



GRADO EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE GRADO OPTIMIZACIÓN CUARTO HORARIA DEL USO DE UNA BATERÍA PARA LA MAXIMIZACIÓN DE BENEFICIOS EN MERCADOS ELÉCTRICOS

Autor: Hugo Raggini Paternain

Director: Andrés Ramos Galán

Madrid

Declaración de originalidad

Declaro bajo mi responsabilidad que el Proyecto presentado con el título **OPTIMIZACIÓN CUARTO HORARIA DEL USO DE UNA BATERÍA PARA LA MAXIMIZACIÓN DE BENEFICIOS EN MERCADOS ELÉCTRICOS**, la ETS de Ingeniería – ICAI de la Universidad Pontificia Comillas en el curso académico **2025-2026** es de mi autoría y no ha sido presentado con anterioridad a otros efectos. El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido tomada de otros documentos está debidamente referenciada.

Uso de Inteligencia Artificial¹

Declaro bajo mi responsabilidad que (indicar la opción correcta):

- ☐ No he utilizado Inteligencia Artificial en la elaboración del presente documento.
- ☐ He utilizado Inteligencia Artificial en la elaboración del presente documento y/o del Anexo B siempre en las condiciones permitidas por la Universidad Pontificia Comillas, es decir, aplicando el Nivel 2 de la [Escala de Evaluación de Perkins et al. \(2024\)](#): *“La IA puede utilizarse para actividades previas a la tarea, como la lluvia de ideas, la descripción y la investigación inicial. Este nivel se centra en el uso de la IA para la planificación, las síntesis y la generación de ideas, pero las evaluaciones deben hacer hincapié en la capacidad de desarrollar y refinar estas ideas de forma independiente”*. En concreto, las Inteligencia Artificial ha sido empleada para:

La IA ha sido usada en los siguientes casos:

- Generación de ideas
- Planificación y estructura de las tareas del proyecto
- Apoyo en la revisión de la redacción del trabajo
- Ayuda en la programación del modelo en Python Pyomo
- Apoyo en la programación del simulador Montecarlo en Python
- Apoyo en la programación de los dashboards en Python
- Traducción al inglés de texto



Firmado (alumno): Hugo Raggin Paternain

Fecha: 30/05/2027

¹ Esta declaración se refiere al uso de la Inteligencia Artificial generativa para realizar los documentos del Proyecto (Anexo B y Memoria). No aplica a Proyectos donde, por su naturaleza, deban emplear inteligencia artificial como parte de los mismos (aplicación de técnicas de aprendizaje automático, redes neuronales, análisis de datos...)

Autorización para la entrega del Proyecto

El Director del Proyecto	El co-Director del Proyecto (si aplica)
Fdo:	Fdo:
Fecha:	Fecha:



GRADO EN INGENIERÍA EN TECNOLOGÍAS DE TELECOMUNICACIÓN

TRABAJO FIN DE GRADO OPTIMIZACIÓN CUARTO HORARIA DEL USO DE UNA BATERÍA PARA LA MAXIMIZACIÓN DE BENEFICIOS EN MERCADOS ELÉCTRICOS

Autor: Hugo Raggini Paternain

Director: Andrés Ramos Galán

Madrid

OPTIMIZACIÓN CUARTO HORARIA DEL USO DE UNA BATERÍA PARA LA MAXIMIZACIÓN DE BENEFICIOS EN MERCADOS ELÉCTRICOS

Autor: Raggini Paternain, Hugo

Director: Ramos Galán, Andrés

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas

RESUMEN DEL PROYECTO

En este proyecto se ha elaborado un modelo para la optimización de beneficios del uso de una batería en los mercados de la energía española. Su robustez se ha evaluado mediante una simulación de Montecarlo que incorpora incertidumbre en la previsión de precios, las ineficiencias reales de la batería y la activación de la reserva secundaria, cuantificando la pérdida de beneficio frente al caso de información perfecta a lo largo de un año.

Palabras clave: Optimización, BESS, Mercado Eléctrico, Regulación Secundaria, Pyomo

1. Introducción

En las últimas décadas, la demanda de energía eléctrica en España ha crecido de forma considerable, impulsada principalmente por la digitalización, el crecimiento económico y, más recientemente, por la expansión masiva de centros de datos necesarios para sostener el desarrollo de la Inteligencia Artificial. Este fenómeno, junto con la tendencia hacia la descarbonización de la sociedad, ha dado un fuerte impulso a las energías renovables, cuya capacidad instalada ha crecido de forma sostenida en las últimas décadas.

En la actualidad, las fuentes renovables representan aproximadamente un 56,8% del total de la generación eléctrica en España, siendo la energía solar fotovoltaica la primera tecnología en potencia instalada del sistema, con una participación del 25,1%. Este escenario de alta penetración renovable e intermitente plantea un desafío crítico para la estabilidad del sistema. Ante la creciente necesidad de flexibilidad, la solución no pasa únicamente por aumentar la capacidad de generación, sino por mejorar la gestión y el aprovechamiento de la energía ya producida. En este contexto, los sistemas de almacenamiento se presentan como la herramienta fundamental para equilibrar la oferta y la demanda.

El mercado eléctrico español, gestionado por OMIE, opera con resolución cuarto horaria y se rige por la ley de la oferta y la demanda, lo que provoca que el precio de la electricidad fluctúe drásticamente a lo largo del día. Esta volatilidad, acentuada por la generación solar en las horas centrales, abre una oportunidad estratégica para el arbitraje energético. El uso de baterías permite desplazar la energía en el tiempo: cargando el sistema en periodos de exceso de oferta y precios reducidos, para posteriormente inyectar dicha energía en la red durante las horas de máxima demanda y precios elevados.

Más allá del mercado diario, la flexibilidad de las baterías permite participar en mercados secundarios o servicios de ajuste, proporcionando reserva de potencia al operador del sistema para corregir desvíos en tiempo real.

Esta participación resulta crítica para el mantenimiento del equilibrio de la red eléctrica, donde la generación debe igualar al consumo en todo momento para mantener la frecuencia nominal en 50 Hz. Un desbalance persistente entre la oferta y la demanda

provoca variaciones de frecuencia que pueden desencadenar el colapso del sistema. Un ejemplo reciente y de gran relevancia fue el apagón generalizado en la península ibérica de abril de 2025, donde una cadena de perturbaciones y la desconexión del sistema europeo provocaron un punto de no retorno en la red, dejando sin suministro a España y Portugal durante horas. En este contexto, las baterías actúan como un activo estratégico de respuesta rápida, capaces de inyectar o absorber potencia en milisegundos para estabilizar la frecuencia y evitar que fallos locales se conviertan en apagones masivos.

2. Motivación

La viabilidad de este proyecto se sustenta en una transformación cada vez más acusada del perfil de precios del mercado eléctrico español: la creciente diferencia entre los precios de las horas centrales del día y los de la tarde-noche, impulsada por la masiva penetración de la energía solar fotovoltaica. Durante las horas de mayor irradiación, el exceso de generación solar deprime el precio del mercado, mientras que al caer el sol, cuando la fotovoltaica desaparece pero la demanda se mantiene alta, el precio repunta con fuerza. Este fenómeno, conocido como efecto canibalización, hace que la propia energía solar reduzca su valor de mercado en las horas en que más abunda.




Figura 1: Perfil horario medio del precio del mercado diario español, normalizado respecto a la media anual de cada año (2021–2024). Fuente: elaboración propia a partir de datos de OMIE.

Como se observa en la Figura 1, el perfil de precios normalizado muestra una tendencia clara: la brecha entre los valles de precio (mediodía) y los picos (tarde-noche) se expande año tras año a medida que aumenta la capacidad solar instalada. Esta divergencia creciente es precisamente la que motiva este trabajo, pues amplía el margen de arbitraje aprovechable por un sistema de almacenamiento.

El reto no es solo técnico, sino también financiero. Dado que los sistemas de almacenamiento requieren una inversión inicial significativa, la rentabilidad del activo

depende directamente de su capacidad para capturar el máximo valor de las fluctuaciones de precio. El propósito central de este trabajo es, por tanto, desarrollar un modelo de optimización que determine la acción óptima en cada intervalo temporal — cargar, reservar capacidad para servicios de ajuste o descargar— con el objetivo de maximizar el beneficio económico de la unidad operando de forma autónoma en el mercado diario y en los servicios de ajuste, a resolución cuarto horaria. Los capítulos siguientes desarrollan el estado de la cuestión, la formulación matemática del modelo y los resultados obtenidos.

3. Definición del proyecto

Este proyecto desarrolla un modelo de optimización para maximizar el beneficio económico de una batería de iones de litio que opera simultáneamente en el mercado diario de electricidad y en el mercado de reserva secundaria del sistema eléctrico español, y evalúa la robustez de la estrategia de operación óptima, es decir, la estabilidad del beneficio económico esperado frente a la incertidumbre en los precios de mercado, mediante simulación de Montecarlo.

4. Descripción del modelo

El modelo desarrollado consta de dos partes. En primer lugar, se formula y desarrolla el modelo de optimización, primero de forma algebraica y posteriormente implementado en Python usando la librería Pyomo con el solver HiGHS. El resultado es un modelo determinista que, asumiendo información perfecta sobre los precios del mercado, determina la estrategia óptima de operación de la batería en cada intervalo del día. La formulación sigue la estructura clásica de un modelo MILP: declaración de sets, parámetros, variables, función objetivo y restricciones.

En segundo lugar, para evaluar si el modelo se comporta bien en condiciones reales, donde la información nunca es perfecta, se desarrolla una simulación de Montecarlo. Esta introduce variabilidad en los distintos parámetros del modelo y ejecuta la simulación a lo largo de un año completo, permitiendo analizar la robustez del modelo bajo distintos escenarios posibles.

Por último, para facilitar la comprensión de los datos y los resultados, se desarrollan herramientas de visualización que permiten analizar el comportamiento del modelo en distintos horizontes temporales.

5. Resultados

Los resultados incluyen el análisis a lo largo de 363 días, prácticamente un año natural completo, una muestra suficientemente amplia para evaluar el comportamiento del modelo a medio y largo plazo sin necesidad de incorporar la variabilidad de precios propia de horizontes temporales más lejanos. Sobre este periodo se ejecutan tanto el modelo determinista como la simulación de Montecarlo, lo que permite observar la distribución estadística del rendimiento para distintos percentiles. El resultado es claro: el modelo se comporta de forma robusta en los distintos escenarios simulados, hasta el

punto de que el beneficio mensual no llega a ser negativo en ninguno de los 12 meses evaluados (Figura 2).




Figura 2: Dashboard simulación anual - Beneficio Total Mensual

6. Conclusiones

Las conclusiones del trabajo son positivas. Se ha demostrado que, bajo las suposiciones del modelo, la diferencia entre el beneficio medio obtenido en la simulación y el beneficio teórico del modelo determinista es de aproximadamente un 14 %. Esta diferencia se conoce como el Valor Esperado de la Información Perfecta (EVPI) y representa el coste de operar sin conocer los precios con antelación. Dicho de otra manera, operando el modelo de forma ininterrumpida a largo plazo, se obtiene de media un 86 % de lo que se ganaría en el caso ideal de conocer los precios con perfecta antelación. La media es el estimador más representativo en este contexto porque, a largo plazo, los escenarios favorables y desfavorables se compensan y el resultado real converge hacia ella. Si se usa la mediana como estimador más conservador, el coste de incertidumbre sube al 18 %, ofreciendo una visión más prudente del rendimiento esperado (Figura 3). En cualquier caso, en ningún mes del periodo analizado el beneficio cae por debajo de cero, lo que confirma que el modelo genera valor de forma consistente a lo largo del año.




Figura 3: Retención de Valor en el Periodo

7. Referencias

- [1] Red Eléctrica de España. "La producción renovable crece en España un 10,3% en 2024 y alcanza sus mayores registros". Red Eléctrica de España, marzo 2025.
<https://www.ree.es/es/sala-de-prensa/actualidad/nota-de-prensa/2025/03/la-produccion-renovable-crece-en-Espana-un-10-3-por-ciento-2024-alcanza-mayores-registros>
- [2] Red Eléctrica de España. "El suministro de la electricidad". Red Eléctrica de España,
https://www.ree.es/sites/default/files/downloadable/el_suministro_de_la_electricidad.pdf
- [3] OMIE. "Operador del Mercado Ibérico de Energía". OMIE, <https://www.omie.es/>
- [4] Ministerio para la Transición Ecológica y el Reto Demográfico (MITECO). "Se presenta el informe del Comité para el análisis de las circunstancias que concurrieron en la crisis de electricidad del 28 de abril de 2025". MITECO, junio 2025.
<https://www.miteco.gob.es/es/prensa/ultimas-noticias/2025/junio/se-presenta-el-informe-del-comite-de-analisis-de-la-crisis-elect.html>
- [5] OMIE. "Resultados de mercado: ficheros". OMIE, <https://www.omie.es/es/file-access-list>

QUARTER-HOURLY OPTIMISATION OF BATTERY USAGE FOR PROFIT MAXIMISATION IN ELECTRICITY MARKETS

Author: Raggini Paternain, Hugo.

Supervisor: Ramos Galán, Andrés

Collaborating Entity: ICAI – Universidad Pontificia Comillas

ABSTRACT

In this project, a model has been developed to optimise the economic benefits of operating a battery in the Spanish energy markets. The robustness of the model has been validated through simulations incorporating randomness, inefficiencies and other realistic factors using Monte Carlo simulation.

Keywords: Optimization, BESS, Electricity Market, Secondary Regulation, Pyomo

1. Introducción

In recent decades, electricity demand in Spain has grown considerably, driven mainly by digitalization, economic growth and, more recently, the massive expansion of data centers required to support the development of Artificial Intelligence. This phenomenon, together with the trend towards decarbonization, has given a strong boost to renewable energies, whose installed capacity has grown steadily over the past decades.

Currently, renewable sources account for approximately 56.8% of total electricity generation in Spain, with solar photovoltaic energy now the leading technology in installed capacity, accounting for 25.1% of the system. This scenario of high and intermittent renewable penetration poses a critical challenge for system stability. Given the growing need for flexibility, the solution lies not only in increasing generation capacity, but in improving the management and use of the energy already produced. In this context, storage systems emerge as the key tool for balancing supply and demand.

The Spanish electricity market, managed by OMIE, operates at quarter-hourly resolution and is governed by the law of supply and demand, causing electricity prices to fluctuate dramatically throughout the day. This volatility, intensified by solar generation during the central hours, opens a strategic opportunity for energy arbitrage. Batteries allow energy to be shifted in time: charging the system during periods of excess supply and low prices, and then injecting that energy into the grid during peak demand and high price periods.

Beyond the day-ahead market, the flexibility of batteries enables participation in ancillary services, providing power reserves to the system operator to correct imbalances in real time.

This participation is critical for maintaining grid balance, where generation must match consumption at all times to keep the nominal frequency at 50 Hz. A persistent imbalance between supply and demand causes frequency variations that can trigger system collapse. A recent and highly relevant example was the widespread blackout across the Iberian Peninsula in April 2025, where a chain of disturbances and disconnection from the

European system pushed the grid to a point of no return, leaving Spain and Portugal without power for several hours. In this context, batteries act as a strategic fast-response asset, capable of injecting or absorbing power within milliseconds to stabilize frequency and prevent local failures from escalating into widespread blackouts.

2. Motivation

The viability of this project is grounded in an increasingly pronounced transformation of the price profile in the Spanish electricity market: the growing gap between prices during the central hours of the day and those in the evening, driven by the massive penetration of solar photovoltaic energy. During the hours of peak irradiation, the surplus of solar generation depresses the market price, while at sunset, when photovoltaic output disappears but demand remains high, the price rebounds sharply. This phenomenon, known as the cannibalization effect, causes solar energy itself to erode its own market value during the hours when it is most abundant.




Figure 1: Average hourly price profile of the Spanish day-ahead market, normalized with respect to each year's annual mean (2021–2024). Source: own elaboration based on OMIE data.

As shown in Figure 1, the normalized price profile reveals a clear trend: the gap between price valleys (midday) and peaks (late afternoon/evening) widens year after year as installed solar capacity grows. This growing divergence is precisely what motivates this work, as it expands the arbitrage margin available to a storage system.

The challenge is not only technical but also financial. Since storage systems require a significant upfront investment, the profitability of the asset depends directly on its ability to capture maximum value from price fluctuations. The central purpose of this work is therefore to develop an optimization model that determines the optimal action at each time interval — charging, reserving capacity for ancillary services, or discharging —

with the aim of maximizing the economic benefit of the unit operating autonomously in the day-ahead market and ancillary services, at quarter-hourly resolution. The following chapters cover the state of the question, the mathematical formulation of the model, and the results obtained.

3. Project definition

This project develops an optimization model to maximize the economic profit of a lithium-ion battery operating simultaneously in the day-ahead electricity market and the secondary reserve market of the Spanish power system, and assesses the robustness of the optimal operating strategy — that is, the stability of the expected economic profit under market price uncertainty — through Monte Carlo simulation.

4. Model description

The model developed consists of two parts. First, the optimization model is formulated algebraically and then implemented in Python using the Pyomo library with the HiGHS solver. The result is a deterministic model that, assuming perfect information about market prices, determines the optimal operating strategy for the battery at each interval of the day. The formulation follows the classic MILP structure: sets, parameters, variables, objective function and constraints.

Second, to evaluate whether the model performs well under real conditions, where information is never perfect, a Monte Carlo simulation is developed. This introduces variability into the model's parameters and runs the simulation over a full year, allowing the model's robustness to be assessed across a range of possible scenarios.

Finally, to make the data and results easier to understand, visualization tools are developed that allow the model's behavior to be analyzed across different time horizons.

5. Results

The results include the analysis of 363 days of both the deterministic model and the Monte Carlo simulation. From these, the statistical distribution of performance across different percentiles can be observed, and what is clear is that the model behaves robustly under different scenarios, as shown in Figure 2, where the benefit is never negative across the 12 months evaluated.




Figure 2: Dashboard anual simulation – Total Monthly Benefit

6. Conclusions

The conclusions of this work are positive. It has been shown that, under the model's assumptions, the difference between the average benefit obtained in the simulation and the theoretical benefit of the deterministic model is approximately 14%. In other words, running the model continuously over the long-term yields on average 86% of what would be earned in the ideal case of knowing prices perfectly in advance. The mean is the most representative estimator in this context because, over the long term, favorable and unfavorable scenarios offset each other, and the real result converges towards it. If the median is used as a more conservative estimator, the uncertainty cost rises to 18%, offering a more cautious view of expected performance (Figure 3). In any case, in no month of the analyzed period does the benefit fall below zero, confirming that the model consistently generates value throughout the year.




Figure 3: Value Retention in the Period

References

- [1] Red Eléctrica de España. "La producción renovable crece en España un 10,3% en 2024 y alcanza sus mayores registros". Red Eléctrica de España, marzo 2025.
<https://www.ree.es/es/sala-de-prensa/actualidad/nota-de-prensa/2025/03/la-produccion-renovable-crece-en-Espana-un-10-3-por-ciento-2024-alcanza-mayores-registros>
- [2] Red Eléctrica de España. "El suministro de la electricidad". Red Eléctrica de España,
https://www.ree.es/sites/default/files/downloadable/el_suministro_de_la_electricidad.pdf
- [3] OMIE. "Operador del Mercado Ibérico de Energía". OMIE, <https://www.omie.es/>
- [4] Ministerio para la Transición Ecológica y el Reto Demográfico (MITECO). "Se presenta el informe del Comité para el análisis de las circunstancias que concurrieron en la crisis de electricidad del 28 de abril de 2025". MITECO, junio 2025.
<https://www.miteco.gob.es/es/prensa/ultimas-noticias/2025/junio/se-presenta-el-informe-del-comite-de-analisis-de-la-crisis-elect.html>
- [5] OMIE. "Resultados de mercado: ficheros". OMIE, <https://www.omie.es/es/file-access-list>

Índice de la memoria

Capítulo 1. Introducción	6
1.1 Motivación	7
Capítulo 2. Descripción de las Tecnologías.....	10
2.1 Sistema de Almacenamiento por Batería (BESS)	10
2.1.1 Definición y concepto de BESS	10
2.1.2 Tipos de Batería	13
2.1.3 Parámetros técnicos relevantes para el modelo.....	13
2.2 Mercados Eléctricos en España	14
2.2.1 Operador del Mercado Ibérico de Energía (OMIE)	15
2.2.2 Red Eléctrica de España (REE).....	16
2.2.3 Acceso a los mercados: requisitos y figura del agregador	17
2.3 Herramientas de Desarrollo.....	18
2.4 Simulación de Montecarlo.....	19
Capítulo 3. Estado de la Cuestión	20
Capítulo 4. Definición del Trabajo	22
4.1 Justificación.....	22
4.2 Objetivos Del Proyecto	23
4.3 Metodología.....	23
4.4 Planificación y Estimación Económica	24
Capítulo 5. Modelo Algebraico	25
5.1 Sets	25
5.2 Parámetros.....	26
5.2.1 Parámetros Variables en el Tiempo	26
5.2.2 Parámetros Constantes	26
5.3 Variables.....	28
5.3.1 Variables de la Batería.....	28
5.3.2 variables del Mercado.....	28
5.3.3 Variables Binarias.....	29

5.4	Función Objetivo	30
5.5	Restricciones	30
5.5.1	Restricciones de Batería	31
5.5.2	Restricciones de Mercados	32
5.5.3	Otras Restricciones	34
Capítulo 6.	Suposiciones	35
6.1	Suposiciones a nivel teórico	35
6.1.1	Suposiciones del Mercado diario	35
6.1.2	Suposiciones Mercado Secundario	36
6.1.3	Suposiciones de la Batería	39
6.2	Suposiciones para la Simulación	43
6.2.1	Suposiciones de la Batería	43
6.2.2	Suposiciones del Mercado	44
Capítulo 7.	Modelo Funcional en Python	48
Capítulo 8.	Simulación Monte Carlo	50
Capítulo 9.	Análisis de Resultados	52
9.1	Análisis de un Día Representativo	52
9.1.1	Optimización de un Día Representativo	52
9.1.2	Simulación de un Día Representativo	59
9.2	Análisis de un Año Representativo	65
9.2.1	Optimización de un Año Representativo	65
9.2.2	Simulación de un Año Representativo	72
Capítulo 10.	Conclusiones y Trabajos Futuros	78
Capítulo 11.	Bibliografía	80
ANEXO I:	ALINEACIÓN DEL PROYECTO CON LOS ODS	83
ANEXO II	84	93

Índice de figuras

Figura 2: El Sistema BESS 1 (Enel,)	12
Figura 3: El Sistema BESS 2 (Enel,)	12
Figura 4: Funcionamiento mercado diario OMIE (OMIE)	15
Figura 5: Precio de baterías de Litio-ion (Solar Insure, 2025)	20
Figura 6: Workflow	49
Figura 7: Convergencia poco estable P5	51
Figura 8: Convergencia P50	51
Figura 9: Dashboard optimización diaria mercado diario	53
Figura 10: Dashboard optimización diaria mercado secundario	54
Figura 11: Dashboard optimización diaria estado de carga.....	55
Figura 12: Dashboard optimización diaria energía operada acumulada.....	56
Figura 13: Dashboards optimización diario composición del beneficio	57
Figura 14: Dashboard optimización diaria desglose financiero	58
Figura 15: Dashboard simulación diaria SOC: plan vs realidad	59
Figura 16: Dashboard simulación diaria energía no entregada vs plan.....	60
Figura 17: Dashboard simulación diaria Eventos de ejecución.....	61
Figura 18: Dashboard simulación diaria Activación real vs prevista.....	62
Figura 19: Dashboard simulación diaria: Distribución del beneficio real.....	63
Figura 20: Dashboard simulación diaria: Desglose por servicio	64
Figura 21: Dashboard simulación diaria: Coste de la incertidumbre	65
Figura 22: Dashboard optimización anual Energía con la red.....	66
Figura 23: Dashboard optimización anual Reserva aFRR ofertada media mensual	67
Figura 24: Dashboard optimización anual Energía activada media mensual	68
Figura 25: Dashboard optimización anual Precio OMIE mensual	68
Figura 26: Dashboard optimización anual Beneficio acumulado.....	69
Figura 27: Dashboard optimización anual Beneficio total por mes	70

Figura 28: Dashboard optimización anual Spread medio mensual	71
Figura 29: Dashboard optimización anual Spread vs Beneficio mensual	71
Figura 30: Dashboard simulación anual Beneficio total mensual	72
Figura 31: Dashboard simulación anual Coste de incertidumbre.....	73
Figura 32: Dashboard simulación anual Coste de incertidumbre.....	74
Figura 33: Dashboard simulación anual Ingreso por mercado (periodo)	74
Figura 34: Dashboard simulación anual Ingreso por mercado (mensual).....	76
Figura 35: Dashboard simulación anual Pérdidas por causa (mensual)	77

Índice de tablas

Tabla 1: Precio por Disponibilidad (€/MWh).....	37
Tabla 2: Precios por Activación (€/MWh)	38
Tabla 3: Porcentaje de Utilización.....	39
Tabla 4: Parámetros de Entrada para cálculo del coste de degradación	41
Tabla 5: Cálculos intermedios para el coste de degradación	43
Tabla 6: IRR por escenario	75

Capítulo 1. INTRODUCCIÓN

En las últimas décadas, la demanda de energía eléctrica en España ha crecido de forma considerable, impulsada principalmente por la digitalización, el crecimiento económico y, más recientemente, por la expansión masiva de centros de datos necesarios para sostener el desarrollo de la Inteligencia Artificial. Este fenómeno, junto con la tendencia hacia la descarbonización de la sociedad, ha dado un fuerte impulso a las energías renovables, cuya capacidad instalada ha crecido de forma sostenida en las últimas décadas (REE).

En la actualidad, las fuentes renovables representan aproximadamente un 56,8% del total de la generación eléctrica en España, siendo la energía solar fotovoltaica la primera tecnología en potencia instalada del sistema, con una participación del 25,1% (REE). Este escenario de alta penetración renovable e intermitente plantea un desafío crítico para la estabilidad del sistema. Ante la creciente necesidad de flexibilidad, la solución no pasa únicamente por aumentar la capacidad de generación, sino por mejorar la gestión y el aprovechamiento de la energía ya producida. En este contexto, los sistemas de almacenamiento se presentan como la herramienta fundamental para equilibrar la oferta y la demanda.

El mercado eléctrico español, gestionado por OMIE, opera con resolución cuarto horaria y se rige por la ley de la oferta y la demanda, lo que provoca que el precio de la electricidad fluctúe drásticamente a lo largo del día (OMIE). Esta volatilidad, acentuada por la generación solar en las horas centrales, abre una oportunidad estratégica para el arbitraje energético. El uso de baterías permite desplazar la energía en el tiempo: cargando el sistema en periodos de exceso de oferta y precios reducidos, para posteriormente inyectar dicha energía en la red durante las horas de máxima demanda y precios elevados.

Más allá del mercado diario, la flexibilidad de las baterías permite participar en mercados secundarios o servicios de ajuste, proporcionando reserva de potencia al operador del sistema para corregir desvíos en tiempo real.

Esta participación resulta crítica para el mantenimiento del equilibrio de la red eléctrica, donde la generación debe igualar al consumo en todo momento para mantener la frecuencia nominal en 50 Hz. Un desbalance persistente entre la oferta y la demanda provoca variaciones de frecuencia que pueden desencadenar el colapso del sistema (REE). Un ejemplo reciente y de gran relevancia fue el apagón generalizado en la península ibérica de abril de 2025, donde una cadena de perturbaciones y la desconexión del sistema europeo provocaron un punto de no retorno en la red, dejando sin suministro a España y Portugal durante horas (MITECO). En este contexto, las baterías actúan como un activo estratégico de respuesta rápida, capaces de inyectar o absorber potencia en milisegundos para estabilizar la frecuencia y evitar que fallos locales se conviertan en apagones masivos.

1.1 MOTIVACIÓN

La viabilidad de este proyecto se sustenta en una transformación cada vez más acusada del perfil de precios del mercado eléctrico español: la creciente diferencia entre los precios de las horas centrales del día y los de la tarde-noche, impulsada por la masiva penetración de la energía solar fotovoltaica. Durante las horas de mayor irradiación, el exceso de generación solar deprime el precio del mercado, mientras que al caer el sol, cuando la fotovoltaica desaparece pero la demanda se mantiene alta, el precio repunta con fuerza. Este fenómeno, conocido como efecto canibalización, hace que la propia energía solar reduzca su valor de mercado en las horas en que más abunda.




Figura 1: Perfil horario medio del precio del mercado diario español, normalizado respecto a la media anual de cada año (2021–2024). Fuente: elaboración propia a partir de datos de OMIE.

Como se observa en la Figura 1, el perfil de precios normalizado muestra una tendencia clara: la brecha entre los valles de precio (mediodía) y los picos (tarde-noche) se expande año tras año a medida que aumenta la capacidad solar instalada. Esta divergencia creciente es precisamente la que motiva este trabajo, pues amplía el margen de arbitraje aprovechable por un sistema de almacenamiento.

El reto no es solo técnico, sino también financiero. Dado que los sistemas de almacenamiento requieren una inversión inicial significativa, la rentabilidad del activo depende directamente de su capacidad para capturar el máximo valor de las fluctuaciones de precio. El propósito central de este trabajo es, por tanto, desarrollar un modelo de optimización que determine la acción óptima en cada intervalo temporal —cargar, reservar capacidad para servicios de ajuste o descargar— con el objetivo de maximizar el beneficio económico de la unidad operando de forma autónoma en el mercado diario y en los servicios de ajuste, a resolución cuarto horaria. Los capítulos

siguientes desarrollan el estado de la cuestión, la formulación matemática del modelo y los resultados obtenidos.

Capítulo 2. DESCRIPCIÓN DE LAS TECNOLOGÍAS

En este trabajo hay cuatro grandes áreas que deben entenderse antes de desarrollar el modelo. La primera es el funcionamiento de los sistemas de almacenamiento energético mediante baterías, ya que son el activo cuya operación se optimiza. La segunda son los mercados de la energía en España, porque es donde opera la batería y de dónde vienen los ingresos. La tercera es Pyomo, la librería de Python usada para formular y resolver el problema de optimización, junto con el solver HiGHS. Y la cuarta es la simulación de Montecarlo, necesaria para entender cómo se evalúa la robustez del modelo bajo condiciones de incertidumbre. Todas ellas se describen en los apartados siguientes.

2.1 SISTEMA DE ALMACENAMIENTO POR BATERÍA (BESS)

2.1.1 DEFINICIÓN Y CONCEPTO DE BESS

Un BESS (*Battery Energy Storage System*) es el conjunto integrado de elementos que permiten almacenar y liberar energía eléctrica de forma controlada. Su funcionamiento es conceptualmente sencillo: cuando el sistema carga, convierte la energía eléctrica en energía química y la almacena; cuando descarga, el proceso se invierte, liberando dicha energía de vuelta a la red (IRENA).

El sistema se compone de cuatro elementos principales (NREL). En primer lugar, la batería, encargada de almacenar la energía en forma química. A nivel estructural, la batería se organiza de forma jerárquica: las celdas electroquímicas se conectan eléctricamente para formar módulos, los módulos se apilan en racks y varios racks se integran dentro de un contenedor. Es esta unidad contenedora la que constituye la batería del BESS como sistema. En segundo lugar, el BMS (*Battery Management System*), que supervisa y controla que las operaciones de carga y descarga se realicen dentro de los límites de seguridad, monitorizando continuamente el voltaje, la corriente y la temperatura de las

celdas. En tercer lugar, el PCS (*Power Conversion System*), responsable de transformar la energía entre corriente continua (DC) y corriente alterna (AC): el lado DC conecta con la batería, mientras que el lado AC conecta con la red eléctrica. Por último, el EMS (*Energy Management System*), que actúa como cerebro del sistema, determinando en cada instante cuánta energía debe cargarse o descargarse en función de las señales del mercado, las restricciones operativas del activo y la estrategia de optimización definida. En este trabajo, esta función de gestión energética no la realiza un controlador comercial con su propia lógica, sino el modelo de optimización desarrollado.

Además de estos cuatro elementos principales, el BESS incorpora una serie de componentes auxiliares necesarios para su operación segura y su integración en la red (Enel). Entre ellos destacan los sistemas de gestión térmica, encargados de mantener las celdas dentro del rango de temperatura óptimo de operación, y los sistemas de protección contra incendios. Asimismo, el acoplamiento del BESS con la red eléctrica requiere transformadores de potencia que elevan la tensión de salida del PCS hasta el nivel de la red, y en instalaciones de mayor escala, una subestación eléctrica que centraliza la conexión, la medición y la protección del punto de interconexión.

En las Figuras 2 y 3 se ilustra mediante esquema la arquitectura de un BESS.




Figura 1: El Sistema BESS 1 (Enel,)



Figura 2: El Sistema BESS 2 (Enel,)

Los sistemas de almacenamiento de baterías se caracterizan a través de tres parámetros relacionados entre sí: la capacidad (Wh), la potencia (W) y la duración (h). La capacidad

representa la energía total que puede almacenar y entregar la batería. La potencia representa el ritmo al que puede entregarla en un instante. Por último, la duración se obtiene directamente de la relación entre ambas:

$$\text{Duración (h)} = \frac{\text{Capacidad (Wh)}}{\text{Potencia (W)}}$$

Esta representa cuánto tiempo puede la batería entregar su potencia máxima antes de agotarse. Los sistemas más habituales tienen duraciones de 2 o 4 horas, siendo los de mayor duración especialmente adecuados para aplicaciones de arbitraje energético.

2.1.2 TIPOS DE BATERÍA

Existen varios tipos de baterías que pueden utilizarse en un BESS (BSLBATT). Las más comunes son las de iones de litio, plomo-ácido, flujo redox e iones de sodio, cada una con sus ventajas e inconvenientes en términos de densidad energética, vida útil y coste. Para este trabajo se asume una batería de iones de litio, que es la tecnología más extendida en aplicaciones de arbitraje energético a escala de red ya que combina alta densidad energética, buena eficiencia, respuesta rápida y una vida útil de entre 10 y 20 años, lo que la convierte en la opción más adecuada para el tipo de operación que se modela.

Las baterías de iones de litio funcionan mediante el movimiento de iones de litio entre sus dos polos, denominados ánodo y cátodo. Durante la carga, los iones migran del cátodo hacia el ánodo, donde quedan almacenados en forma de energía química; durante la descarga, el proceso se invierte y los iones fluyen de vuelta al cátodo, liberando dicha energía química en forma de corriente eléctrica.

2.1.3 PARÁMETROS TÉCNICOS RELEVANTES PARA EL MODELO

El primer parámetro relevante para el modelo es la capacidad máxima de la batería ($E^{\max}$), esta representa la cantidad máxima de energía que puede almacenar la batería, expresado en MWh. Sin embargo, para preservar la vida útil del sistema la batería no opera

entre el 0% y el 100% de su capacidad, sino que dentro de un rango definido por un nivel mínimo ($SOC^{\min}$), y un nivel máximo ($SOC^{\max}$), donde SOC hace referencia al estado de carga (state of charge).

El segundo parámetro relevante es la potencia máxima, que puede ser distinta para la carga ($P^{ch,max}$) y la descarga ($P^{dis,max}$) y que limita el ritmo al que la batería puede intercambiar energía cada intervalo de tiempo, expresada en MW.

De estos dos parámetros se deriva la duración que, como se ha visto en el apartado [2.1.1](#), se obtiene como el cociente entre la capacidad y la potencia máxima, y representa el tiempo que la batería puede operar a plena potencia antes de agotarse.

En tercer lugar, la eficiencia de ciclo (η) representa las pérdidas energéticas asociadas al proceso de carga y descarga. No toda la energía almacenada en la batería puede recuperarse, parte de ella se disipa en forma de calor.

Por último, la degradación recoge el desgaste que cada ciclo de carga y descarga provoca sobre la batería, reduciendo progresivamente su vida útil. Su modelado se abordará más adelante.

Cabe mencionar también el tiempo de respuesta, relevante en aplicaciones de arbitraje dado que en los sistemas BESS actuales es inferior a un segundo. No obstante, dada la resolución cuarto horaria del modelo y el alcance de este trabajo, se asume respuesta inmediata.

2.2 MERCADOS ELÉCTRICOS EN ESPAÑA

Una vez identificado qué es un BESS y cómo funciona, el siguiente paso es estudiar los mercados en los que puede participar para generar ingresos. El mercado eléctrico español se estructura en varios mercados que operan en distintos horizontes temporales y con diferentes mecanismos de casación, gestionados por dos operadores principales: OMIE, responsable del mercado diario e intradiario, y REE, operador del sistema encargado de los

mercados de servicios de ajuste. A continuación, se describen los principales mercados existentes y el papel que puede desempeñar un BESS en cada uno de ellos.

2.2.1 OPERADOR DEL MERCADO IBÉRICO DE ENERGÍA (OMIE)

OMIE es el operador del mercado ibérico de electricidad, responsable de gestionar la compraventa de energía en España y Portugal a través del mercado diario y el mercado intradiario (OMIE).

El mercado diario, también denominado *day-ahead* o mercado diario, es el mercado principal del sistema. Cada día, antes de las 12:00, compradores y vendedores presentan sus ofertas de precio y volumen para cada una de los 96 cuartos de hora del día siguiente. OMIE cruza estas ofertas mediante un mecanismo de precio marginal: las ofertas de venta se ordenan de menor a mayor precio y las de compra de mayor a menor, fijándose el precio de casación de cada hora en el punto donde ambas curvas se cruzan (Figura 4). El resultado se publica en torno a las 14:00, momento a partir del cual se conocen los precios y volúmenes comprometidos para el día siguiente.




Figura 3: Funcionamiento mercado diario OMIE (OMIE)

El mercado intradiario se compone de tres subastas distribuidas a lo largo del día, que permiten a los agentes ajustar sus posiciones una vez conocida la producción real y la demanda prevista, corrigiendo las desviaciones respecto a lo acordado en el mercado diario (OMIE).

En este trabajo se opera únicamente en el mercado diario, que concentra la mayor parte del volumen negociado en el sistema ibérico y donde se forman los precios de referencia del sistema (241,8TWh en el diario frente a 44,9TWh en el intradiario en 2025) (OMIE, 2026). La incorporación del mercado intradiario, si bien teóricamente compatible, añadiría una complejidad de modelado que excede el alcance de este trabajo sin alterar significativamente el comportamiento del modelo ni las conclusiones obtenidas.

2.2.2 RED ELÉCTRICA DE ESPAÑA (REE)

Red Eléctrica de España (REE) es el operador del sistema eléctrico español, responsable de la gestión de la red de transmisión y de garantizar el equilibrio de la red y la seguridad del suministro en todo momento. Es quien gestiona los servicios de ajuste del sistema (REE).

Como se ha mencionado en la [introducción](#), la red debe mantenerse a una frecuencia de 50 Hz en todo momento (REE). Cualquier desvío entre generación y consumo altera dicha frecuencia y, si no se corrige a tiempo, puede activar mecanismos de seguridad que interrumpen la conexión de partes de la red, con el riesgo de desencadenar un apagón en cascada. Los servicios de ajuste son precisamente los mecanismos que REE utiliza para corregir estos desvíos en el menor tiempo posible.

Este reto se ha agravado considerablemente en los últimos años. A medida que las energías renovables representan una fracción cada vez mayor de la generación eléctrica, el sistema se vuelve más sensible a las variaciones de frecuencia, ya que la generación solar y eólica es intermitente y difícilmente predecible con exactitud. Esto incrementa tanto la frecuencia como la magnitud de los desvíos que REE debe gestionar, aumentando la necesidad y el valor económico de los servicios de ajuste.

Los agentes del mercado, pueden contribuir a este equilibrio y obtener una remuneración a cambio participando en los distintos servicios de ajuste. Los más relevantes para un BESS son la regulación secundaria y la regulación terciaria.

La regulación secundaria (aFRR, *automatic Frequency Restoration Reserve*) es un servicio de carácter voluntario que actúa en un horizonte temporal de entre 20 segundos y 15 minutos (REE). El agente oferta ante REE una banda de regulación, es decir, una capacidad disponible tanto a subir (descarga de la batería para inyectar energía a la red) como a bajar (carga de la batería para absorber energía de la red). Por esta disponibilidad se recibe una remuneración fija denominada pago por banda. En caso de que REE active la reserva, se retribuye adicionalmente la energía efectivamente entregada o absorbida, conocida como utilización neta.

La regulación terciaria (mFRR, *manual Frequency Restoration Reserve*) es el siguiente nivel de respuesta del sistema. A diferencia de la secundaria, su activación es manual por parte de REE y su tiempo de respuesta es de hasta 15 minutos desde que se da la orden (REE). Su función principal es resolver desvíos de mayor duración y restituir la banda de regulación secundaria que ha sido consumida, dejando el sistema nuevamente preparado para futuras contingencias. Al igual que la secundaria, remunera tanto la disponibilidad de potencia como la energía activada.

En este trabajo se modela únicamente la participación en la regulación secundaria. La terciaria, si bien es compatible con un BESS, presenta dos inconvenientes que la hacen menos atractiva en el contexto de este modelo: su activación es manual e impredecible, lo que dificulta su incorporación en un modelo de optimización determinista, y su horizonte temporal es menos adecuado para las características de respuesta rápida que definen la ventaja competitiva de una batería frente a otros activos.

2.2.3 ACCESO A LOS MERCADOS: REQUISITOS Y FIGURA DEL AGREGADOR

Para poder operar en los mercados descritos anteriormente, los propietarios de un BESS deben cumplir una serie de requisitos que varían según el mercado.

En el caso del mercado diario de OMIE, los requisitos son principalmente administrativos (OMIE): ser una empresa legalmente constituida en España o en el Espacio Económico Europeo, obtener las autorizaciones necesarias para operar en el sector eléctrico, firmar el contrato de adhesión con OMIE y depositar un aval económico que respalde las operaciones. No existe un mínimo de potencia instalada, por lo que cualquier BESS de tamaño suficiente puede participar directamente, siempre que esté registrado como unidad de programación, que es básicamente el registro que necesita cualquier instalación para poder operar en el mercado.

La situación es muy distinta en el caso de la regulación secundaria gestionada por REE. Para participar directamente, una instalación debe pertenecer a una zona de regulación con un mínimo de 200 MW habilitados (REE). Esto deja fuera a la práctica totalidad de los BESS individuales, cuya potencia habitual se sitúa muy por debajo de ese umbral.

Para salvar esta barrera existe la figura del agregador independiente (MITECO), que agrupa varias instalaciones pequeñas para que en conjunto puedan acceder al mercado. En España esta figura acaba de ser regulada mediante el Real Decreto 88/2026 (MITECO), aunque su operativa efectiva está aún pendiente. En este trabajo se asume que el BESS participar directamente en ambos mercados.

2.3 HERRAMIENTAS DE DESARROLLO

El modelo desarrollado en este trabajo está implementado en Python, uno de los lenguajes de programación más utilizados en el ámbito científico y de análisis de datos. En concreto, se hace uso de las librerías Pandas y NumPy para la carga y tratamiento de los datos de precios.

La optimización se formula con Pyomo, una librería de Python que permite escribir el problema de forma ordenada: variables, restricciones y función objetivo (Pyomo). Una vez listo, Pyomo se lo pasa al solver HiGHS, que es quien realmente lo resuelve y encuentra la solución óptima. HiGHS es una herramienta gratuita y de código abierto especializada en

problemas de optimización lineal entera mixta, que es exactamente el tipo de problema que se plantea en este trabajo (HIGHS).

2.4 SIMULACIÓN DE MONTECARLO

La simulación de Montecarlo es una herramienta ampliamente utilizada en multitud de sectores, y su estudio en profundidad sería por sí solo suficiente para un trabajo de esta magnitud. Por ese motivo, no se entrará en detalle en sus fundamentos matemáticos, aunque sí se explicará lo suficiente para entender su aplicación en este trabajo.

La idea es sencilla: en lugar de asumir que el futuro va a ser exactamente como se ha previsto, se generan miles de escenarios posibles variando aleatoriamente los factores de incertidumbre, y se corre el modelo en cada uno de ellos (IBM). El resultado no es un único número, sino una distribución estadística que permite responder preguntas como: ¿cuánto gana la batería de media?, ¿cuál es el peor escenario probable?, o ¿con qué frecuencia el modelo genera pérdidas?

En este trabajo se utilizará para evaluar la robustez del modelo frente a situaciones distintas a las previstas: variaciones en los precios del mercado, subastas de carga no ganadas, activaciones de reserva inesperadas o fallos técnicos de la batería, entre otros. Su aplicación concreta y los resultados obtenidos se detallan más adelante.

Capítulo 3. ESTADO DE LA CUESTIÓN

El almacenamiento energético mediante baterías y su participación en los mercados eléctricos es un campo de investigación que ha crecido mucho en los últimos años. Esto se debe principalmente a que el precio de las baterías de iones de litio ha caído drásticamente (Figura 5), y a que los sistemas eléctricos necesitan cada vez más flexibilidad para gestionar la energía producida por fuentes renovables como la solar o la eólica. A continuación, se revisan los trabajos más relevantes en este ámbito, centrándonos en aquellos que proponen modelos matemáticos para decidir cuándo cargar y descargar una batería de forma que se maximice el beneficio económico.




Figura 4: Precio de baterías de Litio-ion (Solar Insure, 2025)

El trabajo más cercano al presente proyecto es el de Fernández-Muñoz y Pérez-Díaz (2023), titulado “*Optimisation models for the day-ahead energy and reserve self-scheduling of a hybrid wind–battery virtual power plant*” publicado en el *Journal of Energy Storage*. En él se desarrolla un modelo MILP para optimizar la operación de una

planta virtual compuesta por un parque eólico y una batería de iones de litio que participa simultáneamente en el mercado diario y en el mercado de reserva secundaria del sistema eléctrico español. El modelo maximiza el beneficio económico teniendo en cuenta el coste de degradación de la batería y la incertidumbre en la generación eólica. Los resultados muestran que los ingresos obtenidos con el modelo alcanzan aproximadamente el 90% de los que se obtendrían con información perfecta del mercado.

Mohamed et al. (2023), titulado *“Stacked revenues for energy storage participating in energy and reserve markets with an optimal frequency regulation modeling”* publicado en *Applied Energy*, analizan la participación de una batería en múltiples mercados del sistema eléctrico francés, incluyendo el mercado diario, el intradiario y varios servicios de frecuencia. Sus resultados muestran que los servicios de regulación de frecuencia son consistentemente más rentables que el arbitraje puro en el mercado diario, y que participar de forma conjunta en energía y reserva incrementa los beneficios anuales hasta un 76% respecto a operar únicamente en el mercado diario.

Paredes et al. (2024), titulado *“Revenue stacking of BESSs in wholesale and aFRR markets with delivery guarantees”* publicado en *Electric Power Systems Research*, proponen un modelo de participación simultánea en los mercados Day-Ahead y aFRR que incorpora la incertidumbre en la activación de la reserva. A diferencia de los modelos deterministas, este enfoque ofrece garantías de entrega en tiempo real para un nivel de fiabilidad dado, logrando una mejora del 17,3% en los beneficios respecto a modelos que tratan la activación como un valor fijo conocido de antemano.

De los trabajos revisados se puede concluir que hay una base sólida de modelos matemáticos para optimizar baterías en mercados eléctricos europeos, y que participar a la vez en el mercado diario y en los servicios de reserva es consistentemente más rentable que operar en un solo mercado. Sin embargo, solo se ha encontrado un trabajo enfocado en España —el ya citado de Fernández-Muñoz y Pérez-Díaz (2023)—, por lo que el mercado español, con sus particularidades, está menos estudiado en la literatura.

Capítulo 4. DEFINICIÓN DEL TRABAJO

4.1 JUSTIFICACIÓN

De los trabajos revisados queda claro que la participación simultánea en el mercado diario y en los servicios de reserva es consistentemente más rentable para una batería que operar en un único mercado, y existe literatura sólida que lo respalda. Sin embargo, ninguno aborda el problema en las condiciones que plantea este trabajo. El único estudio centrado en el sistema eléctrico español, el de Fernández-Muñoz y Pérez-Díaz (2023), modela una planta virtual híbrida que combina un parque eólico con una batería, y no un sistema de almacenamiento autónomo (*standalone*) operando como agente independiente. Los otros dos abordan un mercado distinto; el francés, en Mohamed et al. (2023), o plantean enfoques metodológicos generales (Paredes y Aguado, 2024), y en ambos casos recurren a formulaciones probabilísticas que exigen un dominio avanzado de la optimización. A todos ellos se añade una limitación común y decisiva: están formulados a resolución horaria, anterior a la transición del mercado español a la negociación cuarto horaria (MTU15), efectiva en el mercado diario desde septiembre de 2025, que altera la estructura temporal del problema y amplía las oportunidades de arbitraje intradía.

Este trabajo propone una alternativa más sencilla y práctica, adaptada específicamente al mercado eléctrico español y a su resolución cuarto horaria, y pensada para que pueda emplearse sin un dominio avanzado de la optimización matemática. El modelo se formula de manera determinista, priorizando la transparencia y la facilidad de uso. Ahora bien, en la operación real nadie conoce con exactitud los precios del día siguiente, por lo que el trabajo no se limita a calcular la solución óptima con información perfecta: mediante una simulación de Montecarlo se evalúa el comportamiento del modelo bajo distintos escenarios de error de predicción, cuantificando cuánto se aleja el resultado real del óptimo teórico. De este modo se obtiene no solo una herramienta de decisión, sino también una medida de cuánto valor conserva cuando las previsiones fallan, accesible tanto para un inversor particular como para

una empresa del sector que quiera operar su batería de forma fundamentada en el mercado español.

4.2 OBJETIVOS

El objetivo principal de este trabajo es, a partir del estudio del funcionamiento técnico de las baterías y de los mercados eléctricos, y mediante las suposiciones de modelado apropiadas, desarrollar un modelo de optimización robusto capaz de determinar la estrategia óptima de operación de una batería en el mercado diario y en el mercado de regulación secundaria, maximizando el beneficio económico a resolución cuarto horaria.

4.3 METODOLOGÍA

Para alcanzar el objetivo planteado, el trabajo se estructura en las siguientes etapas:

En primer lugar, se realiza un estudio del marco teórico y técnico necesario, que comprende el funcionamiento de los sistemas de almacenamiento por baterías y la mecánica operativa de los mercados eléctricos en los que participan: el mercado diario, gestionado por OMIE, y el mercado de regulación secundaria, supervisado por REE.

A partir de este análisis, se formula algebraicamente el modelo de optimización, definiendo la función objetivo, las variables de decisión y el conjunto de restricciones operativas y de mercado. Esta formulación incorpora las suposiciones de modelado necesarias, tanto en lo relativo a la participación en el mercado de regulación secundaria como en los parámetros numéricos del sistema.

El modelo es posteriormente implementado en Python mediante la librería Pyomo y sometido a un proceso de validación. Para evaluar su robustez frente a la incertidumbre inherente a los precios del mercado, se aplica una simulación de Montecarlo complementada con análisis de sensibilidad sobre los parámetros clave.

Finalmente, los resultados obtenidos son visualizados a través de dashboards desarrollados para distintos horizontes temporales, lo que permite un análisis comprehensivo del comportamiento del modelo y de la rentabilidad del activo bajo diferentes condiciones de mercado.

4.4 PLANIFICACIÓN Y ESTIMACIÓN ECONÓMICA

Planificación

El proyecto se ha desarrollado a lo largo de aproximadamente 10 meses, con una dedicación media de 10 horas semanales, lo que supone un total estimado de 400 horas de trabajo. Las fases se solapan parcialmente, ya que la redacción del TFG se realizó en paralelo al resto del desarrollo:

- Meses 1-2: Estudio del marco teórico sobre baterías y mercados eléctricos
- Meses 2-5: Formulación algebraica del modelo de optimización
- Meses 5-7: Implementación en Python
- Meses 6-8: Simulación de Montecarlo y validación
- Meses 7-9: Análisis de resultados y desarrollo de dashboards
- Meses 7-10: Redacción del TFG (en paralelo)

Estimación Económica

El coste principal del proyecto es el tiempo dedicado por el autor. Valorando las 400 horas a una tarifa de ingeniero junior, el coste de desarrollo se situaría en torno a los valores habituales del sector. Las herramientas utilizadas, Python, Pyomo y el solver HiGHS, son de código abierto y gratuitas, por lo que no suponen coste adicional. En cuanto al mantenimiento futuro del modelo, este requeriría una actualización periódica de los parámetros de mercado con datos históricos recientes, cuyo coste dependerá directamente de la calidad y el origen de los datos utilizados: cuanto más precisas sean las predicciones de precios, mejores serán los resultados, pero también mayor será el coste de obtenerlas.

Capítulo 5. MODELO ALGEBRAICO

El modelo desarrollado en este trabajo es un MILP (*Mixed Integer Linear Programming*, o Programación Lineal Entera Mixta), un tipo de modelo de optimización que combina variables continuas, como la energía cargada o descargada en cada intervalo, con variables binarias enteras, que toman únicamente el valor 0 o 1, como la indicación de si la batería está cargando o descargando en un momento dado.

La formulación de este tipo de modelos sigue siempre la misma estructura. En primer lugar, se definen los sets, que establecen el universo sobre el que opera el modelo, en este caso el conjunto de intervalos de tiempo. A continuación, se definen los parámetros, que son los datos de entrada conocidos, como los precios del mercado, la capacidad de la batería o su eficiencia. En tercer lugar, se definen las variables, que representan las decisiones que toma el modelo en cada intervalo: cuánta energía cargar, vender o reservar para la secundaria. Después se formula la función objetivo, que es lo que el modelo trata de optimizar, en este caso maximizar el beneficio económico. Por último, se definen las restricciones, que son las reglas que deben respetar las variables en todo momento.

5.1 SETS

Los sets de este modelo definen el eje temporal sobre el que opera la optimización. Dado que el modelo trabaja con resolución cuarto horaria y horizonte diario, el conjunto de intervalos de tiempo queda definido como:

$t \in T$ *Intervalos de 15 minutos*

$T = \{1, 2, 3 \dots, 96\}$ *96 intervalos de 15 minutos en un día*

5.2 PARÁMETROS

5.2.1 PARÁMETROS DINÁMICOS

Los parámetros que varían en el tiempo toman un valor distinto para cada intervalo del día. En este modelo, dichos parámetros corresponden a los precios del mercado:

p_t = Precio del mercado en el intervalo t , en €/MWh

$$p_t^{eff} = \max(p_t, 0)$$

El precio efectivo es calculado a partir del precio diario, creado para evitar que el modelo explote las compras de energía a precios negativos. Este punto se trata en detalle en el apartado de suposiciones.

5.2.2 PARÁMETROS ESTÁTICOS

Los parámetros que se mantienen constantes independientemente del intervalo de t son los parámetros constantes, estos son características técnicas y suposiciones.

5.2.2.1 Parámetros de la Batería

Los parámetros constantes relacionados con la batería se pueden ver a continuación, empezando con los referidos a la capacidad de esta. Como se ha mencionado en el apartado [2.1](#), las capacidades de la batería no se usan por completo para desgastar la batería más lentamente, por ello existen los niveles de SOC mínimo y máximo. Por último, hace falta saber en qué nivel de batería empieza el día la batería.

E^{max} = Capacidad máxima de la batería, en MWh

SOC^{min} = Nivel mínimo admisible de energía almacenada, en MWh

SOC^{max} = Nivel máximo admisible de energía almacenada, en MWh

SOC^{init} = Nivel de la batería al inicio del día, en MWh

Otra de las cualidades mencionadas en el [marco teórico](#), es la potencia de una batería, se distingue entre potencia de carga y de descarga.

$$p^{ch,max} = \text{Potencia máxima de carga, en MW}$$

$$p^{dis,max} = \text{Potencia máxima de descarga, en MW}$$

Por último, la batería no es perfecta y disipa calor por lo que la eficiencia de ciclo (carga y descarga de la batería) se debe tener en cuenta, además de la degradación, que tiene en cuenta el uso de la batería. Se entrará a fondo con el modelaje de la degradación más adelante.

$$\eta = \text{Eficiencia de ciclo}$$

$$c^{deg} = \text{coste por degradación al usar la batería, en €/MWh}$$

5.2.2.2 Parámetros Constantes del Mercado

A diferencia del mercado diario, los precios del mercado de regulación secundaria no son públicos en tiempo real y su variabilidad es más difícil de predecir. Por este motivo, su modelado se simplifica asumiendo valores fijos para el pago por disponibilidad y por activación, tanto de entrega como de absorción. Asimismo, dado que el porcentaje de activación real de la reserva es incierto, se asume un valor esperado constante para cada dirección. Todos estos parámetros se detallan a continuación.

$$\pi^{disp} = \text{Pago por disponibilidad en subida, en €/MWh reservado}$$

$$\pi^{disp} = \text{Pago por disponibilidad en bajada, en €/MWh reservado}$$

$$\pi^{act,up} = \text{Pago por activación de entrega, en €/MWh activado}$$

$$\pi^{act,down} = \text{Pago por activación de absorción, en €/MWh activado}$$

$$\alpha^{up} = \text{Porcentaje esperado de activación de la reserva de entrega}$$

$$\alpha^{down} = \text{Porcentaje esperado de activación de la reserva de absorción}$$

Para acabar con los parámetros constantes, se define un parámetro auxiliar necesario para la implementación del modelo:

$$\Delta = \text{Resolución temporal del modelo}$$

5.3 VARIABLES

La definición de variables es uno de los pasos más importantes del modelo, ya que sienta la base de su arquitectura, definiendo que variables se podrán variar para el mejor resultado del modelo. Para más aclaración se han separado por categorías.

5.3.1 VARIABLES DE LA BATERÍA

Las posibles acciones que puede tomar la batería en cada intervalo son cargarse, descargarse o participar en los servicios de ajuste, que se tratan en el siguiente apartado. Además, es necesaria una variable que registre el estado de carga de la batería en todo momento, para evitar que el modelo intente cargar una batería ya llena o descargar una vacía. Estas variables son:

$$x_t^{ch} = \text{Energía cargada a la batería en } t, \text{ en MWh}$$

$$x_t^{dis} = \text{Energía descargada a la batería en } t, \text{ en MWh}$$

$$SOC_t = \text{Energía almacenada en la batería en } t, \text{ en MWh}$$

5.3.2 VARIABLES DEL MERCADO

Esta categoría distingue entre el mercado operado por OMIE y por REE (servicios de ajuste).

5.3.2.1 Variables del Mercado Diario

En el mercado diario, el modelo puede tomar tres alternativas en cada intervalo: comprar energía, venderla, o no hacer nada. Estas dos primeras se modelan con las siguientes variables:

$$x_t^{buy} = \text{Energía comprada al mercado en } t, \text{ en MWh}$$

$$x_t^{sell} = \text{Energía vendida al mercado en } t, \text{ en MWh}$$

5.3.2.2 Variables del Mercado Secundario

El mercado de regulación secundaria introduce una complejidad adicional, ya que el modelo debe distinguir entre dos conceptos distintos: la capacidad que se reserva y ofrece a REE, y la energía que finalmente se activa. En cada intervalo, el modelo puede comprometer una banda de potencia disponible para subir o bajar, y posteriormente REE puede activar parte o la totalidad de esa reserva, provocando cambios reales en el estado de carga de la batería. Las siguientes variables recogen ambos conceptos:

$$r_t^{up} = \text{Capacidad reservada en el intervalo } t \text{ para descargar la batería si el sistema lo requiere, en MWh}$$

$$r_t^{down} = \text{Capacidad reservada en el intervalo } t \text{ para cargar la batería si el sistema lo requiere, en MWh}$$

$$a_t^{up} = \text{Energía efectivamente activada en el intervalo } t \text{ para la entrega a la red a través de la secundaria, en MWh}$$

$$a_t^{down} = \text{Energía efectivamente activada en el intervalo } t \text{ para la absorción desde la red a través de la secundaria, en MWh}$$

5.3.3 VARIABLES BINARIAS

Las variables binarias son útiles para evitar que dos eventos incompatibles ocurran al mismo tiempo. En este modelo se aplican a dos casos: que la batería no cargue y descargue simultáneamente, y que el modelo no compre y venda energía en el mismo intervalo. Las siguientes variables garantizan que esto no ocurra:

$y_t^{bat} = \text{Binario, 1 si la batería está en modo carga, 0 si en descarga}$

$y_t^{grid} = \text{Binario, 1 si se compra al mercado, 0 si se vende}$

5.4 FUNCIÓN OBJETIVO

La función objetivo es quizá lo más característico del modelo, ya que define la dirección que toma la optimización y cómo contribuye cada variable al resultado final: el beneficio económico diario.

$$\begin{aligned} \max z = \sum_{t \in T} & (p_t \cdot x_t^{sell} + \pi^{disp,up} \cdot r_t^{up} + \pi^{disp,down} \cdot r_t^{down} + (\pi^{act,up} - p_t) \cdot a_t^{up} \\ & + (\pi^{act,down} - p_t^{eff}) \cdot a_t^{down} - p_t^{eff} \cdot x_t^{buy} - c^{deg} \cdot (x_t^{ch} + x_t^{dis} + a_t^{up} \\ & + a_t^{down})) \end{aligned}$$

Lo que se está modelando es la maximización del beneficio, cuya fórmula es sencilla: ingresos menos costes. En cuanto a los ingresos, el modelo cuenta con tres fuentes: la venta de energía en el mercado diario, el pago por disponibilidad de banda por parte de REE, y el pago por activación, tanto de entrega como de absorción. En cuanto a los costes, hay únicamente dos: la compra de energía en el mercado diario y el coste de degradación por usar la batería. Este último se aplica sobre toda la energía operada, ya sea en el mercado diario o en el secundario, de ahí los cuatro términos que lo multiplican.

5.5 RESTRICCIONES

Las restricciones garantizan que las decisiones del modelo sean físicamente realizables y coherentes con el funcionamiento real de la batería y de los mercados. Sin ellas, el optimizador podría encontrar soluciones matemáticamente óptimas pero imposibles de ejecutar en la práctica. Se ha dividido por categorías:

5.5.1 RESTRICCIONES DE BATERÍA

5.5.1.1 Dinámica de la Batería

Esta restricción mide el comportamiento de la batería, y está definido por la siguiente ecuación.

$$SOC_t = SOC_{t-1} + \eta \cdot (x_{ch}^t + a_t^{down}) - \frac{x_t^{dis} + a_t^{up}}{\eta} \quad \forall t \in T$$

En ella se expresa que el nivel de la batería en el intervalo t es igual a dicho nivel un intervalo antes y actualizando las cargas y descargas, ya sean del mercado diario o secundario. Nótese que en la carga se produce una disipación de calor, por lo que se pierde energía, de ahí la multiplicación por la eficiencia, y en la descarga, se necesita descargar más cantidad por el mismo motivo, de ahí que esté en el cociente. Esto se cumple para todo intervalo t .

Por último, debido a que t empieza en el intervalo 1, es decir, no tiene el intervalo 0, se debe definir un nivel de comienzo para la batería.

$$SOC_0 = SOC^{init}$$

5.5.1.2 Límites de Carga

Esta ecuación define los límites inferior y superior del estado de carga de la batería. Por motivos de seguridad y para preservar la vida útil del activo, la batería no opera en los extremos del 0% y 100% de su capacidad, sino dentro de un rango acotado cuyos valores se fijan en el apartado de suposiciones:

$$SOC^{min} \leq SOC_t \leq SOC^{max} \quad \forall t \in T$$

5.5.1.3 Restricciones de Potencia de Carga y Descarga

Estas ecuaciones tienen dos funciones. Por un lado, limitan la energía cargada o descargada en cada intervalo a la potencia máxima disponible, multiplicada por Δ para convertir potencia (MW) en energía (MWh) a resolución cuarto horaria. Por otro lado, garantizan que

la batería no pueda cargar y descargar simultáneamente: cuando $y_t^{bat} = 1$ la batería está en modo carga y la descarga queda anulada, y viceversa.

$$x_t^{ch} + a_t^{down} \leq y_t^{bat} \cdot p^{ch,max} \cdot \Delta \quad \forall t \in T$$

$$x_t^{dis} + a_t^{up} \leq (1 - y_t^{bat}) \cdot p^{dis,max} \cdot \Delta \quad \forall t \in T$$

5.5.1.4 Fin de Estado de Carga

Por último, dado que el modelo se optimiza día a día pero su propósito es aplicarse a largo plazo, es necesario garantizar que cada día se trate en igualdad de condiciones. Sin esta restricción, el modelo podría beneficiarse artificialmente en los primeros días descargando la batería sin necesidad de reponerla, lo que distorsionaría los resultados. Por este motivo, se fija que el estado de carga al final del día sea igual al del inicio:

$$SOC_{t_{final}} = SOC^{init}$$

Esta simplificación asegura que el modelo trate todos los días por igual y no priorice los primeros a costa de los siguientes. Se entrará en detalle en el apartado de suposiciones.

5.5.2 RESTRICCIONES DE MERCADOS

5.5.2.1 Balance Energético

La ecuación de balance energético garantiza que todos los flujos de energía del sistema sean coherentes en cada intervalo. En el lado izquierdo se recoge toda la energía que entra al sistema: la comprada al mercado, la descargada de la batería y la activación de reserva a subir. En el lado derecho, toda la energía que sale: la vendida al mercado, la cargada en la batería y la activación de reserva a bajar.

$$x_t^{buy} + x_t^{dis} + a_t^{up} = x_t^{sell} + x_t^{ch} + a_t^{down} \quad \forall t \in T$$

5.5.2.2 Activación Limitada por la Reserva Ofertada

Estas ecuaciones modelan la energía efectivamente activada en función de la banda ofertada. Como se ha mencionado previamente, y se detallará en el apartado de suposiciones, se asume un porcentaje de activación constante sobre la reserva ofertada, tanto para la entrega como para la absorción, en todo intervalo t . Dicho porcentaje está representado por α .

$$a_t^{up} = \alpha^{up} \cdot r_t^{up} \quad \forall t \in T$$

$$a_t^{down} = \alpha^{down} \cdot r_t^{down} \quad \forall t \in T$$

5.5.2.3 Reserva Limitada por Capacidad Disponible en la Batería

Estas ecuaciones garantizan que la reserva ofertada al mercado secundario sea físicamente realizable, es decir, que el modelo no pueda comprometer más capacidad de la que la batería puede realmente entregar o absorber dado su estado de carga en ese momento. La eficiencia aparece de forma análoga a la dinámica del SOC: multiplica en el caso de la entrega y divide en el de la absorción, ya que en ambos sentidos se producen pérdidas por disipación de calor.

$$r_t^{up} \leq \eta \cdot (SOC_{t-1} - SOC^{min}) \quad \forall t \in T$$

$$r_t^{down} \leq \frac{(SOC^{max} - SOC_{t-1})}{\eta} \quad \forall t \in T$$

5.5.2.4 Restricciones de Compra y Venta en el Mercado

Estas ecuaciones impiden que el modelo compre y venda energía en el mismo intervalo en el mercado diario. Para ello se introduce una variable binaria u_t en cada intervalo, que actúa como selector de la operación permitida. El mecanismo es sencillo: cuando $y_t^{grid} = 1$ el modelo puede comprar, pero el techo de venta queda anulado, y cuando $y_t^{grid} = 0$ ocurre lo contrario. El límite de cada operación se fija mediante la potencia máxima que el activo puede intercambiar en cada dirección ($P^{ch,max}$ y $P^{dis,max}$), valor que es suficientemente

grande como para no restringir las operaciones reales del modelo y que garantiza que las dos variables sean mutuamente excluyentes en todo intervalo.

$$x_t^{buy} \leq y_t^{grid} \cdot p^{ch,max} \quad \forall t \in T$$

$$x_t^{sell} \leq (1 - y_t^{grid}) \cdot p^{dis,max} \quad \forall t \in T$$

5.5.3 OTRAS RESTRICCIONES

5.5.3.1 No Negatividad

Por último, para garantizar la coherencia del modelo, se impone que todas las variables continuas sean no negativas y que las variables binarias tomen únicamente los valores 0 o 1. Esto es necesario porque, por ejemplo, si x_t^{buy} pudiera ser negativa, el modelo la estaría usando como variable de venta bajo otro nombre, rompiendo la lógica del modelo.

$$x_t^{buy}, x_t^{sell}, x_t^{ch}, x_t^{dis}, r_t^{up}, r_t^{down}, a_t^{up}, r_t^{down} \geq 0 \quad \forall t \in T$$

$$y_t^{bat}, y_t^{grid} = \{0,1\}$$

Capítulo 6. SUPOSICIONES

En trabajos de esta complejidad, es inevitable realizar suposiciones que simplifiquen la realidad para hacer el modelo tratable. La calidad de estas suposiciones es lo que determina si el modelo refleja fielmente el comportamiento del sistema o si, por el contrario, produce resultados poco representativos. Por este motivo, todas las suposiciones de este trabajo han sido adoptadas de forma razonada y justificada, buscando el equilibrio entre simplicidad y realismo.

Las suposiciones se presentan en dos niveles. El nivel teórico recoge las simplificaciones que permiten formular el problema como una optimización tratable, asumiendo condiciones ideales. El nivel de simulación introduce incertidumbre sobre estos supuestos mediante técnicas de Montecarlo, evaluando la robustez del modelo cuando las condiciones reales difieren de las ideales.

6.1 SUPOSICIONES A NIVEL TEÓRICO

6.1.1 SUPOSICIONES DEL MERCADO DIARIO

Dentro de las suposiciones del mercado diario, se pueden distinguir entre las de desarrollo del modelo y las de uso práctico.

En cuanto al desarrollo, la primera suposición es que no existen precios negativos desde el punto de vista del modelo. Aunque en la realidad el mercado diario puede registrar precios negativos en horas de exceso de generación renovable, el modelo los trata como cero mediante p_t^{eff} , evitando que se explote esta situación de forma irreal. La segunda suposición es que todas las ofertas se casan, es decir, el modelo asume que cualquier decisión de compra o venta se ejecuta en el mercado sin restricciones de aceptación. Por último, se asume que el BESS opera como precio-aceptante (price-taker): dado que su

capacidad es pequeña con relación al volumen total del mercado, sus decisiones no tienen capacidad de alterar el precio marginal.

En cuanto al uso práctico, se asume que los precios del día siguiente son conocidos de antemano en el momento de la optimización. En la realidad, el operador solo dispone de una previsión en el momento de presentar ofertas a las 12:00. Esta simplificación convierte el modelo en determinista, lo que facilita su resolución, pero implica que los resultados representan un escenario óptimo que no es alcanzable en la práctica. Su impacto se evalúa en el apartado de simulación de Montecarlo.

6.1.2 SUPOSICIONES MERCADO SECUNDARIO

En cuanto a las suposiciones en el mercado secundario, conviene primero tratar el modelado y posteriormente pasar a la asignación de valores para este modelado.

6.1.2.1 Modelado Mercado Secundario

El mercado de regulación secundaria funciona de forma significativamente distinta al mercado diario. Los precios que se ofertan y los pagos por activación varían constantemente en tiempo real en función del estado de la red, lo que hace que su modelado fiel sea considerablemente más complejo, especialmente en el caso de la activación.

Dado que el propósito de este trabajo no es reproducir el mercado secundario con exactitud, sino capturar los beneficios que puede aportar al modelo de optimización, se ha optado por una simplificación en la que se fijan como constantes el pago por banda ofertada, el pago por activación tanto de entrega como de absorción, y el porcentaje de activación esperado en cada dirección.

Esta simplificación se justifica por el horizonte de aplicación del modelo. Aunque la optimización se realiza día a día, su propósito es ser aplicado a largo plazo, en un horizonte comparable a la vida útil de una batería. En este contexto, los valores constantes asumidos actúan como medias esperadas que, en horizontes temporales amplios, deberían converger

hacia los valores reales del mercado. Esto implica que el modelo no es fiable en el análisis día a día, ya que difícilmente replicará el comportamiento exacto del mercado en cada jornada, pero en horizontes de meses, cuatrimestres o años los resultados deberían aproximarse cada vez más a la realidad.

6.1.2.2 Suposiciones de Valores para Mercado Secundario

Hay varios valores que se deben justificar en este apartado, por lo que tomaremos un orden. Empezando por los precios por oferta de MW, continuando con los precios de activación y acabando con el porcentaje de activación.

Precios por Disponibilidad

Para hallar este valor se ha calculado la media de los precios de banda de los años 2022, 2024 y 2025, obtenidos de los Informes del Sistema Eléctrico Español (REE). Dado que estos precios se expresan originalmente en €/MW, se han convertido a €/MWh multiplicando por $\Delta = 0,25$ horas, para mantener la coherencia dimensional con el resto del modelo. Los cálculos para subida y bajada se muestran a continuación:

PRECIO POR DISPONIBILIDAD (€/MWh)		
	Subida	Bajada
2022	11,17	11,17
2023	-	-
2024	8,57	9,18
2025	8,09	5,11
Media	9,27	8,48

Tabla 1: Precio por Disponibilidad (€/MWh)

Precios por Activación

De forma similar a los precios de disponibilidad, estos valores se han calculado como la media de los precios de activación de los años 2022, 2023, 2024 y 2025, obtenidos de los Informes del Sistema Eléctrico Español (REE). A diferencia de los precios de banda, estos

ya vienen expresados en €/MWh, por lo que no requieren conversión adicional. Los datos mensuales y las medias anuales se muestran a continuación:

PRECIOS POR ACTIVACIÓN (€/MWh)		
	Subida	Bajada
2022	190,40	127,40
2023	101,30	57,70
2024	77,60	24,30
2025	103,30	2,80
Media	118,15	53,05

Tabla 2: Precios por Activación (€/MWh)

Precios por Activación

En este caso, el porcentaje de activación no es una métrica oficial publicada directamente, por lo que es necesario calcularlo a partir de dos datos. En primer lugar, los GWh anuales de reserva secundaria efectivamente activados, obtenidos del Informe del Sistema Eléctrico denominado *Servicios de ajuste e intercambios internacionales*. En segundo lugar, la banda total contratada, que se obtiene multiplicando la banda media horaria (en MW) por las horas totales del año (8.760 h). El cociente entre ambas magnitudes proporciona el porcentaje de utilización anual, que actúa como proxy del número de veces que se activa la reserva a lo largo del año. La formulación es la siguientes:

$$\alpha^{up/down} = \frac{regulación_secundaria(MWh)}{banda_media_horaria_contratada(MW) \cdot 8760h}$$

Los datos son los siguientes:

PORCENTAJE DE UTILIZACIÓN		
	Subida	Bajada
Utilización (%) 2022	20,8%	33,6%
Utilización (%) 2023	32,6%	25,4%
Utilización (%) 2024	30,2%	19,3%
Utilización (%) 2025	10,7%	10,7%
Media	23,6%	22,2%

Tabla 3: Porcentaje de Utilización

6.1.3 SUPOSICIONES DE LA BATERÍA

En lo que respecta a las suposiciones de la batería, tiene sentido de nuevo dividir esta sección entre las suposiciones de modelado y las suposiciones numéricas de la batería en sí.

6.1.3.1 Modelado de la Batería

Este apartado recoge las decisiones de modelado adoptadas respecto al comportamiento de la batería en la optimización.

La primera suposición es que la batería termina cada día con el mismo nivel de carga con el que empieza. Dado que el modelo opera en horizonte diario, pero se aplica a largo plazo, no incluir esta condición permitiría que el modelo generara beneficios artificiales a corto plazo aprovechando el nivel inicial de carga, vaciando la batería sin necesidad de reponerla. De esta forma, cada día se trata de forma independiente y en igualdad de condiciones, lo cual tiene sentido en la práctica: las predicciones de precios más fiables son las del día siguiente, y obligar al modelo a tener en cuenta horizontes más largos introduciría incertidumbre que perjudicaría su objetivo. Esta suposición ya fue introducida en el [modelo algebraico](#).

La segunda suposición hace referencia a las ineficiencias de la batería. Las pérdidas energéticas se producen en forma de calor tanto durante la carga como durante la descarga. Aunque en la realidad estas ineficiencias pueden ser asimétricas, por motivos de simplicidad se asume que la eficiencia de ciclo η es la misma en ambos sentidos.

Por último, la degradación de la batería. Una batería pierde capacidad máxima progresivamente a medida que acumula ciclos de carga y descarga. Modelar este comportamiento de forma exacta requeriría un horizonte temporal mucho más largo que el diario, lo que va en contra del propósito del modelo. Por ello, en lugar de modelar la degradación como una reducción física de capacidad, se introduce un coste fijo de degradación (c^{deg} , en €/MWh operado) que actúa como penalización económica por cada

MWh cargado o descargado, desincentivando el uso excesivo de la batería sin complicar la formulación.

6.1.3.2 Suposiciones de Valores para la Batería

Eficiencia

En cuanto a la eficiencia, el modelo trabaja con la eficiencia por sentido η , aplicada tanto a la carga como a la descarga. Según datos de la industria, los sistemas BESS de iones de litio presentan una eficiencia de ciclo completo (Round Trip Efficiency, RTE) de entre el 88% y el 94% (Jalthar, 2026). Se ha optado por el extremo más conservador del rango, fijando una RTE del 88%, con el objetivo de que el modelo funcione correctamente incluso en condiciones menos favorables. Dado que en el modelo la eficiencia se aplica de forma simétrica en carga y descarga, el valor de η por sentido se obtiene como:

$$\eta^2 = 0,88$$

Por lo que:

$$\eta = \sqrt{0,88} \approx 0,9381 = 93,81\%$$

Coste de Degradación

El coste de degradación es difícil de modelar como métrica oficial, pero puede aproximarse de forma razonada. La idea es la siguiente: el coste por MWh de degradación equivale al valor del activo distribuido entre toda la energía que es capaz de desplazar a lo largo de su vida útil.

$$c^{deg} = \frac{\text{Valor del Activo (€)}}{\text{Energía total que puede desplazar en su vida útil (MWh)}}$$

Para calcularlo, se asume que la degradación se produce de forma lineal a lo largo de los años de vida de la batería, por lo que las pérdidas anuales son constantes. Sin embargo, dado que el dinero tiene valor temporal, estas pérdidas futuras valen menos hoy que las presentes

(mejor tener dinero hoy que mañana). Por ello, el coste total de degradación se obtiene como el valor presente de una renta constante de pérdidas anuales, descontadas a una tasa de descuento que se ha indicado como la media de los últimos 15 años de la tasa de inflación ($\approx 2\%$) (Macrotrends).

Para realizar los cálculos se trabaja con una batería de referencia de 2 MWh, con 6000 ciclos de vida útil con un DOD del 80% y una vida de 15-20 años (NextG Power, 2026), asumiremos que 15 años. Se asume que, aunque las magnitudes cambien con el tamaño de la batería, el coste de degradación por MWh es independiente de la escala y por tanto extrapolable a cualquier configuración. De los parámetros escogidos para estos cálculos, el único que este hilado al coste de degradación es el DOD, ya que la cantidad de ciclos depende directamente de este valor, por lo tanto, para el modelo que estamos desarrollando el DOD debe de ser un 80%.

La energía total que mueve en su vida útil es:

$$\text{Energía total} = \text{Ciclos} \times \text{Capacidad (MWh)} \times 2$$

Los parámetros se pueden ver en la tabla siguiente:

PARÁMETROS			
Parámetro	Valor	Unidad	Fuente
Capacidad de la batería	2,00	MWh	Supuesto de modelado
Precio del pack (2024)	108,00	\$/kWh	BloombergNEF, 2025
Tipo de cambio USD/EUR	0,86	€/€	A marzo de 2026
Ciclos de vida útil (80% DOD)	6000	ciclos	NextG Power, 2026
Vida útil estimada (15 - 20 años)	15	años	SolarInsure, 2025
CPI últimos 15 años (2010 - 2024)	2,0%	%	Macrotrends, 2025

Tabla 4: Parámetros de Entrada para cálculo del coste de degradación

Una vez tenemos estos parámetros, nos queda calcular el valor presente de las pérdidas totales por degradación, y dividirlo entre la energía total desplazada en la vida de la batería.

Para el valor presente de las pérdidas, en primer lugar, se calcula el coste total del pack, para ellos se multiplica la capacidad de la batería por el precio en €/kWh:

$$\text{Coste total del pack (€)} = 2MWh \cdot \frac{108€}{kWh} \cdot 1000 = 185.760€$$

En segundo lugar se calcula la pérdida anual por degradación como el coste total del pack dividido entre la vida útil estimada:

$$\text{Pérdida anual por degradación} = \frac{185.760€}{15 \text{ años}} = 12.384€/año$$

A continuación, calculamos el valor presente de las pérdidas totales usando la función de *Present Value* de Excel:

$$PV = (\text{rate} = 2\%, nper = 15, pmt = -12.384, FV = 0) = 159.125€$$

Ya tenemos el numerador, pasando el denominador, la energía total desplazada en vida útil, que se calcula como:

$$E_{total} = \text{Capacidad (MWh)} \times \text{Ciclos} \times 2$$

El factor 2 recoge que cada ciclo completo implica una carga y una descarga, y el coste de degradación penaliza ambos sentidos en el modelo. Su cálculo es el siguiente:

$$E^{total} = 2MWh \cdot 6000 \cdot 2 = 24.000MWh$$

Por último, calculamos nuestro coste de degradación (c^{deg}), su fórmula y cálculo son los siguientes:

$$c^{deg} = \frac{\text{Valor presente de las pérdidas totales (€)}}{E^{total} \text{ (MWh)}} = \frac{159.125 €}{24.000MWh} = 6,63€/MWh$$

Todos los cálculos relevantes se pueden ver en la siguiente table:

CÁLCULOS INTERMEDIOS

Coste total del pack (€)	185.760	€
Energía total desplazada en vida útil	24.000	MWh
Pérdida anual por degradación	12.384	€/año
Valor presente de pérdidas totales	159.125	€
Coste de degradación	6,63	€/MWh

Tabla 5: Cálculos intermedios para el coste de degradación

Este resultado de 6,63 €/MWh es el valor que se asigna al parámetro c^{deg} en el modelo. Dado que actúa como penalización económica por cada MWh operado en ambos sentidos (carga y descarga), el optimizador incorpora implícitamente el desgaste de la batería en sus decisiones, usando más ciclos solo cuando el beneficio marginal lo justifica. No se impone una restricción explícita sobre el número de ciclos diarios, asumiendo que c^{deg} es suficiente para moderar el comportamiento del modelo de forma coherente con las suposiciones de vida útil.

6.2 SUPOSICIONES PARA LA SIMULACIÓN

Para la simulación, las suposiciones son clave porque determinan la robustez del modelo: cuanto más conservadoras sean, mayor será la confianza en los resultados. Se pueden distinguir dos categorías: suposiciones de batería y de mercado. Las primeras afectan al comportamiento físico de la batería durante la ejecución real; las segundas modelan la incertidumbre en los precios, las casaciones y los eventos técnicos imprevistos. Se comentan a continuación.

6.2.1 SUPOSICIONES DE LA BATERÍA

Casación no ideal

El modelo de optimización asume que todas las casaciones se producen exactamente como se planifican: si la batería decide comprar o vender una cantidad de energía a un precio determinado, esa operación se ejecuta íntegramente. Sin embargo, en la realidad pueden producirse desvíos que impidan la ejecución exacta del programa, ya sea por precios que difieren de los previstos, ofertas que no se casan, o activaciones de reserva distintas a las

esperadas. La simulación recoge estos desvíos y los penaliza de forma económica, evaluando así la robustez del modelo frente a la incertidumbre real.

Programa no ejecutado

En segundo lugar, se trata el caso en el que el programa no puede ejecutarse íntegramente en algún intervalo del día, ya sea por SOC insuficiente, una oferta perdida o un fallo técnico. En este caso se distinguen dos situaciones según el mercado afectado.

En el mercado diario, se aplica un recorte proporcional: en lugar de cancelar la operación completa, se ejecuta lo que permite el estado de carga en ese momento, reduciendo los ingresos proporcionalmente a la energía efectivamente entregada. No se aplica penalización adicional más allá de la pérdida de ingreso.

En el mercado de reserva secundaria con REE, el tratamiento es más estricto. Al tratarse de un compromiso adquirido con el operador del sistema, el incumplimiento tiene consecuencias económicas significativas reguladas por el Procedimiento de Operación P.O. 7.2. Estas incluyen un factor multiplicador sobre los MW no entregados, así como el coste de recompra de la energía faltante al precio de desvío, que es típicamente superior al precio diario. Por ello, además del recorte proporcional sobre la energía no entregada, se aplica una penalización adicional equivalente al 200% del ingreso que hubiera generado dicha energía no entregada. Este porcentaje recoge de forma agregada tanto el factor multiplicador del P.O. 7.2 como el coste de desvío implícito, modelando de forma conservadora el coste real del incumplimiento con REE y reforzando la robustez del modelo.

6.2.2 SUPOSICIONES DEL MERCADO

Para las suposiciones del mercado, se han seleccionado cuatro fuentes de incertidumbre que reflejan cómo difiere la ejecución real del programa planificado: la variación en los precios diario, la variación en los precios de los servicios de ajuste (disponibilidad y activación), las ofertas perdidas y la variación en el porcentaje de activación de la reserva secundaria.

A diferencia de otros parámetros del modelo, estos valores no se han tomado de fuentes externas de forma arbitraria. Para los precios de los servicios de ajuste y el porcentaje de activación, los valores de incertidumbre se han calculado directamente a partir de los datos históricos de REE de los años 2022 a 2025, usando el coeficiente de variación (desviación típica dividida entre la media) como medida de dispersión relativa. Esto permite que los σ utilizados en la simulación reflejen la volatilidad histórica real observada en el mercado español. Para los precios diario y las ofertas perdidas, donde no se dispone de datos históricos con el mismo nivel de detalle, los valores se han estimado de forma razonada y conservadora, basándose en el conocimiento adquirido a lo largo de este trabajo.

Precios Diario

La variación en los precios diarios se modela mediante un error lognormal multiplicativo con $\sigma = 20\%$. La distribución lognormal es la práctica habitual en la modelización de precios eléctricos: según Pilipovic (2007) en *Energy Risk: Valuing and Managing Energy Derivatives*, ciertas propiedades implican que la distribución del precio en un momento fijo del tiempo sigue una distribución lognormal, lo que garantiza que los precios simulados sean siempre positivos y que los errores sean proporcionales al nivel del precio. El valor de $\sigma = 20\%$ se ha elegido de forma conservadora y sin fuente externa, con el objetivo de estresar el modelo bajo condiciones de alta incertidumbre en la previsión de precios.

Precios reserva

En cuanto a los precios de la reserva secundaria, se ha modelado la variación mediante errores lognormales independientes para cada componente, cuyos valores de σ se han calculado directamente a partir de los datos históricos de REE de los años 2022 a 2025, usando el coeficiente de variación (desviación típica dividida entre la media) como medida de dispersión relativa. Los valores obtenidos son los siguientes:

- Precio de disponibilidad a subida: $\sigma = 17,86\%$
- Precio de disponibilidad a bajada: $\sigma = 36,42\%$
- Precio de activación a subida: $\sigma = 41,95\%$

- Precio de activación a bajada: $\sigma = 102,68\%$

La disponibilidad presenta menor volatilidad que la activación en ambos sentidos, lo cual es coherente con su naturaleza de pago por capacidad reservada, más estable que el pago por energía efectivamente entregada.

Ofertas perdidas

En cuanto a las ofertas perdidas, se modela mediante una distribución de Bernoulli por intervalo con una probabilidad del 5%. Esta distribución es la más adecuada para modelar eventos binarios: o la ofertas se casa o no se casa. Con 96 intervalos al día y una probabilidad del 5%, esto equivale a perder de media aproximadamente 5 ofertas diarias, lo cual se considera un nivel conservador y suficientemente representativo de la operativa real del mercado.

Fallos técnicos

De forma análoga, se modela la posibilidad de un fallo técnico puntual de la batería mediante una distribución de Bernoulli con probabilidad del 2% por intervalo. A diferencia de la oferta perdida, un fallo técnico implica que la batería no opera en absoluto durante ese intervalo, cancelando tanto la carga como la descarga y cualquier activación de reserva. Ambos eventos se modelan de forma independiente en cada intervalo.

Variación de activación

Por último, la variación en el porcentaje de activación de la reserva secundaria. El modelo teórico asume tasas de activación constantes (α^{up} y α^{down}), pero en la realidad REE puede activar más o menos de lo esperado en cada intervalo. Para modelar esta incertidumbre se aplica un factor lognormal multiplicativo sobre la activación prevista, de forma independiente para subida y bajada. Los valores de σ se han calculado directamente a partir de los datos históricos de REE de 2022 a 2025 usando el coeficiente de variación:

- Activación a subida: $\sigma = 42,29\%$

- Activación a bajada: $\sigma = 43,34\%$

En ambos casos la activación real se acota entre cero y la banda de reserva ofertada, garantizando que nunca se activa más de lo comprometido.

Capítulo 7. MODELO FUNCIONAL EN PYTHON

El modelo funcional implementado en Python, que constituye el núcleo del trabajo, puede consultarse en el Apéndice (véase [Anexo II](#)). Dicho modelo es la traducción directa del modelo algebraico presentado en la sección anterior, por lo que su estructura y lógica quedan completamente recogidas en la formulación matemática ya descrita. No se incluye una explicación línea a línea del código, ya que esta no aportaría información adicional respecto a lo ya expuesto, y el lector interesado puede consultarlo directamente en el Apéndice.

La estructura del proyecto se organiza en seis carpetas que pueden dividirse en dos grupos según su contenido.

El primer grupo contiene datos. La carpeta Datos almacena los precios de energía con los que trabaja el modelo. La carpeta Resultados almacena los outputs generados tras la optimización y la simulación, organizados en dos subcarpetas independientes según su origen.

El segundo grupo contiene código y se divide en cuatro carpetas. Parseo contiene el código encargado de convertir los archivos Excel de precios diarios descargados de OMIE en archivos CSV organizados por mes, estandarizando el formato para el resto del flujo. Optimización contiene el modelo MILP diario, núcleo del trabajo, así como un script adicional que permite ejecutarlo en bucle sobre los meses deseados. Simulación contiene el código de simulación Monte Carlo, tanto en su versión diaria como mensual, además de un script auxiliar que analiza la convergencia del modelo para justificar el número de escenarios necesarios. Por último, Visualización permite representar gráficamente los resultados obtenidos tanto en la optimización como en la simulación, en los distintos horizontes temporales disponibles.

Por último, en la raíz del proyecto se encuentran dos archivos fundamentales. `parámetros.py` que recoge para todos los parámetros del sistema: define las características de la batería, los

precios de los servicios de ajuste y las tasas de activación. Al ser importado por el optimizador, el simulador y las visualizaciones, cualquier cambio en este archivo se propaga automáticamente a todo el proyecto. `run.py` es el orquestador del pipeline completo: ejecuta de forma secuencial y automática las etapas de parseo, optimización y simulación para los meses deseados, saltándose los pasos ya completados. El flujo completo del proyecto puede verse en la Figura 6.



Figura 5: Workflow

Capítulo 8. SIMULACIÓN MONTE CARLO

Para realizar una simulación de Montecarlo, hay tres cuestiones fundamentales que deben plantearse: qué parámetros tendrán aleatoriedad, cuánta aleatoriedad tendrán y de qué tipo, y cuántas veces debe repetirse la simulación para confirmar que el modelo es robusto. Las dos primeras cuestiones han sido tratadas en el apartado de [suposiciones de simulación](#). Este apartado se dedica a la tercera: la justificación del número de escenarios.

La elección del número de simulaciones N no es trivial. Un número demasiado bajo introduce ruido estadístico en los estimadores, haciendo que los resultados varíen significativamente entre ejecuciones. Un número demasiado alto aumenta innecesariamente el coste computacional sin mejorar la precisión de forma apreciable.

Para determinar el valor óptimo de N se ha desarrollado un script específico de análisis de convergencia. El procedimiento es el siguiente: se escoge un día y se optimiza su programa una única vez. A continuación, para cada valor de $N \in \{25, 50, 100, 150, 200, 300, 500\}$, se repite la simulación 10 veces con semillas distintas y se mide la desviación típica del estimador P50 entre esas repeticiones. Si dicha desviación es pequeña, el estimador ha convergido y N es suficiente. El análisis se realiza sobre todos los días del periodo de estudio y se adopta el criterio de que N es válido cuando cubre un porcentaje suficientemente alto de días.

El estimador de referencia para la convergencia es el P50, que representa el beneficio mediano y es el más relevante para evaluar la rentabilidad esperada. Se exige una desviación típica inferior al 5% del valor de referencia. El P5, que recoge el peor 5% de los escenarios, presenta una variabilidad intrínsecamente mayor y no alcanza convergencia estable (Figura 7) en un porcentaje significativo de días independientemente del N , por lo que no se usa como criterio de convergencia y se incluye en los resultados con carácter informativo.




Figura 6: Convergencia poco estable P5

Ejecutando el análisis sobre los 363 días del periodo de estudio, el 93% de los días alcanza convergencia del P50 con N=200. Se adopta por tanto N=200 escenarios como valor de referencia, asumiendo que el 7% restante puede presentar mayor variabilidad, lo cual se considera aceptable dado el horizonte anual del análisis. Los resultados se muestran en la Figura 8.




Figura 7: Convergencia P50

Capítulo 9. ANÁLISIS DE RESULTADOS

Para el análisis de resultados se hace uso de los paneles de visualización desarrollados a lo largo del trabajo. El análisis se estructura en dos niveles de detalle.

En primer lugar, se analiza un día concreto en sus dos vertientes: la optimización determinista, que permite entender el funcionamiento del modelo y las decisiones que toma en cada intervalo, y la simulación de ese mismo día, que ilustra cómo penaliza la incertidumbre y qué variabilidad introduce sobre el resultado teórico.

En segundo lugar, se extiende el análisis al periodo completo de marzo de 2025 a febrero de 2026, un total de 363 días. El objetivo de esta segunda parte es evaluar el rendimiento del modelo en un horizonte anual, identificar patrones estacionales y extraer conclusiones sobre la rentabilidad y la robustez del modelo bajo condiciones reales de mercado.

9.1 ANÁLISIS DE UN DÍA REPRESENTATIVO

9.1.1 OPTIMIZACIÓN DE UN DÍA REPRESENTATIVO

Para ilustrar el funcionamiento del modelo se utiliza como caso de estudio el 21 de enero de 2026, tercer miércoles del mes. La elección no es arbitraria: el tercer miércoles de cada mes es el día de referencia que emplea ENTSO-E en su metodología estadística, ya que solo los valores horarios de carga del tercer miércoles, publicados en los informes mensuales, se consideran representativos del mes. La razón es que se trata del día laborable más neutro posible: el miércoles evita las distorsiones de demanda propias del inicio y el fin de semana, y la tercera semana esquivando tanto el principio de mes como los festivos, en el caso de enero, Año Nuevo y Reyes, de modo que el perfil de consumo resulta plenamente representativo. A esto se suma que enero corresponde al pico de demanda invernal del sistema peninsular, un escenario especialmente relevante para un sistema de almacenamiento por el mayor spread de precios y el mayor estrés en los servicios de balance. Por tanto, el objetivo de este

análisis no es extraer conclusiones sobre una jornada concreta, sino mostrar el comportamiento del modelo de optimización y su simulación sobre un día representativo de las condiciones reales de operación.

El análisis del día individual se apoya en dos paneles. El primero recoge la operación física de la batería: cuándo carga y descarga, y cómo evoluciona su estado de carga a lo largo del día. El segundo analiza la dimensión económica: los ingresos generados y su desglose por fuente. Se analizan a continuación.




Figura 8: Dashboard optimización diaria mercado diario

La Figura 9 muestra la actividad en el mercado diario, separando compras de ventas por arbitraje. Lo más destacable es que el modelo no realiza ninguna venta directa de energía: la venta por arbitraje es nula y toda la energía descargada se destina íntegramente a la activación de reserva secundaria a subir.

Las compras se concentran en los dos valles de precio del día, de madrugada entre las 03:00 y las 05:30, y al mediodía entre las 12:00 y las 14:30, con alguna compra puntual adicional al caer la tarde y al cierre del día. En todos los casos coinciden con los mínimos de precio, pero no con el objetivo de vender más caro posteriormente, sino de reponer el SOC consumido por la activación continua de reserva.

Este comportamiento ilustra una conclusión relevante: cuando los precios de activación de la reserva secundaria son suficientemente atractivos respecto al spread del mercado diario, el modelo prioriza el mercado secundario frente al arbitraje puro.




Figura 9: Dashboard optimización diaria mercado secundario

La Figura 10 confirma lo observado anteriormente: el modelo oferta la banda máxima a subir en casi todos los intervalos del día, priorizando el mercado de reserva secundaria frente al arbitraje diario. Solo deja de ofertar banda en las franjas que coinciden con las ventanas de compra y carga en el mercado diario, de madrugada y al mediodía.

Se puede apreciar también que la activación es siempre la misma fracción de la banda ofertada, consecuencia directa de modelar la activación como un porcentaje constante. Esto difiere de la realidad, donde REE activa en función de las necesidades del sistema en cada momento.

Por último, las escasas activaciones a bajar, en torno a las 12:00 y a las 18:00, coinciden con los intervalos de carga, revelando que en algunos de esos intervalos parte de la energía cargada no proviene de la compra en el mercado diario sino de la activación de reserva secundaria a bajar.




Figura 10: Dashboard optimización diaria estado de carga

La Figura 11 muestra la evolución del estado de carga a lo largo del día, consecuencia directa de las decisiones comentadas en las figuras anteriores.

El SOC parte de 1 MWh y desciende entre las 00:00 y las 03:00 por la activación continua de reserva secundaria a subir durante la madrugada. A continuación sube de forma pronunciada entre las 03:00 y las 06:00, coincidiendo con la primera ventana de compras en el mercado diario, hasta acercarse al máximo de 2 MWh. Después vuelve a descender de forma sostenida entre las 06:00 y las 12:00 por la activación de reserva, y repunta de nuevo entre las 12:00 y las 14:00 con la segunda ventana de compras, alcanzando esta vez el máximo de 2 MWh. Finalmente, a partir de las 15:00 desciende de forma sostenida por la activación de reserva hasta recuperar el nivel inicial de 1 MWh al cierre del día, cumpliendo la restricción de cierre de ciclo diario.

La gráfica también permite verificar que el modelo respeta correctamente todas las restricciones del sistema: el SOC nunca supera el límite máximo de 2 MWh ni cae por debajo del mínimo de 0,40 MWh en ningún intervalo del día. Esto confirma que la

formulación algebraica de las restricciones de límites de SOC está correctamente implementada en el modelo.




Figura 11: Dashboard optimización diaria energía operada acumulada

La Figura 12 muestra la energía total operada por la batería de forma acumulada a lo largo del día, expresada tanto en MWh como en ciclos equivalentes. Un ciclo equivalente se define como la energía necesaria para realizar una carga y una descarga completas dentro del rango de operación permitido, es decir, $2 \times E^{max} \times DOD = 2 \times 2 \times 0,8 = 3,2MWh$. Cualquier valor por encima de este umbral implica más de un ciclo completo en el día.

En este caso, la batería opera un total de 4,73 MWh, equivalentes a 1,48 ciclos. La curva muestra dos tramos de pendiente más pronunciada, entre las 03:00 y las 06:00 y entre las 12:00 y las 14:00, coincidiendo con las dos ventanas de carga activa, y un perfil más suave durante el resto del día, donde la operación se limita a la activación continua de reserva secundaria.

El coste de degradación modelado actúa como penalización implícita sobre esta energía operada, por lo que no es necesario imponer un límite explícito de ciclos diarios. Esta gráfica se incluye con carácter informativo, aunque confirma que la batería tiene un uso

intensivo durante el día, condición necesaria para que el modelo genere beneficios relevantes.

En la Figura 13 pasamos a la parte de ingresos de los dashboards diarios.




Figura 12: Dashboards optimización diario composición del beneficio

La Figura 13 desglosa el beneficio del día desde un punto de vista financiero. El arbitraje neto es negativo (169,6 €) porque el modelo únicamente compra energía en el mercado diario sin vender nada directamente, recogiendo exclusivamente el coste de las compras para reponer el SOC.

Los ingresos provienen íntegramente del mercado de reserva secundaria: 88,1 € por disponibilidad y 260,8 € por activación, aproximadamente tres veces mayor. El coste de degradación asciende a 31,3 €, coherente con los 1,48 ciclos equivalentes operados, dando un beneficio neto de 147,9 €.

Destaca el peso de la activación, cuyo valor refleja que el mercado secundario ha sido especialmente rentable en el periodo 2022-2025, que son los años de los cuales se han obtenido las medias para su modelado, lo que explica que el modelo lo priorice sistemáticamente frente al arbitraje diario.




Figura 13: Dashboard optimización diaria desglose financiero

Para leer esta gráfica correctamente conviene empezar por la línea oscura, que representa el beneficio acumulado del día. Esta crece de forma casi continua a lo largo del día, con una pendiente más pronunciada en las franjas donde no hay compras en el mercado diario. Los intervalos en los que la pendiente se reduce o se invierte coinciden con las barras grises negativas, que representan el coste de las compras en el mercado diario, la única fuente de gasto variable a lo largo del día, y que en esta jornada se concentran en dos ventanas, de madrugada en torno a las 03:00 y las 05:00, y al mediodía entre las 12:00 y las 14:00.

Los ingresos provienen en todo momento de la reserva secundaria, representada en dos tonos de azul: el azul claro corresponde al pago por disponibilidad y el azul oscuro al pago por activación, consistentemente mayor en todos los intervalos, aproximadamente tres veces superior, lo que es coherente con lo mostrado en la Figura 13.

Por último, en cada intervalo aparece una pequeña barra naranja que representa el coste de degradación. Aunque es pequeño por intervalo, su acumulación a lo largo del día asciende a 31,3 €, lo que representa aproximadamente un 17,4 % del beneficio bruto, un porcentaje relevante que justifica la importancia de modelar correctamente este parámetro.

9.1.2 SIMULACIÓN DE UN DÍA REPRESENTATIVO

Una vez visto cómo funciona el modelo para el día 21 de enero de 2026, se realiza la simulación para comprobar como de robusto es. Como se ha dicho a lo largo del trabajo, se ha elegido una simulación agresiva para comprobar que el modelo rinde bajo toda circunstancia.




Figura 14: Dashboard simulación diaria SOC: plan vs realidad

La Figura 15 muestra la desviación del SOC final respecto al objetivo de 1 MWh mediante un violín estadístico construido a partir de los 200 escenarios simulados. Cuanto más ancho es el violín en un nivel determinado, más escenarios acaban en ese SOC final. La mediana se sitúa cerca de 1 MWh, pero la distribución presenta una cola hacia el mínimo de 0,40 MWh, correspondiente a los escenarios más desfavorables donde la acumulación de fallos técnicos, ofertas perdidas y variaciones de precio impide recuperar el SOC planificado, activando la penalización por desviación de SOC final.

Esta gráfica ilustra el coste de la incertidumbre: el modelo determinista garantiza por construcción un SOC final igual al inicial, pero la realidad introduce perturbaciones que hacen que este objetivo no siempre se alcance.



Figura 15: Dashboard simulación diaria energía no entregada vs plan

La Figura 16 muestra la distribución de energía no entregada por recorte de SOC a lo largo de los 200 escenarios. En la mayoría de los casos el recorte es cercano a cero, pero la media se sitúa en 0,356 MWh/día, arrastrada por una cola de escenarios con recortes significativos de hasta 3,5 MWh.

El recuadro informativo desglosa las causas: 0,128 MWh no cargados por ofertas perdidas y 0,054 MWh no operados por fallos técnicos. El dato más relevante es que el 38 % de los escenarios presenta algún recorte, lo que significa que casi cuatro de cada diez días simulados la batería no puede ejecutar el programa íntegramente, activando las penalizaciones comentadas en las figuras anteriores.




Figura 16: Dashboard simulación diaria Eventos de ejecución

La gráfica muestra la media de intervalos afectados por cada tipo de evento a lo largo del día. Los resultados son coherentes con los parámetros de simulación asumidos: 4,9 ofertas perdidas y 1,9 fallos técnicos por día se aproximan a los valores esperados de 5 y 2 respectivamente dado el 5 % y 2 % de probabilidad por intervalo. Los 7,0 intervalos con SOC crítico por día explican la energía recortada y las penalizaciones observadas en las figuras anteriores.




Figura 17: Dashboard simulación diaria Activación real vs prevista

En esta gráfica se muestra la distribución del factor de activación real respecto al planificado para los 200 escenarios. Un factor de 1,0 indica que la activación real coincide exactamente con la prevista. Las medias de $\times 1,09$ a subir y $\times 1,11$ a bajar indican que en promedio REE activa ligeramente más de lo esperado, lo que genera ingresos adicionales respecto al plan. La distribución es asimétrica con cola larga a la derecha, reflejando escenarios puntuales con activaciones de hasta $\times 3$.




Figura 18: Dashboard simulación diaria: Distribución del beneficio real

La Figura 19 muestra la distribución del beneficio real obtenido en los 200 escenarios simulados, junto con tres percentiles clave y el beneficio previsto por el modelo determinista.

El P5 (-7 €) indica que solo el 5 % de los escenarios genera un beneficio inferior a ese valor, lo que confirma que el modelo es robusto frente a las perturbaciones introducidas: aunque existen escenarios con beneficio negativo, estos se mantienen por debajo del umbral del 5 %, representando casos excepcionales.

El P50 (97 €) es el estimador central y el más relevante para evaluar la rentabilidad esperada. Representa una diferencia de 51 € respecto al beneficio previsto de 148 €, lo que equivale a un coste de incertidumbre del 34 % aproximadamente. Esta diferencia refleja el impacto acumulado de fallos técnicos, ofertas perdidas y variaciones de precio sobre el resultado real.

El P90 (267 €) recoge los escenarios favorables en los que las perturbaciones juegan a favor del modelo, generando beneficios muy superiores al caso base. Finalmente, en los extremos de la distribución se observan casos aislados con pérdidas de aproximadamente 300 € y ganancias de hasta 460 €, que representan los escenarios más improbables pero posibles.




Figura 19: Dashboard simulación diaria: Desglose por servicio

En el arbitraje y la reserva de disponibilidad, los valores son muy similares entre plan y realidad, lo que indica que estos conceptos son poco sensibles a las perturbaciones introducidas. La reserva de activación es donde aparece la sorpresa: la media real supera al plan, lo que significa que en promedio la activación real es mayor que la prevista, generando más ingresos de los esperados. Esto es coherente con lo observado en la gráfica de activación real vs prevista, donde las medias eran de $\times 1,09$ y $\times 1,11$.

El coste de degradación real es ligeramente superior al previsto, en línea con la mayor activación de la batería, que aumenta la energía total operada.

Los conceptos que más penalizan el resultado real frente al plan son las penalizaciones por desviación de SOC y por incumplimiento con REE, que en el modelo determinista no existen por construcción. Estas penalizaciones compensan e incluso superan las ganancias adicionales obtenidas por la mayor activación, explicando la diferencia entre el beneficio previsto y el P50 observado.




Figura 20: Dashboard simulación diaria: Coste de la incertidumbre

La Figura 21 cuantifica el coste de la incertidumbre descomponiendo la diferencia entre el beneficio previsto (148 €) y la media real (110 €). La mayor ganancia inesperada proviene de la activación (+31 €), acompañada de variaciones menores en arbitraje (-1 €), disponibilidad (+1 €) y degradación (+2 €). Estas se ven más que compensadas por las penalizaciones de REE (-39 €) y de SOC (-32 €), resultando en un coste neto de incertidumbre de 38 €, equivalente al ≈ 26 % del beneficio previsto. Este dato se analizará con mayor profundidad en el análisis anual.

9.2 ANÁLISIS DE UN AÑO REPRESENTATIVO

Una vez visto el modelo diario a modo de ejemplo y para entender de forma micro que hace el modelo, se pasa al análisis anual, de misma forma que en el apartado anterior, se empezará con el modelo determinístico y se pasará a probabilístico.

9.2.1 OPTIMIZACIÓN DE UN AÑO REPRESENTATIVO

En esye apartado se analizarán gráficas relacionadas con la operación en ingresos de la batería, se empezará con los de operación.




Figura 21: Dashboard optimización anual Energía con la red

La gráfica superior muestra el intercambio mensual de energía entre la batería y la red a lo largo del periodo de estudio. Lo primero que destaca es que la compra en el mercado diario es consistentemente mayor que la suma de la venta por arbitraje y la activación de entrega. Esto es coherente con las pérdidas por eficiencia modeladas: parte de la energía comprada se disipa en forma de calor durante los ciclos de carga y descarga, por lo que la energía que sale de la batería es siempre inferior a la que entra.

En segundo lugar, a diferencia de lo observado en el análisis del día individual, sí existe venta directa en el mercado diario, aunque representa aproximadamente el 20% de la energía total vendida a la red, siendo el 80% restante activación de reserva secundaria. Esto ilustra una característica importante del modelo: en el corto plazo puede priorizar completamente el mercado secundario en días concretos, pero en horizontes más largos el arbitraje diario también contribuye de forma regular, demostrando la complementariedad de ambos mercados.




Figura 22: Dashboard optimización anual Reserva aFRR ofertada media mensual

La Figura 23 muestra la reserva aFRR ofertada media mensual a lo largo del periodo de estudio. La diferencia entre subida y bajada es prácticamente absoluta en todos los meses: la reserva a subir se sitúa consistentemente en torno a 8-9 MWh/día, mientras que la reserva a bajar es casi nula. Esto refleja la preferencia sistemática del modelo por el mercado de entrega, directamente explicada por el mayor atractivo económico del precio de activación a subir (118,15 €/MWh) frente al de bajada (53,05 €/MWh).




Figura 23: Dashboard optimización anual Energía activada media mensual

La gráfica muestra la energía activada aFRR media mensual, que replica el patrón de la figura anterior. Al modelarse la activación como un porcentaje fijo de la banda ofertada, la forma de ambas gráficas es prácticamente idéntica: la activación a subir domina de forma absoluta en todos los meses, manteniéndose en torno a 1,85-2,15 MWh/día, mientras que la activación a bajar es insignificante.




Figura 24: Dashboard optimización anual Precio OMIE mensual

La Figura 25 muestra la evolución mensual de los precios OMIE, con el rango máximo-mínimo y el precio medio. Se puede observar que el precio medio presenta cierta estabilidad entre julio y octubre, manteniéndose en torno a 60-75 €/MWh con una variabilidad similar entre meses. Es en los extremos del periodo, especialmente en abril-mayo 2025 y febrero 2026, donde los precios medios caen de forma más pronunciada y la dispersión entre máximo y mínimo se reduce significativamente.

Esta observación es relevante de cara a futuras mejoras del modelo: en periodos de comportamiento estacional homogéneo, el uso de previsiones del día anterior podría ser una aproximación razonable para alimentar el optimizador, reduciendo el gap entre el escenario determinista y la realidad.




Figura 25: Dashboard optimización anual Beneficio acumulado

La Figura 26 muestra el beneficio acumulado a lo largo del periodo de estudio, alcanzando un total de 93.685€ en 363 días. Para evaluar si este resultado es atractivo desde un punto de vista inversor, se realiza un análisis de rentabilidad simplificado a modo de proxy, cuyos detalles se encuentran en el [Anexo II](#).

Las suposiciones son las siguientes (Ember, 2025):

- Ingresos año 1: 93.685€, decrece a ritmo de 8%/año, como protección ante futuros precios desconocidos de la energía
- CapEx: $\$125/kWh \approx 108€/KWh$. $CapEx = 2KWh \cdot 108€/KWh = 216.000€$
- OpEx: $\approx 2\% \text{ of } CapEx \approx 4.320€$ constantes
- Madurez: 10 años
- Valor residual: 0€

Con estas hipótesis se obtiene una TIR del 21% sin apalancamiento financiero, un resultado atractivo para un activo de infraestructura energética. Conviene recordar que este cálculo asume conocer el precio de la energía a lo largo de los 10 años, lo cual es una gran simplificación. No obstante, sirve como indicador de que el modelo genera una rentabilidad potencialmente atractiva para el inversor.




Figura 26: Dashboard optimización anual Beneficio total por mes

La Figura 27 muestra el beneficio mensual a lo largo del periodo de estudio, con una media de 7.807€/mes. Los meses más rentables son abril y mayo 2025, superando los 9.500€. El verano y el otoño se mantienen en torno a la media, mientras que diciembre 2025 y enero 2026 son los meses más débiles, con 5.400€ y 6.000€ respectivamente. Una posible explicación es que en invierno hay menos horas de sol, lo que reduce la generación solar y con ella la diferencia entre el precio más bajo y el más alto del día, dejando menos margen

para ganar dinero. Febrero 2026 recupera hasta los 9.300€, aunque las razones no son evidentes dado que sigue siendo un mes de pocas horas de luz, lo que requeriría un análisis más detallado de los precios de ese mes para extraer conclusiones.




Figura 27: Dashboard optimización anual Spread medio mensual




Figura 28: Dashboard optimización anual Spread vs Beneficio mensual

Las Figuras 28 y 29 analizan la relación entre el spread mensual de precios y el beneficio obtenido. La hipótesis inicial sería que cuanto mayor es la diferencia entre el precio máximo y mínimo del mes, mayor debería ser el beneficio por arbitraje. Sin embargo, el coeficiente

de correlación obtenido es $r = 0,117$, prácticamente nulo, lo que indica que el spread no explica el beneficio mensual.

La explicación más probable es que, como se ha visto a lo largo del análisis, la mayor parte de los ingresos del modelo provienen del mercado de reserva secundaria y no del arbitraje diario. Por tanto, el spread de precios, que sería el driver principal en un modelo de arbitraje puro, tiene un impacto muy limitado en el resultado final.

9.2.2 SIMULACIÓN DE UN AÑO REPRESENTATIVO

Una vez analizado el año determinista, se comprobará la robustez del modelo a través de una simulación de mismo periodo.




Figura 29: Dashboard simulación anual Beneficio total mensual

La Figura 30 compara el beneficio previsto por el modelo determinista con el P50 real de la simulación a lo largo del año. El P50 se sitúa consistentemente por debajo del previsto en todos los meses, lo cual es esperado y refleja el coste de incertidumbre acumulado a escala mensual. Lo más relevante es que en ningún mes el P50 cae por debajo de cero, lo que confirma que el modelo genera beneficios positivos incluso en el escenario mediano bajo condiciones de incertidumbre real, dando una señal sólida de robustez.




Figura 30: Dashboard simulación anual Coste de incertidumbre

La Figura 31 muestra el coste de incertidumbre mensual en términos absolutos y relativos. Destacan dos meses en los extremos: junio 2025 presenta el menor coste relativo (~12%), mientras que diciembre 2025 y enero 2026 alcanzan los valores más altos (~29% y ~26%). Esto sugiere una posible relación entre las horas de luz y la robustez del modelo: en los meses de mayor generación solar el comportamiento del mercado es más predecible y el modelo responde mejor a las perturbaciones, mientras que en invierno la mayor volatilidad e imprevisibilidad de los precios incrementa el coste de incertidumbre. No obstante, con solo 12 meses de datos esta hipótesis no puede confirmarse con rigor estadístico y requeriría un análisis más amplio.



Figura 31: Dashboard simulación anual Coste de incertidumbre

La figura muestra el porcentaje de número de muestras con beneficios negativos y la desviación estándar media por mes. Lo más destacable es que el porcentaje de escenarios negativos se mantiene bajo en general, por debajo del 4% en la mayoría de los meses, con la excepción de diciembre 2025 y enero 2026 donde sube hasta el 7-8%, coincidiendo con los meses de menor beneficio ya comentados.




Figura 32: Dashboard simulación anual Ingreso por mercado (periodo)

La Figura 33 muestra el desglose del beneficio real anual por concepto, cerrando el análisis con una visión global del año completo. El arbitraje diario es negativo (-8.794€) porque, como se ha visto a lo largo del análisis, la batería compra más energía de la que vende directamente en el mercado diario, usando esas compras principalmente para reponer el SOC y seguir operando en el mercado secundario.

Los ingresos provienen íntegramente de la reserva secundaria: 29.589€ por disponibilidad de banda y 90.889€ por activación, siendo esta última la fuente dominante con diferencia. Los costes son la degradación (11.876€), las penalizaciones por incumplimiento con REE (13.288€) y las penalizaciones por desviación de SOC (6.008€), dando un beneficio real anual de 80.512€, frente a los 93.685€ del modelo determinista. La diferencia de 13.173€ representa el coste de incertidumbre anual, equivalente a aproximadamente un 14% del beneficio previsto.

Antes de continuar a la siguiente gráfica, se presenta una tabla con la TIR obtenida bajo distintos escenarios de beneficio anual, usando las suposiciones de inversión descritas anteriormente (CapEx 216.000€, OpEx 4.320€/año, ingresos decrecientes al 10% anual, madurez 10 años, valor residual 0€).

TIR por Escenario		
Escenario	Ingresos Año 1	TIR
Determinista	€ 93.685,00	21,0%
Esperado	€ 80.512,00	16,5%
P50	€ 76.540,00	15,1%
P5	€ 30.011,00	-2,9%
P90	€ 126.863,00	31,7%

Tabla 6: TIR por escenario

El escenario más relevante es el esperado, con una TIR del 16,5%, que representa la rentabilidad realista considerando la incertidumbre del mercado. El P50 da un resultado similar (15,1%), confirmando la consistencia del análisis. Solo en el escenario más pesimista (P5) la inversión destruye valor con una TIR negativa del -2,9%, mientras que en el escenario optimista (P90) la rentabilidad alcanza el 31,7%.




Figura 33: Dashboard simulación anual Ingreso por mercado (mensual)

La Figura 34 muestra el desglose mensual de ingresos por mercado, confirmando de forma consistente a lo largo de todo el año el patrón ya observado: la activación aFRR domina los ingresos en todos los meses, seguida del pago por banda, mientras que el arbitraje diario es negativo o testimonial en todos los meses por igual. El beneficio real mensual sigue la misma tendencia que el beneficio previsto, con diciembre 2025 y enero 2026 como los meses más débiles, explicado principalmente por una menor activación aFRR en esos meses.




Figura 34: Dashboard simulación anual Pérdidas por causa (mensual)

La Figura 35 muestra el desglose mensual de pérdidas por causa. La degradación se mantiene estable en torno a 1.000€/mes durante todo el año, al igual que los fallos REE y las penalizaciones de SOC, que son relativamente constantes. Lo que destaca son diciembre 2025 y enero 2026, donde el arbitraje diario negativo se dispara hasta los 4.000-5.000€, convirtiéndose en la principal causa de pérdidas esos meses.

Esto no es un fallo del modelo sino una consecuencia de su estrategia: el modelo compra energía no para venderla más cara, sino para alimentar el mercado secundario. En invierno, con precios más elevados, el coste de esas compras aumenta significativamente, pero los ingresos por activación no crecen en la misma proporción, generando el desequilibrio visible en diciembre y enero. Esto confirma que el verdadero driver del beneficio es el mercado secundario, y que su rentabilidad depende en parte del coste de la energía necesaria para sostenerlo.

Capítulo 10. CONCLUSIONES Y TRABAJOS

FUTUROS

Este trabajo ha desarrollado un modelo de optimización MILP para maximizar el beneficio de una batería de iones de litio operando simultáneamente en el mercado diario español y en el mercado de reserva secundaria, implementado en Python con Pyomo y el solver HiGHS, y validado mediante simulación de Montecarlo sobre 363 días reales.

En cuanto a los objetivos planteados, todos han sido cubiertos. Se ha realizado un estudio técnico del funcionamiento de los sistemas BESS y de los mercados eléctricos españoles relevantes. Se ha formulado algebraicamente el modelo, definiendo función objetivo, variables y restricciones. Se ha implementado en Python de forma modular y reproducible. Se ha evaluado su robustez mediante simulación de Montecarlo con suposiciones conservadoras y justificadas con datos históricos reales de REE. Y se han desarrollado dashboards de visualización para distintos horizontes temporales que permiten analizar los resultados de forma clara.

Los resultados obtenidos sobre el periodo de estudio muestran un beneficio determinista anual de 93.685€ y un beneficio real esperado de 80.512€, con un coste de incertidumbre del 14%. Lo cual sugiere que el modelo es robusto.

La conclusión más relevante desde el punto de vista del comportamiento del modelo es que, con los parámetros históricos de REE, el mercado de reserva secundaria domina sistemáticamente sobre el arbitraje diario como fuente de ingresos. Esto implica que la rentabilidad del modelo depende en mayor medida de los precios de activación y disponibilidad de la reserva secundaria que del spread de precios del mercado diario, lo cual tiene implicaciones importantes de cara a futuras condiciones de mercado.

Como limitaciones del trabajo cabe destacar las siguientes. En primer lugar, el modelo exige que la batería termine cada día con el mismo nivel de carga con el que empieza, lo que garantiza comparabilidad entre días pero puede no reflejar estrategias óptimas a más largo plazo. En segundo lugar, el coste de degradación se ha simplificado como un valor fijo por MWh operado, cuando en la realidad depende de factores como la profundidad de descarga o la temperatura. En tercer lugar, no se incluyen los costes asociados a la figura del agregador, necesaria para acceder al mercado de reserva secundaria cuando la batería no alcanza la potencia mínima requerida. En cuarto lugar, se asume respuesta inmediata de la batería, ignorando los tiempos de rampa reales, aunque esta simplificación es razonable dada la resolución cuarto horaria del modelo. Por último, el modelo es determinista y no incorpora re-optimización intra-diaria, los parámetros de la reserva secundaria se modelan como constantes cuando en realidad son variables, y los resultados son sensibles a la evolución futura de los precios del mercado secundario.

Como trabajos futuros, sería interesante explorar varias líneas de mejora. En primer lugar, colaborar con agentes especializados en predicción de precios de energía para alimentar el modelo con previsiones reales del día anterior en lugar de precios perfectos, lo que permitiría evaluar de forma más profesional y realista la robustez del modelo en condiciones operativas reales. En segundo lugar, ampliar la participación a otros mercados, como el mercado intradiario y el mercado terciario, lo que podría incrementar significativamente los ingresos y abrir nuevas fuentes de valor para el activo. En tercer lugar, extender el análisis a horizontes temporales más largos para evaluar el impacto real de la degradación física de la batería sobre la rentabilidad del modelo a lo largo de su vida útil. Por último, desarrollar un análisis financiero más completo que incorpore distintos escenarios de financiación, costes de agregador y evolución futura de los precios del mercado, con el objetivo de determinar con mayor rigor si la inversión en una batería operando con este modelo es rentable a largo plazo.

Capítulo 11. BIBLIOGRAFÍA

- [1] Red Eléctrica de España. "La producción renovable crece en España un 10,3% en 2024 y alcanza sus mayores registros". Red Eléctrica de España, marzo 2025.
<https://www.ree.es/es/sala-de-prensa/actualidad/nota-de-prensa/2025/03/la-produccion-renovable-crece-en-Espana-un-10-3-por-ciento-2024-alcanza-mayores-registros>
- [2] Red Eléctrica de España. "El suministro de la electricidad". Red Eléctrica de España,
https://www.ree.es/sites/default/files/downloadable/el_suministro_de_la_electricidad.pdf
- [3] OMIE. "Operador del Mercado Ibérico de Energía". OMIE, <https://www.omie.es/>
- [4] Ministerio para la Transición Ecológica y el Reto Demográfico (MITECO). "Se presenta el informe del Comité para el análisis de las circunstancias que concurrieron en la crisis de electricidad del 28 de abril de 2025". MITECO, junio 2025.
<https://www.miteco.gob.es/es/prensa/ultimas-noticias/2025/junio/se-presenta-el-informe-del-comite-de-analisis-de-la-crisis-elect.html>
- [5] OMIE. "Resultados de mercado: ficheros". OMIE, <https://www.omie.es/es/file-access-list>
- [6] International Renewable Energy Agency (IRENA). "Electricity Storage and Renewables: Costs and Markets to 2030". IRENA, octubre 2017.
<https://www.irena.org/publications/2017/Oct/Electricity-storage-and-renewables-costs-and-markets>
- [7] Cole, Wesley; Ramasamy, Vignesh; Turan, Merve. "Cost Projections for Utility-Scale Battery Storage: 2025 Update". National Renewable Energy Laboratory (NREL/TP-6A40-93281), junio 2025. <https://www.nrel.gov/docs/fy25osti/93281.pdf>
- [8] Enel. "BESS: sistemas de almacenamiento de energía en batería". Enel Learning Hub,
<https://www.enel.com/es/learning-hub/almacenamiento/bess>
- [9] BSLBATT. "¿Cuáles son los diferentes tipos de sistemas de almacenamiento de energía en baterías?". BSLBATT, 2025. <https://bslbatt.com/es/blogs/types-of-battery-energy-storage-systems-comparison-guide/>
- [10] Enlight. "BESS: Qué son y cómo funcionan". Enlight, <https://www.enlight.mx/blog/bess-que-son-y-como-funcionan>

- [11] Mipodo. "OMIE: ¿Qué es y por qué existe?". Mipodo,
<https://www.mipodo.com/blog/omie-que-es>
- [12] OMIE. "Mercado de electricidad". OMIE, <https://www.omie.es/es/mercado-de-electricidad>
- [13] OMIE. "Curvas agregadas de oferta y demanda. Mercado diario". OMIE,
<https://www.omie.es/es/market-results/daily/daily-market/aggragate-suply-curves>
- [14] OMIE. "Informe Anual 2025". OMIE, marzo 2026.
https://www.omie.es/sites/default/files/2026-03/informe-anual-2025_2.pdf
- [15] Red Eléctrica de España (REE). "Servicios de ajuste del sistema". REE,
<https://www.ree.es/es/operacion/garantia-suministro/servicios-ajuste>
- [16] OMIE. "Alta de agentes y alta y modificación de unidades". OMIE,
<https://www.omie.es/es/faq/alta-de-agentes-y-alta-y-modificacion-de-unidades> — detalla la estructura de unidades (unidad de oferta, unidad de programación, unidad física).
- [17] Red Eléctrica de España (REE). "Guía para ser proveedor de servicios de balance". REE,
https://www.ree.es/sites/default/files/12_CLIENTES/Documentos/Guia-Ser-proveedor-servicios-de-balance-v3.pdf
- [18] Ministerio para la Transición Ecológica y el Reto Demográfico (MITECO). "Agregador independiente". MITECO, <https://www.miteco.gob.es/es/energia/energia-electrica/electricidad/distribuidores/agregador-independiente.html>
- [19] Pyomo. "Pyomo — Python Optimization Modeling Objects". Pyomo,
<https://www.pyomo.org/>
- [20] HiGHS. "HiGHS – High-performance parallel linear optimization software". Edinburgh Research Group in Optimization, <https://highs.dev/>
- [21] IBM. "What Is Monte Carlo Simulation?". IBM Think,
<https://www.ibm.com/think/topics/monte-carlo-simulation>
- [22] Solar Insure. "Study: Solar Battery Longevity and Reliability". Solar Insure, marzo 2025.
<https://www.solarinsure.com/solar-battery-longevity>
- [23] Fernández-Muñoz, D.; Pérez-Díaz, J.I. "Optimisation models for the day-ahead energy and reserve self-scheduling of a hybrid wind–battery virtual power plant". Journal of Energy Storage, vol. 57, 2023, 106296.
<https://www.sciencedirect.com/science/article/pii/S2352152X2202285X>

- [24] Mohamed, A. et al. "Stacked revenues for energy storage participating in energy and reserve markets with an optimal frequency regulation modelling". Applied Energy, vol. 350, 2023, 121721. <https://doi.org/10.1016/j.apenergy.2023.121721>
- [25] Paredes, A. et al. "Revenue stacking of BESSs in wholesale and aFRR markets with delivery guarantees". Electric Power Systems Research, vol. 235, 2024. <https://doi.org/10.1016/j.epsr.2024.110900>
- [26] EBL Official. "¿Por qué son mejores las baterías de iones de litio?". EBL Official, <https://www.eblofficial.com/es/blogs/battery-101/advantages-disadvantages-lithium-ion-battery>
- [27] Jalthar, R. "BESS Round Trip Efficiency (RTE): How to Calculate Efficiency in Battery Energy Storage Systems". Sunlit Energy, marzo 2026. <https://sunlithenergy.com/bess-round-trip-efficiency-rte/>
- [28] Macrotrends. "Spain Inflation Rate 1960-2025". Macrotrends, <https://www.macrotrends.net/global-metrics/countries/esp/spain/inflation-rate-cpi>
- [29] NextG Power. "The LFP Battery Life Cycle: Understanding 8000 Cycles and 70% SOH". NextG Power, enero 2026. <https://nextgpower.com/the-lfp-battery-life-cycle-understanding-8000-cycles-and-70-soh/>
- [30] Ember. "How Cheap is Battery Storage?". Ember Energy, diciembre 2025. <https://ember-energy.org/latest-insights/how-cheap-is-battery-storage/>

ANEXO I: ALINEACIÓN DEL PROYECTO CON LOS ODS

Este proyecto contribuye al ODS 7 (Energía asequible y no contaminante) al desarrollar un modelo de optimización que maximiza el aprovechamiento de los sistemas de almacenamiento energético en el mercado eléctrico español. Una gestión eficiente de las baterías permite absorber los excedentes de generación renovable en horas de bajo precio y devolverlos a la red cuando la demanda es mayor, reduciendo el desperdicio energético y facilitando la integración de fuentes intermitentes como la solar y la eólica. Además, la participación en los servicios de regulación secundaria contribuye directamente a la estabilidad de la red, condición necesaria para un suministro eléctrico fiable y asequible.

La alineación con el ODS 13 (Acción por el clima) se deriva de que una mayor integración de energías renovables en el sistema eléctrico reduce la dependencia de combustibles fósiles y, con ello, las emisiones de CO₂ asociadas a la generación eléctrica. Al hacer más rentable la operación de baterías junto a fuentes renovables, este trabajo contribuye a acelerar la transición energética hacia un modelo bajo en carbono, en línea con los objetivos climáticos establecidos en el Acuerdo de París y la agenda energética europea.



ANEXO II

batería.py

```
"""
Optimización Cuarto horaria de Batería – Arbitraje + Mercado
Secundario (aFRR)
Autor: Hugo Raggini Paternain

Modelo de optimización con Pyomo para maximizar beneficios en el
mercado eléctrico.
Lee precios reales del CSV mensual generado por parseo.omie.

Uso:
    python -m optimizacion.bateria      # pregunta fecha
interactivamente
"""

import pyomo.environ as pyo
import pandas as pd
import numpy as np
import sys
from pathlib import Path

ROOT = Path(__file__).resolve().parent.parent
sys.path.insert(0, str(ROOT))

from parametros import (
    E_MAX, P_CH_MAX, P_DIS_MAX, ETA, DOD, SOC_MIN, SOC_MAX,
    SOC_INIT, C_DEG,
    DELTA, M_BIG,
    ALPHA_UP, ALPHA_DOWN, PI_DISP_UP, PI_DISP_DOWN, PI_ACT_UP,
    PI_ACT_DOWN,
)

# --- Configuración de carpetas ---
NOMBRES_MES = {
    1: "Enero",      2: "Febrero",   3: "Marzo",      4: "Abril",
    5: "Mayo",       6: "Junio",     7: "Julio",      8:
    "Agosto",
```

```
9: "Septiembre", 10: "Octubre", 11: "Noviembre", 12:
"Diciembre"
}
COLUMNAS_Q      = [f"H{h}Q{q}" for h in range(1, 25) for q in
range(1, 5)]
CARPETA_SALIDA  = ROOT / "resultados" / "dias_sueltos"
CARPETA_PRECIOS = ROOT / "datos" / "precios"

#
=====
=====
# CARGA DE PRECIOS DESDE CSV
#
=====
=====

def cargar_precios(fecha_str: str) -> np.ndarray:
    """
    Lee los precios cuartohorarios de una fecha dada desde el CSV
    mensual.
    fecha_str formato: 'YYYY-MM-DD'
    """
    fecha  = pd.to_datetime(fecha_str)
    mes    = fecha.month
    anio   = fecha.year
    nombre = NOMBRES_MES[mes]
    csv    = CARPETA_PRECIOS /
f"precios_{nombre.lower()}_{anio}.csv"

    if not csv.exists():
        raise FileNotFoundError(
            f"No se encuentra '{csv}'. Ejecuta primero: python -m
parseo.omie {mes} {anio}"
        )

    df = pd.read_csv(csv)

    # Verificar columnas
    for col in COLUMNAS_Q:
        if col not in df.columns:
            raise ValueError(f"Columna '{col}' no encontrada en
{csv}")
```

```
fila = df[df["fecha"] == fecha_str]
if fila.empty:
    raise ValueError(
        f"Fecha '{fecha_str}' no encontrada en '{csv}'.\n"
        f"  Fechas disponibles: {df['fecha'].min()} →
{df['fecha'].max()}"
    )

precios = fila[COLUMNAS_Q].values[0].astype(float)
if len(precios) != 96:
    raise ValueError(f"Se esperaban 96 valores, se encontraron
{len(precios)}")

return precios

#
=====
# CONSTRUCCIÓN DEL MODELO PYOMO
#
=====

def construir_modelo(precios: np.ndarray):
    """
    Construye el modelo MILP de optimización de batería pura.
    Sin generación fotovoltaica – solo arbitraje + servicios de
    red.

    Mercados modelados:
    · Arbitraje (OMIE): compra barato / vende caro
    · Reserva secundaria (aFRR): disponibilidad + activación
    up/down

    Notación de precios:
    · p[t]      – precio diario del mercado en t (puede ser
    negativo)
    · p_eff[t] – precio efectivo de compra: max(p[t], 0)
                  Evita que el modelo gane dinero comprando a
    precio negativo.
    """
    model = pyo.ConcreteModel(name="Arbitraje_Bateria_Pura")
```

```
T_set = range(1, 97)
model.T = pyo.Set(initialize=T_set)

# --- Parámetros de precio ---
# p[t]: precio diario en el intervalo t (€/MWh) – puede ser
negativo
model.p      = pyo.Param(model.T, initialize={t: precios[t-1]
for t in T_set})
# p_eff[t]: precio efectivo de compra = max(p[t], 0)
model.p_eff = pyo.Param(model.T, initialize={t: max(precios[t-
1], 0.0) for t in T_set})

# --- Parámetros de batería ---
model.E_max      = pyo.Param(initialize=E_MAX)
model.P_ch_max   = pyo.Param(initialize=P_CH_MAX)
model.P_dis_max  = pyo.Param(initialize=P_DIS_MAX)
model.eta        = pyo.Param(initialize=ETA)
model.SOC_min    = pyo.Param(initialize=SOC_MIN)
model.SOC_max    = pyo.Param(initialize=SOC_MAX)
model.SOC_init   = pyo.Param(initialize=SOC_INIT)
model.c_deg      = pyo.Param(initialize=C_DEG)

# --- Parámetros de mercado ---
model.delta      = pyo.Param(initialize=DELTA)
model.M          = pyo.Param(initialize=M_BIG)
model.alpha_up   = pyo.Param(initialize=ALPHA_UP)
model.alpha_down = pyo.Param(initialize=ALPHA_DOWN)
model.pi_disp_up = pyo.Param(initialize=PI_DISP_UP)
model.pi_disp_down = pyo.Param(initialize=PI_DISP_DOWN)
model.pi_act_up  = pyo.Param(initialize=PI_ACT_UP)
model.pi_act_down = pyo.Param(initialize=PI_ACT_DOWN)

# --- Variables ---
model.x_sell = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.x_buy  = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.x_ch   = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.x_dis  = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.r_up   = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.r_down = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.a_up   = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.a_down = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.SOC    = pyo.Var(model.T, domain=pyo.NonNegativeReals)
model.y_bat  = pyo.Var(model.T, domain=pyo.Binary)
```

```

model.y_grid = pyo.Var(model.T, domain=pyo.Binary)

# --- Función objetivo ---
# Ingresos por venta en diario:          p[t]          * x_sell[t]
# Costes por compra en diario:          p_eff[t] * x_buy[t]
# Ingresos disponibilidad aFRR up:      pi_disp_up  * r_up[t]
# Ingresos disponibilidad aFRR down:    pi_disp_down *
r_down[t]
# Ingresos netos por activación up:      (pi_act_up -
p[t])          * a_up[t]
# Ingresos netos por activación down:    (pi_act_down sk-
p_eff[t]) * a_down[t]
# Costes de degradación:                  c_deg * (energía total
operada)
def obj_rule(m):
    return sum(
        m.p[t]          * m.x_sell[t]
        - m.p_eff[t] * m.x_buy[t]
        + m.pi_disp_up  * m.r_up[t]
        + m.pi_disp_down * m.r_down[t]
        + (m.pi_act_up - m.p[t])          * m.a_up[t]
        + (m.pi_act_down - m.p_eff[t]) * m.a_down[t]
        - m.c_deg * (m.x_ch[t] + m.x_dis[t] + m.a_up[t] +
m.a_down[t])
        for t in m.T
    )
model.obj = pyo.Objective(rule=obj_rule, sense=pyo.maximize)

# --- Restricciones ---

# Balance energético en cada intervalo
def balance_rule(m, t):
    return (m.x_buy[t] + m.x_dis[t] + m.a_up[t]
            == m.x_sell[t] + m.x_ch[t] + m.a_down[t])
model.balance = pyo.Constraint(model.T, rule=balance_rule)

# Dinámica del SOC
def soc_rule(m, t):
    soc_prev = m.SOC_init if t == 1 else m.SOC[t-1]
    return (m.SOC[t] == soc_prev
            + m.eta * (m.x_ch[t] + m.a_down[t])
            - (m.x_dis[t] + m.a_up[t]) / m.eta)
model.soc_dyn = pyo.Constraint(model.T, rule=soc_rule)

```

```

    model.soc_min_c = pyo.Constraint(model.T, rule=lambda m, t:
m.SOC[t] >= m.SOC_min)
    model.soc_max_c = pyo.Constraint(model.T, rule=lambda m, t:
m.SOC[t] <= m.SOC_max)

    # Límites de potencia de carga y descarga
    model.pmax_ch = pyo.Constraint(model.T,
        rule=lambda m, t: m.x_ch[t] + m.a_down[t]
            <= m.y_bat[t] * m.P_ch_max * m.delta)
    model.pmax_dis = pyo.Constraint(model.T,
        rule=lambda m, t: m.x_dis[t] + m.a_up[t]
            <= (1 - m.y_bat[t]) * m.P_dis_max *
m.delta)

    # Reserva limitada por potencia máxima
    model.res_up_pow = pyo.Constraint(model.T,
        rule=lambda m, t: m.x_dis[t] + m.r_up[t] <= m.P_dis_max
* m.delta)
    model.res_down_pow = pyo.Constraint(model.T,
        rule=lambda m, t: m.x_ch[t] + m.r_down[t] <=
m.P_ch_max * m.delta)

    # Activación limitada por reserva ofertada
    model.act_up_c = pyo.Constraint(model.T,
        rule=lambda m, t: m.a_up[t] == m.alpha_up * m.r_up[t])
    model.act_down_c = pyo.Constraint(model.T,
        rule=lambda m, t: m.a_down[t] == m.alpha_down *
m.r_down[t])

    # Reserva limitada por SOC disponible
    def res_up_soc_rule(m, t):
        soc_prev = m.SOC_init if t == 1 else m.SOC[t-1]
        return m.r_up[t] <= m.eta * (soc_prev - m.SOC_min)
    def res_down_soc_rule(m, t):
        soc_prev = m.SOC_init if t == 1 else m.SOC[t-1]
        return m.r_down[t] <= (m.SOC_max - soc_prev) / m.eta
    model.res_up_soc = pyo.Constraint(model.T,
rule=res_up_soc_rule)
    model.res_down_soc = pyo.Constraint(model.T,
rule=res_down_soc_rule)

    # No comprar y vender simultáneamente
    model.buy_c = pyo.Constraint(model.T,

```

```

        rule=lambda m, t: m.x_buy[t] <= m.y_grid[t] * m.M)
    model.sell_c = pyo.Constraint(model.T,
        rule=lambda m, t: m.x_sell[t] <= (1 - m.y_grid[t]) * m.M)

    # SOC final igual al inicial
    model.soc_final = pyo.Constraint(rule=lambda m: m.SOC[96] ==
m.SOC_init)

    return model

#
=====
=====
# RESOLUCIÓN Y RESULTADOS
#
=====
=====

def resolver_modelo(model, solver="highs"):
    opt = pyo.SolverFactory(solver)
    opt.options["time_limit"] = 120
    opt.options["mip_rel_gap"] = 0.001
    opt.options["output_flag"] = 0
    opt.options["log_to_console"] = 0
    results = opt.solve(model, tee=False)
    return results

def extraer_resultados(model):
    data = []
    for t in model.T:
        data.append({
            "t": t,
            "hora": f"{(t-1)//4:02d}:{((t-1)%4)*15:02d}",
            "p": round(pyo.value(model.p[t]), 2),
            "p_eff": round(pyo.value(model.p_eff[t]), 2),
            "x_sell": round(pyo.value(model.x_sell[t]), 4),
            "x_buy": round(pyo.value(model.x_buy[t]), 4),

```

```

        "x_ch
[MWh] ":          round(pyo.value(model.x_ch[t]), 4),
        "x_dis
[MWh] ":          round(pyo.value(model.x_dis[t]), 4),
        "r_up
[MWh] ":          round(pyo.value(model.r_up[t]), 4),
        "r_down
[MWh] ":          round(pyo.value(model.r_down[t]), 4),
        "a_up
[MWh] ":          round(pyo.value(model.a_up[t]), 4),
        "a_down
[MWh] ":          round(pyo.value(model.a_down[t]), 4),
        "SOC
[MWh] ":          round(pyo.value(model.SOC[t]), 4),
        "y_bat":          int(pyo.value(model.y_bat[t])),
        "y_grid":         int(pyo.value(model.y_grid[t])),
        "pi_disp_up [€/MWh]": float(pyo.value(model.pi_disp_up)),
        "pi_disp_down [€/MWh]": float(pyo.value(model.pi_disp_down)),
        "pi_act_up [€/MWh]": float(pyo.value(model.pi_act_up)),
        "pi_act_down [€/MWh]": float(pyo.value(model.pi_act_down)),
        "E_max [MWh]":     float(pyo.value(model.E_max)),
        "SOC_min [MWh]":   float(pyo.value(model.SOC_min)),
    })
    df = pd.DataFrame(data)
    beneficio_total = pyo.value(model.obj)

    print(f"\n{'='*50}")
    print(f"    BENEFICIO TOTAL DEL DÍA: {beneficio_total:.2f} €")
    print(f"{'='*50}\n")

    return df, beneficio_total

# =====
# MAIN
# =====

if __name__ == "__main__":

    print("\n=== Optimización de Batería – Día Suelto ===")
    print("Introduce la fecha a optimizar.")
    print("(Los datos deben estar en el CSV mensual generado por parseo.omie)\n")

    while True:
        entrada = input("Fecha (DD/MM/YYYY o YYYY-MM-DD): ").strip()
        try:
            if "/" in entrada:
                fecha_dt = pd.to_datetime(entrada, dayfirst=True)
            else:
                fecha_dt = pd.to_datetime(entrada)
            fecha_str = fecha_dt.strftime("%Y-%m-%d")

```

```
        break
    except Exception:
        print("  [!] Formato no reconocido. Prueba: 13/03/2026 o 2026-03-13")

try:
    precios = cargar_precios(fecha_str)
except (FileNotFoundError, ValueError) as e:
    print(f"\n[!] Error: {e}")
    sys.exit()

print(f"\n Fecha          : {fecha_str}")
print(f" Precio máx   : {precios.max():.2f} €/MWh")
print(f" Precio mín   : {precios.min():.2f} €/MWh")
print(f" Spread       : {precios.max() - precios.min():.2f} €/MWh")
print(f" Precio medio: {precios.mean():.2f} €/MWh")
print(f" Optimizando...\n")

model    = construir_modelo(precios)
results  = resolver_modelo(model)

status = results.solver.termination_condition
if status not in (pyo.TerminationCondition.optimal,
                  pyo.TerminationCondition.feasible):
    print(f"[!] Solver terminó con estado: {status}")
    sys.exit()

df, beneficio = extraer_resultados(model)
df.insert(0, "fecha", fecha_str)

CARPETA_SALIDA.mkdir(parents=True, exist_ok=True)
csv_salida = CARPETA_SALIDA / f"resultado_{fecha_str}.csv"
df.to_csv(csv_salida, index=False)

print(f" CSV guardado: {csv_salida}")
print(f" Listo. Puedes visualizar con: python -m visualizacion.dia
{fecha_str}\n")
```

Modelo Financiero

Modelo IRR — Proyecto													
Supuestos (inputs)		Determinista	Esperado	P50	P5	P90							
Inversión inicial (CapEx)		€216,000											
Vida útil (años)		10											
Ingresos anuales (Revenue)		€93,685	€80,512	€76,540	€30,011	€126,863							
Costes operativos (OpEx)		€4,320											
Tasa impositiva		35.0%											
Crecimiento anual Revenue		-8.0%											
Proyección de Flujos		Año	Year 0	Year 1	Year 2	Year 3	Year 4	Year 5	Year 6	Year 7	Year 8	Year 9	Year 10
Revenue				€93,685	€86,190	€79,295	€72,951	€67,115	€61,746	€56,806	€52,262	€48,081	€44,234
OpEx				€4,320	€4,320	€4,320	€4,320	€4,320	€4,320	€4,320	€4,320	€4,320	€4,320
EBITDA				€89,365	€81,870	€74,975	€68,631	€62,795	€57,426	€52,486	€47,942	€43,761	€39,914
Depreciación				€21,600	€21,600	€21,600	€21,600	€21,600	€21,600	€21,600	€21,600	€21,600	€21,600
EBIT				€67,765	€60,270	€53,375	€47,031	€41,195	€35,826	€30,886	€26,342	€22,161	€18,314
Impuestos				€23,718	€21,095	€18,681	€16,461	€14,418	€12,539	€10,810	€9,220	€7,756	€6,410
Net Income				€44,047	€39,176	€34,694	€30,570	€26,777	€23,287	€20,076	€17,122	€14,405	€11,904
(-) Depreciación				€21,600	€21,600	€21,600	€21,600	€21,600	€21,600	€21,600	€21,600	€21,600	€21,600
(-) CapEx			(€216,000)	-	-	-	-	-	-	-	-	-	-
Free Cash Flow			(€216,000)	€65,647	€60,776	€56,294	€52,170	€48,377	€44,887	€41,676	€38,722	€36,005	€33,504
Resultado													
IRR del proyecto			21.0%										
IRR por Escenario													
Escenario		Revenue Año 1	IRR										
Determinista		€93,685	21.0%										
Esperado		€80,512	16.5%										
P50		€76,540	15.1%										
P5		€30,011	-2.9%										
P90		€126,863	31.7%										
Proyección FCF — Esperado		Año	Year 0	Year 1	Year 2	Year 3	Year 4	Year 5	Year 6	Year 7	Year 8	Year 9	Year 10
Revenue			-	€80,512	€74,071	€68,145	€62,694	€57,678	€53,064	€48,819	€44,913	€41,320	€38,015
FCF			(€216,000)	€57,085	€52,898	€49,046	€45,503	€42,243	€39,244	€36,484	€33,946	€31,610	€29,462
Proyección FCF — P50		Año	Year 0	Year 1	Year 2	Year 3	Year 4	Year 5	Year 6	Year 7	Year 8	Year 9	Year 10
Revenue			-	€76,540	€70,417	€64,783	€59,601	€54,833	€50,446	€46,410	€42,698	€39,282	€36,139
FCF			(€216,000)	€54,503	€50,523	€46,861	€43,493	€40,393	€37,542	€34,919	€32,505	€30,285	€28,242
Proyección FCF — P5		Año	Year 0	Year 1	Year 2	Year 3	Year 4	Year 5	Year 6	Year 7	Year 8	Year 9	Year 10
Revenue			-	€30,011	€27,610	€25,401	€23,369	€21,500	€19,780	€18,197	€16,742	€15,402	€14,170
FCF			(€216,000)	€24,259	€22,699	€21,263	€19,942	€18,727	€17,609	€16,580	€15,634	€14,763	€13,963
Proyección FCF — P90		Año	Year 0	Year 1	Year 2	Year 3	Year 4	Year 5	Year 6	Year 7	Year 8	Year 9	Year 10
Revenue			-	€126,863	€116,714	€107,377	€98,787	€90,884	€83,613	€76,924	€70,770	€65,108	€59,900
FCF			(€216,000)	€87,213	€80,616	€74,547	€68,963	€63,826	€59,100	€54,753	€50,753	€47,073	€43,687

Repositorio

<https://github.com/hugoragg/Lithium-Battery-Trading-Optimization>