



UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

Implementación de un modelo para la oferta eficiente de energía en un mercado Day Ahead, para una planta eólica con almacenamiento BESS utilizando redes neuronales

Michael Nicolás Castillo Olmos
2024

Requisito parcial para obtener el título de:
Ingeniero Civil Electricista

Profeso Guía:
Dr. Esteban Gil Sagás

Correferente Externo:
Juan Araya Pérez



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: **Implementación de un modelo para la oferta eficiente de energía en un mercado Day-Ahead, para una planta eólica con almacenamiento BESS utilizando redes neuronales.**

Nombre del candidato(a): **Michael Nicolás Castillo Olmos.**

Carrera / Grado: **Ingeniero Civil Electricista.**

Campus: **Casa Central** Departamento: **Ingeniería Eléctrica.**

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Esteban Manuel Gil Sagás, 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: 20/10/2025

Firma: 

Estudiante o Candidato(a):

Fecha: 20/10/2025 Firma: 

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

Agradecimientos

Primero y ante todo, quiero agradecer a Dios, porque sin Él nada somos. Es nuestro compañero y amigo día a día, y a pesar de conocer nuestros corazones y pensamientos, nos ama incondicionalmente.

A mis padres, Moisés y Beatriz, les agradezco profundamente por su continuo esfuerzo, amor y por su disposición incondicional hacia mí. Su apoyo ha sido fundamental en cada paso de este camino.

Agradezco a todos los amigos que hice durante mi etapa universitaria. Hasta el día de hoy, los llevo en mis pensamientos. Siempre unidos y dándonos la mano unos a otros, su amistad ha sido un pilar importante en mi vida.

A los profesores del Departamento de Ingeniería Eléctrica, quienes, a pesar de no tener del todo claro mi preferencia por la carrera, me mostraron un mundo desafiante en cuanto al conocimiento. Ellos me hicieron apasionarme por aprender y superarme continuamente. En especial, agradezco a mi profesor guía, Esteban Gil, por su colaboración, tiempo y disposición en la elaboración de esta memoria. A Juan Araya, por su ayuda desinteresada y que siempre fue un apoyo en esto.

Finalmente, agradezco a todos los que, de una u otra manera, me han extendido una mano durante esta etapa universitaria. Sus gestos de apoyo y ayuda han sido invaluable en este proceso.

Índice general

Agradecimientos	1
Índice de Figuras	4
Índice de Tablas	5
Abstract	6
Resumen	7
1. Introducción	8
1.1. Justificación del tema	8
1.2. Objetivos	9
1.3. Estructura de la Memoria	9
2. Fundamentos Conceptuales	10
2.1. Plantas Híbridas	10
2.2. Mercados eléctricos	12
2.2.1. Mercado basado en costos auditados	12
2.2.2. Mercado basado en ofertas	13
2.3. Optimización secuencial bajo incertidumbre	14
2.3.1. Programación Estocástica	15
2.3.2. Programación Robusta	15
2.3.3. Reinforcement Learning	15
2.3.4. Redes Neuronales	16
3. Metodología	17
3.1. Supuestos	17
3.2. Diagrama Procedimental	17
3.2.1. Preprocesamiento de datos	17
3.2.2. Generación de escenarios	18
3.2.3. Formulación del problema para la resolución estocástica y robusta	18
3.2.4. Sistema de control para la operación de la batería	20
3.2.5. Entrenamiento de redes	21
3.3. Descripción general de los datos	22
3.3.1. Cabo Leones I	22
3.3.2. Santiago Solar	23
3.3.3. Distintos criterios de operación para el almacenamiento	25
4. Resultados	26
4.1. Santiago Solar	26
4.1.1. Perfil de Operación	26
4.1.2. Desempeño Económico	28
4.1.3. Ciclado de la Batería	29
4.1.4. Gestión de Energía y Análisis de Desbalances	30

4.2. Cabo Leones II	33
4.2.1. Perfil de Operación	33
4.2.2. Desempeño Económico	35
4.2.3. Ciclado de la Batería	36
4.2.4. Gestión de Energía y Análisis de Desbalances	37
5. Conclusiones	39
5.1. Implicaciones y Recomendaciones	40
5.2. Limitaciones del Estudio	40
Bibliografía	41
Anexos	42

Índice de figuras

2.1. Representación visual de una planta híbrida	11
3.1. Generación de escenarios	18
3.2. Representación gráfica del control de la batería	21
3.3. Datos de generación Cabo Leones I	22
3.4. Datos del Mercado Cabo Leones I	23
3.5. Datos de generación Santiago Solar	24
3.6. Datos del Mercado para Santiago Solar	24
4.1. Operación de los distintos métodos para un día del <i>test set</i> considerando retiros, Santiago Solar.	27
4.2. Desempeño económico para los distintos casos y métodos en Santiago Solar.	28
4.3. Número de ciclos de batería para los distintos casos y métodos, Santiago Solar.	29
4.4. Energía Ofertada e Inyectada para cada caso y método. Santiago Solar	31
4.5. Sobre y subgeneración para cada caso y método, Santiago Solar	31
4.6. Operación de los distintos métodos para un día del <i>test set</i> considerando retiros, Cabo Leones I.	34
4.7. Desempeño económico para los distintos casos y métodos en Cabo Leones I.	35
4.8. Número de ciclos de batería para los distintos casos y métodos.	36
4.9. Energía Ofertada e Inyectada para cada caso y método.	37
4.10. Sobre y subgeneración para cada caso y método.	38
5.1. Desempeño económico para los distintos casos y métodos en Santiago Solar.	44
5.2. Desempeño económico para los distintos casos y métodos en Cabo Leones I.	45

Índice de tablas

3.1. Parámetros del sistema de almacenamiento y generación para Santiago Solar.	25
3.2. Parámetros del sistema de almacenamiento y generación para Cabo Leones I.	25
4.1. Cantidad de años estimados para alcanzar los 2,000 ciclos, Santiago Solar.	30
4.2. Cantidad de años estimados para alcanzar los 2,000 ciclos.	36

Abstract

Energy storage systems are essential for achieving a clean energy matrix and strengthening electrical systems against the challenges of integrating non-conventional renewable energy (NCRE). These systems enhance supply reliability and optimize generation, transmission, and distribution. In this context, lithium-based BESS storage systems have grown rapidly, driven by their modularity and the rise of electromobility. This growth creates new investment opportunities, with increasing confidence from banks and investors in their revenue streams.

To ensure the viability of these projects, it is crucial to develop operational strategies under uncertainty. This study implements a previously developed neural network model adapted to the Chilean context, evaluating its performance at the Cabo Leones I wind farm and the Santiago Solar photovoltaic plant, both with batteries of different sizes (25 % and 75 % of nominal capacity). Two scenarios are considered: energy injection only and one that incorporates withdrawals, enabling greater energy arbitrage.

The model is compared with traditional methods such as stochastic and robust programming. Results show that the neural network-based approach is competitive in photovoltaic generation, improving revenues and reducing imbalances. In wind generation, stochastic programming leads in profitability and robustness. Overall, larger batteries enhance economic outcomes: at Santiago Solar, they increase revenues and reduce imbalance penalties, while at Cabo Leones I, they mainly reduce penalties.

The impact of withdrawals varies: in wind generation, they reduce imbalances, but in photovoltaic generation, results are mixed. The neural network-based model adopts a conservative strategy, using fewer battery cycles, potentially extending battery life, though it generates imbalances due to undergeneration caused by low charge levels.

In conclusion, the neural network-based method offers a conservative and competitive strategy. However, its effectiveness depends on the operational context, influenced by factors such as prices, resource availability, and local conditions, meaning it does not automatically guarantee higher economic benefits.

Resumen

Los sistemas de almacenamiento de energía son esenciales para una matriz energética limpia y fortalecen los sistemas eléctricos frente a los desafíos de integrar energías renovables no convencionales (ERNC). Estos sistemas aportan confiabilidad al suministro y optimizan la generación, transmisión y distribución. En este contexto, los sistemas de almacenamiento BESS basados en litio han crecido rápidamente, impulsados por su modularidad y el auge de la electromovilidad. Esto genera nuevas oportunidades de inversión con creciente confianza de bancos e inversores en sus flujos de ingresos.

Para garantizar la viabilidad de estos proyectos, es crucial desarrollar estrategias operativas bajo incertidumbre. En este trabajo se implementa un modelo de redes neuronales previamente desarrollado y se adapta al contexto chileno, evaluando su desempeño en el parque eólico Cabo Leones I y la planta fotovoltaica Santiago Solar, ambos con baterías de distintos tamaños (25 % y 75 % de la capacidad nominal). Se consideran dos escenarios: solo inyección de energía y uno que incorpora retiros, habilitando mayor arbitraje energético.

El modelo se compara con métodos tradicionales como la programación estocástica y robusta. Los resultados muestran que el enfoque basado en redes neuronales es competitivo en generación fotovoltaica, mejorando ingresos y reduciendo desbalances. En generación eólica, la programación estocástica lidera en rentabilidad y robustez. En general, el uso de baterías más grandes mejora los resultados económicos: en Santiago Solar aumenta los ingresos y reduce pagos por desbalance, mientras que en Cabo Leones I se reducen penalizaciones.

El impacto de los retiros varía: en generación eólica disminuyen desbalances, pero en generación solar los resultados son mixtos. El modelo basado en redes neuronales adopta una estrategia conservadora, usando menos ciclos de batería, lo que podría extender su vida útil, aunque genera desbalances por subgeneración debido a bajos niveles de carga.

En conclusión, el método basado en redes neuronales ofrece una estrategia conservadora y competitiva. Sin embargo, su efectividad depende del contexto operativo, influido por factores como precios, disponibilidad de recursos y condiciones locales, por lo que no garantiza automáticamente mayores beneficios económicos.

Capítulo 1

Introducción

1.1. Justificación del tema

La descarbonización de la matriz energética es un tema muy latente en la actualidad, tanto a nivel nacional como internacional. En el caso de Chile, el acuerdo de descarbonización establece el fin de nuevos proyectos en base a carbón, actualmente con un 15,76 % de la capacidad instalada de acuerdo con datos de la CNE (Comisión Nacional de Energía), marca un precedente de cómo el sector energético apunta a una operación más sustentable en el contexto del cambio climático que afecta al planeta. La masificación de las tecnologías de generación renovable es una de las columnas sobre las que se asentará esta nueva matriz energética. Según datos entregados por la misma Comisión Nacional de Energía, la generación solar y eólica corresponden a un 29.92 % de potencia instalada (con un 17.29 % y 12.63 %, respectivamente).

Uno de los problemas que tienen las ERNC (Energías Renovables No Convencionales) es la incertidumbre que traen consigo, sobre todo la eólica, ya que predecir con exactitud la disponibilidad del recurso primario es una tarea difícil. Esto se traduce en brechas o diferencias entre la generación programada y la real, lo que a su vez conduce a una necesidad de control de frecuencia en el sistema eléctrico.

Por otro lado, las centrales térmicas tienen mucho más control sobre su despacho, pueden bajar o subir su inyección según las necesidades del coordinador y por ende vuelven al sistema completo mucho más robusto. Con el fin de darle factibilidad a una matriz fuertemente integrada por plantas de ERNC y que a su vez no pierda robustez, una alternativa es utilizar plantas híbridas con almacenamiento de energía, el cual otorga control sobre su inyección y capacidad de ofrecer servicios complementarios como lo hacen actualmente las generadoras basadas en combustibles fósiles.

Actualmente, para determinar las inyecciones de las generadoras y precios de la energía, se resuelve un problema de optimización de la operación, generalmente con solvers como Gurobi. A diferencia de los métodos tradicionales de resolución de este problema, este trabajo de memoria toma como referencia el modelo planteado en [1] que utiliza las redes neuronales para la operación de una planta híbrida solar-BESS. Dentro de las conclusiones que se llegan en este trabajo es que el modelo propuesto logra mejores decisiones de oferta que los métodos tradicionales, lo que se traduce en mayores ganancias para la planta; menor variabilidad en desbalances, ingresos diarios y cantidades ofertadas. Esto hace que valga la pena su aplicación en otros contextos y con enfoque en otras necesidades.

El fin de esta memoria es operar una planta híbrida de generación renovable más almacenamiento de energía, ofertando en un mercado Day Ahead (DA). Para ello, se implementará el modelo en [1], pero que se enfoque principalmente en el mercado DA, incorporando distintas alternativas en cuanto a cómo operar la componente de almacenamiento.

En cuanto a la operación de la batería BESS, intentando adelantarse a las futuras normativas que regirán este tipo de tecnología, se explorará la consideración de realizar retiros desde la red eléctrica. Por otra parte, se estudiará la operación con una batería del 75 % y 25 % de la potencia nominal del parque eólico.

Por último, otro aspecto importante de este trabajo es situar la planta en un mercado en base a ofertas, mercado que aún no se desarrolla en Chile, pero es mayoritario en el resto del mundo. Resulta de interés

cuantificar las ventajas que puede suponer para las generadoras la implementación de dicho modelo, para ello también será necesario recopilar datos e información para simular cómo se comportaría dicho mercado en nuestro contexto. Estimar estos datos será otro de los puntos principales del trabajo a realizar, una de las estrategias a realizar será estimar dichos datos a partir de los precios en mercados Day Ahead aplicados en otros países, intentando escalarlos a nuestro sistema eléctrico. También se estudiarán los actuales sistemas de subasta en cuanto a productos energéticos que rigen en el país y lograr el escalamiento al caso de la transacción de las inyecciones de energía. Como punto de comparación se utilizarán los métodos de optimización robusta y estocástica, a partir del desarrollo en [1] que también programa estos problemas en un código de Julia. Se realizará una modificación del mismo para este contexto. Con esto se podrá mostrar qué aspectos económicos y técnicos logran mejorarse a partir del modelo de redes neuronales y del porqué debería implementarse para resolver la operación de este tipo de plantas. Para el mandante resulta de interés demostrar las bondades que puede tener el cambio en nuestro país del sistema marginalista al nuevo basado en ofertas, además de creer que este cambio tarde o temprano dará lugar y es su deseo estar preparado cuando esto llegue. Todo esto sumado a la aplicación de estos nuevos modelos que resuelven el problema de optimización resulta motivante por ser un camino investigativo que puede tener mucho trabajo y opciones por delante.

1.2. Objetivos

Objetivo general:

Implementar y ajustar un modelo de redes neuronales para optimizar los ingresos por ventas de energía eléctrica de dos plantas renovables, una eólica y otra fotovoltaica, con almacenamiento BESS bajo incertidumbre, considerando la potencial creación de un mercado Day-Ahead basado en ofertas en Chile para distintos criterios de operación para el almacenamiento.

Objetivos específicos:

- Adaptar el modelo de redes neuronales desarrollado en [1] para ofertar eficientemente la energía de una planta híbrida considerando la creación de un mercado Day-Ahead basado en ofertas en Chile.
- Estimar datos del hipotético mercado basado en ofertas a partir de información recopilada de este tipo de mercado aplicado en otros países o mecanismos de subasta aplicados en el mercado eléctrico chileno, para utilizarlos como entrada del modelo.
- Analizar el desempeño económico de la planta en el mercado de energía para distintos criterios de operación del almacenamiento a partir de simulaciones computacionales.
- Contrastar los resultados al aplicar el modelo en base a redes neuronales con los métodos de optimización robusta y estocástica

1.3. Estructura de la Memoria

En el primer capítulo se proporciona el contexto y la motivación detrás del trabajo realizado. Además, se presentan los objetivos específicos que se buscan alcanzar con este estudio. En el segundo capítulo se detallan los conceptos fundamentales y el marco teórico necesario para comprender la aplicación práctica del modelo desarrollado. Se abordan temas como las plantas híbridas, los distintos tipos de mercados eléctricos y técnicas de optimización bajo incertidumbre.

En el capítulo tercero describe detalladamente la metodología seguida durante el desarrollo del trabajo. Se incluyen los supuestos iniciales, el diagrama procedimental que incluye los pasos específicos para llevar a cabo el trabajo. El cuarto capítulo presenta y analiza los resultados obtenidos. Se muestra cómo se utilizó el almacenamiento de energía y se realiza una comparación entre los distintos métodos aplicados para evaluar su eficiencia y efectividad.

El quinto y último capítulo ofrece un resumen de las conclusiones derivadas del estudio y los comentarios finales. Además, se identifican y plantean posibles desafíos y áreas de mejora para investigaciones futuras.

Capítulo 2

Fundamentos Conceptuales

2.1. Plantas Híbridas

En términos generales, una planta híbrida es una instalación que integra múltiples fuentes de generación eléctrica para aprovechar las sinergias entre ellas. Comúnmente, se utiliza una fuente renovable como principal, complementada con sistemas de control y respaldo, tales como almacenamiento de energía o generadores diésel. En este trabajo, el enfoque estará en las plantas eólicas con *Battery Energy Storage System* (BESS) basadas en litio, ya que estos sistemas de almacenamiento están a la vanguardia en el aspecto comercial debido a su alta densidad energética, buena eficiencia *round-trip*, respuesta rápida y costos en disminución.

Como se ha destacado anteriormente, las energías renovables pueden ser intermitentes e impredecibles; por ello, la generación secundaria busca aportar mayor predictibilidad al flujo de la planta. En particular, el almacenamiento de energía permite que las fuentes renovables tengan una participación más activa en los mercados eléctricos, dotándolas de capacidad de respuesta ante las fluctuaciones de precio en los diferentes productos energéticos.

Además, estas plantas pueden contribuir a la eficiencia de producción, asegurando que la energía barata pueda ser suministrada en periodos de tiempo donde es más demanda, lo que se conoce como arbitraje de energía. Esto es especialmente útil para gestionar la demanda durante los picos de consumo y puede ayudar a reducir los vertimientos de energías, un problema creciente en el sistema eléctrico chileno, donde los vertimientos alcanzaron 1471 GWh en 2022 y 2615 GWh en 2023.

Otra aplicación es en los servicios complementarios, donde, gracias a su rápida respuesta, el sistema puede ofrecer regulación de frecuencia, tensión o capacidad de reserva. Destaca especialmente en la provisión de *spinning reserve* en comparación con otras alternativas.

Estos sistemas también presentan nuevos desafíos en su diseño, el cual depende en gran medida del contexto en el que se instala la planta. Factores como la disponibilidad del recurso primario, la prevalencia o escasez regional, los costos de las tecnologías y su evolución son cruciales para el desarrollo exitoso de las plantas híbridas. En la realidad chilena, aún se está esclareciendo el mejor método de participación en los distintos segmentos del sistema para que estos proyectos sean viables y atractivos para las inversiones.




Figura 2.1: Representación visual de una planta híbrida

La Figura 2.1 presenta una representación gráfica de una planta híbrida y sus flujos de energía. En la ilustración se distinguen tres componentes principales: el parque eólico, la red eléctrica y el sistema de almacenamiento de energía. Los flujos de energía se indican con flechas. El sistema de almacenamiento actúa como un complemento a las plantas que inyectan energía directamente, proporcionándoles una mayor capacidad de decisión y la posibilidad de absorber energía de la red cuando las condiciones lo permitan.

2.2. Mercados eléctricos

En su forma más general, el mercado eléctrico es un sistema organizado en el que generadores y consumidores convergen para establecer acuerdos mediante negociaciones. Las interacciones entre ambas partes determinan los precios de la electricidad, modelados por la intersección entre oferta y demanda. A diferencia de otros bienes, un aspecto único de este mercado es que la producción y el consumo deben mantenerse equilibrados en todo momento. Además, deben cumplirse diversas restricciones técnicas impuestas por la infraestructura, que aseguran una operación físicamente viable y contribuyen a la estabilidad y seguridad del sistema eléctrico. Para facilitar esta interacción bajo dichas restricciones, surge un tercer actor, el Operador Central o Coordinador, quien garantiza la eficiencia económica y la seguridad del sistema.

La teoría microeconómica sostiene que en un mercado de competencia perfecta, cuando las partes actúan individualmente buscando maximizar sus beneficios, se genera un resultado que optimiza el excedente total. Basándose en este principio, los mercados eléctricos han evolucionado a lo largo de los años, pasando de grandes industrias verticalmente integradas a estructuras segmentadas que fomentan la competencia en los segmentos donde es viable. Sin embargo, sectores como la transmisión y la distribución siguen siendo monopolios naturales debido a las características inherentes de su infraestructura.

En los mercados eléctricos, los precios desempeñan un papel crucial como señales resultantes de la resolución del problema de optimización sujeto a restricciones, reflejando de manera eficiente las condiciones de oferta y demanda, así como las limitaciones del sistema. Estos precios no solo indican dónde hay escasez o abundancia de recursos eléctricos, sino que también señalan la existencia de restricciones en la red de transmisión. Por ejemplo, cuando una línea de transmisión está congestionada, el precio de la electricidad puede aumentar en las barras eléctricas conectadas a dicha línea, alertando sobre la necesidad de ajustes en la generación o en la gestión del consumo. Esta dinámica de precios incentiva a los generadores y consumidores a modificar su producción y consumo, respectivamente, guiando el sistema hacia un equilibrio más eficiente y estable. Por lo tanto, los precios en los mercados eléctricos son esenciales para una asignación óptima de recursos y para garantizar la confiabilidad y eficiencia del suministro eléctrico, cumpliendo una función vital en la operación y planificación del sistema eléctrico.

Para fomentar la competencia y así acercarse más al ideal teórico que maximiza el excedente económico, se regula el mercado eléctrico. En esencia, esto implica establecer un conjunto de reglas y mecanismos que guían la interacción entre los distintos actores del mercado. El objetivo principal de esta regulación es asegurar que los precios de la energía reflejen fielmente las necesidades y oportunidades dentro del sistema eléctrico, promoviendo un mercado más eficiente y justo para todos los participantes.

2.2.1. Mercado basado en costos auditados

El mercado basado en costos auditados regula la generación de energía mediante un operador central que maneja información detallada sobre cada planta generadora y sus costos reales de producción, los cuales están directamente ligados al precio del recurso primario utilizado para la generación. Utilizando esta información, el operador central resuelve el problema de operación del sistema, priorizando el despacho de las unidades más económicas que cumplan con las restricciones del sistema.

En este modelo de mercado, los precios de transacción de la energía se determinan según la unidad marginalista, es decir, la central de generación más costosa que se despacha en un momento determinado. Esto asegura que el precio refleje el costo de satisfacer la última unidad de demanda bajo las condiciones actuales del sistema.

Uno de los motivos para emplear este modelo de mercado radica en la preocupación de las autoridades regulatorias sobre la posibilidad de que las empresas generadoras abusen de su poder de mercado para crear artificialmente escasez de recursos y aumentar los precios, lo que se conoce como ineficiencia de mercado. Sin embargo, según [6], este tipo de mercado solo puede limitar temporalmente el ejercicio del poder de mercado, ya que existe la posibilidad de que las empresas intenten ejercerlo a través de inversiones. Estas buscarán aumentar el número de horas durante el año en las que las centrales de alto costo determinen el precio marginal.

Otro argumento en contra de este diseño de mercado es la dificultad para calcular los costos reales de producción, lo que puede llevar a una operación subóptima. Los costos marginales de los generadores no solo dependen del costo del recurso primario, sino también de un costo de oportunidad. La información necesaria

para realizar estas estimaciones en tiempo real es difícil de obtener con precisión por parte del operador del sistema.

En el contexto chileno, el diseño del mercado eléctrico basado en costos auditados se estableció en 1982, cuando la matriz energética estaba compuesta principalmente por generación hidroeléctrica y termoeléctrica. Desde entonces, la matriz ha experimentado cambios significativos, con una creciente penetración de Energías Renovables No Convencionales (ERNC). Sin embargo, el diseño actual del mercado ha generado problemas para la viabilidad de las inversiones y el cumplimiento de las metas de descarbonización del sistema.

En el año 2022, varias empresas dedicadas a la generación solar declararon insolvencia financiera. Uno de los desafíos que enfrentan estas empresas es que en áreas del sistema con excedente de generación, los precios de remuneración de las plantas son cercanos a cero, ya que el recurso solar tiene un costo marginal casi nulo. Otras tecnologías, como el almacenamiento de energía, presentan un fuerte componente de costo de oportunidad, lo que limita su operación eficiente y afecta la rentabilidad de las inversiones en este tipo de infraestructura.

2.2.2. Mercado basado en ofertas

En un mercado basado en ofertas, los participantes proponen precios y volúmenes para inyectar o retirar energía del sistema. Con estas propuestas, el operador del sistema resuelve el problema de optimización y obtiene el despacho eficiente, cumpliendo con las restricciones del sistema. Aunque este análisis se centra en el mercado de energía eléctrica, es relevante señalar que otros productos, como los servicios complementarios y las reservas, también pueden ser cooptimizados y ofrecidos al operador de forma similar.

La política energética actual, según lo indicado por el Ministerio de Energía, requiere flexibilidad ante la creciente penetración de fuentes de energía renovable no convencional (ERNC), las cuales son intrínsecamente menos flexibles. El diseño del mercado podría necesitar actualizaciones para adaptarse mejor a las tecnologías emergentes.

En un mercado de ofertas, existen múltiples instancias horarias vinculantes para la transacción de energía, como los mercados *day-ahead*, intradiarios y en tiempo real. En el mercado *day-ahead*, los participantes transan energía basándose en sus proyecciones de generación y consumo, lo que establece precios para cada hora del día siguiente. El mercado *spot*, por su parte, actúa como una instancia de corto plazo donde las partes realizan transacciones según las condiciones actuales del sistema. Esto les permite ajustar y responder a cualquier desviación de las proyecciones hechas el día anterior. Dentro de este último, se incluyen tanto los mercados intradiarios como los de tiempo real.

Uno de los retos de este modelo de mercado es la posibilidad de que las empresas ejerzan su poder de mercado para influir en los precios a corto plazo. Para contrarrestar esto, es crucial implementar mecanismos de supervisión tanto estructurales, que identifican potenciales para ejercer dicho poder, como conductuales, que analizan y sancionan comportamientos que distorsionan la competencia.

Según informes internacionales, los mercados de ofertas pueden organizarse de diferentes maneras. Por ejemplo, los sistemas en Estados Unidos tienden a integrar más estrechamente las restricciones físicas del sistema, reduciendo la necesidad de servicios complementarios y limitando la flexibilidad para alcanzar acuerdos. En contraste, los sistemas europeos son más descentralizados, utilizan modelos simplificados de operación y dan mayor importancia a las negociaciones de mercado, facilitando los acuerdos bilaterales.

Las subastas también permiten la participación activa de la demanda, como clientes libres o comercializadoras, contribuyendo directamente a la flexibilidad que persigue la política energética, y permitiendo capturar mayor elasticidad en las curvas de demanda.

A pesar de centrarse en ofertas de mercado, los datos sobre costos auditados no son ignorados, sino que se utilizan como referencia para analizar el comportamiento de los participantes en el mercado. Según diversos estudios, un mercado de ofertas con varias etapas proporciona a los participantes una mayor flexibilidad para gestionar sus riesgos y posiciones con información más precisa a medida que se acercan a la operación en tiempo real.

2.3. Optimización secuencial bajo incertidumbre

La optimización secuencial bajo incertidumbre implica tomar decisiones en un futuro incierto, con recursos y capacidades limitadas, lo que se traduce en restricciones en las acciones que podemos tomar. Este campo es amplio e importante ya que, desde las áreas más simples de la vida (como comprar suministros o establecer una ruta de un viaje) hasta aplicaciones en áreas cruciales como la coordinación de una flota o un plan de negocios sobre un producto, estamos sujetos a eventos futuros de los cuales no tenemos certeza. Siempre estamos tomando decisiones que pueden no ser óptimas si conociéramos el futuro.

Este tipo de problemas puede ser bastante complejo y de gran tamaño, por lo que en lugar de resolverlo mentalmente, recurrimos a establecer un modelo del problema que estamos enfrentando. Uno de los primeros enfoques para resolver problemas con recursos limitados es la programación lineal, que se encarga de los problemas de optimización determinista, es decir, cuando tenemos certeza sobre el modelo que estamos implementando y el futuro proyectado no cambiará. En el contexto de la operación de sistemas de potencia, está el problema básico de *Unit Commitment*, en el cual buscamos tomar decisiones sobre las inyecciones de un grupo de generadores de tal forma que encontremos la combinación que minimice el costo de generar la energía necesaria para satisfacer la demanda del sistema, sujeto a las restricciones físicas del mismo.

Sin embargo, suponer que el mundo se comporta de manera predecible puede resultar muy costoso al operar el sistema. Esto se debe a que hay muchos aspectos difíciles de predecir, como los precios del mercado de la energía o de los *commodities*, la generación solar y eólica, y la demanda de los clientes. Aunque es posible predecir patrones en los movimientos de estas variables (cierta componente estacional), también tienen una componente de aleatoriedad que transforma el problema en uno aún más difícil de solucionar. Por ejemplo, podemos predecir las horas en que saldrá el sol sobre nuestra planta fotovoltaica, pero no tenemos el mismo grado de certeza sobre la dinámica de las nubes y cómo afectará a la generación. Hay una amplia gama de fuentes de incertidumbre, incluyendo los modelos utilizados, los cuales no garantizan ser una representación exacta del fenómeno estudiado.

La optimización secuencial bajo incertidumbre aborda esta gama de problemas donde estamos en un flujo continuo de toma de decisiones y recepción de información sobre las proyecciones realizadas y el estado de nuestro sistema. En [7] se propone que cualquier problema dentro de esta categoría puede ser modelado para su posterior resolución a partir de cinco elementos principales:

- Variables de estado : Abarca todo lo que debemos conocer para tomar la decisión en el tiempo t . Este estado tiene tres naturalezas: (i) física, asociada a sensores o mediciones, como la posición o el estado de la batería; (ii) información, que abarca aspectos más abstractos como el precio de los bienes o la demanda; (iii) conocimiento, relacionado con las verdaderas distribuciones de probabilidad sobre aspectos que creemos conocer.
- Variables de decisión: Son las acciones que tomaremos a partir de la información que tengamos en ese momento, por lo que dependen del estado del sistema. El objetivo de la resolución del problema es encontrar una estrategia o *policy* para lograr un desempeño bajo parámetros definidos.
- Información Exógena: Este tipo de información está asociada a la componente del futuro que no se puede predecir y que solo se conoce una vez tomadas las decisiones. Por ejemplo, podemos tener proyecciones sobre el precio de la energía, pero debido a su comportamiento aleatorio, nunca será igual al observado realmente. Se asocia con la componente no controlable y exterior del sistema.
- Funciones de transición: Son las ecuaciones que actualizan el estado del sistema a partir de nuestras decisiones, el estado actual y la información exógena. Aquí se describen las dinámicas del sistema y su evolución. Estas ecuaciones explican la naturaleza secuencial que enfrentamos, ya que nuestras acciones afectan al sistema y dichos cambios provocan que tomemos otras acciones según la estrategia definida.
- Función objetivo: A partir de las decisiones que tomamos, obtenemos ingresos o costos que buscaremos optimizar. Existen diversas formas de definir una función objetivo en torno a distintas métricas. La gran diferencia con el caso determinista es que se contempla un valor esperado, tomando el promedio sobre las fuentes de incertidumbre.

En resumen, las principales diferencias entre el problema determinista y la optimización secuencial bajo incertidumbre son (i) Al no tener certeza sobre el futuro, en lugar de buscar las decisiones óptimas buscamos una estrategia óptima que sea capaz de otorgar flexibilidad ante el futuro incierto. (ii) En lugar de optimizar

una función con parámetros conocidos, se optimiza una función de contribución que considera la información aleatoria que afecta el estado del sistema. (iii) Se utiliza un valor esperado para capturar todos los posibles futuros a enfrentar.

2.3.1. Programación Estocástica

La programación estocástica es una técnica crucial en la gestión de problemas donde los parámetros son inherentemente inciertos, como es común en el sector energético. Este método aprovecha el conocimiento de las distribuciones de probabilidad que rigen estos parámetros inciertos, derivado de datos históricos, por ejemplo, la producción variable de una planta eólica.

Utilizando estos datos, se modela el futuro a través de un enfoque probabilístico que identifica diversos escenarios, cada uno asignado con una probabilidad específica de ocurrencia. Por ejemplo, los escenarios podrían incluir un día ventoso, un día normal y un día con poco viento. Las probabilidades de cada escenario dependen de la muestra de datos históricos utilizada. La estrategia de decisión en este contexto busca optimizar con respecto al valor esperado de estos escenarios, es decir, un promedio ponderado según las probabilidades. Esto implica sacrificar la optimización perfecta en un escenario único a favor de obtener resultados robustos y aceptables sin importar cómo se desarrolle el futuro cercano.

Este enfoque permite simplificar la visión del futuro, modelándolo a través de la realización de distintos escenarios. Aunque esto convierte el problema estocástico en uno que puede ser tratado como determinista, también significa que estos problemas suelen ser más grandes en tamaño y demandan mayores recursos computacionales.

Una limitación importante de la programación estocástica es la denominada “maldición de la dimensionalidad” (*Curse of Dimensionality*), donde el número de escenarios posibles aumenta exponencialmente con cada variable adicional, lo que complica significativamente la resolución del problema y puede limitar la aplicabilidad del método en situaciones con múltiples incertidumbres y dimensiones.

2.3.2. Programación Robusta

En contraste con la programación estocástica, que considera múltiples escenarios con probabilidades asignadas, la programación robusta busca soluciones que sean válidas para todos los escenarios posibles dentro de un cierto conjunto de incertidumbres. En lugar de intentar predecir la probabilidad exacta de cada escenario, la programación robusta se centra en la creación de soluciones que sean robustas”, es decir, que funcionen bien bajo una amplia gama de condiciones.

Para el problema abordado en este trabajo, la programación robusta puede ser un método óptimo y viable, especialmente cuando se aplican penalizaciones por desviaciones entre los compromisos adquiridos en el mercado y la energía realmente inyectada por la planta. En este contexto, adoptar una estrategia conservadora puede conducir a mejores resultados, ya que los ahorros derivados de evitar penalizaciones podrían superar la diferencia de ingresos entre una estrategia conservadora basada en la optimización robusta y el enfoque de la programación estocástica.

2.3.3. Reinforcement Learning

A diferencia de la programación estocástica o robusta, que basan sus modelos en principios probabilísticos y deterministas, el *Reinforcement Learning* (aprendizaje por refuerzo) es una técnica de *Machine Learning* que imita el proceso de ensayo y error humano a través de un agente que interactúa con el entorno mediante una estrategia o *policy*. El agente es capaz de medir el estado actual del sistema, tomar una acción y recibir una recompensa o castigo de la misma, privilegiando así las acciones que maximicen la acumulación de recompensas. Además, es posible modificar el modelo para darle más o menos peso a las decisiones presentes sobre las de largo plazo.

La idea central de este método es aproximar el futuro incierto a través de aprender el valor $Q(s, a)$, que representa el valor de estar en un estado s del sistema y tomar la acción a . Esto se realiza a través de simulaciones computacionales donde el agente toma distintas acciones en cada instancia y recibe retroalimentación sobre si sus decisiones fueron acertadas o no a través de un *reward*. La *Q-function* es una aproximación de las posibles recompensas a obtener por el agente para los distintos futuros que continúan al par (estado,

acción) tomados en el presente. De esta manera, es posible que el agente aprenda las acciones individuales que ayudan a obtener un resultado final satisfactorio y cuáles no.

2.3.4. Redes Neuronales

Las redes neuronales son un método de inteligencia artificial que busca enseñar a las computadoras las reglas del conocimiento humano a través de la experiencia en forma de grandes conjuntos de datos. Están inspiradas en modelos que intentan recrear el funcionamiento del cerebro humano, es decir, neuronas interconectadas en una estructura por capas.

En general, las redes neuronales pueden resumirse como una serie de transformaciones tensoriales que toman los datos *input* y los transforman capa por capa hasta llevarlos a un espacio dimensional distinto donde es más sencillo asociar los datos con un *output* concreto. Similar a un proceso de destilado de la información para llevarla a su forma más pura.

Una de las desventajas es que son modelos con millones de parámetros, por lo que pueden tener una predisposición al *overfitting*. Para ello, el diseño de las redes caso a caso es un factor importante donde los usuarios definen los hiperparámetros del modelo asociado a distintas técnicas que buscan un modelo que generalice el reconocimiento de parámetros a datos más allá de los utilizados en su entrenamiento.

La principal diferencia entre los métodos robusto y estocástico y los modelos basados en redes neuronales radica en su enfoque hacia la incertidumbre y el aprendizaje. Los métodos robusto y estocástico aproximan la incertidumbre mediante modelos probabilísticos, asociando el futuro con diferentes escenarios posibles. En contraste, un modelo basado en redes neuronales se centra en aprender patrones y relaciones que definen el futuro a partir de una gran cantidad de datos históricos, sin asumir un modelo probabilístico explícito.

En el contexto de este trabajo, la red neuronal actúa como un agente de *Reinforcement Learning* que recibe como *input* el estado del sistema y da como *output* las acciones a tomar. La red neuronal es una función compleja que representará la *policy*.

Capítulo 3

Metodología

3.1. Supuestos

- La planta opera como un *price taker*, es decir, no puede influir en el precio de la energía a partir de sus inyecciones en el sistema
- Se establece una relación lineal entre los mercados *spot* de Chile y Real Time en California, esta relación se mantiene y es utilizada para estimar un mercado Day-Ahead en Chile a partir de la misma instancia en California.

3.2. Diagrama Procedimental

El primer paso fue estudiar el modelo descrito en el trabajo [1], el cual consta de cinco secciones principales, detalladas a continuación:

3.2.1. Preprocesamiento de datos

El preprocesamiento de datos es una fase crucial previa a la optimización del modelo, cuyo objetivo es limpiar, transformar y estructurar los datos en bruto, haciéndolos aptos para la red neuronal.

El primer paso es asegurar y completar todos los datos faltantes en las series de tiempo. Debido a la extensión de estas series, pueden existir valores vacíos o *NaN* causados por errores de recopilación o transmisión. Para la corrección, se emplean dos estrategias según la extensión de los datos faltantes. Si la ventana de datos faltantes es mayor a 30 días, se sustituyen por los datos de la misma fecha (mes, día y hora) del año anterior. Para intervalos menores a 30 días, los valores se estiman en función del promedio entre sus vecinos más cercanos o del valor de una hora específica desfasada un día.

Una vez completadas las series de tiempo, los datos se dividen en los conjuntos de *training*, *validation* y *test*. El conjunto de entrenamiento se utiliza para ajustar los parámetros internos de la red (pesos y *bias*) mediante la maximización del *reward*. El conjunto de validación sirve como una antesala al test, ayudando a escoger entre varios modelos entrenados con diferentes hiperparámetros. Estos hiperparámetros no son entrenables, sino definidos por el usuario o seleccionados aleatoriamente. El conjunto de validación permite establecer un criterio de selección entre modelos, aunque no garantiza un mejor rendimiento en el test. El conjunto de test se utiliza para evaluar el desempeño real del modelo frente a información nueva, no expuesta previamente, y será utilizado para comparar el modelo de redes neuronales con los de programación estocástica y robusta, según los objetivos definidos.

Por otra parte, se aplica una etapa de *normalization* debido a que los *inputs* están en distintas escalas (potencia, precios, entre otros), lo cual puede afectar el rendimiento de la red neuronal. Diferentes escalas de datos pueden sesgar los cálculos del gradiente al ajustar los parámetros. Para evitar esto, se utiliza la transformación *Min-Max* ϕ , que convierte las variables desde un dominio $[\check{c}, \hat{c}]$ a uno en $[-1, 1]$. Dado que la red neuronal trabajará en esta nueva escala, se debe definir ϕ^{-1} para devolver las salidas del modelo a la escala original.

$$\phi(x, \check{c}, \hat{c}) = \frac{2x - (\hat{c} + \check{c})}{\hat{c} - \check{c}} \quad (3.1)$$

$$\phi^{-1}(x, \check{c}, \hat{c}) = \frac{\check{c} + \hat{c} + x(\hat{c} - \check{c})}{2} \quad (3.2)$$

Además, para el caso de los precios de la energía, se aplica una transformación logarítmica con el objetivo de que su distribución se asemeje más a una normal, principalmente debido a su *skewness* (sesgo), ya que los datos presentan una cola larga hacia la derecha. La razón principal para buscar distribuciones normales es que pueden acelerar y facilitar el aprendizaje de las redes neuronales.

3.2.2. Generación de escenarios

Como se mencionó anteriormente, tanto la programación estocástica como la robusta abordan la incertidumbre del futuro mediante la generación de escenarios. Tras el preprocesamiento de los datos, el siguiente paso en el trabajo es la creación de estos escenarios, que serán utilizados para obtener los resultados a comparar con el modelo de inteligencia artificial.

Para ello, la estrategia propuesta en [1] consiste en realizar una búsqueda exhaustiva para el parámetro T , que indica cuántas horas considerar hacia el pasado con el fin de seleccionar los candidatos a la realización de las variables estocásticas de precio y generación. Se busca el valor de T que pueda proporcionar el mejor conjunto de candidatos basados en los patrones históricos de dichas variables.

El enfoque es recorrer una ventana continua de 30 días, evaluando cada día específico. Para cada día, se toma como punto de inicio las 10 AM y se considera un periodo de T horas hacia atrás. Estos datos históricos se comparan con el conjunto de datos de entrenamiento, seleccionando las 10 muestras que más se asemejen a la serie temporal de longitud T . Para medir la calidad de estos candidatos, las variables inciertas se proyectan a partir de las 10 AM en adelante y se comparan estas proyecciones con los valores reales. Dependiendo de las diferencias entre los valores reales y las proyecciones, se asigna un puntaje para ese día. El desempeño de un valor específico de T se determina promediando los puntajes obtenidos a lo largo de los 30 días. Este proceso se repite para un rango de valores de T definido entre 1 y 192 horas.




Figura 3.1: Generación de escenarios

La Figura 3.1 muestra gráficamente los resultados de esta etapa. Se realiza una proyección del futuro basada en siete posibles escenarios, representados por las curvas amarillas. Las curvas azules ilustran los perfiles más similares a la observación de las variables aleatorias, considerando un horizonte temporal T de 24 horas para los precios de la energía y 17 horas para la generación eólica.

3.2.3. Formulación del problema para la resolución estocástica y robusta

En esta sección se detalla la formulación del problema de operación de una planta eólica con almacenamiento, sujeta a la incertidumbre en el recurso de generación y en los precios. La formulación tiene como objetivo implementar los métodos estocástico y robusto, que servirán como comparación frente al método basado en inteligencia artificial.

El problema de operación presenta diferentes granularidades horarias: la participación en el mercado se mide en horas, mientras que la generación eólica y la energía en la batería se miden en minutos. Para convertir de potencia a energía, considerando estas distintas escalas temporales, se introducen los factores de conversión Δ^1 y Δ^{60} , que representan la equivalencia entre un *step* de una hora y uno de un minuto.

$$\Delta^1 = \frac{1}{60}[\text{h}] , \Delta^{60} = 1[\text{h}]$$

Los parámetros necesarios para formular el problema son:

$$h^{DA} = 14 \quad , \quad \Upsilon^{DA} = \left\{ 1, \dots, \frac{48 + h^{DA}}{\Delta^1} \right\} \quad , \quad \Xi = \{1, 2, \dots, 7\}$$

Primero, es necesario describir el proceso del mercado. La planta generadora debe presentar su esquema de inyección o retiro para las 24 horas de un día específico a las 10 de la mañana del día anterior. Por lo tanto, al momento de realizar la optimización, la empresa tendrá compromisos asociados al período previo. Debido a esto, se considera que la optimización se realiza con 14 horas de anticipación, asociadas al parámetro h^{DA} . El conjunto Υ^{DA} define el horizonte de simulación con granularidad por minuto. Para esto, el horizonte se divide por Δ^1 para convertir de horas a minutos. El conjunto Ξ corresponde al número de escenarios considerados para aproximar la incertidumbre de las variables.

Las variables de decisión son:

$$p_{t,\xi}^g \quad , \quad p_{t,\xi}^d \quad , \quad p_{t,\xi}^c \quad , \quad p_{h(t),\xi}^{DA} \quad , \quad \delta_{t,\xi}^+ \quad , \quad \delta_{t,\xi}^- \quad , \quad e_{t,\xi}^s \quad , \quad \forall t \in \Upsilon^{DA} \quad , \quad \forall \xi \in \Xi$$

La primera variable representa la generación de la planta, es decir, la inyección o el retiro de energía de esta. Luego están las potencias de descarga y carga de la batería, mientras que $p_{h(t),\xi}^{DA}$ representa los compromisos de operación suscritos en el mercado. Las variables δ indican los desequilibrios provocados por discrepancias entre la operación programada y la real. Finalmente, $e_{t,\xi}^s$ corresponde al nivel de energía almacenada en la batería.

La función objetivo se define en función del desempeño económico de la planta, asociado a las ventas en el mercado Day-Ahead, menos las penalizaciones por desviaciones de los compromisos:

$$\sum_{h=h^{DA}+1}^{h|\Upsilon^{DA}|} (\lambda_{t,\xi}^{DA} p_{t,\xi}^{DA}) \Delta^{60} + \sum_{t=1}^{|\Upsilon^{DA}|} \lambda^{imb} \left(|\delta_{t,\xi}^+| + |\delta_{t,\xi}^-| \right) \Delta^1 \quad , \quad \forall \xi \in \Xi \quad (3.3)$$

Es importante destacar que las ofertas en el mercado, representadas como $p_{t,\xi}^{DA}$, son únicas para todos los escenarios. Esto se debe a que se busca una solución determinista que sea válida en todos los casos, considerando el valor esperado en el enfoque estocástico y el peor caso en el enfoque robusto. Este planteamiento se implementa mediante una optimización en dos etapas: en la primera etapa, se obtiene una solución determinista para las primeras 24 horas; en la segunda, esta solución se ajusta con decisiones específicas para cada escenario en las siguientes 24 horas, justificando así un horizonte de planificación de 48 horas.

Las condiciones iniciales están definidas por las ofertas suscritas del período anterior que aún no se han materializado.

$$p_{t,\xi}^{DA} = \bar{p}_{t,\xi}^{DA}, \quad \forall h \in \{1, \dots, h^{DA}\}, \quad \forall \xi \in \Xi \quad (3.4)$$

$$e_{ini}^s = \bar{e}_{ini}^s, \quad \forall t \in \{1\}, \quad \forall \xi \in \Xi \quad (3.5)$$

Por último, las restricciones que rigen el problema son:

$$p_{t,\xi}^g = p_{t,\xi}^{eo} + p_{t,\xi}^d - p_{t,\xi}^c \quad \forall t \in \Upsilon^{DA}, \quad \forall \xi \in \Xi \quad (3.6)$$

$$p_{h(t),\xi}^{DA} = p_{t,\xi}^g + \delta_{t,\xi}^+ - \delta_{t,\xi}^- \quad \forall t \in \Upsilon^{DA}, \quad \forall \xi \in \Xi \quad (3.7)$$

$$\check{\alpha} \leq p_{h(t),\xi}^{DA} \leq \hat{\alpha} \quad \forall t \in \Upsilon^{DA}, \quad \forall \xi \in \Xi \quad (3.8)$$

$$e_{t,\xi}^s - e_{\text{ini}}^s = \left(\eta^c p_{t,\xi}^c - \frac{p_{t,\xi}^d}{\eta^d} \right) \Delta t \quad \forall t \in \{1\}, \quad \forall \xi \in \Xi \quad (3.9)$$

$$e_{t+1,\xi}^s - e_{t,\xi}^s = \left(\eta^c p_{t+1,\xi}^c - \frac{p_{t+1,\xi}^d}{\eta^d} \right) \Delta t \quad \forall t \in \Upsilon^{DA}, \quad \forall \xi \in \Xi \quad (3.10)$$

$$\check{e}_s \leq e_{t,\xi} \leq \hat{e}_s \quad \forall t \in \Upsilon^{DA}, \quad \forall \xi \in \Xi \quad (3.11)$$

$$0 \leq p_{t,\xi}^c \leq \hat{p}_s, \quad 0 \leq p_{t,\xi}^d \leq \hat{p}_s \quad \forall t \in \Upsilon^{DA}, \quad \forall \xi \in \Xi \quad (3.12)$$

La expresión (3.6) define la potencia real de la planta como la suma de la generación eólica y la actuación del almacenamiento. La ecuación (3.7) muestra cómo la diferencia entre los compromisos $p_{h(t),\xi}^{DA}$ y la generación $p_{t,\xi}^g$ es igual a los desequilibrios provocados en la red. El resto de las ecuaciones rigen las dinámicas de la batería, siendo (3.9) y (3.10) las que relacionan los cambios en la energía almacenada en función de las potencias de carga y descarga, con su respectiva eficiencia. Por último, (3.11) y (3.12) son restricciones técnicas de límites inferior y superior para la potencia de la batería y su energía.

Para la resolución de este problema, que se acaba de presentar, se debe llevar a cabo un script en Julia, que será resuelto con la ayuda del solver Gurobi. Dicho script resuelve los problemas estocástico y robusto, entregando las ofertas para las 24 horas del día siguiente. Para la resolución sobre una ventana de tiempo más amplia, se asocia con un *Jupyter Notebook* que itera sobre los días de *test* (que corresponden desde el 07-01-2020 hasta el 05-04-2020). Los resultados serán analizados en el capítulo 5 de este documento.

3.2.4. Sistema de control para la operación de la batería

El trabajo original [1] también presenta un sistema de control que opera la batería con el objetivo de minimizar los desequilibrios provocados por la operación real, sujeto a las restricciones del problema descrito en la sección anterior. El resultado son dos reglas de operación descritas de la siguiente manera:

$$p_t^c(p_t^*, e_{t-1}^s) = \mathbb{1}(p_t^* \leq 0) \min \left\{ \overset{\textcircled{1}}{-p_t^*}, \overset{\textcircled{2}}{\frac{\hat{e}^s - e_{t-1}^s}{\eta^c \Delta^1}}, \overset{\textcircled{3}}{\hat{p}^s} \right\}$$

$$p_t^d(p_t^*, e_{t-1}^s) = \mathbb{1}(p_t^* > 0) \min \left\{ \overset{\textcircled{4}}{p_t^*}, \overset{\textcircled{5}}{\frac{\eta^d (e_{t-1}^s - \check{e}^s)}{\Delta^1}}, \overset{\textcircled{6}}{\hat{p}^s} \right\}$$

En resumen, esta ley de control establece que, dependiendo de la potencia de entrada a la batería p_t^* , existe la posibilidad de ajustar dicha potencia, ya sea para cargar o descargar, con el fin de minimizar los desequilibrios provocados. Por ello, y dependiendo de si p_t^* es positivo o negativo (indicando carga o descarga mediante el operador $\mathbb{1}$), se escoge el mínimo entre tres opciones. Esto se ilustra en la figura 3.2. Siempre que la potencia de entrada no supere la potencia máxima de la batería $\hat{p}^s$ y la energía almacenada esté lejos de los límites mínimo o máximo, se opera en las zonas de operación normal $\textcircled{1}$ o $\textcircled{4}$, donde no se producen desbalances.

Por otro lado, si la potencia de entrada supera el límite técnico, solo es posible cargar o descargar según dicho límite, lo que genera desbalances debido a la diferencia entre p_t^* y $\hat{p}^s$ en las zonas $\textcircled{3}$ y $\textcircled{6}$. Finalmente, si los niveles de energía están muy cerca de los límites de operación, no es posible para la batería operar según p_t^* , y la operación se define por el nivel disponible, correspondiente a las zonas $\textcircled{2}$ y $\textcircled{5}$.




Figura 3.2: Representación gráfica del control de la batería

3.2.5. Entrenamiento de redes

En esta sección se describe cómo se modificó el proceso de entrenamiento del trabajo original [1] para adaptarlo a las necesidades actuales. Uno de los primeros cambios relevantes es que, dado que el análisis se centra en el mercado Day-ahead, y específicamente en el de energía, solo se utiliza un agente en la red neuronal original, descartando el agente encargado de la operación en tiempo real. Además, no se consideran los productos de servicios complementarios de reserva hacia arriba y hacia abajo, lo que reduce la cantidad de inputs del modelo.

La información de entrada al modelo está en forma de *buffer rolls*, que son estructuras de datos utilizadas para manejar información secuencial. En otras palabras, estas estructuras encapsulan las series de tiempo necesarias para la simulación y evaluación de las decisiones secuenciales del modelo de aprendizaje automático. Cada *buffer roll* está asociado a un día específico.

El contenido de cada *buffer roll* esta compuesto por:

- **Información de entrada:** Series de tiempo de los precios de mercado, generación eólica y representaciones temporales bidimensionales.
- **Información de control:** Series temporales que contribuyen a la simulación de la operación controlada del PV-ESS, manteniéndose en su forma original para no distorsionar la simulación.
- **Condiciones iniciales:** Decisiones de mercado y energía almacenada al inicio del horizonte de simulación, necesarias tanto para las entradas de los MVANNs como para la simulación.

El proceso de entrenamiento sigue los siguientes pasos:

1. Inicializar los hiperparámetros y pesos de la red neuronal.
2. Para cada iteración del conjunto de entrenamiento o *epoch*:
 - a) Separar los datos en *mini batches* de *buffer rolls*:
 - i.- Recorrer por hora el horizonte de cada *buffer roll*.
 - ii.- Obtener las ofertas Day-ahead para las próximas 24 horas.
 - iii.- Para cada hora con ofertas designadas, obtener la operación de la batería y los desbalances a partir del control.
 - iv.- Actualizar los pesos del modelo.
 - b) Actualizar las condiciones iniciales del siguiente *buffer roll* a partir de las ofertas obtenidas.
 - c) Calcular el *reward* sobre el *mini batch*.
 - d) Actualizar los pesos de la red.

El primer paso para entrenar la red neuronal es la selección de los hiperparámetros. Sin entrar en complejidades, estos corresponden a números enteros obtenidos a partir de elecciones aleatorias dentro de un rango definido por el diseñador de la red. Los hiperparámetros incluyen el número de unidades en las capas LSTM, encargadas del procesamiento de series temporales, así como el número de neuronas en las demás capas de la red.

En general, hiperparámetros que definen redes más complejas pueden mejorar la capacidad del modelo para comprender la relación entre los datos de entrada y el *reward*. Sin embargo, dado que se busca un modelo que generalice en lugar de especializarse en los datos de entrenamiento, se entrenan varios modelos con diferentes combinaciones de hiperparámetros.

Los pesos de la red se actualizan con el objetivo de maximizar el desempeño económico sobre un *mini batch*, que en este caso es un subconjunto de 16 días. Este enfoque permite calcular un gradiente más representativo del conjunto de datos, lo cual conduce a una convergencia más rápida y estable.

3.3. Descripción general de los datos

3.3.1. Cabo Leones I

Los datos de generación eólica utilizados en las simulaciones se obtuvieron del sitio web del Coordinador Eléctrico Nacional (<https://www.coordinador.cl/operacion/graficos/operacion-real/>), cubriendo el período del 1 de septiembre de 2021 al 31 de diciembre de 2022. Mientras que los datos de precios son de la barra Maitencillo 220kV.

Es importante señalar que el Coordinador entrega los datos en intervalos horarios, mientras que en este trabajo se requirió una resolución por minuto. Para ello, los datos fueron adaptados mediante interpolación, generando la granularidad necesaria para los análisis.




Figura 3.3: Datos de generación Cabo Leones I

La Figura 3.3 muestra el perfil diario de la generación eólica, evidenciando su naturaleza estocástica y la amplia variabilidad en sus niveles de producción. Las líneas punteadas indican los percentiles 25, 50 y 75, permitiendo observar un patrón cíclico con picos de generación en horas de la tarde y noche, y niveles más bajos durante el día. Inicialmente, se observa que la generación coincide con los periodos de precios altos, lo que sugiere que la batería debería desempeñar un papel de respaldo para asegurar el cumplimiento de los compromisos de venta.

Dado que en Chile aún no existe un mercado Day-Ahead para las inyecciones y retiros de energía, se recurrió a datos del sistema de potencia de California, EE.UU., disponibles en el sistema OASIS de acceso abierto del ISO de California. Estos datos incluyeron información de los mercados de *Real Time* y *Day Ahead*. Para estimar un mercado Day-Ahead hipotético en Chile, se desarrolló un modelo lineal que relaciona el mercado *spot* chileno con el *Real Time* de California, permitiendo escalar una referencia para un potencial mercado en Chile.




Figura 3.4: Datos del Mercado Cabo Leones I

En la Figura 3.4 se muestra cómo los precios tienden a ser altos durante la noche y la madrugada en comparación con las horas del día, donde la alta penetración de energía solar causa una disminución en los precios. Esta variación revela oportunidades para el arbitraje de energía, considerando la posibilidad de retirar energía de la red y así maximizar los beneficios económicos.

3.3.2. Santiago Solar

Los datos de generación de la planta Santiago Solar abarcan desde el 1 de enero de 2020 hasta el 31 de diciembre de 2022, y los precios de energía correspondientes se obtuvieron en la barra Las Vegas 110kV.




Figura 3.5: Datos de generación Santiago Solar

La Figura 3.5 presenta el perfil diario de generación solar, mostrando un patrón estocástico, aunque más controlado y predecible en comparación con la generación eólica. Las variaciones estacionales crean dos subconjuntos de curvas, asociados a los periodos de días más largos y más cortos del año. También es notable el patrón de generación máxima en la mañana y tarde, disminuyendo hacia la noche, lo cual plantea la posibilidad de almacenar energía para desplazarla a horas de mayor valorización.




Figura 3.6: Datos del Mercado para Santiago Solar

La Figura 3.6 muestra los precios de la energía en la barra Las Vegas 110kV, cercana al punto de conexión de Santiago Solar. Al tratarse de una zona céntrica, la variación de precios entre el día y la noche es menor que en el norte del país, reflejando la menor penetración solar en esta región.

3.3.3. Distintos criterios de operación para el almacenamiento

Considerando que uno de los objetivos específicos de este trabajo es utilizar los métodos mencionados bajo distintos criterios de operación del sistema de almacenamiento, fue necesario definir ciertos parámetros sobre las características técnicas de la planta y su interacción con el mercado.

En términos de operación de la planta, se consideran dos escenarios: (i) solo es posible inyectar potencia, y (ii) además de la inyección, la planta puede realizar retiros de potencia. Por otra parte, se consideran dos casos para el tamaño de la batería utilizada: (i) el 25 % de la potencia nominal del parque, y (ii) el 75 % de la potencia nominal. Con esto, se estudiarán cuatro casos por planta, correspondientes a las combinaciones entre los escenarios de operación y los tamaños de batería. En las tablas 3.1 y 3.2 se presentan los parámetros de cada caso.

Caso	p_s [MW]	$\hat{e}_s$ [MWh]	$\check{e}_r$ [MWh]	η_c	η_d	$\check{\alpha}$ [MW]	$\hat{\alpha}$ [MW]	λ_{imb} [\$/MWh]
Potencia de batería 25 % de P_{nom} sin retiros	28.7	150	15	0.9	0.95	0	145	200
Potencia de batería 25 % de P_{nom} con retiros	28.7	150	15	0.9	0.95	-30	145	200
Potencia de batería 75 % de P_{nom} sin retiros	86.2	429.2	47.1	0.9	0.95	0	200	200
Potencia de batería 75 % de P_{nom} con retiros	86.2	429.2	47.1	0.9	0.95	-90	200	200

Tabla 3.1: Parámetros del sistema de almacenamiento y generación para Santiago Solar.

Caso	p_s [MW]	$\hat{e}_s$ [MWh]	$\check{e}_r$ [MWh]	η_c	η_d	$\check{\alpha}$ [MW]	$\hat{\alpha}$ [MW]	λ_{imb} [\$/MWh]
Potencia de batería 25 % de P_{nom} sin retiros	43.8	218	23.8	0.9	0.95	0	220	200
Potencia de batería 25 % de P_{nom} con retiros	43.8	218	23.8	0.9	0.95	-50	220	200
Potencia de batería 75 % de P_{nom} sin retiros	131.6	655.3	72	0.9	0.95	0	320	200
Potencia de batería 75 % de P_{nom} con retiros	131.6	655.3	72	0.9	0.95	-150	320	200

Tabla 3.2: Parámetros del sistema de almacenamiento y generación para Cabo Leones I.

Capítulo 4

Resultados

4.1. Santiago Solar

En esta sección se presentan los resultados obtenidos para la planta fotovoltaica Santiago Solar, poniendo énfasis en cómo los distintos métodos de optimización enfrentan los desafíos inherentes a la operación de un sistema basado en generación solar. La intermitencia y, a la vez, previsibilidad general del recurso solar ofrecen una oportunidad única para analizar estrategias de planificación bajo incertidumbre moderada, donde la variabilidad diaria y estacional juega un rol fundamental.

El análisis se centra en un periodo de tres meses representativo, estructurado en cuatro subsecciones principales: perfil de operación, desempeño económico, ciclado de la batería, y gestión de desbalances de generación y compromisos de inyección. Estas subsecciones profundizan en los aspectos técnicos y económicos, permitiendo comparar el desempeño de los métodos de Programación Robusta, Programación Estocástica y *Deep Reinforcement Learning* (DRL).

4.1.1. Perfil de Operación

El propósito de esta subsección es proporcionar una visión inicial del proceso de toma de decisiones de los métodos de optimización y cómo estos responden a las condiciones del mercado y a las restricciones operativas de la planta. Este análisis permite no solo identificar el comportamiento estratégico de cada método frente a escenarios de incertidumbre, sino también destacar patrones clave en el uso de los recursos disponibles y en los desbalances generados.

La Figura 4.1 muestra gráficamente la operación de la planta durante un día representativo del *test set*, considerando los precios de la energía para esa jornada, los cuales están representados por la curva roja en la primera fila. Las filas inferiores ilustran las decisiones de oferta de energía realizadas en función de dichos precios y de la generación renovable disponible, representada por la curva naranja. Las gráficas de la columna izquierda corresponden a escenarios en los que se permite el retiro de energía desde la red, mientras que las de la derecha reflejan escenarios en los que esta opción está restringida.

Además, las áreas sombreadas en verde destacan la energía que no pudo ser entregada, generando desbalances en el sistema. Estos desbalances son principalmente consecuencia de las limitaciones técnicas de energía y potencia en la batería, así como de las decisiones dinámicas tomadas bajo incertidumbre. Este análisis preliminar es fundamental para entender las diferencias operativas entre los métodos y cómo estas afectan el desempeño global de la planta, tanto a nivel técnico como económico.




Figura 4.1: Operación de los distintos métodos para un día del *test set* considerando retiros, Santiago Solar.

Al analizar las diferencias entre los métodos para este y otros perfiles diarios de operación, se destaca una característica relevante: la respuesta más pronunciada en el uso de la capacidad de potencia de la batería. Tanto la programación robusta como la estocástica tienden a utilizar la batería de manera más agresiva, alcanzando frecuentemente valores cercanos a su potencia nominal, en comparación con el método basado en *Deep Reinforcement Learning*. Esto se aprecia gráficamente en los diagramas de la columna derecha, donde la potencia de la batería corresponde a la pendiente de la curva del estado de carga. Este enfoque más exhaustivo refleja un uso intensivo del recurso, lo que podría impactar su vida útil a largo plazo.

En este día en particular, también es evidente otro aspecto clave que distingue a los métodos: los desbalances generados por la discrepancia entre los compromisos asumidos y la energía realmente inyectada. Estos desbalances conllevan pagos adicionales por parte de la planta, los cuales, como se discutirá más adelante, tienen un impacto significativo en el desempeño económico global del sistema. Debido a la naturaleza dinámica del problema, donde la información se revela progresivamente con el paso del tiempo, las decisiones tomadas en días anteriores (reflejadas, por ejemplo, en un mayor nivel de carga inicial en la batería) pueden repercutir negativamente en días posteriores. Esto se manifiesta en la incapacidad de cumplir con los compromisos de inyección o retiro en determinados períodos.

Por último, es destacable que todos los métodos logran adaptarse a los períodos de precios bajos, particularmente entre la una y las ocho de la tarde. En estas ventanas, se observa una estrategia consistente: los compromisos asumidos tienden a situarse por debajo de la generación del parque fotovoltaico. Esta decisión permite acumular energía en la batería, incrementando su nivel de carga durante estas horas. Posteriormente, la batería se descarga cuando los precios son más altos, maximizando así los ingresos económicos de la planta.

4.1.2. Desempeño Económico

En esta subsección se analiza el desempeño económico de los métodos implementados, utilizando como referencia el gráfico de la Figura 4.2. En dicho gráfico se representa, para cada caso, los ingresos por venta de energía (eje y) y las pérdidas asociadas a los pagos por desbalances (eje x). Los puntos que se ubican más cerca de la esquina superior derecha corresponden a aquellos con un mejor desempeño económico neto, ya que combinan altos ingresos con bajas pérdidas.




Figura 4.2: Desempeño económico para los distintos casos y métodos en Santiago Solar.

Cada punto en el gráfico está representado por un símbolo específico que corresponde a los cuatro casos analizados: (i) batería equivalente al 25 % de la potencia de la planta sin retiros, (ii) batería al 25 % con retiros, (iii) batería al 75 % sin retiros y (iv) batería al 75 % con retiros. El color del punto indica el método utilizado (*Deep Reinforcement Learning*, Programación Robusta o Programación Estocástica), tal como se detalla en la leyenda.

Los resultados evidencian que el caso con el mejor desempeño económico es el correspondiente al **método DRL con batería al 75 % de la potencia nominal de la planta y con retiros permitidos**, alcanzando una ganancia neta de 3.8 millones de dólares. Este caso combina ingresos elevados con los menores pagos por desbalances dentro de su categoría. Aunque sus ingresos son similares a otros casos con batería al 75 % (como el DRL sin retiros y la Programación Estocástica con y sin retiros), la diferencia radica en los pagos por desbalances, los cuales son aproximadamente la mitad que en los casos de Programación Estocástica.

En contraposición, el método basado en **Programación Robusta** muestra el peor desempeño económico global. En los cuatro casos analizados, sus ganancias netas son significativamente menores en comparación con los otros métodos, lo que refleja tanto menores ingresos como mayores pérdidas por desbalances.

Un aspecto importante a destacar es que **aumentar el tamaño de la batería tiene un impacto positivo en el desempeño económico para todos los casos estudiados**. Los escenarios con baterías al 75 % de la potencia de la planta presentan consistentemente mayores ingresos y menores pérdidas por desbalances en comparación con aquellos donde la batería equivale al 25 %. Esto se debe a la mayor capacidad para gestionar las variaciones en la generación y la demanda, lo que reduce las penalizaciones asociadas a los desbalances.

Otro punto relevante es que, **en general, los casos que permiten retiros desde la red tienden a mostrar un peor desempeño económico en comparación con sus contrapartes sin retiros**, salvo el caso del DRL con batería pequeña (25 %). Esto se debe a que los ingresos por venta de energía son similares en ambos escenarios, mientras que los pagos por desbalances aumentan al incluir los retiros. Esto refuerza la idea de que la estrategia de retiro debe evaluarse cuidadosamente, considerando no solo el impacto en los ingresos, sino también en las pérdidas asociadas.

Finalmente, los resultados resaltan la eficiencia económica del método DRL, especialmente en escenarios con baterías grandes (75 % de la potencia de la planta), al demostrar una capacidad superior para minimizar las pérdidas por desbalances mientras se mantienen ingresos competitivos. Este comportamiento refuerza su utilidad no solo como una estrategia de optimización económica, sino también como una solución que mejora la sostenibilidad técnica y financiera de las operaciones.

4.1.3. Ciclado de la Batería

Para esta subsección se analiza el impacto de las decisiones operativas en el uso de la batería, comparando los métodos implementados en función del parámetro denominado "Número de ciclos". Este parámetro se define como el cociente entre la energía total inyectada por la batería a la red y la energía máxima nominal del sistema de almacenamiento.




Figura 4.3: Número de ciclos de batería para los distintos casos y métodos, Santiago Solar.

La Figura 4.3 ilustra la comparación del número de ciclos de la batería para los cuatro casos analizados, considerando los métodos de optimización implementados. Cada barra representa el número de ciclos acumulados en tres meses de operación, y se agrupan por caso para facilitar la comparación entre métodos.

Las diferencias en el ciclado de la batería son más marcadas en los casos donde la potencia de la batería equivale al 75 % de la potencia nominal de la planta. En estos escenarios, los métodos de Programación Robusta y Estocástica muestran un uso más intensivo de la batería, alcanzando valores significativamente más altos. Esto sugiere que estos métodos tienden a maximizar el aprovechamiento de la capacidad de almacenamiento para satisfacer compromisos de venta o realizar arbitraje energético.

Además, como era de esperarse, los casos que permiten el retiro de energía desde la red presentan un mayor número de ciclos en comparación con aquellos donde esta opción está restringida. Esto se debe a la mayor cantidad de energía disponible para su gestión, lo que incrementa la actividad de carga y descarga en el sistema de almacenamiento.

Por otro lado, el método basado en DRL exhibe una estrategia más conservadora en el uso de la batería, logrando un número de ciclos aproximadamente **25 % a 30 % menor** en comparación con los otros dos

métodos. Esta reducción es relevante en el contexto de la degradación del sistema de almacenamiento, ya que un menor número de ciclos se traduce en una vida útil más prolongada de la batería. Según la referencia [9], las baterías de litio experimentan una pérdida de aproximadamente el 20 % de su capacidad después de alcanzar entre 500 y 2,000 ciclos, dependiendo de la tecnología. La referencia [8] señala que los fabricantes están avanzando hacia baterías con una *cycle life* de hasta 10,000 ciclos, lo que podría mitigar los efectos de un uso intensivo.

Caso	Programación Robusta	Programación Estocástica	Deep Reinforcement Learning
25 % Sin retiros	7.8	9.4	13
25 % Con retiros	6.4	7.4	7.3
75 % Sin retiros	7.7	7.8	10.6
75 % Con retiros	5.7	6.2	9.1

Tabla 4.1: Cantidad de años estimados para alcanzar los 2,000 ciclos, Santiago Solar.

La Tabla 4.1 presenta el tiempo estimado para alcanzar el umbral de 2,000 ciclo. Estos valores se obtuvieron bajo el supuesto de que las tendencias observadas en tres meses son representativas a largo plazo. Se observa que el método DRL prolonga significativamente este tiempo, reforzando su perfil de operación conservador.

Esto sugiere que el método DRL no solo optimiza los beneficios económicos, sino que también ofrece un enfoque sostenible para el uso de la batería, lo que resulta en menores costos de mantenimiento y reemplazo a largo plazo.

Además, es importante considerar que la disminución de la capacidad de almacenamiento debido a la degradación de la batería tendrá un impacto directo en la resolución del problema de optimización. A medida que la capacidad de la batería se reduzca con el tiempo, los parámetros operativos deberán ajustarse, lo que podría afectar negativamente el desempeño económico de la planta. Esto refuerza la importancia de estrategias que minimicen el uso excesivo del almacenamiento, como las implementadas en el método DRL, para preservar tanto la funcionalidad del sistema como su viabilidad económica a largo plazo.

4.1.4. Gestión de Energía y Análisis de Desbalances

En esta sección, se busca profundizar en las causas subyacentes a los resultados económicos obtenidos, analizando la capacidad de los métodos de predecir y gestionar la generación de energía del parque fotovoltaico. Los desbalances surgen como consecuencia de las limitaciones del sistema de almacenamiento para satisfacer los compromisos establecidos, ya sea por restricciones de energía (quedarse sin carga o no poder almacenarla en su totalidad) o de potencia (no ser capaz de absorber toda la generación instantánea o inyectar al ritmo requerido).

Un análisis inicial se realiza mediante el gráfico de energía ofertada e inyectada de la Figura 4.4. Sin embargo, este enfoque tiene ciertas limitaciones, ya que valores negativos de subgeneración pueden cancelarse con valores positivos de sobregeneración, ocultando los niveles de incumplimiento. Por ejemplo, los métodos de programación robusta, que presentan los niveles más bajos de cumplimiento general, no se ven tan perjudicados en este gráfico debido a este efecto compensatorio.




Figura 4.4: Energía Ofertada e Inyectada para cada caso y método. Santiago Solar

La principal observación sobre el gráfico de la Figura 4.4 es la tendencia de las soluciones obtenidas mediante DRL a sobreofertar energía. Este patrón puede ser un síntoma de dificultades para proyectar adecuadamente la disponibilidad del recurso fotovoltaico, lo que genera estrategias conservadoras que terminan inyectado en menor cantidad de los compromisos suscritos.




Figura 4.5: Sobre y subgeneración para cada caso y método, Santiago Solar

En general, las soluciones DRL tienden a tener bajos niveles desbalances de sobregeneración y una alta subgeneración. Esto está alineado con observaciones previas respecto al menor ciclado de la batería: las estrategias de DRL utilizan menos intensamente el recurso de almacenamiento, lo que resulta en niveles más bajos de carga promedio y menor capacidad para cubrir las diferencias cuando la generación es inferior a lo proyectado. Aunque este aspecto es una desventaja para esta estrategia, ofrece ventajas como una vida útil más prolongada de la batería.

En términos de cumplimiento de cada solución (calculado como porcentaje del total de desbalances respecto

a la energía ofertada) y que se muestra sobre cada punto en la figura 4.5. Los resultados muestran diferencias importantes entre los métodos y los casos estudiados:

- Programación Estocástica: Mantiene niveles consistentes de cumplimiento, entre el 92 % y el 93 %, logrando un balance adecuado entre sobregeneración y subgeneración.
- Programación Robusta: Presenta los niveles más bajos, en torno al 85 %, debido a estrategias que favorecen escenarios conservadores pero que resultan en mayores desbalances.
- DRL: Muestra una mayor variabilidad según el tamaño de la batería y la consideración de retiros, con un cumplimiento que va desde el 84 % (batería pequeña sin retiros) hasta el 95 % (batería grande sin retiros).

El análisis de los retiros desde la red indica que su impacto en los desbalances es variable. En los métodos de programación estocástica y robusta, los retiros no afectan significativamente los resultados. Sin embargo, en el caso de DRL, los retiros ayudan a reducir los desbalances para configuraciones con baterías pequeñas, mientras que con baterías más grandes generan un efecto adverso.

El impacto del tamaño de la batería es especialmente notable en las soluciones DRL. Los casos con baterías más grandes logran mitigar significativamente los problemas de subgeneración, optimizando el desempeño general. Esto se debe a una mayor capacidad para almacenar energía en momentos de abundancia y utilizarla para cumplir compromisos cuando la generación real es insuficiente.

Los desbalances no solo son un reflejo de las limitaciones físicas del sistema (almacenamiento y potencia), sino también de la capacidad de los métodos para tomar decisiones dinámicas bajo incertidumbre. La programación estocástica logra un mejor balance entre sobregeneración y subgeneración, mientras que DRL, aunque más conservador, introduce ventajas relacionadas con la vida útil de la batería.

4.2. Cabo Leones I

En esta sección, se presentan los resultados correspondientes a la planta eólica Cabo Leones I, destacando su comportamiento operativo y económico bajo los mismos métodos de optimización utilizados previamente en el análisis de la planta solar. Debido a la naturaleza intermitente y variable de la generación eólica, las estrategias de gestión de energía en este contexto enfrentan desafíos particulares, como la necesidad de prever fluctuaciones más rápidas e intensas en la disponibilidad del recurso energético.

Al igual que en el caso solar, este análisis abarca un periodo representativo de tres meses, dividido en subsecciones que permiten explorar en profundidad los aspectos más relevantes: el perfil de operación, el desempeño económico, el impacto en el ciclado de la batería, y la capacidad para gestionar desbalances de generación y compromisos de inyección.

Dado que los patrones de generación eólica presentan diferencias significativas respecto a los solares, se espera que los métodos implementados muestren adaptaciones específicas, lo que permite identificar las fortalezas y debilidades de cada enfoque. Este análisis es crucial no solo para evaluar la eficiencia técnica y económica de la planta eólica, sino también para identificar estrategias que puedan ser escalables a otros sistemas con características similares.

4.2.1. Perfil de Operación

En esta subsección se analiza el comportamiento operativo de los métodos de optimización para la planta eólica Cabo Leones I, con énfasis en las decisiones relacionadas con el uso de la batería y la interacción con la red. Este análisis permite identificar cómo cada enfoque responde a las condiciones del mercado y a la generación renovable disponible, destacando las diferencias clave en el manejo de la incertidumbre y los patrones operativos.

La Figura 4.6 ilustra la operación de la planta para un día representativo del *test set*, mostrando la evolución de los precios de energía (curva roja) y las decisiones de oferta y retiro de energía en función de la generación eólica (curva naranja). Las columnas comparan escenarios con y sin la posibilidad de realizar retiros desde la red, mientras que las áreas sombreadas en verde representan los desbalances generados.




Figura 4.6: Operación de los distintos métodos para un día del *test set* considerando retiros, Cabo Leonés I.

Los tres métodos presentan un comportamiento coherente en cuanto al uso estratégico de la batería: durante las horas de menor precio, principalmente entre las 9:00 y las 17:00, esta se carga para luego descargarse en los períodos de mayor rédito económico. Este patrón refleja una planificación eficiente que aprovecha las señales de mercado para maximizar los ingresos.

En los escenarios con retiros de energía, se observa que estos tienden a concentrarse en los horarios de menor precio y menor generación eólica, lo que resulta consistente con las limitaciones operativas de la batería. Pasado este intervalo, la generación eólica comienza a aumentar significativamente, superando la capacidad de la batería para absorber potencia adicional mientras retira energía de la red.

Otro aspecto interesante es la actividad operativa durante la madrugada, especialmente en respuesta a señales de precio que, aunque no alcanzan los niveles del horario punta, son más atractivas en comparación con los precios diurnos. Este comportamiento es más pronunciado en la programación robusta y estocástica, donde las decisiones tienden a anticiparse a estas oportunidades, mientras que el método DRL muestra una menor variabilidad en este período.

Por último, todos los métodos presentan una estrategia consistente de moderar los compromisos asumidos

durante las horas de precios bajos, lo que permite utilizar la batería para gestionar desbalances y mejorar la flexibilidad operativa. Sin embargo, las decisiones tomadas en días previos, como un nivel de carga inicial elevado, pueden limitar la capacidad de reacción a corto plazo, especialmente frente a escenarios de alta generación eólica o fluctuaciones en el mercado.

4.2.2. Desempeño Económico

En esta subsección se analiza el desempeño económico de los métodos implementados, utilizando como referencia el gráfico de la Figura 4.7. En dicho gráfico se representa, para cada caso, los ingresos por venta de energía (eje y) y las pérdidas asociadas a los pagos por desbalances (eje x). Los puntos que se ubican más cerca de la esquina superior derecha corresponden a aquellos con un mejor desempeño económico neto, ya que combinan altos ingresos con bajas pérdidas.




Figura 4.7: Desempeño económico para los distintos casos y métodos en Cabo Leones I.

Cada punto en el gráfico está representado por un símbolo específico que corresponde a los cuatro casos analizados: (i) batería equivalente al 25 % de la potencia de la planta sin retiros, (ii) batería al 25 % con retiros, (iii) batería al 75 % sin retiros y (iv) batería al 75 % con retiros. El color del punto indica el método utilizado (*Deep Reinforcement Learning*, Programación Robusta o Programación Estocástica), tal como se detalla en la leyenda.

Los resultados evidencian que el caso con el mejor desempeño económico es el correspondiente al **método de Programación Estocástica con batería al 75 % de la potencia nominal de la planta y con retiros permitidos**, alcanzando una ganancia neta de 5.2 millones de dólares. Este desempeño superior se debe a una combinación de altos ingresos por ventas de energía y menores pagos por desbalances, lo que sugiere que este método cumple de manera más eficiente el objetivo de maximizar la venta de energía en periodos de alto precio, al mismo tiempo que gestiona adecuadamente las limitaciones técnicas de la batería y la planta.

Por otra parte, el método basado en **Programación Robusta** y el **DRL** comparten niveles de desempeño similares, con ganancias netas notablemente inferiores al caso de Programación Estocástica. Este menor desempeño podría estar relacionado con diferencias en la estrategia de optimización y la capacidad para gestionar las limitaciones técnicas y económicas del sistema, aspectos que serán analizados con mayor detalle en las siguientes subsecciones.

Un aspecto importante a destacar es que **aumentar el tamaño de la batería tiene un impacto positivo en el desempeño económico para todos los métodos estudiados**. Los escenarios con baterías al 75 % de la potencia de la planta presentan consistentemente mayores ingresos y menores pérdidas por desbalances en comparación con aquellos donde la batería equivale al 25 %.

Otro punto relevante es que, **en general, los casos que permiten retiros desde la red tienden a mostrar un mejor desempeño económico en comparación con sus contrapartes sin retiros**. Esto es particularmente evidente en escenarios con baterías grandes (75 %), donde los retiros ayudan al aumento de los ingresos por concepto de venta de energía.

Finalmente, los resultados resaltan la eficiencia económica del método de Programación Estocástica, especialmente en escenarios con baterías grandes (75 % de la potencia de la planta), al demostrar una capacidad superior para minimizar las pérdidas por desbalances mientras se mantienen ingresos elevados. Este comportamiento refuerza su utilidad no solo como una estrategia de optimización económica, sino también como una solución confiable para gestionar la operación de un sistema eólico bajo incertidumbre.

4.2.3. Ciclado de la Batería

En esta sección se analiza el impacto de las estrategias de operación en el uso de la batería, evaluado mediante el "Número de ciclos", definido como el cociente entre la energía total inyectada por la batería a la red y su capacidad nominal. La Figura 4.8 muestra los ciclos acumulados en tres meses de operación para los distintos casos y métodos de optimización, mientras que la Tabla 4.2 presenta el tiempo estimado en años para alcanzar 2,000 ciclos, suponiendo que las tendencias observadas se mantienen constantes.




Figura 4.8: Número de ciclos de batería para los distintos casos y métodos.

Los resultados destacan que los métodos de **Programación Robusta** y **Estocástica** tienen un uso más intensivo de la batería, alcanzando valores de ciclado significativamente mayores. Esto refleja una estrategia orientada a maximizar el aprovechamiento del almacenamiento para satisfacer compromisos energéticos y realizar arbitraje entre periodos de precios altos y bajos.

Caso	Programación Robusta	Programación Estocastica	Deep Reinforcement Learning
25 % Sin retiros	8.4	10.4	14.2
25 % Con retiros	7.1	9.2	9.1
75 % Sin retiros	12.5	12.8	17.8
75 % Con retiros	6.6	7.8	9.8

Tabla 4.2: Cantidad de años estimados para alcanzar los 2,000 ciclos.

Por otro lado, el método de **Deep Reinforcement Learning (DRL)** muestra un enfoque más conservador, con un número de ciclos menor en comparación con los otros métodos, lo que se traduce en una mayor vida

útil estimada para la batería. Como se observa en la Tabla 4.2, el DRL extiende el tiempo para alcanzar los 2,000 ciclos en todos los casos, alcanzando hasta **17.8 años** en el escenario de batería grande sin retiros. Esto sugiere que este método no solo optimiza los beneficios económicos, sino que también prioriza la sostenibilidad técnica, reduciendo los costos asociados a la degradación y al mantenimiento del sistema de almacenamiento.

4.2.4. Gestión de Energía y Análisis de Desbalances

Al igual que en el caso de Santiago Solar, se profundizará en el análisis de la relación entre la energía ofertada e inyectada. Este enfoque permitirá identificar las causas por las cuales los resultados económicos del método estudiado no logran superar a los obtenidos con la Programación Robusta y Estocástica, proporcionando un diagnóstico más completo de su desempeño.




Figura 4.9: Energía Ofertada e Inyectada para cada caso y método.

La Figura 4.9 presenta la relación entre la energía ofertada y la energía inyectada para los distintos casos analizados. Se observa que varios puntos están alejados de la línea de referencia (oferta = inyección), lo que evidencia diferencias significativas entre la energía comprometida y la efectivamente entregada. Estas diferencias son más pronunciadas en la generación eólica debido a su naturaleza más variable e impredecible, tal como se destacó en la sección de descripción de datos. Esta variabilidad limita la capacidad de los métodos de optimización para predecir correctamente la disponibilidad del recurso, impactando negativamente en los niveles de cumplimiento.




Figura 4.10: Sobre y subgeneración para cada caso y método.

En la Figura 4.10, se analizan las relaciones entre sobregeneración, subgeneración y el porcentaje de cumplimiento. La Programación Robusta exhibe los mayores niveles de sobregeneración entre todos los métodos. Por otro lado, el DRL muestra una tendencia predominante a la subgeneración, consistente con lo observado en los resultados para generación solar. Esto refuerza la idea de que el DRL prioriza estrategias más conservadoras en su planificación, lo que reduce los desbalances por sobregeneración, pero al mismo tiempo tiende a no cubrir completamente la energía comprometida.

A pesar de estos desbalances, la estrategia del DRL ofrece ventajas como una mayor vida útil de la batería, ya que minimiza el uso excesivo del sistema de almacenamiento. Sería valioso profundizar en futuros estudios cómo este intercambio entre beneficio económico y sostenibilidad del recurso puede integrarse en un plan de negocios integral.

Finalmente, se debe destacar que los niveles de cumplimiento en el caso de generación eólica, entre 50 % y 70 %, son considerablemente menores que los observados en la generación solar (cerca del 90 %). Esto refleja las diferencias inherentes entre ambas fuentes de energía, donde la eólica, por su naturaleza más errática, presenta mayores desafíos para las estrategias de optimización.

Capítulo 5

Conclusiones

Este trabajo implementa el modelo de [1] en un entorno de un solo agente participando en el mercado Day-Ahead como *price taker*, utilizando un modelo lineal basado en datos de los mercados *spot* chileno y Real-Time estadounidense. Se demuestra la viabilidad de este enfoque para diferentes estrategias de operación del almacenamiento, incluyendo la posibilidad de realizar retiros de energía desde la red eléctrica. Este enfoque no solo se alinea con la normativa chilena emergente, sino que también representa una alternativa prometedora para mejorar la viabilidad de las tecnologías de almacenamiento energético. Para el estudio, se consideraron baterías con capacidades del 25 % y 75 % de la potencia nominal de los parques Santiago Solar y Cabo Leones I.

En términos de desempeño económico, el método de *Deep Reinforcement Learning* (DRL) obtuvo resultados intermedios, mientras que la programación estocástica destacó por un buen desempeño en la mayoría de los casos. No obstante, en Santiago Solar, el DRL con una batería del 75 % de capacidad sin retiros logró superar al resto de los métodos.

El tamaño de la batería se confirma como un factor crítico para el desempeño económico. Aumentar la capacidad de la batería mejora significativamente los resultados para todos los métodos analizados, aunque los efectos varían según el tipo de generación y la estrategia utilizada.

- Santiago Solar: El aumento en el tamaño de la batería beneficia particularmente al DRL y a la programación estocástica, con impactos tanto en mayores ingresos por ventas como en menores pagos por desbalances. Además, una batería de mayor tamaño reduce los niveles de subgeneración en el método DRL, optimizando su desempeño general.
- Cabo Leones I: En este parque eólico, el aumento de la capacidad de la batería tiene un efecto más notable en la reducción de los pagos por desbalances en el método DRL que en el incremento de los ingresos por ventas. Esto se debe a la mayor variabilidad de la generación eólica, que dificulta una predicción y gestión precisas. En contraste, para Santiago Solar, los altos niveles de cumplimiento permiten que la batería trascienda su función de respaldo, desempeñando un rol más activo en el arbitraje energético.

En relación con los retiros, los resultados son mixtos:

- En Santiago Solar, los retiros mejoran el desempeño del DRL con baterías pequeñas, pero disminuyen su eficacia en baterías de mayor capacidad, lo que sugiere que el impacto depende del balance entre capacidad de almacenamiento y necesidad de respaldo.
- En Cabo Leones I, los retiros tienen un efecto positivo en todos los casos, indicando que las plantas con mayores desbalances pueden beneficiarse más de esta estrategia al disponer de una fuente adicional de energía.

Finalmente, un aspecto clave del método DRL es su menor uso de la batería, como se observa en los gráficos de ciclado. Aunque esta estrategia favorece una vida útil más prolongada del sistema de almacenamiento, también resulta en mayores niveles de subgeneración. Este intercambio entre longevidad del sistema y desempeño

económico abre la puerta a futuros estudios sobre cómo la degradación de las baterías y la pérdida de capacidades afectan la rentabilidad y la gestión eficiente de generación variable a largo plazo.

5.1. Implicaciones y Recomendaciones

Los hallazgos sugieren que la integración de métodos basados en inteligencia artificial puede ofrecer una alternativa viable y eficiente en comparación con las técnicas tradicionales, especialmente en entornos con alta variabilidad e incertidumbre en los precios y la generación eólica. Sin embargo, se recomienda considerar las siguientes acciones para futuras investigaciones y aplicaciones:

- **Implementar modelos de predicción del recurso:** En este trabajo se dejó la tarea de predicción de recurso junto con la incorporación de precios y toma de decisiones a la red. Una posible mejora se puede traer por parte de modelos más complejos que incorporen meteorología. De esta forma mejorar la información que recibe el modelo, que las discrepancias entre lo ofertado e inyectado fueron uno de los problemas que se observó, sobre todo en generación eólica.
- **Modelos de Precio Más Complejos:** Implementar y evaluar modelos más avanzados para la estimación de señales de precio en el mercado Day-Ahead, lo que podría mejorar la precisión y efectividad del modelo de inteligencia artificial.
- **Participación en Mercados de Servicios Complementarios:** Explorar la inclusión de otros mercados, como los de servicios complementarios, aunque esto puede ser limitado en el contexto chileno debido a la escasa presencia de actores en dichos mercados.
- **Optimización del *sizing* de la batería:** Determinar las capacidades óptimas de un sistema de almacenamiento es un problema complejo y depende de cada aplicación. Los tamaños presentados en este estudio buscan ser representativos, mas no optimizados.
- **Simulaciones a Largo Plazo:** Realizar simulaciones a largo plazo para evaluar la estabilidad y robustez del modelo en diferentes condiciones de mercado y escenarios de generación eólica.
- **Incorporación de deterioro:** Incorporar el deterioro de los parámetros de la batería según el uso de la misma.

5.2. Limitaciones del Estudio

Aunque el modelo muestra resultados prometedores, es importante reconocer ciertas limitaciones:

- **Datos Limitados:** La disponibilidad y precisión de los datos pueden afectar los resultados y la generalización del modelo a otros contextos.
- **Suposiciones del Modelo:** Las suposiciones realizadas, como la relación lineal entre los mercados, pueden no capturar completamente la dinámica real del mercado.
- **Escalabilidad:** La escalabilidad del modelo a otros entornos debe ser estudiada caso a caso.

En resumen, este trabajo demuestra el potencial de los métodos basados en inteligencia artificial para optimizar la operación de plantas con almacenamiento energético en mercados eléctricos, destacando su capacidad para gestionar la incertidumbre y mejorar el desempeño económico. Sin embargo, también identifica desafíos y oportunidades para mejorar su implementación práctica, especialmente en contextos con alta variabilidad, como el mercado chileno. Futuros estudios deberían enfocarse en desarrollar modelos más robustos y adaptativos, considerar criterios multiobjetivo e incluir el impacto del deterioro de las baterías y cambios regulatorios. Estas líneas de investigación no solo contribuirán a superar las limitaciones actuales, sino que también maximizarán la aplicabilidad y beneficios de estas tecnologías en un sistema energético global en evolución.

Bibliografía

- [1] Tomás Ochoa, Esteban Gil, Alejandro Ángulo, Carlos Valle. “Multi-agent deep reinforcement learning for efficient multi-timescale bidding of a hybrid power plant in day-ahead and real-time markets”. *Applied Energy*, 2022.
- [2] K. Arulkumaran, M. P. Deisenroth, M. Brundage, A. A. Bharath, “Deep reinforcement learning: A brief survey”, *IEEE Signal Process. Mag.* 34 (6) (2017) 26–38.
- [3] Qinbo Bai, Mridul Agarwal, Vaneet Aggarwal. “Joint Optimization of Multi-Objective Reinforcement Learning with Policy Gradient Based Algorithm”. *arXiv preprint arXiv:2105.14125*, 2021.
- [4] F. J. Heredia, M. D. Cuadrado, C. Corchero, “On optimal participation in the electricity markets of wind power plants with battery energy storage systems”. *Computers & Operations Research* 96 (2018) 316–329.
- [5] Comisión Nacional de Energía. *Energía Abierta*, potencia instalada al 6 de Junio 2022.
- [6] Francisco D. Muñoz, Sonja Wogrin, Shmuel S. Oren, Benjamin F. Hobbs, “Economic Inefficiencies of Cost-based Electricity Market Designs” *The Energy Journal*, Vol. 39, No. 3.
- [7] Warren B. Powell, “Reinforcement Learning and Stochastic Optimization: A Unified Framework for Sequential Decisions” 1st Edición, 2022.
- [8] Drew Lebowitz, Sean Daly, Swetha Sundaram, “The BESS Book”, 1st Edición, 2024
- [9] Battery University, “BU-808: How to Prolong Lithium-based Batteries”, 2023.

Anexos

Resumen Ejecutivo

El propósito de este estudio es implementar y explorar el desempeño de aplicar un modelo basado en inteligencia artificial para la toma de decisiones al operar una planta eólica y una solar, ambas con almacenamiento bajo incertidumbre de precios y de generación. A continuación se presenta un resumen del trabajo, mostrando los puntos principales a destacar de cada capítulo.

Capítulo 1: Introducción

El capítulo 1 aborda la situación actual del sector energético, destacando el papel del almacenamiento como una solución clave para integrar y fortalecer las fuentes renovables no convencionales. Analiza la importancia de estudiar métodos que diseñen estrategias de operación para este tipo de generación.

La descarbonización de la matriz energética es un tema crucial tanto a nivel nacional como internacional. En Chile, el acuerdo de descarbonización establece el fin de nuevos proyectos basados en carbón, que actualmente representan el 15.76 % de la capacidad instalada según la Comisión Nacional de Energía (CNE). Este acuerdo marca un precedente hacia una operación más sostenible en el contexto del cambio climático global. Además, la minería en Chile está adoptando un plan sustentable de operación, valorando cada vez más la electricidad proveniente de generación renovable.

Uno de los principales desafíos de las Energías Renovables No Convencionales (ERNC), especialmente la eólica, es la incertidumbre en la disponibilidad del recurso, lo que causa brechas entre la generación programada y la real. Esto genera la necesidad de un control de frecuencia en el sistema eléctrico. A diferencia de las centrales térmicas, que tienen un control más preciso sobre su despacho, las plantas de ERNC requieren soluciones adicionales para mantener la robustez del sistema eléctrico. El almacenamiento de energía surge como una alternativa para otorgar control sobre la inyección de energía y ofrecer servicios complementarios, similares a las generadoras basadas en combustibles fósiles.

En 2023, el Coordinador Eléctrico impulsó una licitación de asesoría para el diseño de un mercado basado en ofertas, un paso significativo hacia la integración de estas tecnologías. Actualmente, para determinar las inyecciones de las generadoras y los precios de la energía, se utilizan métodos de optimización tradicionales. Sin embargo, este trabajo toma como referencia un modelo de redes neuronales planteado en [1], que se utilizó exitosamente en la operación de una planta solar con almacenamiento BESS en California, Estados Unidos, en un mercado Day-Ahead (DA) de energía y reservas, además del mercado de energía en tiempo real. Este modelo demostró ser competitivo frente a métodos estocásticos y robustos, con resultados prometedores que son adaptables a otras realidades, como la idealización de un mercado DA en Chile.

El objetivo de esta memoria es operar una planta híbrida de generación eólica con almacenamiento de energía (BESS), ofertando en el mercado como *price taker*. Se estudiaron dos plantas: (i) el parque fotovoltaico Santiago Solar, de 115 MW (ii) el parque eólico Cabo Leones, con una potencia de 175 MW. Para este análisis, se implementará y ajustará el modelo de redes neuronales de [1], explorando la operación bajo distintos criterios de almacenamiento, incluyendo la consideración de retiros desde la red y la exploración de dos tamaños de batería.

Capítulo 2: Fundamentos Conceptuales

El Capítulo 2 de este trabajo presenta los fundamentos conceptuales que contextualizan el trabajo realizado, abordando temas clave como las plantas híbridas de generación eléctrica, el actual mercado chileno de energía, y la propuesta de un mercado basado en ofertas. La operación de plantas renovables enfrenta el desafío de optimizar secuencialmente bajo incertidumbre, especialmente en un entorno de precios variables que afectan la rentabilidad y la estabilidad del sistema energético.

Las plantas híbridas son instalaciones que combinan múltiples fuentes de generación eléctrica para aprovechar sinergias entre ellas. Principalmente, se utilizan fuentes renovables complementadas con sistemas de almacenamiento y respaldo, como el Battery Energy Storage System (BESS) basado en litio. Al permitir que los sistemas de almacenamiento realicen retiros desde la red eléctrica, se les otorga la capacidad de llevar a cabo el arbitraje de energía. Este proceso implica la compra de energía cuando los precios son bajos o abundantes, almacenándola para su uso posterior cuando los precios sean altos. Esta práctica no solo optimiza el uso de recursos energéticos, sino que también contribuye a la estabilidad y eficiencia del sistema eléctrico al mitigar picos de demanda y suavizar variaciones en la oferta de energía renovable intermitente. El diseño de estas plantas depende de factores como la disponibilidad del recurso, costos tecnológicos y el contexto regional, asegurando mayor predictibilidad y participación activa en mercados eléctricos, así como la reducción de vertimientos de energía renovable no convencional.

Los mercados eléctricos son plataformas donde interactúan las empresas generadoras y los consumidores para la compra y venta de electricidad. Un coordinador opera estos mercados asegurando que la generación y la demanda se equilibren de manera técnica viable, garantizando la seguridad del suministro y la eficiencia económica. En teoría, en un mercado de competencia perfecta, tanto productores como consumidores maximizan sus beneficios.

Los precios en estos mercados actúan como canales de información crucial. Transmiten señales a los productores sobre las necesidades de los consumidores, lo que orienta las decisiones de producción a corto y largo plazo. En un sistema eficiente, los precios reflejan con precisión los costos marginales de la generación, facilitando una operación eficiente y minimizando el poder de mercado.

Existen dos principales enfoques en la operación de estos mercados: el basado en costos auditados y el basado en ofertas. En el primero, el coordinador establece precios basados en costos verificados de generación, creando una lista de mérito para despachar desde las unidades más baratas. Este método busca mitigar el poder de mercado al asignar recursos de manera eficiente. Sin embargo, calcular los costos de oportunidad para todos los participantes puede ser complejo, afectando la calidad de las señales de precio.

En contraste, en el mercado basado en ofertas, los participantes determinan sus costos de oportunidad y presentan ofertas que reflejan sus preferencias. La competencia entre ofertas debería generar precios más precisos y eficientes, alineados con las condiciones reales del mercado.

La adopción de estos mercados no solo facilita la integración de fuentes de energía renovable como la solar y eólica, sino que también promueve una participación más activa de los consumidores. Sin embargo, la incorporación de estas tecnologías presenta desafíos, como la necesidad de controlar el poder de mercado y garantizar la flexibilidad del sistema.

El desarrollo de mercados eléctricos suele comenzar con un mercado Day-Ahead basado en ofertas, expandiéndose luego hacia otros mecanismos como el mercado Real-Time o intradiario. Esto permite una gestión más dinámica y eficiente de la electricidad, adaptándose a las complejidades cambiantes del sistema eléctrico moderno.

La optimización secuencial bajo incertidumbre es crucial en múltiples contextos donde las decisiones deben tomarse en un entorno incierto y con recursos limitados. Este enfoque enfrenta el desafío de maximizar resultados adaptándose a cambios imprevistos, como variaciones en los precios del mercado de la energía o la disponibilidad de recursos renovables. Utilizando modelos que consideran la incertidumbre en eventos futuros, la optimización secuencial busca adaptarse continuamente a medida que se recibe nueva información, optimizando así funciones de contribución que incorporan el valor esperado sobre todas las posibles evoluciones del sistema.

En resumen, los métodos como la programación estocástica y robusta se utilizan para abordar problemas secuenciales bajo incertidumbre en distintos contextos. La programación estocástica busca maximizar el ren-

dimiento considerando múltiples escenarios posibles modelados con distribuciones de probabilidad, mientras que la programación robusta desarrolla soluciones menos sensibles a la incertidumbre, garantizando decisiones robustas y confiables ante escenarios extremos o variaciones significativas en los datos.

Capítulo 3: Metodología

El capítulo 3 se centra en los pasos y tareas necesarios para llevar a cabo la implementación del agente de *Deep Reinforcement Learning* (DRL) y de los métodos basados en programación estocástica y robusta. A continuación, se detallan los principales pasos metodológicos seguidos:

1. Preprocesamiento de Datos: Se inicia con la limpieza y transformación de datos en bruto para hacerlos aptos para la red neuronal. Se corrigen valores faltantes en series de tiempo y se normalizan los datos utilizando la transformación Min-Max para evitar sesgos en los cálculos del gradiente. Además, se aplica una transformación logarítmica a los precios de la energía para aproximar una distribución normal, facilitando el aprendizaje de las redes neuronales.

2. Generación de Escenarios: Se crean escenarios para abordar la incertidumbre del futuro, esenciales tanto para la programación estocástica como robusta. Estos escenarios se generan mediante una búsqueda exhaustiva del parámetro T, que determina el mejor conjunto de candidatos basado en patrones históricos de las variables estocásticas de precio y generación eólica.

3. Formulación del Problema para la Resolución Estocástica y Robusta: Se definen parámetros técnicos de la planta y su interacción con el mercado, considerando dos escenarios de operación (inyección de potencia y retiros de potencia) y dos tamaños de batería (25 % y 75 % de la potencia nominal del parque).

4. Sistema de Control para la Operación de la Batería: Se describe el sistema de control necesario para la operación eficiente de la batería, considerando las restricciones y parámetros operativos establecidos.

5. Entrenamiento de Redes Neuronales: El proceso de entrenamiento se adapta específicamente al mercado Day-ahead de energía. La red neuronal se entrena utilizando estructuras de datos secuenciales (buffer rolls) y se ajustan los pesos de la red para maximizar el rendimiento económico. Se seleccionan y optimizan hiperparámetros, y se utilizan varias combinaciones de estos para garantizar que el modelo generalice bien y no se sobreajuste a los datos de entrenamiento.

Capítulo 4: Resultados

Desempeño de los Métodos: Las Figuras 5.1 y 5.2, presentan un resumen del desempeño económico de los distintos casos bajo los tres métodos implementados




Figura 5.1: Desempeño económico para los distintos casos y métodos en Santiago Solar.




Figura 5.2: Desempeño económico para los distintos casos y métodos en Cabo Leones I.

El desempeño económico de las estrategias analizadas mostró diferencias significativas entre las plantas solares y eólicas, reflejando las características particulares de cada tipo de generación. En el caso de Santiago Solar, la generación más predecible y constante permitió que los métodos basados en DRL y programación estocástica alcanzaran resultados competitivos. En particular, el DRL destacó como la estrategia más rentable cuando se utilizó una batería de gran capacidad (75 % de la capacidad nominal) sin considerar retiros desde la red, logrando superar a los demás métodos en términos de ingresos netos.

Por otro lado, en Cabo Leones I, la mayor variabilidad e incertidumbre de la generación eólica planteó mayores desafíos. Aquí, la programación estocástica demostró ser la estrategia más robusta, manteniendo un desempeño económico consistente incluso bajo condiciones de alta imprevisibilidad. El método DRL, aunque presentó menores ingresos netos que la programación estocástica, mostró una notable reducción en los costos asociados a desbalances al incorporar una batería de mayor tamaño. Esto refleja la capacidad del modelo para adaptarse a la dinámica de la generación eólica mediante un manejo más eficiente del almacenamiento energético.

En ambas plantas, se observó que incrementar el tamaño de la batería mejoró significativamente el desempeño económico de todas las estrategias, subrayando la relevancia de un dimensionamiento óptimo del sistema de almacenamiento. No obstante, el impacto de los retiros desde la red mostró una mayor heterogeneidad: si bien benefició ciertas configuraciones, en otras tuvo efectos adversos. Cabe destacar que los retiros resultaron ser una medida particularmente favorable cuando los niveles de cumplimiento de la energía ofertada eran bajos, lo que sugiere que esta estrategia puede ser efectiva como garantía para asegurar el cumplimiento de los compromisos adquiridos.

El análisis de gestión de energía y desbalances evidencia que el método *Deep Reinforcement Learning* (DRL) enfrenta desafíos particulares en la predicción y cumplimiento de los compromisos energéticos, especialmente debido a su tendencia a estrategias conservadoras. Estas estrategias priorizan un menor uso de la batería, lo que resulta en bajos niveles de sobregeneración pero altos niveles de subgeneración. Aunque esta característica limita el cumplimiento energético en comparación con otros métodos, tiene la ventaja de prolongar la vida útil del sistema de almacenamiento.