



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

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. Generación Eólica	22
3.3.2. Precios de la Energía	23
3.3.3. Distintos criterios de operación para el almacenamiento	23
4. Resultados	25
5. Conclusiones	34
5.1. Implicaciones y Recomendaciones	35
5.2. Limitaciones del Estudio	35

Bibliografía

36

Anexos

37

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 eólica	22
3.4. Datos del Mercado Day-Ahead	23
4.1. Operación de los distintos métodos para un día del <i>test set</i> considerando retiros	25
4.2. Operación de los distintos métodos para un día del <i>test set</i> sin retiros	26
4.3. Nivel de carga de los distintos métodos para un día del <i>test set</i>	27
4.4. Nivel de almacenamiento para caso 75% P_{nom}	28
4.5. Nivel de almacenamiento para caso 25% P_{nom}	28
4.6. Uso de la batería en ciclos de descarga	32

Índice de tablas

3.1. Parámetros del sistema de almacenamiento y generación batería 25% P_{nom} sin retiros.	23
3.2. Parámetros del sistema de almacenamiento y generación batería 25% P_{nom} con retiros.	24
3.3. Parámetros del sistema de almacenamiento y generación batería 75% P_{nom} sin retiros.	24
3.4. Parámetros del sistema de almacenamiento y generación batería 75% P_{nom} con retiros.	24
4.1. Resultados económicos	29
4.2. Pagos por desbalances provocados en millones de dólares	30
4.3. Ingresos por venta de energía en millones de dólares	30
4.4. Detalle de los desequilibrios generados	31
4.5. Inyecciones y retiros netos para los distintos casos	31
4.6. Energía total de descarga y carga para los distintos casos	32
5.1. Resultados económicos	39

Abstract

Energy storage systems are essential for achieving the goals of a clean energy matrix. Their integration strengthens current electrical systems, addressing the challenges that arise with a higher penetration of non-conventional renewable energies, enhancing the reliability and robustness of power supply. This technology offers versatile solutions at the generation, transmission, and distribution levels.

Currently, there is significant growth in lithium-based Battery Energy Storage Systems (BESS) due to their modular nature and the development driven by the e-mobility industry. This trend presents opportunities for power companies to invest in such infrastructure, with both banks and investors showing increased confidence in the potential revenue streams it can offer.

To ensure the viability of these projects, it is essential to explore methods for decision-making under uncertainty. In this context, neural network-based methods emerge as a promising alternative, capable of recognizing complex patterns through training and leveraging increasingly abundant environmental data. This study implements a neural network-based method previously developed and adapts it to new data, having already demonstrated competitive results against traditional approaches within the context of a photovoltaic park in the United States.

This study focuses on the Horizonte wind farm, located in the Antofagasta region and owned by Colbún S.A., analyzing its economic performance by incorporating a lithium battery. Different battery sizes and two operating scenarios are evaluated: (i) energy injection only and (ii) allowing both injections and withdrawals. The latter scenario enables the battery to respond to price signals, facilitating energy arbitrage to optimize economic use.

The neural network method is compared with robust and stochastic programming approaches. Results indicate that the economic performance of the neural network method is intermediate, with stochastic programming leading in profitability. Generally, it was observed that using a larger battery (75% of the nominal power of the farm) yields positive returns for all methods, whereas a 25% battery capacity results in losses across all methods, as penalties for imbalances between scheduled and actual operations exceed energy sales revenue.

A key finding involves the consideration of withdrawals from the grid for energy arbitrage. It was observed that robust and stochastic methods deteriorate in performance with this approach, regardless of battery size, whereas the neural network method improved by approximately 35%, making it competitive.

Additionally, due to the strategy defined by the AI agent, battery use in terms of cycling was lower in cases where the battery had greater capacity relative to the wind farm, approximately 30% lower than with stochastic programming. This is significant, as excessive cycling accelerates battery deterioration, impacting its energy and power capacities.

In summary, the neural network model results in a more conservative yet competitive battery usage strategy, particularly if legislation permits energy withdrawals from the grid. However, these findings do not imply that implementing this method will guarantee better decision-making or profitability in other environments, as factors such as prices, resource availability, third-party generation, transmission conditions, and project location significantly affect outcomes.

Resumen

Los sistemas de almacenamiento de energía son esenciales para lograr una matriz energética limpia y fortalecen los sistemas eléctricos actuales frente a los desafíos de una mayor penetración de energías renovables no convencionales, aportando confiabilidad y robustez al suministro eléctrico. Son una tecnología versátil, capaz de ofrecer soluciones tanto a nivel de generación como de transmisión y distribución.

Actualmente, se observa un rápido crecimiento en los sistemas de almacenamiento BESS (Battery Energy Storage Systems) basados en litio, impulsado por su carácter modular y por el desarrollo de la industria de la electromovilidad. Esto abre oportunidades para que las empresas generadoras inviertan en este tipo de infraestructura, y tanto bancos como inversores muestran una creciente confianza en los flujos de ingresos que pueden derivarse de estas tecnologías.

Para asegurar la viabilidad de estos proyectos, es fundamental explorar métodos que permitan definir estrategias de toma de decisiones bajo condiciones de incertidumbre. En este contexto, los métodos basados en redes neuronales emergen como una alternativa prometedora, pues permiten reconocer patrones complejos mediante entrenamiento, aprovechando la información cada vez más abundante del entorno. Este trabajo implementa un método basado en redes neuronales desarrollado previamente, adaptándolo a nuevos datos. Este método ha mostrado resultados competitivos frente a enfoques tradicionales en el contexto de un parque fotovoltaico en Estados Unidos.

Este estudio se centra en el parque eólico Horizonte, ubicado en la región de Antofagasta y propiedad de Colbún S.A., donde se evalúa su desempeño económico al incorporar una batería de litio. Se analizan diferentes tamaños de batería y dos escenarios operativos: (i) inyección exclusiva de energía a la red y (ii) inyección y retiros. Este último permite a la batería responder a señales de precio, realizando arbitraje energético para optimizar su uso económico.

El método de redes neuronales se compara con enfoques de programación robusta y estocástica. Los resultados muestran que el desempeño económico del método de redes neuronales es intermedio, con la programación estocástica liderando en rentabilidad. En términos generales, se observó que el uso de una batería de mayor capacidad (75 % de la potencia nominal del parque) genera ganancias positivas en todos los métodos, mientras que una batería del 25 % de la potencia nominal lleva a pérdidas en todos los casos, debido a penalizaciones por desbalances entre la operación programada y la real, que superan los ingresos por venta de energía.

Un aspecto clave es la consideración de retiros de la red para arbitraje de energía. Se observó que los métodos robusto y estocástico empeoran su desempeño con esta estrategia, independientemente del tamaño de la batería, mientras que el método de redes neuronales mejoró en un 35 %, volviéndose competitivo.

Además, el uso de la batería, en términos de ciclado, fue menor cuando esta contaba con mayor capacidad respecto a la planta eólica, siendo aproximadamente un 30 % menor que en la programación estocástica. Esto es relevante, ya que un ciclado excesivo acelera el deterioro de la batería, afectando sus capacidades de energía y potencia.

En resumen, el modelo basado en redes neuronales resulta en una estrategia de uso más conservadora y competitiva, particularmente si se permite la extracción de energía desde la red. No obstante, los resultados sugieren que su implementación en otros contextos no garantiza automáticamente una toma de decisiones más acertada o mayor rentabilidad, dado que factores como precios, disponibilidad de recursos, generación de terceros, estado de la transmisión y localización del proyecto afectan significativamente el desempeño.

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 como 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 entregadas por la misma Comisión Nacional de Energía, la generación solar y eólica corresponden un 29.92 % 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, puede 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 llega 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 eólica más almacenamiento de energía, ofertando en un mercado Day Ahead (DA). Para ello se implementará el modelo en [1], la idea general es tomar este trabajo como referencia y desarrollar otro similar 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 registrarán 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 como 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 que aspectos económicos y técnicos logran mejorarse a partir del modelo de redes neuronales y del porque 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 a 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 una planta eólica 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 (eólica + BESS) 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 con 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 co-optimizados 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.
- La generación del parque Eólico Horizonte es igual al promedio de los parques Tal tal, Valle de los Vientos y Sierra Gorda. Ponderado por un factor de 7.62 obtenido por el cociente entre las potencias instaladas promedio entre los tres parque y la de Horizonte.

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 eólica. 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 periodo anterior que aún no se han materializado.

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

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

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:

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

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

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 imbalances 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

Los datos utilizados comprenden desde 01-01-2018 hasta 05-05-2020. A continuación se muestra un mayor detalle sobre los mismos.

3.3.1. Generación Eólica

Los datos de generación eólica utilizados en las simulaciones se obtuvieron a través de la página web del Coordinador Eléctrico Nacional (<https://www.coordinador.cl/operacion/graficos/operacion-real/>). Debido a que el proyecto Horizonte aún no está operativo, se tomaron los datos de tres parques eólicos de la misma región: Taltal, Sierra Gorda y Valle de los Vientos. Dado que la potencia nominal de los tres parques es similar (106 MW, 112 MW y 90 MW respectivamente), se promedió la generación de los tres parques y luego se escaló por un factor de 7.62, ya que la potencia nominal de Horizonte es de 778 MW.

Cabe señalar que el Coordinador entrega datos de potencia por hora, pero en el trabajo se requirió una resolución por minuto. Para ello, se adaptaron los datos mediante interpolaciones, generando datos con dicha granularidad.

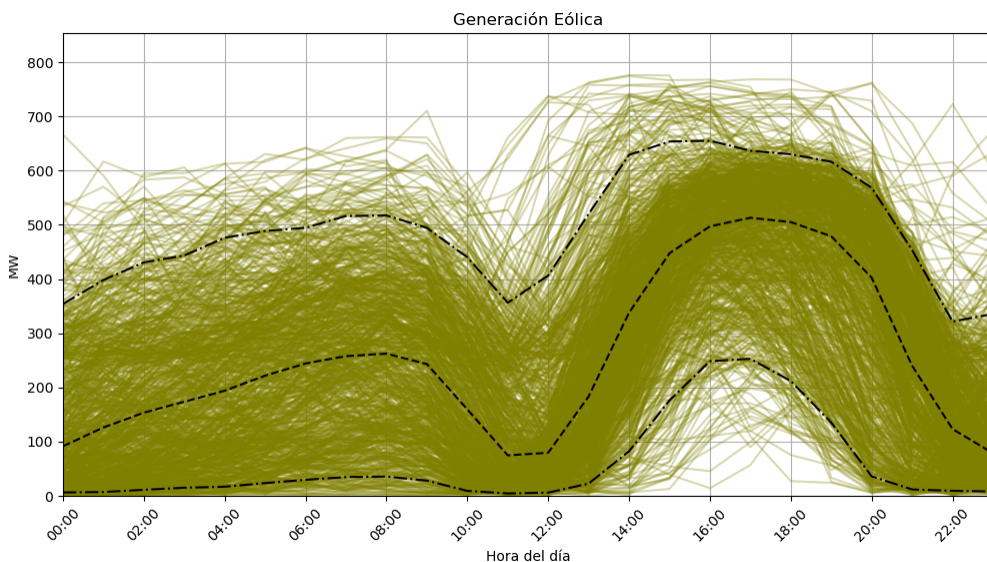


Figura 3.3: Datos de generación eólica

La Figura 3.3 muestra el perfil diario de la generación eólica. Se puede apreciar el comportamiento estocástico de la muestra y el amplio rango de variación. Las líneas punteadas representan los percentiles 5, 50 y 95.

Otro aspecto a destacar es el patrón marcado de fuerte inyección en la mañana y por la tarde, aunque existe un decaimiento hacia los horarios punta pasadas las 18 horas. Esto, en primera instancia, sugiere la factibilidad del uso del almacenamiento para trasladar esa energía a horarios donde es mejor valuada.

3.3.2. Precios de la Energía

Dado que en Chile aún no existe un mercado Day-Ahead para las inyecciones y retiros de energía, se propone utilizar datos del sistema de potencia en California, EE.UU., obtenidos del *California's ISO Open Access Same-time Information System (OASIS)*. De esta fuente se obtuvieron datos de los mercados *Real Time* y *Day Ahead*.

La metodología para estimar un hipotético mercado Day-Ahead en Chile consistió en desarrollar un modelo lineal entre los mercados spot de Chile y el *Real Time* en California. Bajo el supuesto de que la relación lineal entre ambos mercados puede utilizarse para escalar un eventual mercado Day-Ahead en Chile.

Además, resulta interesante destacar que la matriz energética del California ISO es similar a la matriz de la región de Antofagasta, con una gran presencia de energía solar fotovoltaica, lo que reduce los precios por la tarde y provoca el perfil característico de la curva de pato en los precios.

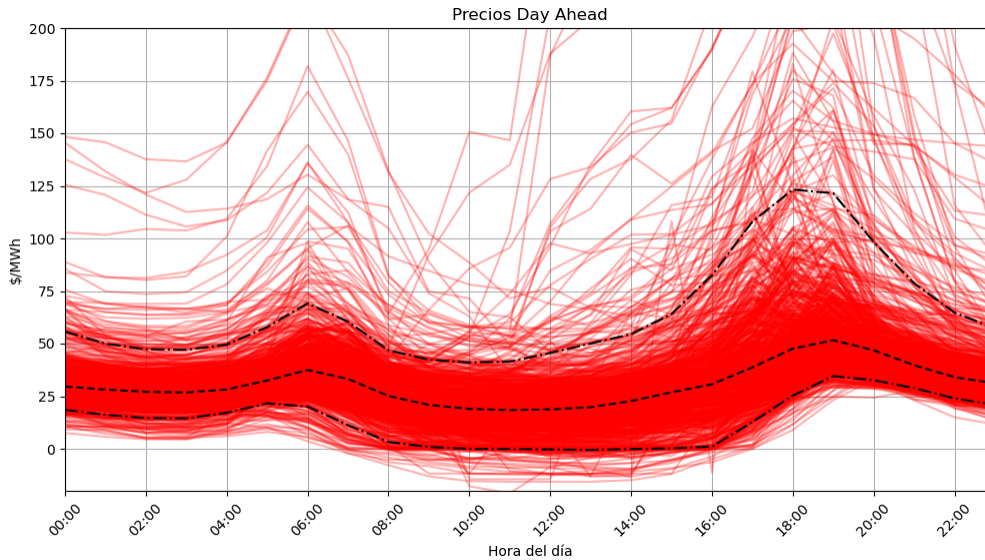


Figura 3.4: Datos del Mercado Day-Ahead

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, correspondientes a las combinaciones entre los escenarios de operación y los tamaños de batería. En las tablas 3.1, 3.2, 3.4 y 3.3 se presentan los parámetros de cada uno.

p_s	\hat{e}_s	\check{e}_r	η_c	η_d	$\check{\alpha}$	$\hat{\alpha}$	λ_{imb}
195 MW	970 MWh	105 MWh	0.9	0.95	0 MWh	1000 MWh	200 \$/MWh

Tabla 3.1: Parámetros del sistema de almacenamiento y generación batería 25% P_{nom} sin retiros.

p_s	\hat{e}_s	\check{e}_r	η_c	η_d	$\check{\alpha}$	$\hat{\alpha}$	λ_{imb}
195 MW	970 MWh	105 MWh	0.9	0.95	-300 MWh	1000 MWh	200 \$/MWh

Tabla 3.2: Parámetros del sistema de almacenamiento y generación batería 25% P_{nom} con retiros.

p_s	\hat{e}_s	\check{e}_r	η_c	η_d	$\check{\alpha}$	$\hat{\alpha}$	λ_{imb}
585 MW	2915 MWh	320 MWh	0.9	0.95	0 MWh	1000 MWh	200 \$/MWh

Tabla 3.3: Parámetros del sistema de almacenamiento y generación batería 75% P_{nom} sin retiros.

p_s	\hat{e}_s	\check{e}_r	η_c	η_d	$\check{\alpha}$	$\hat{\alpha}$	λ_{imb}
585 MW	2915 MWh	320 MWh	0.9	0.95	-300 MWh	1000 MWh	200 \$/MWh

Tabla 3.4: Parámetros del sistema de almacenamiento y generación batería 75% P_{nom} con retiros.

Capítulo 4

Resultados

Esta sección analiza los resultados experimentales al operar la planta híbrida bajo las estrategias definidas por el modelo de redes neuronales, programación estocástica y robusta basada en escenarios. El análisis se realiza para un período de tres meses (90 días).

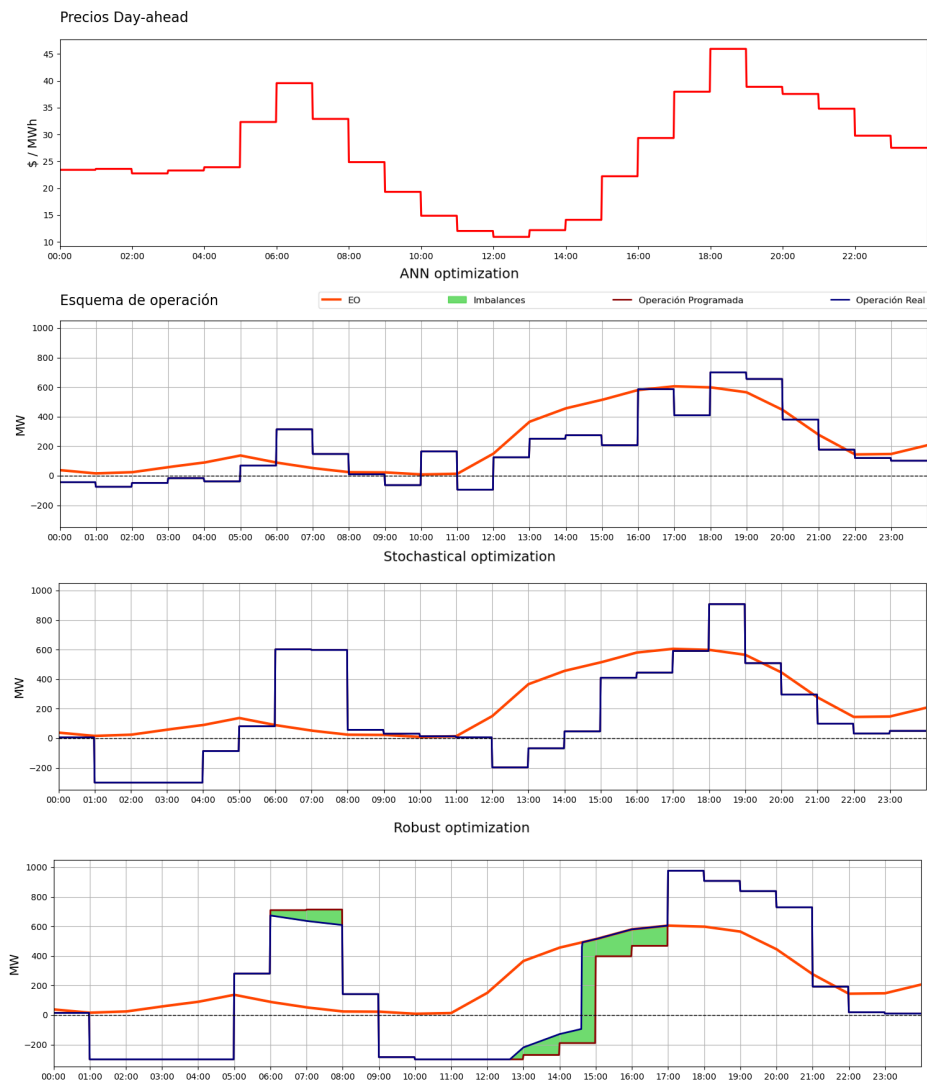


Figura 4.1: Operación de los distintos métodos para un día del *test set* considerando retiros

La Figura 4.1 muestra los resultados de la operación de la planta bajo los distintos métodos mencionados, en función de los precios Day-Ahead para esa jornada, representados por la primera curva roja. Se observa cómo las decisiones se toman considerando la incertidumbre de la generación eólica, ya que el esquema de operación (curva azul) es similar a la potencia generada por el viento (curva naranja). Las diferencias entre ambas curvas están relacionadas con la respuesta a las señales del mercado, utilizando la batería para optimizar las ganancias.

Entre los métodos, las principales diferencias para este día específico muestran una respuesta más acentuada ante los precios por parte de las estrategias basadas en la optimización estocástica y robusta. La actuación de la batería, que representa las variaciones entre las curvas azul y naranja, es más significativa en estos casos. Los retiros desde la red son mayores en los casos estocástico y robusto, llegando a retirar el máximo definido de 300 [MW] mientras que la estrategia ANN realiza retiros menores.

El área verde para el caso robusto muestra los desbalances provocados por la planta. Estos desbalances se deben a que las capacidades de la batería, ya sea en términos de potencia o energía almacenada, han llegado a su límite, limitando la capacidad de respuesta de la planta y provocando pérdidas monetarias.

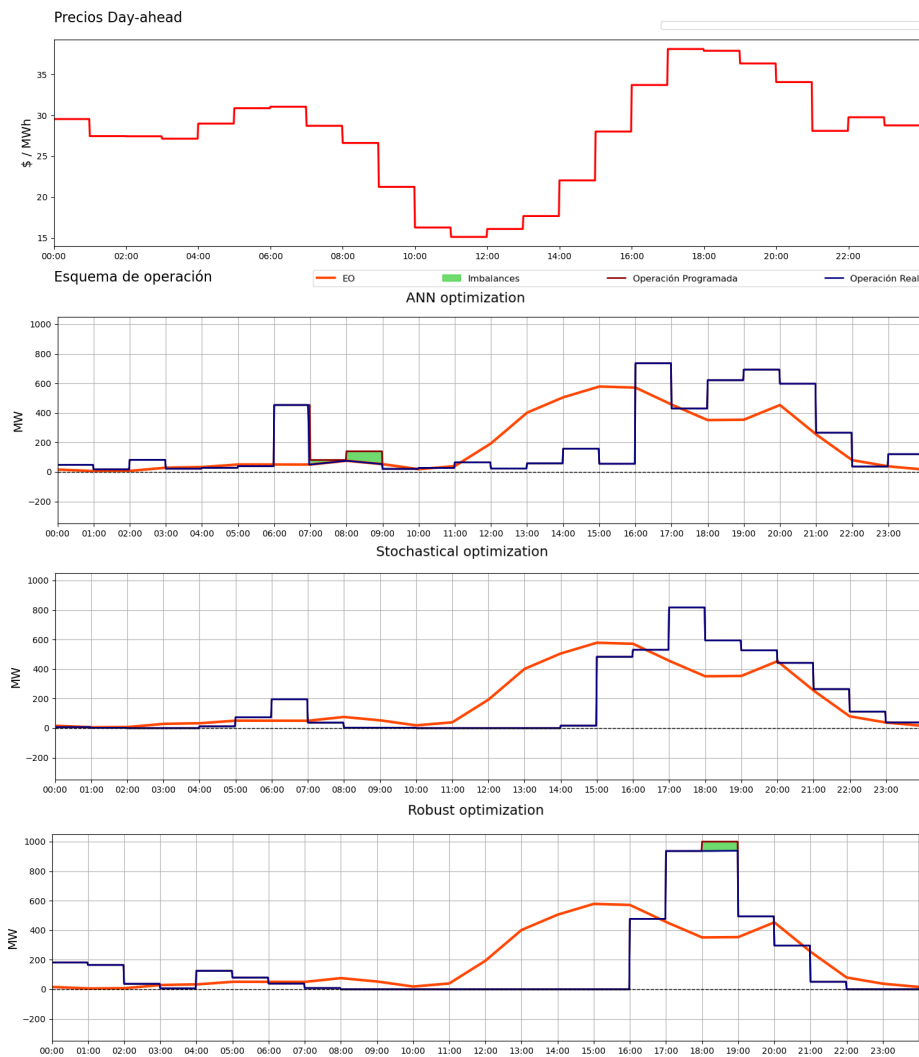


Figura 4.2: Operación de los distintos métodos para un día del *test set* sin retiros

La Figura 4.2 muestra la operación para otro día del conjunto de test, ilustrando gráficamente cómo se

logran diferentes criterios de operación del almacenamiento. A diferencia de la Figura 4.1, aquí los métodos no consideran los retiros desde la red eléctrica.

Se observa que los tres métodos logran capturar comportamientos deseados por el operador, para los periodos de precios bajos entre las 9 y 15 horas, se utiliza el almacenamiento para desplazar la generación eólica hacia horas de la tarde y noche, contribuyendo con eficiencia a la hora de operar el sistema.




Figura 4.3: Nivel de carga de los distintos métodos para un día del *test set*

La Figura 4.3 muestra las decisiones tomadas bajo los distintos métodos, pero desde la perspectiva de la toma de decisiones sobre el nivel de carga en la batería. La pendiente de la curva representa la potencia de entrada en la batería, ya sea para carga o descarga.

Si comparamos los tres métodos, se observa una diferencia en la potencia en la batería, tanto la resolución robusta como estocástica tienen cargas y descargas más pronunciadas, provocando una mayor variabilidad en el nivel de carga de la batería. Mientras que la estrategia definida por el agente de redes neuronales tiene un perfil de carga más suave, prefiere que pase un menor flujo de energía por el almacenamiento.

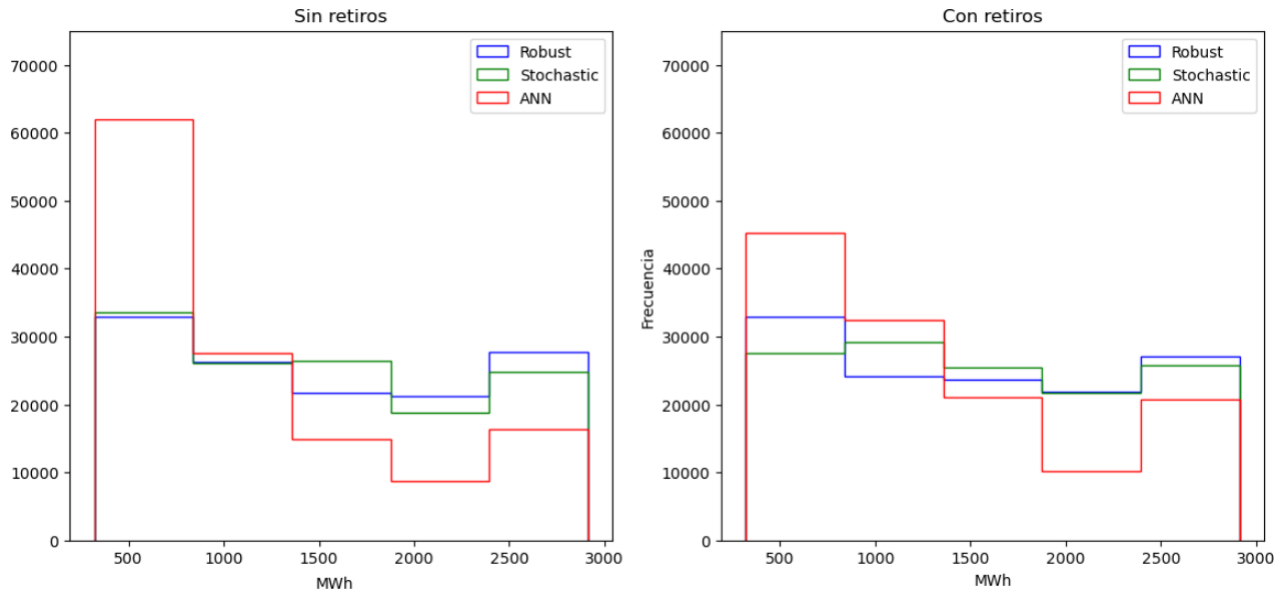


Figura 4.4: Nivel de almacenamiento para caso 75% P_{nom}




Figura 4.5: Nivel de almacenamiento para caso 25% P_{nom}

Las Figuras 4.4 y 4.5 muestran los niveles de energía en la batería para los métodos estudiados, considerando ambos tamaños de batería en escenarios con y sin retiros. Los datos están organizados en cinco subgrupos, representados por las cinco barras del gráfico, que abarcan desde niveles bajos de energía (a la izquierda) hasta niveles altos de energía (a la derecha). El tamaño de cada barra corresponde al tiempo que la batería se encuentra en cierto nivel de energía durante el horizonte de simulación.

Con una capacidad de almacenamiento del 75% de P_{nom} (Figura 4.4), se observa una mayor diferencia en el método de redes neuronales (ANN) en comparación con la programación robusta y estocástica. La estrategia de ANN tiende a operar la batería en niveles bajos de energía, mientras que los otros métodos mantienen un perfil más equilibrado. Al permitir los retiros desde la red, el método basado en redes neuronales adopta un perfil más equilibrado, aunque sigue mostrando cierta distancia con respecto a los otros dos métodos.

Cuando la batería tiene una capacidad del 25 % de P_{nom} , las diferencias en los niveles de almacenamiento son menores que en el caso anterior. Sin embargo, se sigue observando cierta distancia entre el método de inteligencia artificial y los otros dos, especialmente en los subgrupos de los extremos. Esta diferencia puede explicarse por la respuesta más acentuada a los precios que tienen la programación estocástica y robusta.

La diferencia entre los perfiles de energía se explica porque los métodos robusto y estocástico se adaptan de forma más pronunciada a cada uno de los casos estudiados, debido a que en la formulación de dichos problemas la operación del almacenamiento está explícita. En contraste, el perfil de carga del método ANN tiende a ser más conservador y no cambia de caso a caso, ya que en la optimización del problema las restricciones que definen el almacenamiento no se explicitan dentro del modelo, sino que se reciben de forma indirecta a partir de los inputs.

Ganancias netas \$		Robust	Stochastic	SADRL
① Batería 25 % P_{nom} sin retiros	\bar{X}	20,275	28,857	20,869
	σ	33,879	32,594	35,699
	Total	1,824,831	2,597,169	1,878,242
② Batería 25 % P_{nom} con retiros	\bar{X}	19,302	29,063	25,130
	σ	34,322	33,114	35,160
	Total	1,737,257	2,615,696	2,261,745
③ Batería 75 % P_{nom} sin retiros	\bar{X}	32,146	-32,271	42,458
	σ	32,128	54,875	28,233
	Total	2,893,228	-3,354,436	3,821,246
④ Batería 75 % P_{nom} con retiros	\bar{X}	29,983	42,924	35,640
	σ	33,939	29,690	32,495
	Total	2,698,503	3,863,222	3,207,659

Tabla 4.1: Resultados económicos

La Tabla 4.1 detalla el desempeño económico de los distintos métodos bajo los casos de operación definidos, presentando promedios diarios con su respectiva desviación estándar, así como las ganancias totales a lo largo de 90 días.

Como primera observación, el método de redes neuronales logra un desempeño intermedio entre la programación robusta y estocástica, excepto en el caso de una batería con el 75 % P_{nom} sin retiros desde la red, donde muestra el peor desempeño. En general, la programación estocástica obtuvo los mejores resultados, aunque en el caso de una batería al 75 % P_{nom} con retiros, las redes neuronales logran una posición competitiva con el método estocástico.

En cuanto al tamaño de la batería, se observa que una mayor capacidad de almacenamiento está directamente relacionada con la obtención de ganancias positivas en el mercado, independientemente del método y de si se consideran o no los retiros desde la red. La batería más pequeña genera pérdidas para la planta, que solo podrían ser recuperables si existieran otros mecanismos de mercado paralelos, como pagos por potencia instalada.

Permitir retiros desde la red eléctrica empeora los resultados tanto del método robusto como del estocástico, especialmente en el caso de una batería de mayor capacidad, donde el desempeño económico se ve más afectado. Esto se puede explicar a partir de la estrategia más agresiva observada anteriormente, permitir retiros habilita a la planta a tomar posiciones de arbitraje de energía que en estos casos puede afectar las ganancias de la planta.

Por otro lado, el método basado en inteligencia artificial se beneficia de los retiros desde la red, mejorando su margen de ganancia independientemente del tamaño de la batería. El desempeño económico mejora aproximadamente un 35 %.

Además, al analizar las ganancias promedio por día con su desviación estándar, se observa un mejor desempeño de la resolución estocástica, con promedios más elevados y desviaciones más acotadas, implicando ganancias levemente más estables. En el caso ④ donde el modelo de redes neuronales consigue un nivel competitivo respecto a la programación estocástica, se observa una menor variación en los resultados diarios.

Este resultado, comprobado en horizontes más largos, podría ser interesante ya que implicaría flujos más proyectables.

Pagos totales por desbalances [MMUS\$]	Robust	Stochastic	SADRL
① Batería 25 % P_{nom} sin retiros	-1,41	-0.8	-1.8
② Batería 25 % P_{nom} con retiros	-1.4	-0.8	-1.1
③ Batería 75 % P_{nom} sin retiros	-1.2	-1.0	-0.4
④ Batería 75 % P_{nom} con retiros	-1.3	-0.6	-1.0

Tabla 4.2: Pagos por desbalances provocados en millones de dólares

La Tabla 4.2 muestra los pagos por la diferencia entre los compromisos de la planta en el mercado y la operación real. Se observa que al aumentar la capacidad de la batería las penalizaciones se reducen de forma considerable, explicando lo observado en las ganancias netas, que con una batería del 75 % de P_{nom} se gana dinero bajo todos los métodos estudiados, con o sin retiros desde la red.

Al enfocar el análisis a la influencia de los retiros desde la red, se observa que los métodos robusto y estocástico aumentan los pagos por este concepto. Por otra parte el método de redes neuronales se ve beneficiado de los retiros, ya que en ambos casos logra disminuir sus pagos por desequilibrio.

Ingresos por venta de energía [MMUS\$]	Robust	Stochastic	SADRL
① Batería 25 % P_{nom} sin retiros	3.2	3.4	3.7
② Batería 25 % P_{nom} con retiros	3.2	3.4	3.4
③ Batería 75 % P_{nom} sin retiros	4.1	7.0	4.3
④ Batería 75 % P_{nom} con retiros	4.0	4.5	4.2

Tabla 4.3: Ingresos por venta de energía en millones de dólares

La Tabla 4.3 muestra los ingresos por concepto de la participación en el mercado Day-Ahead de energía.

Con respecto a la capacidad de la batería, se observa una relación directa con los ingresos. Esto se debe a que una batería más grande es capaz de desplazar más generación eólica desde horarios con precios bajos a otros donde la energía se valora más. Al comparar este efecto con la reducción de penalizaciones lograda por la batería más grande, la reducción de las penalizaciones aporta en un 85 % en el aumento de las ganancias, mientras que los ingresos un 15 %.

A partir de la información mostrada hasta el momento, se observa que al permitir los retiros desde la red eléctrica, tanto la programación robusta como la estocástica no logran obtener un provecho económico significativo del arbitraje de energía. Esto se debe a que el aumento en los ingresos por la venta de energía es menor al incremento en los pagos por desequilibrio entre la operación programada y la real. En este contexto, estos métodos tienden a enfocarse más en el arbitraje y pierden parte de la capacidad de utilizar el sistema de almacenamiento como respaldo. Esta pérdida de capacidad de respaldo provoca mayores desequilibrios, empeorando los resultados al hacer que el sistema sea menos eficiente y menos capaz de manejar las fluctuaciones en la generación y la demanda. Por otro lado, el método de redes neuronales, al actuar de forma más conservadora, no participa mayormente en el arbitraje de energía. En su lugar, se enfoca en proporcionar respaldo a la generación eólica, consiguiendo así reducir más sus desequilibrios.

Sobregeneración / Subgeneración [MWh]	Robust		Stochastic		SADRL	
Batería 25 % P_{nom} sin retiros	4,404	-2,660	1,125	-2,921	682	-8,422
Batería 25 % P_{nom} con retiros	4,588	-2,731	1,156	-3,063	776	-5,110
Batería 75 % P_{nom} sin retiros	4,246	-2,086	-	-	903	-1,492
Batería 75 % P_{nom} con retiros	4,284	-2,519	1,039	-2,397	691	-4,611

Tabla 4.4: Detalle de los desequilibrios generados

La Tabla 4.4 muestra el detalle de la sobre y subgeneración que provocan los pagos por desbalances en la operación. En general, aumentar el tamaño de la capacidad de la batería reduce tanto la sobre como la subgeneración para todos los métodos.

Por otra parte, el efecto que tiene el permitir retiros no es el mismo para todos los métodos. Para la resolución estocástica y robusta se incrementan en ambos tipos de desbalance. Por otra parte el agente de redes neuronales se ve favorecido ya que una segunda fuente de carga reduce un punto débil de su estrategia: la subgeneración.

Los datos mostrados concuerdan con lo observado anteriormente. El método SADRL que opera en niveles de energía más bajos tiene la menor sobregeneración y mayor subgeneración, al trabajar a estos niveles más bajos es más probable que se quede sin energía y por ende no sea capaz de cumplir los compromisos, por otra parte tiene más disponibilidad a absorber la energía que sobre de parte del parque eólico y a no sobregenerar. Por el contrario los métodos robusto y estocástico que tienden a tener un perfil con niveles más alto de energía provocan desbalances por concepto de sobregeneración.

Inyecciones / Retiros [MWh]	Robust		Stochastic		SADRL	
① Batería 25 % P_{nom} sin retiros	51,315	-	51,622	-	52,025	-
② Batería 25 % P_{nom} con retiros	53,902	2,895	54,021	2,728	56,549	5,197
③ Batería 75 % P_{nom} sin retiros	47,895	-	47,933	-	49,616	-
④ Batería 75 % P_{nom} con retiros	52,584	15,850	59,875	12,762	57,831	8,784

Tabla 4.5: Inyecciones y retiros netos para los distintos casos

La tabla 4.5 muestra las inyecciones y retiros totales de energía para el horizonte simulado.

Para la batería de menor capacidad, las diferencias entre considerar o no retiros son menores. Inclusive los distintos métodos no difieren en gran medida en las inyecciones totales durante los tres meses. Los retiros representan un 1% de las inyecciones totales, por lo que casi toda la energía tranzada viene desde los generadores eólicos. Esto apunta en la misma dirección que las observaciones anteriores, para un tamaño menor de batería las distintas estrategias utilizan el almacenamiento como un soporte, compensando la variabilidad del recurso y el arbitraje es menor.

Al aumentar el tamaño de la batería, se observa que al no considerar retiros las inyecciones totales son menores, esto se explica porque al aumentar la capacidad del almacenamiento es mayor la energía que pasa por la batería y por lo tanto la eficiencia de la misma castiga la energía total inyectada en la red. Pero esta baja en la cantidad tranzada se compensa por un mejor desempeño económico mostrado en la Tabla 4.1, logrando desplazar energía a periodos donde se valora más y evitando los castigos por desequilibrios provocados.

Al analizar el caso ④ se observan las mayores diferencias entre el método de redes neuronales y la programación robusta y estocástica. Solo el 3.5% de las inyecciones vienen de energía retirada desde la red, mientras que para la programación robusta y estocástica el aporte es cercano al 15%.

Con esto podemos ir destacando dos observaciones (i) A mayor tamaño de la batería el arbitraje se vuelve más relevante, pero es una consideración secundaria (ii) El método de redes neuronales basa su estrategia

en una compensación de la energía eólica y logra una posición competitiva inyectando menos energía pero siendo más preciso en las predicciones de los patrones de generación de los aerogeneradores.

Energía descarga / carga [MWh]	Robust		Stochastic		SADRL	
① Batería 25% P_{nom} sin retiros	56,185	65,906	45,633	53,546	47,392	55,179
② Batería 25% P_{nom} con retiros	59,578	69,862	46,897	55,024	54,670	63,912
③ Batería 75% P_{nom} sin retiros	162,107	190,926	140,775	166,270	100,427	118,867
④ Batería 75% P_{nom} con retiros	204,146	239,795	176,935	208,538	108,358	128,245

Tabla 4.6: Energía total de descarga y carga para los distintos casos

La Tabla 4.6 muestra la energía total que entra de la batería (carga) y que sale de ella (descarga). Las diferencias entre el flujo entrante y el saliente es de aproximadamente 15% lo cual concuerda con los parámetros de eficiencia que definen el ciclo de la batería ($\eta_c \eta_d = 0,85$).

Si se considera la potencia de carga y se compara con los retiros de la Tabla 4.5, el método de redes neuronales obtiene cerca del 10% desde la red mientras que los otros métodos se abastecen un 40% de la energía total en la batería desde la red.

Las observaciones van en línea con lo planteado anteriormente, el nivel de uso que se hace del almacenamiento para los casos con una batería pequeña no presenta diferencias considerables entre los métodos. Pero al aumentar el tamaño las decisiones comienzan a separarse, sobre todo el método de redes neuronales con respecto a los otros dos. Cuando la batería es más grande y se permiten los retiros, la programación robusta y estocástica operan de tal manera de considerar el arbitraje de energía como una opción de aumentar sus ganancias, pero sus decisiones empeoran las ganancias económicas hasta tal punto que el método de redes neuronales que es más conservador al arbitrar energía logra un resultado competitivo con respecto a la programación estocástica.

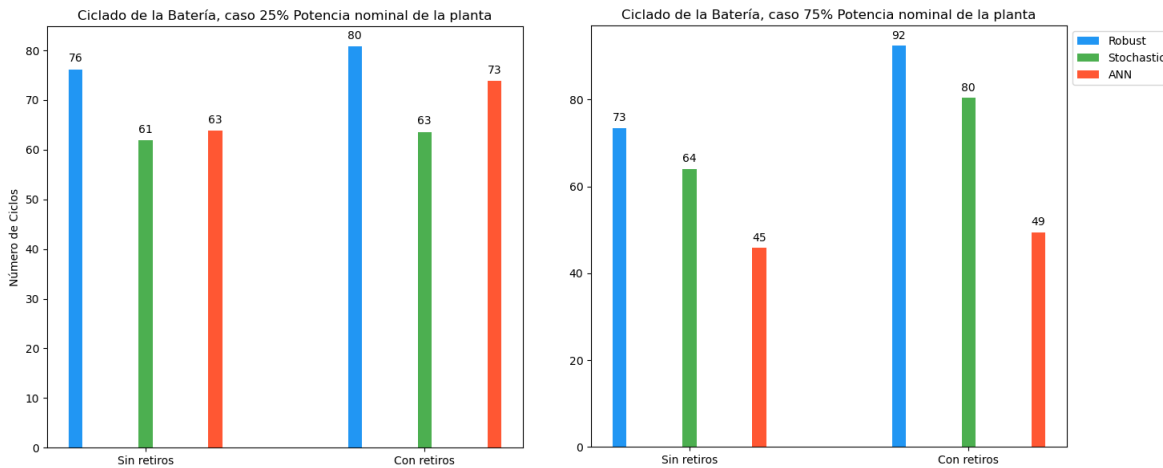


Figura 4.6: Uso de la batería en ciclos de descarga

La Figura 4.6 ilustra el uso del almacenamiento medido en número de ciclos de la batería durante el periodo simulado. El número de ciclos se calcula dividiendo la energía de carga total por la capacidad nominal de la batería. Este resultado es relevante, ya que la vida útil de la batería no solo se mide en tiempo, sino también en ciclos. Según [8], tras 10,000 ciclos, las baterías mantienen aproximadamente el 80% de su capacidad inicial.

En este aspecto, el modelo implementado demuestra una ventaja sobre los otros dos métodos en los casos de mayor tamaño de batería. Con un 30% menos de ciclos, la estrategia de la red neuronal se posiciona de manera competitiva con la programación estocástica, proporcionando una opción económica que permite conservar las capacidades de flujo energético de la batería por más años.

Capítulo 5

Conclusiones

El trabajo presentado logra la implementación de [1] en un modelo de un solo agente participando en el mercado Day-Ahead, estimado a partir de un modelo lineal construido con datos de los mercados spot chileno y Real-Time estadounidense. Se ha demostrado la viabilidad de utilizar esta herramienta bajo distintos criterios de operación del almacenamiento, incluyendo la posibilidad de retirar energía desde la red eléctrica. Este enfoque no solo anticipa la normativa chilena actual, sino que también ofrece una alternativa que podría aumentar la viabilidad de esta tecnología. Se consideraron dos tamaños de batería, con el 25 % y el 75 % de la potencia nominal del parque eólico Horizonte.

Los resultados, comparados con las implementaciones robusta y estocástica basadas en escenarios, muestran que el modelo estudiado alcanza un desempeño económico intermedio, donde la programación estocástica logra el mejor desempeño entre los tres. Sin embargo, hubo una excepción: en el caso de una batería de mayor capacidad permitiendo retirar desde la red, el método de inteligencia artificial logró una posición competitiva, empatando en el mejor desempeño económico.

Con una batería de menor capacidad, las diferencias en el desempeño económico se deben principalmente a los niveles de desequilibrios generados. En este contexto, el método de redes neuronales destaca por uno de sus puntos débiles: la subgeneración. Este problema se explica al analizar los perfiles de carga de la batería, donde el método tiende a operar a niveles bajos de carga durante más tiempo que los otros métodos, aumentando la probabilidad de quedarse sin energía para cubrir la generación incierta. Esto resulta en mayores penalizaciones por no cumplir con los compromisos de entrega de energía.

Sin embargo, el método estudiado logra una posición competitiva frente a la programación estocástica debido principalmente a que se beneficia de los retiros desde la red como una segunda fuente de carga, lo que disminuye significativamente sus niveles de subgeneración. Un aspecto relevante es que las inyecciones totales de la planta no aumentan significativamente con respecto al caso sin retiros (cerca de un 3 %), lo que sugiere que la energía retirada se utiliza principalmente para cumplir la función de respaldo de la generación. En contraste, los otros métodos presentan un incremento mayor en las inyecciones totales: un 13 % en el caso de la programación estocástica y un 17 % en el caso de la robusta. Esto indica que estos métodos están operando con una mayor componente de arbitraje, lo que resulta en mayores desequilibrios y empeora su desempeño económico.

Aumentar la capacidad de la batería en la operación de una planta eólica con almacenamiento tiene un impacto significativo en los resultados económicos de todos los métodos. Con una batería de menor capacidad, se generaron pérdidas netas debido a los desequilibrios; el almacenamiento no fue capaz de suplir las diferencias entre lo ofertado y lo generado. Sin embargo, al incrementar la capacidad de la batería, todos los métodos lograron ganancias netas positivas. Este cambio se explica en gran medida por una reducción significativa en los pagos por desequilibrios y, en menor medida, por un aumento en los ingresos por venta de energía.

La estrategia conservadora desarrollada presenta beneficios importantes, ya que al reducir el uso del almacenamiento se prolonga su vida útil. Este efecto es especialmente relevante en el caso de mayor capacidad, donde el ciclado de la batería se reduce en un 30 % en comparación con la opción estocástica, igualmente competitiva en términos económicos. Un uso intensivo está asociado con el deterioro de las capacidades nominales de energía y potencia, lo que implica un desgaste acelerado y menor eficiencia 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:

- **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 tipos de generación y tamaños debe ser estudiada caso a caso.

En resumen, este trabajo demuestra el potencial de los métodos de inteligencia artificial para mejorar la operación de plantas eólicas con almacenamiento en el mercado eléctrico. Sin embargo, se necesita seguir investigando y desarrollando estos métodos para superar las limitaciones actuales y maximizar su aplicabilidad y beneficios económicos.

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

Anexos

Resumen Ejecutivo

El propósito de este estudio implementar y explorar el desempeño de aplicar un modelo basado en inteligencia artificial para la toma de decisiones al operar una planta eólica 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 un mercado DA. La planta en estudio es el parque eólico Horizonte, el más grande de América Latina hasta la fecha, con una potencia de 816 MW. Ubicado en la región de Antofagasta, el parque Horizonte se encuentra en sus etapas finales previas a su puesta en operación. 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 o la demanda sea mayor. 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.

Capitulo 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.

Capitulo 4: Resultados

Desempeño de los Métodos:

Desempeño Económico MMUS\$	Robust	Stochastic	SADRL
Batería 25 % P_{nom} sin retiros	-6.2	-0.1	-3.5
Batería 25 % P_{nom} con retiros	-6.8	-0.1	-2.2
Batería 75 % P_{nom} sin retiros	4.4	7.2	3.8
Batería 75 % P_{nom} con retiros	3.0	5.9	5.9

Tabla 5.1: Resultados económicos

El método DRL muestra un desempeño intermedio en comparación con los métodos robusto y estocástico. La optimización estocástica obtiene los mejores resultados económicos en la mayoría de los casos.

Para el caso con una batería del 75 % de P_{nom} considerando retiros desde la red, el agente de inteligencia artificial logra una posición competitiva frente a la resolución estocástica. Debido principalmente al efecto negativo que tienen los retiros sobre esta última, mientras que el agente DRL se beneficia de ellos.

Operación del Almacenamiento:

En escenarios con una batería al 75 % de P_{nom} , la optimización estocástica y robusta utilizan el almacenamiento de manera más agresiva, mostrando mayores respuestas ante el precio, ya sea cargando o descargando con mayor potencia. Mientras que el DRL tiende a operar a niveles más bajos de energía, lo que lleva a una mayor probabilidad de caer en subgeneración.

Con una batería al 25 % de P_{nom} , las diferencias operativas entre los métodos se reducen, y todos utilizan el almacenamiento principalmente como respaldo.

Impacto de los Retiros de la Red:

Permitir retiros desde la red mejora los resultados del DRL, aumentando sus ganancias aproximadamente en un 35 % con ambos tamaños de batería. Los métodos robusto y estocástico presentan resultados económicos negativos con retiros desde la red, especialmente con baterías de mayor capacidad.

Ingreso por venta:

Los ingresos por ventas de energía no varían significativamente entre los métodos, pero la disminución de penalizaciones por desbalances es clave para la mejora económica. El método estocástico tiene promedios de ganancias más altos y desviaciones estándar más bajas, lo que implica una mayor estabilidad.

Penalizaciones por Desbalances:

Las mejoras en los resultados económicos del DRL se deben a la disminución de penalizaciones por desbalances, principalmente gracias a que los retiros le permiten fortalecer una de sus debilidades estrategias: subgeneración.

Las estrategias robustas y estocásticas generan mayores desbalances al permitir los retiros en comparación con el DRL, que opera a niveles más bajos de energía.

Arbitraje y Uso del Almacenamiento:

El arbitraje se vuelve más relevante con baterías de mayor tamaño, pero es una consideración secundaria. El método DRL inyecta menos energía en la red pero es más preciso en sus predicciones, logrando una posición competitiva con menor uso del almacenamiento.

En resumen, la implementación del agente de Deep Reinforcement Learning tiene una estrategia más conservadora frente a los retiros y uso del almacenamiento. La estrategia se ve beneficiada al desestimar el arbitraje de energía que provoca pérdidas en los métodos comparados.

Capítulo 5: Conclusiones

Viabilidad del Modelo: Se implementó exitosamente el modelo DRL en el parque eólico Horizonte (816 MW), ubicado en la región de Antofagasta, utilizando dos tamaños de batería (25 % y 75 % de la potencia nominal).

Desempeño Económico: Comparado con métodos robustos y estocásticos, el DRL mostró un desempeño económico intermedio, con la programación estocástica logrando el mejor desempeño general. Sin embargo, en escenarios con baterías de mayor capacidad y posibilidad de retiros desde la red, el DRL igualó el mejor desempeño económico.

Gestión del Almacenamiento: El DRL opera eficientemente como respaldo de la generación eólica y herramienta de arbitraje de energía, maximizando ingresos y minimizando penalizaciones por desbalances.

Impacto de los Retiros: Permitir retiros desde la red mejoró significativamente los resultados del DRL, reduciendo niveles de subgeneración y penalizaciones asociadas.

Tamaño de la Batería: Incrementar la capacidad de la batería resultó en ganancias netas positivas para todos los métodos estudiados, destacando la reducción de pagos por desequilibrios.