondeo de variables relajadas frente a la estrategia híbrida propuesta utilizando el modelo predictivo óptimo.

Primeramente, se muestran los resultados de la aplicación de redondeo simple (y con umbrales) en comparación con Gurobi Base y la estrategia híbrida con IA, en la Tabla 4.2.

Cuadro 4.2: Resumen de factibilidad física y rendimiento computacional promedio (Modelos Híbridos vs. Heurísticas de Redondeo) durante la semana base.

| Método          | Factibilidad  | Ahorro T. Prom. (%) | Error Prom. (%) |
|-----------------|---------------|---------------------|-----------------|
| Gurobi Base     | 100.0 % (7/7) | 0.00                | 0.0000          |
| Híbrido LGB     | 100.0 % (7/7) | 21.82               | 0.0093          |
| Híbrido XGB     | 100.0 % (7/7) | 28.98               | 0.0188          |
| Round Simple    | 85.7 % (6/7)  | 55.72               | 8150.8696       |
| Round Threshold | 85.7 % (6/7)  | 41.12               | 286.7620        |

La comparación del acoplamiento híbrido frente a las heurísticas tradicionales de redondeo de la relajación lineal evidencia la necesidad física y matemática de incorporar modelos de ML para la aceleración del Unit Commitment. Mientras que los modelos híbridos asistidos por LightGBM y XGBoost garantizan un 100 % de factibilidad en el horizonte operativo, las heurísticas basadas en redondeo simple y redondeo por umbrales fijos desencadenan escenarios de infactibilidad irresolubles en el Día 2 (ver Tabla A.4 y A.5). Este comportamiento se atribuye a la carencia de

visión intertemporal de las reglas heurísticas directas, las cuales omiten restricciones dinámicas críticas de acoplamiento temporal como las rampas de generación y los tiempos mínimos de operación.

Asimismo, la calidad económica de las soluciones obtenidas mediante redondeo directo resulta impracticable. En los días en que estas heurísticas logran factibilidad matemática, lo hacen vulnerando la seguridad de reserva del sistema, lo que obliga al solver a activar variables de holgura penalizadas de frecuencia e inercia que disparan el costo del sistema a valores absurdos, registrando desviaciones promedio de costo de 8150.87 % para el redondeo simple y de 286.76 % para el redondeo por umbrales. En contraste, el acoplamiento asistido por IA actúa bajo variables de contexto global (margen de reserva y ROI esperado) que resguardan la seguridad de la red. Lo que permita a los modelos de IA mantener una desviación de costo operacional prácticamente nula, consolidando al ML como una herramienta habilitante para resolver el problema de forma acelerada y segura.




Figura 4.4: Evolución del tiempo de cómputo y desviación de costo a lo largo de una semana para horizonte diario.




Figura 4.5: Evolución de la cantidad de variables fijadas y el índice de coincidencia a lo largo de una semana para horizonte diario.

El comportamiento diario de la simulación en horizonte rodante (Figuras 4.4 y 4.5) demuestra la robustez y consistencia del acoplamiento híbrido asistido por IA. Se observa que ambos clasificadores (XGBoost y LightGBM) mantienen un alto índice de coincidencia respecto al óptimo real, superando el 90 % en casi todos los días operativos (alcanzando hasta un 95.8 % en el Día 3). Es notable la naturaleza adaptativa del Triage: en días de alta incertidumbre o comportamiento atípico como el Día 6, el índice de coincidencia predictiva decae a cerca del 75 %, pero el algoritmo actúa de forma conservadora reduciendo drásticamente la cantidad de variables que fija a valores cercanos a 40 (frente a las más de 120 variables fijadas en días de mayor certidumbre como el Día 1 o 5). Esta precaución resguarda la factibilidad del sistema ante posibles errores de predicción.

Esta prudencia en la fijación se traduce directamente en los resultados de la Figura 4.4. A lo largo de la semana, se logra una aceleración consistente en la resolución del Unit Commitment, con factores de speedup entre 1.0x y 1.87x (alcanzando el máximo el Día 5 con XGBoost). Esta mejora en los tiempos de cómputo se consigue sin penalizar la calidad de las soluciones, registrando desviaciones de costo operacional que fluctúan en un rango estrecho entre -0.01 % y +0.09 %. La presencia de desviaciones ligeramente negativas (como la observada el Día 4 con el modelo XGBoost) es un fenómeno característico en esquemas de horizonte rodante, donde variaciones marginales en los estados de partida de las unidades térmicas de días previos pueden provocar despachos acumulados sutilmente más económicos sin comprometer las restricciones físicas de la red.

#### 4.4.2. Impacto de la Calibración de Probabilidades

Para evidenciar la solidez del módulo de calibración, la Tabla 4.3 contrapone el comportamiento del optimizador cuando el *Triage* es alimentado con probabilidades crudas respecto a cuando opera con probabilidades procesadas mediante Regresión Isotónica.

Cuadro 4.3: Impacto del uso de probabilidades sin calibrar en la factibilidad y velocidad del acoplamiento híbrido.

| Métrica Evaluada       | Calibrado  | Sin Calibrar | Impacto Físico                                  |
|------------------------|------------|--------------|-------------------------------------------------|
| Tasa de FP             | 0.1324 %   | 0.0309 %     | Previene fijación errónea de térmicas apagadas  |
| Inactividad Forzada    | 0.2011 %   | 0.3860 %     | Reduce apagado forzado de unidades críticas     |
| Tasa de Infactibilidad | 0.0 %      | 0.0 %        | Evita restricciones eléctricas irresolubles     |
| Tiempos Totales        | 101.9354 s | 122.0552 s   | Mantiene aceleración sin penalizar convergencia |
| Desviación Costo       | -0.0004 %  | -0.0037 %    | Garantiza optimalidad económica del UC          |

Se entrenaron dos modelos LightGBM idénticos utilizando los mismos hiperparámetros del entrenamiento principal: uno calibrado y otro que opera con probabilidades crudas (sin calibrar). Ambos modelos fueron evaluados estadísticamente sobre el conjunto de test y sometidos a una simulación de horizonte rodante de 5 días. Los resultados de la Tabla 4.3 revelan que, si bien el modelo sin calibrar reporta una tasa de falsos positivos marginalmente menor (0,0309 % vs. 0,1324 %), esto ocurre a expensas de duplicar la tasa de inactividad forzada (falsos negativos), la cual asciende de 0,2011 % a 0,3860 %. Físicamente, esta omisión obliga al optimizador a mantener apagadas unidades térmicas críticas que el sistema requiere encendidas para abastecer la demanda, dificultando la convergencia del solver Gurobi.

En consecuencia, el modelo sin calibrar requiere un tiempo de cómputo acumulado sustancialmente mayor (122,06 s frente a los 101,94 s del modelo calibrado). Esto demuestra que la calibración de probabilidades es un módulo crítico en el acoplamiento híbrido, ya que equilibra de forma óptima los errores de triage, mitigando el apagado forzado y maximizando la velocidad de resolución sin comprometer la optimalidad económica del despacho (con una desviación de costo prácticamente nula de  $-0,0004\%$ ).

## 4.5. Análisis de Sensibilidades Avanzadas (Pruebas de Robustez)

A continuación, se demuestra la resiliencia del modelo propuesto mediante cinco pruebas de sensibilidad. Estas validan que el acoplamiento heurístico mantiene su eficacia y factibilidad ante variaciones críticas en el diseño y en la operación del sistema de potencia.

### 4.5.1. Sensibilidad a la Escala del Sistema

Se analiza el comportamiento computacional de la estrategia híbrida al incrementar geométricamente el número de unidades generadoras y los componentes de la red, evaluando la escalabilidad de la metodología. Los resultados se muestran en las Tablas A.8, A.9, A.10 y A.11 y las Figuras 4.6, 4.7, 4.8 y 4.9.




Figura 4.6: Evolución del tiempo de cómputo y desviación de costo para un escalamiento x2 (Base vs. Híbrido).




Figura 4.7: Evolución de la cantidad de variables fijadas y el índice de coincidencia para un escalamiento x2 (Base vs. Híbrido).




Figura 4.8: Evolución del tiempo de cómputo y desviación de costo para un escalamiento x3 (Base vs. Híbrido).




Figura 4.9: Evolución de la cantidad de variables fijadas y el índice de coincidencia para un escalamiento x3 (Base vs. Híbrido).

El análisis de sensibilidad a la escala evalúa el desempeño de los modelos híbridos de aceleración (LightGBM y XGBoost) al incrementar proporcionalmente la complejidad del sistema eléctrico mediante el parámetro `FACTOR_ESCALA`. Este proceso clona las unidades de generación originales de la red (pasando de las 10 iniciales a 20 y 30 generadores térmicos), a la vez que escala proporcionalmente la demanda del sistema y la capacidad de las líneas de transmisión en simulaciones de horizonte rodante durante un ciclo de 7 días. El objetivo principal es medir la capacidad de los modelos de IA para mantener un volumen de fijación de variables de decisión ( $u_{g,t}$ ) seguro y efectivo a medida que la dimensión del vector de variables binarias del problema de Unit Commitment aumenta de 240 (para 20 unidades) a 720 (para 30 unidades).

Los resultados muestran que para un sistema de 20 generadores el esquema híbrido funciona de manera consistente, logrando reducciones de tiempo promedio de entre el 46 % y 50 % con un elevado porcentaje de variables fijadas bajo umbrales de alta confianza y desviaciones en el costo operativo despreciables ( $\leq 0,06$  %). Sin embargo, al escalar a 30 generadores, los resultados de aceleración pierden consistencia: el ahorro promedio de LightGBM cae a valores negativos (-2.0 %) y el de XGBoost se reduce al 18.4 %. Este deterioro se debe a que la mayor complejidad física del sistema y las nuevas dinámicas de congestión disminuyen la confianza de los modelos de IA, reduciendo drásticamente la cantidad de variables fijadas (cayendo a solo 8 variables en días complejos), lo cual anula el efecto de la aceleración y genera un retraso neto (overhead) debido al tiempo de evaluación de los modelos y las heurísticas adicionales impuestas en el árbol de búsqueda de Gurobi.

4.5.2. Sensibilidad a la Penetración de Energías Renovables (ERNC)

Esta subsección documenta la capacidad del modelo para lidiar con el aumento de la variabilidad estocástica inducida por diferentes niveles de penetración de energía eólica y solar (ej. 25 %, 30 %, 150 %). Los resultados se exponen en las Tablas A.13, A.12, A.15, A.14, A.17 y A.16 y las Figuras 4.10 y 4.11.




Figura 4.10: Impacto de la Penetración ERNC en el Speedup y Riesgo Económico.




Figura 4.11: Impacto de la Penetración ERNC en el Deesempeño Predictivo.

La semana simulada con un 25 % de inyección renovable representa el escenario de mayor coste operativo total (aproximadamente \$3,327,437 USD) debido a la alta dependencia de la generación térmica para cubrir la demanda. En cuanto al rendimiento de la aceleración, este caso presenta pérdidas de tiempo netas (ahorros negativos de entre -10 % y -46 % en casi todos los días). Esto ocurre porque el problema del Unit Commitment en este nivel de baja inyección es muy sencillo y estable para Gurobi Base, resolviéndose en promedio en apenas 13 segundos. Al ser tan rápido el solver clásico, el tiempo adicional requerido en Python para la extracción de características y predicción de la IA supera las pequeñas ganancias de tiempo en el solver, resultando en pérdidas de tiempo netas (overhead) a pesar de lograr una buena coincidencia física y cero errores en el costo operativo.

En la semana con un 50 % de inyección renovable, el coste total de operación disminuye a unos \$2,992,422 USD (un ahorro neto de más de \$335,000 USD respecto al caso del 25 %) conforme la energía limpia desplaza a los combustibles térmicos. El comportamiento de la aceleración aquí es mixto: en los días donde el modelo es sencillo se observan ligeras pérdidas por overhead, pero en los días donde Gurobi clásico empieza a tardar más (como el Día 5, que tomó 44.2 segundos), los modelos híbridos demuestran su verdadero valor logrando aceleraciones del 62.2 % (LGB) y 71.6 % (XGB). El volumen de variables fijadas fue el más alto de los tres escenarios (promediando más de 100 variables fijadas por día), lo que indica que en este nivel de penetración los modelos mantienen una alta confianza de predicción sin comprometer la precisión económica.

Para la semana con una inyección renovable extrema del 150 %, el coste de operación cae a su mínimo histórico (\$2,535,763 USD) gracias a la abundante generación renovable a coste marginal cero. Sin embargo, la alta penetración de ERNC introduce una gran volatilidad y variabilidad en el despacho, aumentando los tiempos base de Gurobi (que llegó a tardar 75.8 segundos en el Día 1). Frente a esta incertidumbre, la confianza de la IA disminuye sensiblemente, lo que reduce el triage a un promedio de solo 30 variables fijadas por día. Esto limita las tasas de aceleración (con ahorros positivos moderados del 6 % al 25 % e incluso pérdidas de tiempo de hasta -40 % en el Día 5) e introduce pequeños errores económicos en el costo del Híbrido (de hasta un 0.35 % en el Día 5), ya que las pocas variables fijadas forzaron un redespacho ligeramente subóptimo ante las fluctuaciones extremas de la red.

La comparación entre los tres escenarios revela una clara relación de compromiso (trade-off) entre el costo de operación y la complejidad de la aceleración híbrida. A medida que la penetración renovable sube del 25 % al 150 %, el coste operativo del sistema disminuye un 23.8 %, pero la predictibilidad de la operación térmica empeora notablemente. En el extremo de 25 % el sistema es tan estable y fácil de resolver que la IA no aporta valor y genera retraso por overhead. En el escenario intermedio de 50 % se alcanza el punto óptimo de aceleración, donde el sistema sigue siendo lo suficientemente predecible para que la IA fije muchas variables con alta confianza y acelere significativamente los días difíciles. Finalmente, en el escenario extremo de 150 % la altísima volatilidad de la inyección limpia reduce la confianza de los modelos de IA, limitando la aceleración y provocando por primera vez pequeñas desviaciones de costo ante la rigidez de las decisiones pre-fijadas.

### 4.5.3. Sensibilidad al Tamaño del Bloque de Optimización (Chunk Size)

Se explora la robustez del modelo al expandir el horizonte rodante de resolución desde la unidad básica (24 horas) hacia ciclos completos semanales (168 horas) e incluso mensuales (720 horas), tal como lo exponen las Tablas 4.4 y 4.5 y las Figuras 4.12, 4.13, 4.14 y 4.15.




Figura 4.12: Evolución del tiempo de cómputo y desviación de costo a lo largo de un mes para horizonte semanal.




Figura 4.13: Evolución de la cantidad de variables fijadas y el índice de coincidencia a lo largo de un mes para horizonte semanal.

Los gráficos anteriores demuestran que, a pesar de la alta variabilidad en la complejidad de resolución de Gurobi Base entre semanas (oscilando de 1,927 s en la semana 1 a un máximo de 5,929 s en la semana 2), el esquema híbrido acelera el cálculo de forma robusta en todos los periodos analizados. En la semana 1, los ahorros de tiempo se sitúan en 52.0 % para LGB y 43.8 % para XGB, con coincidencias predictivas con el óptimo de 93.8 % y 89.7 % respectivamente. No obstante, en las semanas de mayor complejidad (semanas 2 a 4), la aceleración de ambos métodos se intensifica significativamente: XGBoost logra reducciones de tiempo espectaculares de entre 89.6 % y 94.5 % al fijar de forma segura un alto volumen de variables (entre 872 y 1,116 de las 1,680 totales) con coincidencias superiores al 94.9 %, limitando la desviación de costo a un rango despreciable (menor al 0.15 %). Por su parte, LightGBM presenta un comportamiento ligeramente más conservador en variables fijadas (entre 715 y 924) pero con una coincidencia superior (alcanzando un máximo de 98.5 % en la semana 3), lo que le permite acelerar la resolución de forma estable sobre el 56 % en los bloques difíciles con errores económicos mínimos ( $\leq 0,37\%$ ).




Figura 4.14: Evolución del tiempo de cómputo y desviación de costo a lo largo del horizonte mensual.




Figura 4.15: Evolución de la cantidad de variables fijadas y el índice de coincidencia a lo largo del horizonte mensual.

Los gráficos anteriores evidencian cómo el incremento del horizonte impacta severamente al solver Gurobi clásico. Mientras que resolvió el bloque 1 en 12,258 s, alcanzó su límite de tiempo máximo de 6 horas (21,600 s) en los bloques 2 y 3 sin poder converger al óptimo (quedando con gaps residuales de 1.57 % y 1.05 % respectivamente, resultados los cuales se expresan en las Tablas A.24 y A.24). En cambio, los esquemas híbridos muestran una aceleración excepcional y homogénea en los tres periodos analizados, resolviendo todos los bloques en un rango de entre 1.0 y 1.2 horas (ahorros de tiempo estables de entre 65.1 % y 83.1 %). Esta consistencia radica en un volumen de fijación sumamente estable de aproximadamente el 20 % del total de las variables binarias (entre 1,385 y 1,464 variables) y coincidencias predictivas muy altas, que van desde el 92.1 % al 95.8 % en LightGBM y del 93.6 % al 96.1 % en XGBoost. Además, debido a que el solver clásico se vio truncado por tiempo en los bloques 2 y 3, los métodos híbridos lograron desviaciones de costo negativas (hasta -0.13 %), lo que demuestra que las decisiones pre-fijadas por la IA no solo aceleraron drásticamente el cálculo, sino que guiaron al solver hacia despachos de generación económicamente superiores en menos del 20 % del tiempo de búsqueda de la base.

Cuadro 4.4: Desempeño del enfoque híbrido XGBoost frente a expansiones en la escala del horizonte temporal de resolución (mejores soluciones encontradas).

| Horizonte (Chunk Size) | T. Base | T. Híbrido | Speedup | $\Delta$ Costo (%) |
|------------------------|---------|------------|---------|--------------------|
| Diario (24h)           | 49.25   | 18.76      | 2.63x   | -0.0007            |
| Semanal (168h)         | 2267.04 | 236.79     | 9.57x   | 0.0684             |
| Mensual (720h)         | 21600   | 4003.45    | 5.40x   | -0.0030            |

Cuadro 4.5: Desempeño del enfoque híbrido LightGBM frente a expansiones en la escala del horizonte temporal de resolución (mejores soluciones encontradas).

| Horizonte (Chunk Size) | T. Base | T. Híbrido | Speedup | $\Delta$ Costo (%) |
|------------------------|---------|------------|---------|--------------------|
| Diario (24h)           | 49.25   | 19.55      | 2.52x   | -0.0007            |
| Semanal (168h)         | 2267.04 | 262.87     | 8.62x   | 0.2068             |
| Mensual (720h)         | 21600   | 3640.52    | 5.93x   | -0.0684            |

Los resultados revelan que la aceleración alcanza su punto de rendimiento óptimo en la resolución Semanal (168h), registrando los mayores factores de speedup con 9.57x para XGBoost y 8.62x para LightGBM. En la escala Diaria (24h), aunque el problema es sencillo, la aceleración se ve limitada a aproximadamente 2.5x debido a que el tiempo de resolución base es muy corto (49 s) y el overhead de procesamiento y evaluación en Python tiene un peso proporcional mayor. En el extremo Mensual (720h), la alta complejidad combinatoria desborda al solver clásico obligándolo a detenerse por límite de tiempo (21,600 s) con brechas sin converger, mientras que los enfoques híbridos logran resolver el problema en aproximadamente 1 hora, registrando speedups de 5.40x (XGB) y 5.93x (LGB); cabe destacar que en este escenario mensual los métodos híbridos obtienen desviaciones de costo negativas (hasta -0.068 % en LGB), indicando que encontraron soluciones económicamente superiores a las del base interrumpido. En la comparación entre algoritmos, XGBoost muestra una leve ventaja en velocidad y precisión económica en la escala semanal (236.79 s de resolución y +0.068 % de error frente a los 262.87 s y +0.207 % de LightGBM), mientras que LightGBM resulta ligeramente más rápido y eficiente en el bloque mensual.

#### 4.5.4. Sensibilidad a Congestionamientos

Finalmente, se simulan reducciones severas en la capacidad de transferencia térmica de las líneas principales de transmisión para comprobar si el modelo es capaz de reaccionar ante cuellos de botella inesperados.

Cuadro 4.6: Desempeño estadístico predictivo y validación de factibilidad (Energía No Suministrada) para el modelo XGBoost ante contingencias.

| Día             | Escenario de Red | Var. Fijadas | Coincidencia (%) | ENS Híbrido (MW) |
|-----------------|------------------|--------------|------------------|------------------|
| 1               | Normal           | 131          | 92.5 %           | 0.0              |
| 2               | 1 Línea al 20 %  | 49           | 95.4 %           | 0.0              |
| 3               | 2 Líneas al 20 % | 50           | 89.6 %           | 0.0              |
| 4               | 3 Líneas al 20 % | 48           | 92.1 %           | 0.0              |
| 5               | 4 Líneas al 20 % | 48           | 92.5 %           | 0.0              |
| 6               | 5 Líneas al 20 % | 93           | 91.7 %           | 42.9             |
| 7               | 5 Líneas al 10 % | 51           | 63.3 %           | 461.6            |
| <b>Promedio</b> | -                | <b>67</b>    | <b>88.16 %</b>   | -                |

Cuadro 4.7: Desempeño estadístico predictivo y validación de factibilidad (Energía No Suministrada) para el modelo LightGBM ante contingencias.

| Día      | Escenario de Red | Var. Fijadas | Coincidencia (%) | ENS Híbrido (MW) |
|----------|------------------|--------------|------------------|------------------|
| 1        | Normal           | 115          | 93.8 %           | 0.0              |
| 2        | 1 Línea al 20 %  | 49           | 96.7 %           | 0.0              |
| 3        | 2 Líneas al 20 % | 49           | 90.0 %           | 0.0              |
| 4        | 3 Líneas al 20 % | 49           | 91.2 %           | 0.0              |
| 5        | 4 Líneas al 20 % | 49           | 92.5 %           | 0.0              |
| 6        | 5 Líneas al 20 % | 73           | 90.8 %           | 42.9             |
| 7        | 5 Líneas al 10 % | 52           | 62.5 %           | 461.6            |
| Promedio | -                | 62           | 88.21 %          | -                |




Figura 4.16: Evolución del tiempo de cómputo y desviación de costo a lo largo de una semana sensibilizando la cantidad de líneas congestionadas.




Figura 4.17: Evolución de la cantidad de variables fijadas y el índice de coincidencia a lo largo de una semana sensibilizando la cantidad de líneas congestionadas.

Para evaluar la resiliencia y el comportamiento del *Triage* de IA frente a estados operativos extremos, se sometió al sistema a un análisis de sensibilidad de contingencias progresivas (N-k) sobre un horizonte rodante de 7 días. Como se expone en las Tablas A.25, A.26, 4.6, 4.7 y en las Figuras 4.16, 4.17, durante los primeros cinco días de simulación con congestión moderada, los modelos híbridos mantienen una coincidencia sobresaliente con el óptimo global ( $> 90\%$ ), logrando reducciones del tiempo de cómputo de hasta un 52%. No obstante, al alcanzar contingencias múltiples severas (Días 6 y 7, con 5 líneas críticas limitadas al 20% y 10% de su capacidad, respectivamente), el sistema experimenta un estrangulamiento físico severo que impide el flujo de potencia hacia las barras de demanda. Esto fuerza al solver a incurrir en Energía No Suministrada (ENS), registrando déficits de 42,9 MW y 461,6 MW respectivamente, lo cual eleva los costos operativos en dos órdenes de magnitud debido a las penalizaciones de falla. Frente a este escenario atípico y altamente estresado, el índice de coincidencia de la IA cae al 62,5%; no obstante, el algoritmo de triage responde de manera robusta reduciendo la cantidad de variables binarias fijadas. Esta flexibilidad permite al optimizador resolver el despacho óptimo con asistencia parcial, logrando un ahorro de tiempo del 29,9% en el peor escenario y alcanzando con precisión el mismo volumen de ENS y costo operacional que el solver Gurobi clásico (con un error marginal del 0,06%).

# Capítulo 5

## Conclusiones

El presente trabajo de memoria ha permitido explorar cómo las técnicas de Inteligencia Artificial pueden ayudar a resolver uno de los problemas más complejos en la operación de sistemas eléctricos: el *Unit Commitment* (UC). El objetivo principal de desarrollar y validar una estrategia híbrida, que combina la optimización matemática clásica con modelos de aprendizaje automático, se ha cumplido satisfactoriamente. Se ha demostrado que es posible reducir considerablemente los tiempos de resolución del problema sin sacrificar la eficiencia económica del despacho ni vulnerar las restricciones técnicas fundamentales que operan en nuestro Sistema Eléctrico Nacional (SEN).

Para lograr este resultado, el trabajo siguió una ruta metodológica clara. Primero, se analizaron en detalle las restricciones operacionales —como tiempos mínimos de encendido, rampas y reservas— que definen el comportamiento de las centrales. Esto permitió construir una base de datos representativa, la cual sirvió de entrenamiento para los modelos de IA. Tras diseñar y validar una arquitectura capaz de predecir el estado de encendido de las unidades, se comprobó mediante pruebas de rendimiento que el enfoque híbrido logra resultados muy cercanos al óptimo tradicional, pero operando en una fracción del tiempo necesario para los métodos convencionales.

La comparación técnica mostró que las técnicas de *gradient boosting* son superiores a los métodos tradicionales de clasificación. Más allá de la selección del algoritmo, el mayor hito de esta evaluación fue contrastar la IA contra enfoques heurísticos clásicos, como el redondeo directo o por umbrales de la relajación lineal (LP). Se demostró que los métodos de redondeo son incapaces de lidiar con el acoplamiento temporal del sistema, provocando infactibilidades matemáticas y errores operacionales catastróficos que derivaron en sobre costos extremos por inyección de Energía No Suministrada. En contraste, los modelos de IA mantuvieron intacta la seguridad y factibilidad de la red, confirmando que la red neuronal no se limita a adivinar variables, sino que ha aprendido a respetar la física del problema. Asimismo, se corroboró que calibrar las probabilidades de predicción es un paso esencial. Cuando el modelo no está bien ajustado, tiende a cometer errores que fuerzan el apagado de máquinas necesarias, lo cual termina complicando la resolución del problema y anulando los beneficios de la aceleración. Una buena calibración, en cambio, asegura que el sistema se comporte de forma robusta, previsible y eficiente.

Al revisar qué variables influyen más en las decisiones del modelo, se hizo evidente que la IA no opera como una “caja negra” que memoriza despachos, sino que ha aprendido a seguir la lógica física del sistema. La mayor parte de su capacidad predictiva se basa en los estados de las unidades en las horas contiguas, lo que refleja que el modelo entiende el acoplamiento temporal y las restricciones de operación. Además, el uso de indicadores económicos y de costos le permite reconocer cuándo una central es eficiente para el despacho, funcionando como un complemento inteligente que refina la probabilidad de encendido ante cambios en el mercado. De igual manera, el análisis de distribución de errores demostró que la IA es capaz de cuantificar de forma precisa su propia incertidumbre; esto permitió segmentar sus predicciones mediante un esquema de umbrales (*Triage*), asegurando que las fijaciones estrictas se apliquen exclusivamente donde el riesgo operativo es casi nulo, blindando así la confiabilidad del sistema.

Bajo condiciones de operación estándar, la estrategia propuesta mostró una gran estabilidad. En la mayoría de los casos, la IA fue capaz de identificar correctamente las decisiones de encendido, superando el 90 % de coincidencia con el óptimo real. Esto permitió que el modelo acelerara la resolución del UC de forma consistente, logrando mejoras de tiempo significativas. Es importante destacar que el modelo demostró ser capaz de adaptarse a diferentes situaciones, actuando con mayor cautela en días complejos y permitiendo al solver clásico resolver el problema sin inconvenientes.

El análisis de sensibilidad ante el aumento del tamaño del sistema eléctrico permitió identificar los límites de la actual propuesta. Para una red de 20 generadores, los beneficios en tiempo de respuesta se mantuvieron claros y consistentes. Sin embargo, al escalar a 30 generadores, la mayor complejidad física de la red redujo la confianza del modelo predictivo. Esto demuestra que, a medida que aumentamos la dimensión del problema, el modelo híbrido requiere ajustes más finos en su lógica de toma de decisiones para seguir entregando una aceleración neta positiva.

El estudio sobre la integración de energías renovables evidenció un claro equilibrio entre la complejidad del despacho y el aporte de la IA. En escenarios con muy poca generación renovable, el problema es lo suficientemente sencillo para los métodos tradicionales, por lo que la IA solo añade complejidad innecesaria. Por el contrario, en escenarios con alta inyección de renovables, la IA juega un rol fundamental al gestionar la volatilidad. Se concluyó que el modelo híbrido alcanza su máximo potencial en niveles intermedios de penetración renovable, donde ayuda al sistema a gestionar la complejidad sin perder la precisión en los costos.

El análisis de sensibilidad al tamaño del bloque de resolución evidenció de manera categórica cómo el enfoque híbrido mitiga la “maldición de la dimensionalidad”. Al evaluar distintos horizontes, se determinó que la escala semanal representa el punto de rendimiento óptimo de la metodología, logrando reducciones de tiempo de hasta un 89.6 % (*speedups* cercanos a 9.6×) gracias al balance ideal entre la complejidad del árbol de búsqueda y el *overhead* de procesamiento de la IA. Sin embargo, el mayor aporte de la Inteligencia Artificial se constató en la planificación a escala mensual. En este escenario, la combinatoria desbordó por completo al *solver* clásico, obligándolo a detenerse tras seis horas de ejecución continua sin lograr cerrar el *Gap*

de convergencia. En contraste, al fijar de forma certera aproximadamente un 20 % de las variables del sistema, los modelos híbridos lograron converger en apenas una hora. Más aún, debido a que el *solver* tradicional fue truncado, el modelo asistido por IA logró encontrar soluciones económicamente superiores a las del método base (registrando desviaciones de costo negativas de hasta  $-0,13\%$ ). Esto demuestra que, en planificaciones a largo plazo, la IA no solo acelera drásticamente los cálculos, sino que guía al optimizador hacia zonas de alta eficiencia económica que los métodos convencionales son incapaces de alcanzar en tiempos viables.

Al someter al sistema a contingencias severas, el modelo mostró una capacidad de respuesta destacable. Aunque ante condiciones críticas de red la incertidumbre natural redujo la precisión de la IA, el sistema fue capaz de actuar con prudencia. En lugar de forzar soluciones erróneas, el mecanismo de *Triage* delegó la mayor parte de la decisión compleja al optimizador clásico. Esto garantizó que el sistema mantuviera su factibilidad operativa y una calidad económica equiparable a la del método tradicional, validando la robustez de la estrategia incluso frente a escenarios imprevistos.

A pesar de los resultados positivos, el modelo presenta áreas de mejora. La consistencia del aceleramiento depende del escenario: en situaciones de alta volatilidad o cuando el sistema está cerca de sus límites físicos, la confianza de la IA disminuye, limitando la cantidad de variables que se pueden fijar con seguridad. Además, este trabajo se centró en un sistema de tamaño reducido; su escalabilidad al Sistema Eléctrico Nacional (SEN) requiere evaluar el entrenamiento con un *dataset* más amplio y representativo.

En cuanto a la formulación del modelo predictivo, un trabajo futuro fundamental consiste en redefinir el alcance de las variables objetivo: en lugar de limitar la estimación al estado de operación de la unidad, se propone entrenar a la IA para predecir directamente las decisiones de encendido y apagado, o evaluar una arquitectura de salida múltiple que clasifique de forma simultánea y lógicamente acoplada la combinación de estas tres variables. Asimismo, resulta de alto interés estructurar la inferencia de manera longitudinal, es decir, predecir el perfil temporal completo generador por generador en lugar de realizar una clasificación variable a variable. Este cambio de enfoque permitiría introducir nuevos métodos de validación, o variables de estado auxiliares, que corroboren y garanticen matemáticamente el cumplimiento estricto de las restricciones intertemporales de la máquina, tales como los tiempos mínimos de operación y detención. Finalmente, se propone explorar arquitecturas como las *Graph Neural Networks* (GNN), que podrían capturar de forma nativa la topología de la red eléctrica, y evaluar el potencial de extraer variables de entrenamiento más ricas desde relajaciones no lineales para maximizar la precisión global del acoplamiento híbrido.

En última instancia, este trabajo subraya la viabilidad de integrar la inteligencia artificial como un facilitador estratégico para modernizar la operación de sistemas eléctricos complejos, sentando las bases para una planificación operativa más ágil, económica y resiliente ante los desafíos energéticos del futuro.

# Apéndice A

## A.1. Resultados

### A.1.1. Análisis de Importancia de Variables

Cuadro A.1: Importancia de variables del modelo clasificador XGBoost en el proceso de Triage.

| Variable (Feature)        | Descripción / Significado Físico                        | Importancia (%) |
|---------------------------|---------------------------------------------------------|-----------------|
| u_lp_t_prev               | Estado relajado en la hora previa ( $u_{t-1}^{LP}$ )    | 63.98 %         |
| u_lp_t_act                | Estado relajado en la hora actual ( $u_t^{LP}$ )        | 11.38 %         |
| u_lp_t_next               | Estado relajado en la hora siguiente ( $u_{t+1}^{LP}$ ) | 6.02 %          |
| costo_operativo_ponderado | Costo de generación ponderado relativo                  | 4.38 %          |
| mu_pmin_relativo          | Multiplicador de potencia mínima ( $\mu_t^{\min}$ )     | 3.89 %          |
| mu_pmax_relativo          | Multiplicador de potencia máxima ( $\mu_t^{\max}$ )     | 3.30 %          |
| roi_esperado              | Retorno sobre la inversión esperado de la unidad        | 2.13 %          |
| horas_para_recuperar      | Horas requeridas para recuperar costo de partida        | 2.08 %          |
| lmp_relativo              | Costo marginal local de energía relativo                | 1.63 %          |
| margen_reserva_sistema    | Holgura de capacidad de reserva en el sistema           | 1.20 %          |

### A.1.2. Semana Base

Cuadro A.2: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la semana base.

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)     | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|--------------------|---------------|---------------|--------------|
| 1            | 447042         | 447069         | 0.0061             | 22.75         | 17.83         | 1.28x        |
| 2            | 382587         | 382704         | 0.0306             | 16.46         | 16.83         | 0.98x        |
| 3            | 348092         | 348092         | 0.0000             | 19.47         | 15.45         | 1.26x        |
| 4            | 377918         | 377929         | 0.0028             | 11.70         | 11.56         | 1.01x        |
| 5            | 358941         | 358961         | 0.0056             | 20.28         | 11.83         | 1.71x        |
| 6            | 354729         | 354747         | 0.0051             | 24.92         | 14.93         | 1.67x        |
| 7            | 421262         | 421325         | 0.0148             | 13.92         | 12.82         | 1.09x        |
| <b>Total</b> | <b>2690571</b> | <b>2690827</b> | <b>0.0095 %</b>    | <b>129.50</b> | <b>101.25</b> | <b>1.28x</b> |

Cuadro A.3: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la semana base.

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)     | T.Híb.(s)    | Speedup      |
|--------------|----------------|----------------|--------------------|---------------|--------------|--------------|
| 1            | 447042         | 447070         | 0.0064             | 22.75         | 15.69        | 1.45x        |
| 2            | 382587         | 382704         | 0.0306             | 16.46         | 13.80        | 1.19x        |
| 3            | 348092         | 348411         | 0.0917             | 19.47         | 14.08        | 1.38x        |
| 4            | 377918         | 377874         | -0.0118            | 11.70         | 10.95        | 1.07x        |
| 5            | 358941         | 358949         | 0.0022             | 20.28         | 10.87        | 1.87x        |
| 6            | 354729         | 354729         | 0.0000             | 24.92         | 15.16        | 1.64x        |
| 7            | 421262         | 421315         | 0.0125             | 13.92         | 11.45        | 1.22x        |
| <b>Total</b> | <b>2690571</b> | <b>2691052</b> | <b>0.0179 %</b>    | <b>129.50</b> | <b>92.00</b> | <b>1.41x</b> |

Cuadro A.4: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Benchmark Heurístico: Redondeo Simple LP) durante la semana base.

| Día           | C.Base(\$)     | C.Híb.(\$)       | $\Delta$ Costo( %) | T.Base(s)     | T.Híb.(s)    | Speedup      |
|---------------|----------------|------------------|--------------------|---------------|--------------|--------------|
| 1             | 447042         | 455190           | 1.8227             | 22.75         | 8.01         | 2.84x        |
| 2             | 382587         | NaN              | NaN                | 16.46         | 7.83         | 2.10x        |
| 3             | 348092         | 353287           | 1.4924             | 19.47         | 8.60         | 2.26x        |
| 4             | 377918         | 383980           | 1.6040             | 11.70         | 8.03         | 1.46x        |
| 5             | 358941         | 366250           | 2.0362             | 20.28         | 8.62         | 2.35x        |
| 6             | 354729         | 167709480        | 47178.21           | 24.92         | 8.02         | 3.11x        |
| 7             | 421262         | 7667186          | 1720.05            | 13.92         | 8.24         | 1.69x        |
| <b>Total*</b> | <b>2307984</b> | <b>176935373</b> | <b>7566.23 %</b>   | <b>129.50</b> | <b>57.35</b> | <b>2.26x</b> |

\*El costo total excluye el Día 2 debido a la infactibilidad matemática (NaN) del redondeo.

Cuadro A.5: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Benchmark Heurístico: Umbrales LP) durante la semana base.

| Día           | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)     | T.Híb.(s)    | Speedup      |
|---------------|----------------|----------------|--------------------|---------------|--------------|--------------|
| 1             | 447042         | 447493         | 0.1010             | 22.75         | 15.94        | 1.43x        |
| 2             | 382587         | NaN            | NaN                | 16.46         | 9.36         | 1.76x        |
| 3             | 348092         | 348539         | 0.1283             | 19.47         | 10.65        | 1.83x        |
| 4             | 377918         | 379737         | 0.4812             | 11.70         | 8.73         | 1.34x        |
| 5             | 358941         | 360341         | 0.3899             | 20.28         | 10.08        | 2.01x        |
| 6             | 354729         | 359943         | 1.4698             | 24.92         | 12.22        | 2.04x        |
| 7             | 421262         | 7658555        | 1718.00            | 13.92         | 9.28         | 1.50x        |
| <b>Total*</b> | <b>2307984</b> | <b>9554608</b> | <b>313.98 %</b>    | <b>129.50</b> | <b>76.26</b> | <b>1.70x</b> |

\*El costo total excluye el Día 2 debido a la infactibilidad matemática (NaN) del umbral LP.

Cuadro A.6: Desempeño estadístico predictivo (Variables Fijadas y Coincidencia) para los modelos LightGBM y XGBoost en la semana base.

| Día         | Var. Fij. LGB | Coin. LGB ( %) | Var. Fij. XGB | Coin. XGB ( %) |
|-------------|---------------|----------------|---------------|----------------|
| 1           | 123           | 93.3 %         | 142           | 93.8 %         |
| 2           | 49            | 94.2 %         | 49            | 93.3 %         |
| 3           | 93            | 95.8 %         | 119           | 95.0 %         |
| 4           | 88            | 92.5 %         | 116           | 92.1 %         |
| 5           | 133           | 92.1 %         | 137           | 92.5 %         |
| 6           | 42            | 75.4 %         | 45            | 74.6 %         |
| 7           | 100           | 91.2 %         | 115           | 90.4 %         |
| <b>Prom</b> | <b>90</b>     | <b>90.64 %</b> | <b>103</b>    | <b>90.24 %</b> |

Cuadro A.7: Desempeño estadístico predictivo (Variables Fijadas y Coincidencia) para los modelos Heurísticos Benchmark (Redondeo LP) en la semana base.

| Día             | Coin. R. Simple ( %)* | Var. Fij. R. Umbral | Coin. R. Umbral ( %) |
|-----------------|-----------------------|---------------------|----------------------|
| 1               | 94.6 %                | 199                 | 99.5 %               |
| 2               | 95.0 %                | 205                 | 97.6 %               |
| 3               | 92.9 %                | 188                 | 99.5 %               |
| 4               | 86.7 %                | 200                 | 96.0 %               |
| 5               | 86.7 %                | 198                 | 97.0 %               |
| 6               | 75.8 %                | 171                 | 91.8 %               |
| 7               | 92.5 %                | 191                 | 95.3 %               |
| <b>Promedio</b> | <b>89.17 %</b>        | <b>193</b>          | <b>96.67 %</b>       |

\*El método de Redondeo Simple fija siempre el total de las variables (240 por día).

### A.1.3. Sensibilidad a Escala del Sistema

Cuadro A.8: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) - Sensibilidad a escala (20 Generadores).

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)      | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|--------------------|----------------|---------------|--------------|
| 1            | 305015         | 304821         | -0.0635            | 120.04         | 29.52         | 4.07x        |
| 2            | 261464         | 261464         | 0.0000             | 77.91          | 33.66         | 2.31x        |
| 3            | 282296         | 282296         | 0.0000             | 55.08          | 72.54         | 0.76x        |
| 4            | 237722         | 237735         | 0.0056             | 66.35          | 37.66         | 1.76x        |
| 5            | 224668         | 224668         | 0.0000             | 71.47          | 46.16         | 1.55x        |
| 6            | 252760         | 252879         | 0.0472             | 454.97         | 63.04         | 7.22x        |
| 7            | 217259         | 217259         | 0.0000             | 198.35         | 87.41         | 2.27x        |
| <b>Total</b> | <b>1781185</b> | <b>1781124</b> | <b>-0.0034 %</b>   | <b>1044.18</b> | <b>370.00</b> | <b>2.82x</b> |

Cuadro A.9: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) - Sensibilidad a escala (20 Generadores).

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)      | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|--------------------|----------------|---------------|--------------|
| 1            | 305015         | 304821         | -0.0635            | 120.04         | 32.79         | 3.66x        |
| 2            | 261464         | 261465         | 0.0001             | 77.91          | 26.26         | 2.97x        |
| 3            | 282296         | 282296         | 0.0000             | 55.08          | 35.42         | 1.55x        |
| 4            | 237722         | 237722         | 0.0000             | 66.35          | 55.72         | 1.19x        |
| 5            | 224668         | 224668         | 0.0000             | 71.47          | 50.41         | 1.42x        |
| 6            | 252760         | 252879         | 0.0472             | 454.97         | 42.74         | 10.65x       |
| 7            | 217259         | 217259         | 0.0000             | 198.35         | 119.85        | 1.65x        |
| <b>Total</b> | <b>1781185</b> | <b>1781111</b> | <b>-0.0042 %</b>   | <b>1044.18</b> | <b>363.19</b> | <b>2.87x</b> |

Cuadro A.10: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) - Sensibilidad a escala (30 Generadores).

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)      | T.Híb.(s)      | Speedup      |
|--------------|----------------|----------------|--------------------|----------------|----------------|--------------|
| 1            | 223167         | 223167         | 0.0000             | 78.27          | 39.06          | 2.00x        |
| 2            | 251605         | 251548         | -0.0229            | 43.88          | 40.61          | 1.08x        |
| 3            | 215097         | 215214         | 0.0541             | 40.34          | 67.32          | 0.60x        |
| 4            | 182614         | 182922         | 0.1687             | 1073.25        | 433.50         | 2.48x        |
| 5            | 202458         | 202281         | -0.0873            | 839.19         | 928.85         | 0.90x        |
| 6            | 225447         | 225281         | -0.0739            | 345.16         | 372.50         | 0.93x        |
| 7            | 194005         | 194005         | 0.0002             | 419.24         | 610.09         | 0.69x        |
| <b>Total</b> | <b>1494393</b> | <b>1494417</b> | <b>0.0016 %</b>    | <b>2839.33</b> | <b>2491.93</b> | <b>1.14x</b> |

Cuadro A.11: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) - Sensibilidad a escala (30 Generadores).

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo(%) | T.Base(s)      | T.Híb.(s)      | Speedup      |
|--------------|----------------|----------------|-------------------|----------------|----------------|--------------|
| 1            | 223167         | 222565         | -0.2699           | 78.27          | 48.47          | 1.61x        |
| 2            | 251605         | 251534         | -0.0281           | 43.88          | 63.39          | 0.69x        |
| 3            | 215097         | 215097         | -0.0001           | 40.34          | 33.87          | 1.19x        |
| 4            | 182614         | 183369         | 0.4138            | 1073.25        | 501.66         | 2.14x        |
| 5            | 202458         | 203584         | 0.5562            | 839.19         | 517.62         | 1.62x        |
| 6            | 225447         | 225517         | 0.0310            | 345.16         | 274.88         | 1.26x        |
| 7            | 194005         | 194006         | 0.0004            | 419.24         | 388.96         | 1.08x        |
| <b>Total</b> | <b>1494393</b> | <b>1495673</b> | <b>0.0856 %</b>   | <b>2839.33</b> | <b>1828.85</b> | <b>1.55x</b> |

#### A.1.4. Sensibilidad a la Penetración de Energías Renovables

Cuadro A.12: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la sensibilidad a 25 % de ERNC.

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo(%) | T.Base(s)    | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|-------------------|--------------|---------------|--------------|
| 1            | 502377         | 502344         | -0.0066           | 16.39        | 19.27         | 0.85x        |
| 2            | 483989         | 483978         | -0.0023           | 15.29        | 21.42         | 0.71x        |
| 3            | 441490         | 441490         | -0.0000           | 21.06        | 21.24         | 0.99x        |
| 4            | 464660         | 464683         | 0.0051            | 9.26         | 11.43         | 0.81x        |
| 5            | 474596         | 474596         | 0.0000            | 9.65         | 14.10         | 0.68x        |
| 6            | 487350         | 487273         | -0.0158           | 14.16        | 20.43         | 0.69x        |
| 7            | 472978         | 472992         | 0.0030            | 11.42        | 12.50         | 0.91x        |
| <b>Total</b> | <b>3327440</b> | <b>3327356</b> | <b>-0.0025 %</b>  | <b>97.22</b> | <b>120.39</b> | <b>0.81x</b> |

Cuadro A.13: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la sensibilidad a 25 % de ERNC.

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo(%) | T.Base(s)    | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|-------------------|--------------|---------------|--------------|
| 1            | 502377         | 502371         | -0.0012           | 16.39        | 21.07         | 0.78x        |
| 2            | 483989         | 484277         | 0.0595            | 15.29        | 21.37         | 0.72x        |
| 3            | 441490         | 441747         | 0.0583            | 21.06        | 23.65         | 0.89x        |
| 4            | 464660         | 464660         | -0.0000           | 9.26         | 12.76         | 0.73x        |
| 5            | 474596         | 474596         | 0.0000            | 9.65         | 13.37         | 0.72x        |
| 6            | 487350         | 487273         | -0.0158           | 14.16        | 13.24         | 1.07x        |
| 7            | 472978         | 472977         | -0.0001           | 11.42        | 12.45         | 0.92x        |
| <b>Total</b> | <b>3327440</b> | <b>3327902</b> | <b>0.0139 %</b>   | <b>97.22</b> | <b>117.90</b> | <b>0.82x</b> |

Cuadro A.14: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la sensibilidad a 50 % de ERNC.

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)     | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|--------------------|---------------|---------------|--------------|
| 1            | 491564         | 491590         | 0.0053             | 16.01         | 16.96         | 0.94x        |
| 2            | 458026         | 458206         | 0.0393             | 18.40         | 12.62         | 1.46x        |
| 3            | 399964         | 399964         | 0.0000             | 10.54         | 11.01         | 0.96x        |
| 4            | 412389         | 412385         | -0.0011            | 11.48         | 13.69         | 0.84x        |
| 5            | 411333         | 411344         | 0.0027             | 11.54         | 11.06         | 1.04x        |
| 6            | 414769         | 416297         | 0.3684             | 44.26         | 12.54         | 3.53x        |
| 7            | 348329         | 348335         | 0.0016             | 28.12         | 25.27         | 1.11x        |
| <b>Total</b> | <b>2936375</b> | <b>2938121</b> | <b>0.0595 %</b>    | <b>140.35</b> | <b>103.15</b> | <b>1.36x</b> |

Cuadro A.15: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la sensibilidad a 50 % de ERNC.

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)     | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|--------------------|---------------|---------------|--------------|
| 1            | 491564         | 491564         | 0.0000             | 16.01         | 14.13         | 1.13x        |
| 2            | 458026         | 458604         | 0.1261             | 18.40         | 18.57         | 0.99x        |
| 3            | 399964         | 399964         | 0.0000             | 10.54         | 11.40         | 0.92x        |
| 4            | 412389         | 412426         | 0.0088             | 11.48         | 13.54         | 0.85x        |
| 5            | 411333         | 411339         | 0.0016             | 11.54         | 11.85         | 0.97x        |
| 6            | 414769         | 414850         | 0.0196             | 44.26         | 16.72         | 2.65x        |
| 7            | 348329         | 348335         | 0.0016             | 28.12         | 26.39         | 1.07x        |
| <b>Total</b> | <b>2936375</b> | <b>2937082</b> | <b>0.0241 %</b>    | <b>140.35</b> | <b>112.60</b> | <b>1.25x</b> |

Cuadro A.16: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la sensibilidad a 150 % de ERNC.

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo( %) | T.Base(s)     | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|--------------------|---------------|---------------|--------------|
| 1            | 435579         | 435579         | 0.0000             | 33.77         | 30.33         | 1.11x        |
| 2            | 357087         | 357413         | 0.0914             | 75.83         | 89.50         | 0.85x        |
| 3            | 328146         | 328115         | -0.0096            | 22.97         | 23.22         | 0.99x        |
| 4            | 340015         | 339996         | -0.0054            | 21.13         | 22.98         | 0.92x        |
| 5            | 341133         | 341133         | 0.0000             | 20.51         | 15.33         | 1.34x        |
| 6            | 385477         | 386856         | 0.3577             | 29.31         | 41.07         | 0.71x        |
| 7            | 348329         | 348335         | 0.0016             | 28.12         | 25.27         | 1.11x        |
| <b>Total</b> | <b>2535767</b> | <b>2537427</b> | <b>0.0655 %</b>    | <b>231.64</b> | <b>247.70</b> | <b>0.94x</b> |

Cuadro A.17: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la sensibilidad a 150 % de ERNC.

| Día          | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo(%) | T.Base(s)     | T.Híb.(s)     | Speedup      |
|--------------|----------------|----------------|-------------------|---------------|---------------|--------------|
| 1            | 435579         | 435601         | 0.0050            | 33.77         | 27.55         | 1.23x        |
| 2            | 357087         | 357409         | 0.0903            | 75.83         | 59.93         | 1.27x        |
| 3            | 328146         | 328135         | -0.0034           | 22.97         | 24.42         | 0.94x        |
| 4            | 340015         | 340032         | 0.0052            | 21.13         | 22.97         | 0.92x        |
| 5            | 341133         | 341133         | 0.0000            | 20.51         | 15.33         | 1.34x        |
| 6            | 385477         | 386787         | 0.3399            | 29.31         | 27.43         | 1.07x        |
| 7            | 348329         | 348335         | 0.0016            | 28.12         | 26.39         | 1.07x        |
| <b>Total</b> | <b>2535767</b> | <b>2537433</b> | <b>0.0657 %</b>   | <b>231.64</b> | <b>204.02</b> | <b>1.14x</b> |

### A.1.5. Sensibilidad al Tamaño del Bloque de Optimización

Cuadro A.18: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante el horizonte semanal.

| Semana       | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo(%) | T.Base(s)      | T.Híb.(s)      | Speedup      |
|--------------|----------------|----------------|-------------------|----------------|----------------|--------------|
| 1            | 2521247        | 2523952        | 0.1073            | 767.26         | 388.16         | 1.98x        |
| 2            | 2514725        | 2517266        | 0.1011            | 2255.03        | 248.93         | 9.06x        |
| 3            | 2392441        | 2394077        | 0.0684            | 2267.04        | 236.79         | 9.57x        |
| 4            | 2435746        | 2433600        | -0.0881           | 2168.30        | 308.23         | 7.03x        |
| <b>Total</b> | <b>9864159</b> | <b>9868896</b> | <b>0.0480 %</b>   | <b>7457.63</b> | <b>1182.11</b> | <b>6.31x</b> |

Cuadro A.19: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante el horizonte semanal.

| Semana       | C.Base(\$)     | C.Híb.(\$)     | $\Delta$ Costo(%) | T.Base(s)      | T.Híb.(s)      | Speedup      |
|--------------|----------------|----------------|-------------------|----------------|----------------|--------------|
| 1            | 2521247        | 2523952        | 0.1073            | 767.26         | 422.41         | 1.82x        |
| 2            | 2514725        | 2516486        | 0.0700            | 2255.03        | 301.84         | 7.47x        |
| 3            | 2392441        | 2397389        | 0.2068            | 2267.04        | 262.87         | 8.62x        |
| 4            | 2435746        | 2435069        | -0.0278           | 2168.30        | 314.47         | 6.90x        |
| <b>Total</b> | <b>9864159</b> | <b>9872895</b> | <b>0.0886 %</b>   | <b>7457.63</b> | <b>1301.59</b> | <b>5.73x</b> |

Cuadro A.20: Desempeño estadístico predictivo (Variables Fijadas y Coincidencia) para los modelos LightGBM y XGBoost en simulación de horizonte semanal.

| Semana      | Var. Fij. LGB | Coin. LGB (%)  | Var. Fij. XGB | Coin. XGB (%)  |
|-------------|---------------|----------------|---------------|----------------|
| 1           | 920           | 93.8 %         | 1193          | 89.7 %         |
| 2           | 924           | 97.6 %         | 1087          | 96.1 %         |
| 3           | 901           | 98.5 %         | 1116          | 96.2 %         |
| 4           | 715           | 98.3 %         | 872           | 94.9 %         |
| <b>Prom</b> | <b>865</b>    | <b>97.05 %</b> | <b>1067</b>   | <b>94.23 %</b> |

Cuadro A.21: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante el horizonte mensual.

| Mes          | C.Base(\$)      | C.Híb.(\$)      | $\Delta$ Costo(%) | T.Base(s)       | T.Híb.(s)       | Speedup      |
|--------------|-----------------|-----------------|-------------------|-----------------|-----------------|--------------|
| 1            | 11220807        | 11231006        | 0.0909            | 12258.48        | 4270.12         | 2.87x        |
| 2            | 11066373        | 11059011        | -0.0665           | 21600.00        | 4425.73         | 4.88x        |
| 3            | 11157028        | 11156689        | -0.0030           | 21600.00        | 4003.45         | 5.40x        |
| <b>Total</b> | <b>33444208</b> | <b>33446706</b> | <b>0.0075 %</b>   | <b>55458.48</b> | <b>12699.30</b> | <b>4.37x</b> |

Cuadro A.22: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante el horizonte mensual.

| Mes          | C.Base(\$)      | C.Híb.(\$)      | $\Delta$ Costo(%) | T.Base(s)       | T.Híb.(s)       | Speedup      |
|--------------|-----------------|-----------------|-------------------|-----------------|-----------------|--------------|
| 1            | 11220807        | 11206515        | -0.1274           | 12258.48        | 4067.59         | 3.01x        |
| 2            | 11066373        | 11058316        | -0.0728           | 21600.00        | 4133.23         | 5.23x        |
| 3            | 11157028        | 11149398        | -0.0684           | 21600.00        | 3640.52         | 5.93x        |
| <b>Total</b> | <b>33444208</b> | <b>33414229</b> | <b>-0.0896 %</b>  | <b>55458.48</b> | <b>11841.34</b> | <b>4.68x</b> |

Cuadro A.23: Desempeño estadístico predictivo y Gap de convergencia (Gurobi Base vs Modelo Híbrido LightGBM) en simulación de horizonte mensual.

| Mes         | Gap Base (%) | Var. Fij. LG) | Coin. LGB (%) | Gap LGB (%) |
|-------------|--------------|---------------|---------------|-------------|
| 1           | 2.20         | 1440          | 94.5          | 0.72        |
| 2           | 1.57         | 1385          | 92.1          | 0.85        |
| 3           | 1.05         | 1450          | 95.8          | 0.91        |
| <b>Prom</b> | <b>1.61</b>  | <b>1425</b>   | <b>94.1</b>   | <b>0.83</b> |

Cuadro A.24: Desempeño estadístico predictivo y Gap de convergencia (Gurobi Base vs Modelo Híbrido XGBoost) en simulación de horizonte mensual.

| Mes         | Gap Base (%) | Var. Fij. XGB | Coin. XGB (%) | Gap XGB (%) |
|-------------|--------------|---------------|---------------|-------------|
| 1           | 2.20         | 1440          | 94.2          | 0.94        |
| 2           | 1.57         | 1400          | 93.6          | 0.97        |
| 3           | 1.05         | 1464          | 96.1          | 1.02        |
| <b>Prom</b> | <b>1.61</b>  | <b>1435</b>   | <b>94.6</b>   | <b>0.98</b> |

### A.1.6. Sensibilidad a Congestiones

Cuadro A.25: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado XGBoost) durante la sensibilidad a contingencias.

| Día          | C.Base(\$)      | C.Híb.(\$)      | $\Delta$ Costo(%) | T.Base(s)     | T.Híb.(s)     | Speedup      |
|--------------|-----------------|-----------------|-------------------|---------------|---------------|--------------|
| 1            | 440027          | 440027          | 0.0000            | 18.54         | 19.96         | 0.93x        |
| 2            | 390566          | 390566          | -0.0001           | 16.01         | 16.32         | 0.98x        |
| 3            | 332722          | 332923          | 0.0605            | 26.57         | 13.40         | 1.98x        |
| 4            | 357455          | 357744          | 0.0810            | 35.95         | 17.96         | 2.00x        |
| 5            | 365976          | 365766          | -0.0575           | 24.87         | 15.02         | 1.66x        |
| 6            | 4684473         | 4684547         | 0.0016            | 14.86         | 10.36         | 1.43x        |
| 7            | 46589859        | 46617971        | 0.0603            | 15.47         | 10.85         | 1.43x        |
| <b>Total</b> | <b>53161078</b> | <b>53189544</b> | <b>0.0535 %</b>   | <b>152.27</b> | <b>103.87</b> | <b>1.47x</b> |

Cuadro A.26: Comparativa de costos operativos y tiempos de cómputo (Gurobi Clásico vs. Modelo Híbrido Calibrado LightGBM) durante la sensibilidad a contingencias.

| Día          | C.Base(\$)      | C.Híb.(\$)      | $\Delta$ Costo(%) | T.Base(s)     | T.Híb.(s)     | Speedup      |
|--------------|-----------------|-----------------|-------------------|---------------|---------------|--------------|
| 1            | 440027          | 440113          | 0.0194            | 18.54         | 20.77         | 0.89x        |
| 2            | 390566          | 390585          | 0.0049            | 16.01         | 16.55         | 0.97x        |
| 3            | 332722          | 332957          | 0.0706            | 26.57         | 12.66         | 2.10x        |
| 4            | 357455          | 357744          | 0.0810            | 35.95         | 18.13         | 1.98x        |
| 5            | 365976          | 365970          | -0.0018           | 24.87         | 14.05         | 1.77x        |
| 6            | 4684473         | 4685765         | 0.0276            | 14.86         | 11.58         | 1.28x        |
| 7            | 46589859        | 46617559        | 0.0595            | 15.47         | 11.17         | 1.39x        |
| <b>Total</b> | <b>53161078</b> | <b>53190692</b> | <b>0.0557 %</b>   | <b>152.27</b> | <b>104.91</b> | <b>1.45x</b> |

# Referencias

- [1] Coordinador Eléctrico Nacional, “Anuario estadístico y memoria anual,” CEN, Santiago, Chile, Tech. Rep., 2024. [Online]. Available: <https://www.coordinador.cl>
- [2] L. A. Wolsey, *Integer Programming*, 2nd ed. Hoboken, NJ, USA: John Wiley & Sons, 2020.
- [3] International Energy Agency, “Renewables 2024: Analysis and forecast to 2030,” IEA, Paris, France, Report, 2024. [Online]. Available: <https://www.iea.org/reports/renewables-2024>
- [4] J. Lara *et al.*, “Day ahead unit commitment with high penetration of renewable energy sources and electric vehicle charging stations,” *Int. J. Eng. Trends Technol.*, vol. 72, no. 6, pp. 434–441, Jun. 2024.
- [5] L. Yang, W. Li, Y. Xu, C. Zhang, and S. Chen, “Two novel locally ideal three-period unit commitment formulations in power systems,” *Appl. Energy*, vol. 284, Feb. 2021.
- [6] I. de Cominges Guerra *et al.*, “A comprehensive analysis of PINNs for power system transient stability,” *Electronics*, vol. 13, no. 2, Jan. 2024.
- [7] D. Jiménez, A. Angulo, A. Street, and F. Mancilla-David, “A closed-loop data-driven optimization framework for the unit commitment problem: A Q-learning approach under real-time operation,” *Appl. Energy*, vol. 330, Jan. 2023.
- [8] A. G. Expósito *et al.*, *Análisis y Operación de Sistemas de Energía Eléctrica*. Madrid, España: McGraw-Hill, 2003.
- [9] B. Knueven, J. Ostrowski, and J. P. Watson, “On mixed-integer programming formulations for the unit commitment problem,” *INFORMS Journal on Computing*, vol. 32, no. 4, pp. 857–876, 2020.
- [10] Gurobi Optimization, LLC, *Gurobi Optimizer Reference Manual*, Gurobi Optimization, LLC, 2023. [Online]. Available: <https://www.gurobi.com>
- [11] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016. [Online]. Available: <http://www.deeplearningbook.org>

- [12] T. Chen and C. Guestrin, “Xgboost: A scalable tree boosting system,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 2016, pp. 785–794.
- [13] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, and T.-Y. Liu, “Lightgbm: A highly efficient gradient boosting decision tree,” in *Advances in Neural Information Processing Systems*, vol. 30, 2017.
- [14] J. Wang *et al.*, “Surrogate model-based optimization of electrical machines in Ārtap framework,” in *Proc. 19th Int. Power Electron. Motion Control Conf. (PEMC)*, 2021, pp. 562–568.
- [15] A. J. Wood, B. F. Wollenberg, and G. B. Sheblé, *Power Generation, Operation, and Control*, 3rd ed. Hoboken, NJ, USA: John Wiley & Sons, 2013.
- [16] F. Teng, V. Trovato, and G. Strbac, “Stochastic scheduling with inertia-dependent fast frequency response requirements,” *IEEE Transactions on Power Systems*, vol. 31, no. 2, pp. 1557–1566, 2016.
- [17] Energy Exemplar, *PLEXOS Integrated Energy Model: Reference Manual*, Energy Exemplar, Adelaide, Australia, 2023. [Online]. Available: <https://www.energyexemplar.com/plexos>
- [18] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.
- [19] S. J. D. Prince, *Understanding Deep Learning*. Cambridge, MA, USA: MIT Press, 2024. [Online]. Available: <http://udlbook.com>
- [20] A. S. Xavier, F. Qiu, and S. Ahmed, “Learning to solve large-scale security-constrained unit commitment problems,” *INFORMS Journal on Computing*, vol. 33, no. 2, pp. 739–756, 2021.
- [21] Y. Bengio, A. Lodi, and A. Prouvost, “Machine learning for combinatorial optimization: A methodological tour d’horizon,” *European Journal of Operational Research*, vol. 290, no. 2, pp. 405–421, 2021.
- [22] E. B. Khalil, P. L. Bodic, L. Song, G. Nemhauser, and B. Dilkina, “Learning to branch in mixed integer programming,” in *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, 2017, pp. 724–731.
- [23] C. Guo, G. Pleiss, Y. Sun, and K. Q. Weinberger, “On calibration of modern neural networks,” in *Proceedings of the 34th International Conference on Machine Learning (ICML)*, vol. 70. PMLR, 2017, pp. 1321–1330.