



COMILLAS
UNIVERSIDAD PONTIFICIA

ICAI

GRADO EN INGENIERÍA EN TECNOLOGÍAS INDUSTRIALES

TRABAJO FIN DE GRADO

Programación matemática para la optimización de la
gestión de una batería en una instalación fotovoltaica de
autoconsumo

Autor: José Antonio Álvarez Solanas

Director: José Luis Sancha Gonzalo

Madrid

Junio de 2026

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título

Programación matemática para la optimización de la gestión de una batería en una instalación fotovoltaica de autoconsumo

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico 2025/26 es de mi autoría, original e inédito 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.

Fdo.: José Antonio Álvarez Solanas

Fecha: 22/06/2026

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.: José Luis Sancha Gonzalo

Fecha: 23/06/2026



COMILLAS
UNIVERSIDAD PONTIFICIA

ICAI

GRADO EN INGENIERÍA EN TECNOLOGÍAS INDUSTRIALES

TRABAJO FIN DE GRADO

Programación matemática para la optimización de la
gestión de una batería en una instalación fotovoltaica de
autoconsumo

Autor: José Antonio Álvarez Solanas

Director: José Luis Sancha Gonzalo

Madrid

Agradecimientos

Me gustaría agradecer de forma sincera a las personas que me han apoyado, tanto durante este trabajo, como durante estos años a:

José Luis, director de este trabajo, por su orientación y experiencia en este sector, además de su disponibilidad pese a la diferencia horaria y a su continua ayuda para el desarrollo de este proyecto.

ICAI, por darme acceso a un futuro prometedor y haberme permitido vivir durante el año de intercambio una de las mejores experiencias de mi vida, estudiando en una de las universidades más prestigiosas del mundo.

Mis amigos, por apoyarme durante estos años tan difíciles y conseguir que cada día se hiciera tan ameno y se hayan convertido en tantos recuerdos para el resto de mi vida.

Mi hermana Paula, por ser la mejor. Por siempre alegrarse por mí, llamarme y cogerme el teléfono siempre que ha hecho falta, y por invitarme a detallitos para estar más contento.

Y a mamá y papá, por quererme y ayudarme tanto durante toda la vida, dándome todo de vosotros. Sin vosotros nada hubiera sido posible. Gracias por priorizarme siempre, por escucharme, por apoyarme tanto y por motivarme a ser mejor cada día. Os quiero mucho.

PROGRAMACIÓN MATEMÁTICA PARA LA OPTIMIZACIÓN DE LA GESTIÓN DE UNA BATERÍA EN UNA INSTALACIÓN FOTOVOLTAICA DE AUTOCONSUMO

Autor: Álvarez Solanas, José Antonio.

Director: Sancha Gonzalo, José Luis.

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas

RESUMEN DEL PROYECTO

Se ha desarrollado un modelo de programación lineal que determina la gestión económicamente óptima de una batería en una vivienda con autoconsumo fotovoltaico, contrastándolo con el comportamiento real de un inversor comercial sobre datos horarios de 2025. La gestión óptima reduce la factura un 17,1 % respecto al inversor real mientras que en su versión realista el ahorro es de 5,37 € en el año 2025 aunque implementado también para el año 2026 con datos con mayor incertidumbre.

Palabras clave: Autoconsumo fotovoltaico, programación lineal, optimización, batería, PVPC.

1. Introducción

El sistema eléctrico atraviesa una transformación marcada por el crecimiento de las energías renovables, que ha incrementado la volatilidad del precio horario de la electricidad. Para un consumidor acogido al Precio Voluntario para el Pequeño Consumidor (PVPC), el coste de la energía deja de ser constante y depende de la hora de consumo, lo que abre una oportunidad de ahorro a quien disponga de una batería capaz de almacenar energía barata para emplearla en las horas caras.

La mayoría de los inversores domésticos gestionan la batería con una lógica reactiva que prioriza el autoconsumo instantáneo, pero no anticipa la evolución de los precios. Se evalúa en este proyecto, por tanto, cuánto ahorro adicional permitiría una gestión que decidiera de forma matemáticamente óptima cada flujo de energía, conociendo la evolución de precios y generación.

2. Definición del Proyecto

El trabajo estudia una vivienda real situada en Madrid, equipada con 1 kWp de paneles fotovoltaicos, una batería de 3 kWh y un inversor de 3 kW, de la que se dispone del registro horario completo del año 2025. El objetivo es minimizar el coste neto de la energía mediante

un modelo de optimización y comparar el resultado con el funcionamiento real del inversor, cuantificando el ahorro alcanzable y encontrando un techo de optimización.

El alcance se limita a la gestión de una instalación ya dimensionada, modalidad de autoconsumo con excedentes bajo compensación simplificada y regulada por el Real Decreto 244/2019. El objetivo de optimización es estrictamente económico, quedando fuera otros factores como la minimización de emisiones o la maximización de la vida útil de la batería, que se analizan de forma cualitativa.

3. Descripción del modelo/sistema/herramienta

Se ha formulado un modelo de programación lineal que decide, en cada hora, el reparto de la energía entre los seis flujos posibles del sistema. De los paneles al hogar, a la batería o a la red; de la red al hogar o a la batería; y de la batería al hogar, minimizando el coste neto de la energía. El modelo respeta los balances de energía, los límites de potencia y capacidad de la batería, y una restricción antifraude que impide verter a la red energía que no proceda de excedente solar real.

Implementado en Python mediante las librerías Pyomo y el solver GLPK, el modelo se ejecuta en dos modalidades: una con conocimiento perfecto de todo el año, que establece el techo teórico de ahorro, y otra de horizonte deslizante de 24 horas, que reproduce las condiciones de un controlador real que solo conoce la información de cada día.

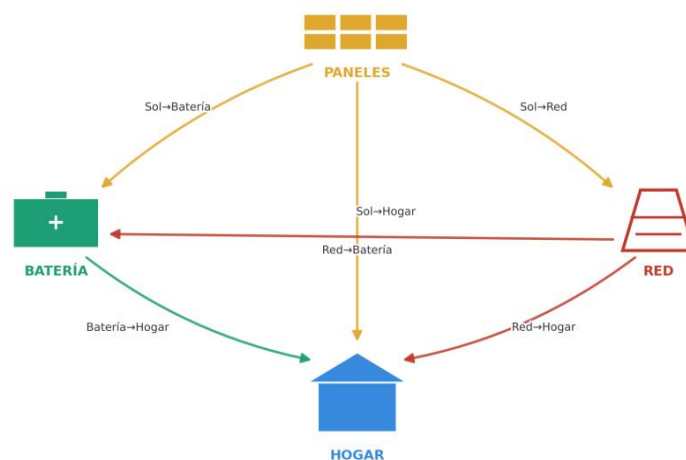


Ilustración 1. Esquema de los flujos de energía de la instalación

4. Resultados

Sobre los datos reales de 2025, el caso sin instalación supone un coste anual de 339,99 €, que el inversor real reduce a 118,14 €. La gestión óptima alcanza los 97,97 €, lo que representa un ahorro adicional del 17,1 % respecto al inversor. En su versión realista de horizonte deslizante, el ahorro frente al inversor es de 5,37 € anuales, y la diferencia entre ambas cifras cuantifica el coste de no conocer el futuro.

El análisis de sensibilidad revela que la rentabilidad depende críticamente de la eficiencia y la capacidad de la batería: con una eficiencia del 90 % por conversión, el modelo dejaría de ser rentable, mientras que el ahorro crece con la capacidad.




Ilustración 2. Coste anual de la energía por escenario

5. Conclusiones

La gestión óptima logra de forma sistemática un ahorro respecto al inversor comercial, si bien este resulta reducido en una instalación de tamaño tan pequeño como la estudiada. Para que la incorporación de un sistema de control inteligente fuera rentable, su sobrecoste no debería superar unas pocas decenas de euros, considerando un periodo de amortización de diez años. La principal aportación del trabajo es, por tanto, de carácter metodológico. Se proporciona un procedimiento reproducible para cuantificar el ahorro que permite la gestión óptima de la batería e identificar los factores de los que depende su rentabilidad, principalmente la eficiencia y la capacidad del almacenamiento.

6. Referencias

- [1] International Energy Agency, *Electricity 2024: Analysis and Forecast to 2026*. Paris, Francia: IEA, 2024.
- [2] Ministerio para la Transición Ecológica y el Reto Demográfico, "Real Decreto 244/2019, de 5 de abril, por el que se regulan las condiciones del autoconsumo de energía eléctrica," *Boletín Oficial del Estado*, núm. 83, 2019.
- [3] R. Bean y H. Khan, "Using solar and load predictions in battery scheduling at the residential level," arXiv:1810.11178, 2018.

MATHEMATICAL PROGRAMMING FOR THE OPTIMIZATION OF BATTERY MANAGEMENT IN A SELF-CONSUMPTION PHOTOVOLTAIC INSTALLATION

Author: Álvarez Solanas, José Antonio.

Supervisor: Sancha Gonzalo, José Luis.

Collaborating Entity: ICAI – Universidad Pontificia Comillas

ABSTRACT

A linear programming model has been developed to determine the economically optimal management of a battery in a household with photovoltaic self-consumption, validated against the real behaviour of a commercial inverter using hourly data from 2025. Optimal management reduces the electricity bill by 17.1 % compared to the real inverter; in its realistic rolling-horizon version, the annual saving is 5.37 €.

Keywords: Photovoltaic self-consumption, linear programming, optimization, battery, PVPC

1. Introduction

The electricity system is undergoing a transformation driven by the growth of renewable energy, which has increased the volatility of hourly electricity prices. For a consumer under the regulated PVPC tariff (Precio Voluntario para el Pequeño Consumidor, the Spanish regulated electricity tariff), the cost of energy is no longer constant and depends on the hour of consumption, which opens up a saving opportunity for those who own a battery able to store cheap energy and use it during expensive hours.

Most domestic inverters manage the battery with a reactive logic that prioritizes instantaneous self-consumption but does not anticipate price evolution. This project therefore evaluates how much additional saving could be achieved through a management strategy that optimally decides, in mathematical terms, each energy flow, knowing the evolution of prices and generation.

2. Project definition

This work studies a real household located in Madrid, equipped with 1 kWp of photovoltaic panels, a 3 kWh battery and a 3 kW inverter, for which the complete hourly record of 2025 is available. The aim is to minimize the net cost of energy by means of an optimization model and

to compare the result with the actual operation of the inverter, quantifying the achievable saving and establishing an optimization ceiling.

The scope is limited to the management of an already-sized installation, under the surplus self-consumption scheme with simplified compensation, regulated by Royal Decree 244/2019. The optimization objective is strictly economic, leaving aside other factors such as the minimization of emissions or the maximization of the battery's service life, which are analysed qualitatively.

3. Model/System description

A linear programming model has been formulated that decides, for each hour, the distribution of energy among the six possible flows of the system: from the panels to the home, to the battery or to the grid; from the grid to the home or to the battery; and from the battery to the home, minimizing the net cost of energy. The model respects the energy balances, the power and capacity limits of the battery, and an anti-fraud constraint that prevents feeding into the grid any energy that does not come from real solar surplus.

Implemented in Python using the Pyomo library and the GLPK solver, the model is run in two modes: one with perfect knowledge of the whole year, which establishes the theoretical saving ceiling, and another with a 24-hour rolling horizon, which reproduces the conditions of a real controller that only knows the information of each day.

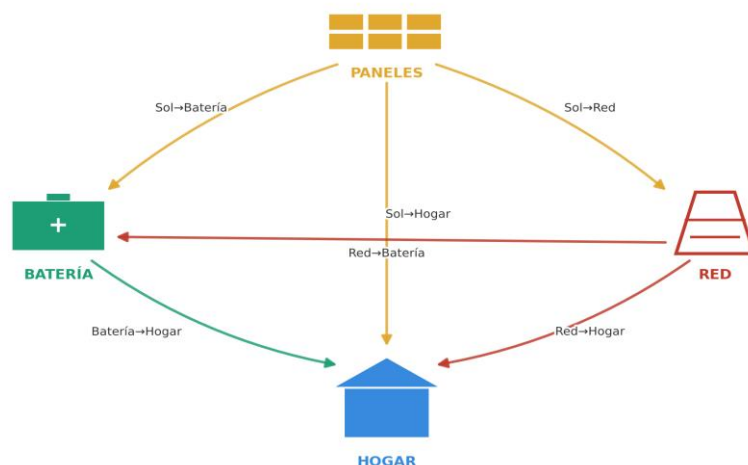


Ilustración 3. Energy flow diagram of the installation

4. Results

On the real 2025 data, the no-installation case entails an annual cost of 339.99 €, which the real inverter reduces to 118.14 €. Optimal management reaches 97.97 €, representing an additional saving of 17.1 % with respect to the inverter. In its realistic rolling-horizon version, the saving against the inverter is 5.37 € per year, and the difference between both figures quantifies the cost of not knowing the future.

The sensitivity analysis reveals that profitability depends critically on the efficiency and capacity of the battery: at 90 % efficiency per conversion, the model would no longer be profitable, while savings grow with capacity, although with diminishing returns.




Ilustración 4. Annual energy cost per scenario

5. Conclusions

Optimal management systematically achieves savings with respect to the commercial inverter, although these are limited in an installation as small as the one studied. For the incorporation of an intelligent control system to be profitable, its additional cost should not exceed a few tens of euros, assuming a ten-year payback period. The main contribution of this work is therefore methodological. It provides a reproducible procedure to quantify the savings achievable through optimal battery management and to identify the factors on which its profitability depends, mainly the efficiency and the capacity of the storage system.

6. References

- [1] International Energy Agency, *Electricity 2024: Analysis and Forecast to 2026*. Paris, France: IEA, 2024.

- [2] Ministry for the Ecological Transition and the Demographic Challenge, "Royal Decree 244/2019, of 5 April, regulating the administrative, technical and economic conditions of electricity self-consumption," *Boletín Oficial del Estado*, no. 83, 2019.

- [3] R. Bean and H. Khan, "Using solar and load predictions in battery scheduling at the residential level," arXiv:1810.11178, 2018.

ÍNDICE DE LA MEMORIA

<i>Índice de la memoria</i>	<i>I</i>
<i>Índice de figuras</i>	<i>IV</i>
<i>Índice de tablas</i>	<i>V</i>
<i>Lista de Abreviaturas</i>	<i>VI</i>
<i>Glosario de términos</i>	<i>VII</i>
<i>Capítulo 1. Introducción</i>	<i>11</i>
1.1 Contexto del mercado eléctrico y volatilidad de precios.....	11
1.2 El auge del autoconsumo fotovoltaico y el almacenamiento.....	12
1.3 Motivación.....	14
1.4 Alcance y delimitación del proyecto	15
1.5 Objetivos del proyecto.....	16
1.6 Metodología de trabajo y planificación	17
1.7 Alineación con los Objetivos de Desarrollo Sostenible	19
1.8 Estructura de la memoria.....	20
<i>Capítulo 2. Estado del arte</i>	<i>21</i>
2.1 Marco regulatorio del autoconsumo en España.....	21
2.1.1 El precio de la energía: PVPC y mercado mayorista	22
2.1.2 La compensación simplificada de excedentes	22
2.1.3 La tarifa de acceso 2.0TD	23
2.2 Tecnología de almacenamiento residencial.....	24
2.3 Contexto internacional del autoconsumo	24
2.4 Estrategias de control de baterías	25
2.5 Optimización matemática en la gestión energética	26
2.6 Posicionamiento del trabajo.....	27
<i>Capítulo 3. Metodología</i>	<i>29</i>

3.1	Descripción de la instalación.....	29
3.2	Adquisición y tratamiento de datos	30
3.2.1	<i>Fuentes de datos</i>	30
3.2.2	<i>Variables originales y derivadas</i>	31
3.2.3	<i>Análisis de coherencia de los datos</i>	32
3.3	Definición de los escenarios de comparación.....	33
3.3.1	<i>El escenario C: comportamiento del inversor real</i>	34
3.4	Formulación matemática del modelo	35
3.4.1	<i>Conjuntos, parámetros y variables de decisión</i>	36
3.4.2	<i>Función objetivo</i>	37
3.4.3	<i>Restricciones</i>	38
3.4.4	<i>Naturaleza del problema: un problema lineal</i>	40
3.5	Tratamiento de la eficiencia de la batería.....	40
3.6	Implementación computacional.....	41
3.7	Del techo teórico al modelo realista	42
3.8	Construcción del escenario 2026.....	43
Capítulo 4. Análisis de resultados.....		47
4.1	Caracterización de los datos de 2025	47
4.2	Comparativa económica anual de escenarios	49
4.2.1	<i>Verificación de la compensación simplificada mensual</i>	52
4.3	Análisis de comportamiento horario.....	52
4.4	Validación del modelo: Horizonte frente a previsión perfecta.....	57
4.5	Análisis de sensibilidad	59
4.5.1	<i>Sensibilidad de la eficiencia de la batería</i>	59
4.5.2	<i>Sensibilidad a la capacidad de la batería</i>	61
4.5.3	<i>Indicadores técnicos para tener en cuenta</i>	63
4.6	Resultados de la proyección a 2026	64
4.7	Estudio económico y amortización.....	66
Capítulo 5. Conclusiones y trabajos futuros		68
5.1	Conclusiones principales	68
5.2	Grado de consecución de los objetivos.....	69
5.3	Limitaciones del trabajo	70

5.4 Aportaciones y validez	71
5.5 Líneas de desarrollo futuro	71
Capítulo 6. Bibliografía.....	73
Anexo I. Alineación con los Objetivos de Desarrollo Sostenible (ODS).....	76
Anexo II. Código Fuente.....	78
Anexo III. Descripción de los Archivos de Datos	94
Anexo IV. Manual de Uso de Pyomo/Colab.....	97
Anexo V. Uso IA en este Proyecto	102

ÍNDICE DE FIGURAS

Figura 1.1 Perfil horario del precio mayorista (PVPC).....	12
Figura 1.2 Diagrama de Gantt de la planificación temporal del proyecto	19
Figura 2.1 Periodos horarios de la tarifa de acceso 2.0TD en un día laborable peninsular	23
Figura 2.2 Familias de estrategias de control de baterías.....	26
Figura 3.1 Esquema de los flujos de energía de la instalación.....	30
Figura 4.1 Perfil horario medio de demanda y generación en 2025	48
Figura 4.2 Generación solar mensual en 2025	49
Figura 4.3 Coste anual de la energía por escenario (2025)	51
Figura 4.4 Día tipo de invierno: evolución del estado de carga, demanda, generación y precio	54
Figura 4.5 Día tipo de verano: evolución del estado de carga, demanda, generación y precio	57
Figura 4.6 Validación: inversor real, modelo realista y techo teórico	58
Figura 4.7 Sensibilidad del coste óptimo a la eficiencia de la batería	60
Figura 4.8 Sensibilidad del coste óptimo a la capacidad de la batería	62
Figura 4.9 Coste por escenario en la proyección de 2026.....	65

ÍNDICE DE TABLAS

Tabla 1.1 Distribución de horas por fase del proyecto.....	18
Tabla 3.1 Variables registradas y derivadas empleadas en el análisis	31
Tabla 3.2 Definición de los escenarios de comparación	34
Tabla 3.3 Notación del modelo de optimización.....	35
Tabla 3.4 Parámetros de configuración de PVGIS para la generación del año sintético 2026	45
Tabla 4.1 Coste anual de la energía por escenario	50
Tabla 4.2 Distribución horaria de los flujos de energía en un día tipo de invierno (9 de enero de 2025).....	54
Tabla 4.3 Distribución horaria de los flujos de energía en un día tipo de verano (23 de julio de 2025).....	56
Tabla 4.4 Comparación entre el inversor real, el modelo realista y el techo teórico (2025) ..	58
Tabla 4.5 Sensibilidad del modelo a la eficiencia de la batería	60
Tabla 4.6 Sensibilidad del modelo a la capacidad de la batería.....	62
Tabla 4.7 Coste por escenario en la proyección de 2026 (1 de enero a 12 de junio).....	64
Tabla 4.8 Sobrecoste máximo admisible del control según el plazo de amortización.....	66

LISTA DE ABREVIATURAS

<i>Sigla</i>	<i>Significado</i>
CAPEX	Capital Expenditure (inversión inicial)
ESIOS	Sistema de Información del Operador del Sistema
IEA	International Energy Agency (Agencia Internacional de la Energía)
IRPF	Impuesto sobre la Renta de las Personas Físicas
LP	Linear Programming (programación lineal)
MILP	Mixed Integer Linear Programming (programación lineal entera mixta)
MPC	Model Predictive Control (control predictivo basado en modelo)
ODS	Objetivos de Desarrollo Sostenible
PVGIS	Photovoltaic Geographical Information System
PVPC	Precio Voluntario para el Pequeño Consumidor
RD	Real Decreto
SOC	State of Charge (estado de carga de la batería)
TFG	Trabajo de Fin de Grado

GLOSARIO DE TÉRMINOS

Autoconsumo fotovoltaico. Modalidad de generación eléctrica en la que una instalación de paneles solares produce energía para satisfacer el consumo propio de la vivienda o edificio donde se ubica, pudiendo verter los excedentes a la red eléctrica.

Balance neto (net metering). Mecanismo de compensación de excedentes en el que la energía vertida a la red se descuenta directamente de la consumida en términos de energía, como si el contador girase hacia atrás. Empleado en otros países, resulta más favorable al consumidor que la compensación económica española, pero reduce el incentivo a instalar almacenamiento.

Batería de almacenamiento. Dispositivo electroquímico capaz de acumular energía eléctrica para su posterior uso. En el contexto del autoconsumo, permite desacoplar temporalmente la generación solar del consumo del hogar.

Bornes de corriente alterna. Puntos de conexión del inversor en su lado de corriente alterna, donde se realizan las mediciones de energía. Las pérdidas internas de conversión y de la batería, situadas aguas arriba de estos puntos no resultan observables en dichas mediciones.

Calendar shift (desplazamiento de calendario). Técnica de construcción de datos sintéticos que reasigna los registros de un año a las fechas de otro respetando el día de la semana, los festivos y los cambios de hora, de modo que se conserva la estructura semanal y estacional del original.

Compensación de excedentes. Mecanismo regulado por el RD 244/2019 mediante el cual el valor económico de la energía solar vertida a la red se descuenta de la factura eléctrica mensual del titular de la instalación. El saldo resultante nunca puede ser negativo.

Control greedy. Estrategia de gestión de la batería basada en reglas reactivas: se prioriza el autoconsumo instantáneo, se carga la batería con el excedente solar disponible y se descarga cuando hay déficit de generación, sin considerar la evolución futura de precios ni de generación. También denominada control heurístico o reactivo.

Control predictivo basado en modelo (MPC). Estrategia de control que emplea previsiones de generación, demanda y precios para planificar las decisiones sobre un horizonte futuro, reoptimizando

de forma continua a medida que se dispone de nueva información.

Datos sintéticos. Conjunto de datos construido artificialmente a partir de fuentes externas y transformaciones sobre datos históricos reales, utilizado para simular periodos para los que no se dispone de mediciones directas. En este trabajo, los datos de generación solar de 2026 proceden de PVGIS y la demanda se obtiene desplazando temporalmente los registros reales de 2025.

Degradación de la batería. Pérdida progresiva de capacidad útil de una batería como consecuencia de su uso, asociada principalmente al número de ciclos de carga y descarga, a la profundidad de dichos ciclos y a la temperatura de operación.

Densidad energética. Cantidad de energía que un dispositivo de almacenamiento puede contener por unidad de masa o de volumen. Una densidad elevada permite almacenar más energía en menos espacio, factor clave en el éxito de las baterías de litio-ion.

Descarbonización. Proceso de reducción progresiva de las emisiones de dióxido de carbono asociadas a la generación y el consumo de energía, con el objetivo de alcanzar la neutralidad climática.

Estado de carga (SOC, del inglés State of Charge). Magnitud que expresa la cantidad de energía almacenada en la batería en un instante dado, referida a su capacidad máxima. En este trabajo se expresa en kilovatios-hora (kWh), con un rango entre 0 y 3 kWh.

Excedente solar. Energía generada por los paneles fotovoltaicos que supera la demanda instantánea del hogar y que, en ausencia de almacenamiento, se vierte a la red eléctrica.

Función objetivo. Expresión matemática que un problema de optimización busca minimizar o maximizar. En este trabajo, representa el coste neto de la energía eléctrica.

Generación distribuida. Modelo de producción eléctrica basado en instalaciones de pequeña escala situadas próximas al punto de consumo, en contraposición a la generación centralizada en grandes plantas. El autoconsumo fotovoltaico residencial es una de sus manifestaciones más extendidas.

Horizonte deslizante (rolling horizon). Técnica de optimización en la que el problema se resuelve de forma repetida para ventanas temporales sucesivas, utilizando únicamente la información disponible en cada momento. En este trabajo se emplea una ventana de 24 horas que avanza día a día.

Inversor. Dispositivo electrónico que convierte la corriente continua generada por los paneles fotovoltaicos en corriente alterna apta para el consumo doméstico y la conexión a la red. En instalaciones con batería, gestiona también los flujos de carga y descarga.

Mercado marginalista. Sistema de fijación del precio de la electricidad en el que el precio de cada periodo horario lo determina la oferta más cara necesaria para cubrir la demanda total. Implica que todas las tecnologías que entran en el mercado cobran ese precio marginal, independientemente de su coste de producción.

Precio Voluntario para el Pequeño Consumidor (PVPC). Tarifa eléctrica regulada, de acceso voluntario para consumidores domésticos con potencia contratada no superior a 10 kW, cuyo precio varía hora a hora siguiendo el precio del mercado mayorista. Los precios son publicados por Red Eléctrica de España con un día de antelación a través de ESIOS.

Programación lineal (LP, del inglés Linear Programming). Técnica de optimización matemática que busca minimizar o maximizar una función objetivo lineal sujeta a un conjunto de restricciones también lineales. Constituye el núcleo metodológico del modelo desarrollado en este trabajo.

Programación lineal entera mixta (MILP). Variante de la programación lineal en la que algunas variables están restringidas a tomar valores enteros o binarios. Permite modelar decisiones discretas (encendido/apagado), a costa de un mayor esfuerzo computacional.

Prosumidor. Consumidor activo que interviene en el proceso de creación, mejora o promoción de los productos o servicios que consume.

Restricción. Condición matemática que limita los valores que pueden tomar las variables de un problema de optimización. En este modelo, las restricciones garantizan la coherencia física del sistema y el cumplimiento de la normativa.

Solver. Programa informático especializado en resolver problemas de optimización matemática. En este trabajo se emplea GLPK, un solver de código abierto para problemas lineales.

Superfluo. Que es innecesario o que excede de lo necesario. En el contexto de este trabajo, se aplica a los movimientos de energía que el modelo podría realizar sin que ello reduzca el coste, como cargar y descargar la batería de forma simultánea, y que se evitan por carecer de utilidad y suponer un desgaste innecesario de los componentes.

Tarifa 2.0TD. Tarifa de acceso regulada aplicable a los suministros eléctricos de baja tensión con potencia contratada no superior a 15 kW, vigente en España desde junio de 2021. Divide el día en tres periodos (punta, llano y valle) con distinto coste de peajes y cargos.

Tasa de autoconsumo. Fracción de la energía generada por los paneles que se aprovecha en la propia instalación (directamente o a través de la batería) en lugar de verterse a la red. Se expresa en porcentaje sobre la generación total.

Techo de optimización. Límite teórico del ahorro alcanzable, obtenido mediante una optimización con conocimiento perfecto de todos los precios y datos futuros del periodo analizado. Ninguna estrategia de control realista puede superar este valor, por lo que constituye una referencia absoluta para evaluar cualquier solución práctica.

Variable de decisión. Magnitud cuyo valor determina el modelo de optimización. En este trabajo, las variables de decisión son los flujos de energía entre los distintos elementos del sistema.

Vertido. Energía eléctrica generada por los paneles solares que se inyecta a la red eléctrica por no poder ser consumida ni almacenada en el instante de su generación.

Capítulo 1. INTRODUCCIÓN

1.1 CONTEXTO DEL MERCADO ELÉCTRICO Y VOLATILIDAD DE PRECIOS

El sistema eléctrico atraviesa una transformación profunda. La descarbonización de la economía, impulsada por los compromisos climáticos internacionales y por la propia evolución tecnológica, ha situado a las energías renovables como las estrellas de la generación eléctrica. En la última década, la energía fotovoltaica y la eólica han pasado de ser tecnologías marginales y subvencionadas a constituir la fuente de nueva capacidad más barata en la mayor parte del mundo [1]. Sin embargo, esta irrupción de renovables no es gratuita en términos de operación del sistema ya que introduce una variabilidad considerable tanto en la generación como, por lo tanto, en los precios de la electricidad.

El precio mayorista de la electricidad en España se fija mediante un mercado marginalista, en el que el precio horario lo determina la última tecnología necesaria para cubrir la demanda en cada periodo, como ha sido el ejemplo de la implementación de las energías fotovoltaicas y eólicas comentadas. Cuando la generación renovable es abundante, por ejemplo, en las horas centrales de un día soleado y con viento, el precio cae, en ocasiones hasta valores incluso negativos. Por el contrario, en las horas en que la demanda es alta y la aportación renovable escasa, el precio se dispara al depender de que entren en funcionamiento centrales de respaldo más caras. El resultado es un perfil de precios fluctuante a lo largo del día, con diferencias que pueden ser muy significativas entre las horas más baratas y las más caras.

La Figura 1 muestra un ejemplo de esta volatilidad correspondiente a un día de invierno de 2025, en el que el precio oscila entre 110 €/MWh a mediodía y más de 205 €/MWh a las 20:00.

DESDE EL 02-02-2025 A LAS 00:00 HASTA EL 03-02-2025 A LAS 00:55 AGRUPADOS POR HORA



Figura 1.1 Perfil horario del precio mayorista (PVPC)

Esta volatilidad se traslada al consumidor doméstico a través del Precio Voluntario para el Pequeño Consumidor (PVPC), una tarifa regulada indexada al mercado mayorista cuyo precio varía cada hora, siendo estos precios conocidos el día anterior. Por este motivo, el coste de consumir un kilovatio-hora deja no es una cantidad fija, sino que depende del momento exacto en que se consume. Esta circunstancia, que a primera vista complica la factura de la luz, abre en realidad una oportunidad de ahorro: si el consumidor dispone de algún mecanismo para desplazar su consumo de las horas caras a las baratas, o para almacenar energía cuando es barata y emplearla cuando es cara, puede reducir su factura de forma significativa. Es precisamente en esta oportunidad en la que cobra sentido el presente trabajo.

1.2 EL AUGE DEL AUTOCONSUMO FOTOVOLTAICO Y EL ALMACENAMIENTO

De forma paralela a la transformación del mercado, el autoconsumo fotovoltaico ha experimentado un crecimiento notable en España. La derogación del denominado «impuesto al sol», en la cual se penalizaba a los particulares y empresas que generaban su propia electricidad,

y la aprobación de un marco regulatorio favorable a partir de 2019, desencadenaron una rápida expansión de las instalaciones de generación distribuida en el sector residencial. Hoy, un número creciente de viviendas cuenta con paneles solares que cubren una parte de su demanda eléctrica y pueden verter el excedente a la red a cambio de una compensación económica. A ello se suman los incentivos fiscales asociados a la instalación, que permiten deducir en algunos casos entre un 20% y un 60% de la inversión en la declaración del Impuesto sobre la Renta de las Personas Físicas (IRPF) cuando la obra acredita una mejora de la eficiencia energética de la vivienda, suponiendo así un ahorro de miles de euros al sumarse los deducidos y el ahorro por la generación de la energía [2].

La incorporación de baterías a estas instalaciones supone un salto cualitativo como se verá posteriormente en los resultados. Una instalación fotovoltaica sin almacenamiento solo puede aprovechar la energía solar en el mismo instante en que se genera; todo lo que no se consume en ese momento debe verterse a la red. Dado que el pico de generación solar (mediodía) rara vez coincide con el pico de demanda doméstica (mañana y, sobre todo, tarde-noche), una parte importante de la energía generada se vierte a precios bajos, mientras que el hogar continúa comprando energía cara en las horas sin sol. La batería rompe ese desajuste temporal ya que permite almacenar el excedente solar del mediodía para consumirlo por la noche, e incluso si la gestión es lo bastante inteligente, almacenar energía de la red en las horas más baratas para emplearla en las más caras [3].

Ahora bien, disponer de una batería no garantiza por sí solo un aprovechamiento óptimo. La cuestión decisiva es cómo se gestiona: en qué momento cargarla, con qué energía (solar o de red), cuándo descargarla y cuándo conviene verter a la red en lugar de almacenar. Estas decisiones, que deben tomarse hora a hora, determinan en última instancia el ahorro que la instalación es capaz de generar. La mayoría de los inversores domésticos comerciales adoptan una estrategia reactiva y sencilla, que prioriza el autoconsumo instantáneo y carga la batería con el excedente solar disponible. Esta lógica, que se denominará “greedy” a lo largo de la memoria, es robusta y no requiere previsión alguna, pero ignora una información importante que es la evolución futura de los precios y de la generación. Un sistema capaz de anticipar que la energía será barata de madrugada o que no habrá sol al día siguiente podría tomar decisiones

sustancialmente mejores ya que encuentra los precios a los que evitar comprar a toda costa, o esos en los que debe comprar por ser los más bajos.

1.3 MOTIVACIÓN

La motivación de este Trabajo de Fin de Grado nace de una pregunta concreta y de interés práctico inmediato: ¿cuánto dinero deja de ahorrar un hogar por el hecho de que su inversor toma decisiones reactivas en lugar de óptimas? Dicho de otro modo, si se sustituyera la lógica de control del inversor por un sistema que sea capaz de decidir de forma matemáticamente óptima cada flujo de energía, conociendo la evolución de los precios y de la generación, ¿qué reducción de la factura se podría conseguir?

Responder a esta pregunta tiene un doble valor. Desde el punto de vista del usuario, cuantifica el beneficio potencial de una gestión inteligente y permite valorar si merece la pena invertir en un sistema de control más avanzado. Desde el punto de vista metodológico, establece un techo de ahorro que es el límite teórico que ninguna estrategia de control, por sofisticada que sea, podría superar, puesto que se obtiene suponiendo un conocimiento perfecto del futuro. Conocer este techo es muy útil para evaluar cualquier estrategia realista, ya que ofrece una referencia absoluta contra la que medir su grado de aproximación al óptimo.

El trabajo dispone también de datos reales lo cual le da mayor validez al análisis. La instalación analizada es una vivienda concreta de la que se dispone del registro horario de datos completo del año 2025. Se conoce tanto la demanda como la generación solar, precios de compra y de vertido, y comportamiento real del inversor. Esto permite no solo formular el problema en abstracto, sino contrastar el modelo con el funcionamiento efectivo de un inversor comercial como el que tiene la instalación actualmente, y cuantificar el ahorro en euros sobre un caso real y no sobre un perfil sintético idealizado.

1.4 ALCANCE Y DELIMITACIÓN DEL PROYECTO

Con el fin de acotar con precisión el objeto de estudio y evitar ambigüedades en la interpretación de los resultados, conviene delimitar explícitamente el alcance del trabajo.

El proyecto se centra en una única vivienda con una instalación de autoconsumo fotovoltaico con almacenamiento, compuesta por un campo de paneles solares, una batería de 3 kWh de capacidad útil y un inversor con una potencia de 3 kW. El análisis se realiza sobre datos horarios reales del año 2025 y como adición al proyecto, se evaluarán también los primeros meses del año 2026, construido a partir de datos sintéticos que se explicarán posteriormente. Estos meses de 2026 se simularán el funcionamiento real diario del inversor que se pretende evaluar, es decir, el óptimo que se tratará de crear mediante los datos conocidos de 2025. La instalación se supone acogida a la modalidad de autoconsumo con excedentes bajo compensación simplificada, regulada por el Real Decreto 244/2019 [4].

El objetivo de optimización es estrictamente económico: se busca minimizar el coste neto de la energía eléctrica (compras a la red menos compensación por excedentes). Quedan por lo tanto fuera del alcance directo de la optimización otros objetivos legítimos pero distintos, como podrían ser la minimización de las emisiones de dióxido de carbono, la maximización de la vida útil de la batería o la maximización de la independencia respecto a la red. No obstante, varios de estos aspectos se analizan cualitativamente en el análisis de resultados y en las conclusiones al estar muy ligado con todo el sistema.

El trabajo se limita a la gestión de una instalación ya existente y dimensionada por lo que no es posible añadir paneles o baterías ni si esto fuera conveniente para los resultados, es decir, no se aborda el dimensionado óptimo de la instalación. De todas formas, el análisis de sensibilidad incluido en el capítulo de resultados ofrece indicaciones valiosas al respecto.

Por supuesto que el proyecto debe garantizar el cumplimiento de las normas. Se debe operar de forma que la vivienda obedezca las normas vigentes. Al tratarse de una instalación de autoconsumo residencial con compensación de excedentes, la energía que se vierta a la red se trata de energía estrictamente sobrante, es decir, que se habrá utilizado la producida por los

paneles para satisfacer la demanda de la vivienda, sin uso de batería ni red. Se evita el "lavado de energía" en el cual se utiliza la red eléctrica comercial como una forma de generar dinero (compra de energía barata para su posterior venta más cara desde la batería). El objetivo es establecer restricciones claras que garanticen que cualquier inyección a la red provenga únicamente de generación solar sobrante real de los paneles.

Finalmente, la degradación de la batería asociada al ciclado no se incorpora a la función objetivo del modelo, por las razones que se exponen en el apartado correspondiente, aunque si se analizará cualitativamente su relevancia.

1.5 OBJETIVOS DEL PROYECTO

El objetivo general del trabajo es desarrollar y validar un modelo de programación matemática que determine la gestión económicamente óptima de una batería en una instalación fotovoltaica de autoconsumo. Se cuantificará el ahorro que esta gestión permite comparado con el funcionamiento de un inversor comercial convencional.

Este objetivo general se concreta en los siguientes objetivos específicos:

1. Modelar matemáticamente el sistema energético de la vivienda, identificando todos los flujos de energía posibles entre los paneles, la batería, la red eléctrica y el consumo del hogar, así como las restricciones físicas y regulatorias que los gobiernan.
2. Formular un problema de optimización determinando si hacerlo mediante programación lineal (LP, del inglés Linear Programming) o programación lineal entera mixta (MILP, del inglés Mixed Integer Linear Programming) que minimice el coste neto de la energía, e implementarlo computacionalmente con herramientas de código que se describirán y comentarán en un apartado posterior.
3. Definir y comparar escenarios representativos, desde la ausencia de instalación (Caso A donde solo se cuenta con la red) hasta la gestión óptima pasando por pasos intermedios como el de red y paneles (Caso B) y red, paneles y baterías (caso C) el cual

es equivalente al funcionamiento real del inversor. Esto permitirá aislar y cuantificar la contribución de cada elemento al ahorro.

4. Distinguir el techo teórico de la solución realista, evaluando la diferencia entre una optimización con conocimiento perfecto del futuro y una estrategia operable que solo dispone de información a corto plazo. Se realizará una evaluación cruzada en la que, usando los datos de 2025, se probará el código de 2026. De esta forma se podrá ver si supone un ahorro o no, ya que, si no supone un ahorro, indicaría que el inversor optimizado puede no ser útil para datos futuros.
5. Cuantificar el ahorro económico que aporta la gestión óptima y analizar su viabilidad, estudiando el sobrecoste asociado a la implantación de un control inteligente y el periodo en que dicho sobrecoste se recupera.

1.6 METODOLOGÍA DE TRABAJO Y PLANIFICACIÓN

El desarrollo del trabajo se ha estructurado en seis fases, que se iniciaron a mediados de febrero de 2026. Al tratarse de una asignatura de 6 créditos, se ha tomado como referencia la dedicación estipulada de 150 horas, distribuidas entre las fases en función de su carga de trabajo estimada.

La primera fase, de análisis y tratamiento de datos, se dedicó a la extracción, limpieza y estructuración de los registros del inversor fotovoltaico, así como a la búsqueda de coherencia en los datos y la generación de nuevas variables a partir de las originales. A partir de las cinco columnas disponibles en los registros (producción de paneles, batería cargada de paneles, batería descargada en consumo, batería cargada de red y consumo de red) se derivaron variables de mayor interés, como la demanda real de la vivienda, el estado de la batería o la energía vertida a la red. En esta fase se obtuvieron también los precios PVPC y de compensación de excedentes de la plataforma ESIOS de Red Eléctrica de España [5].

La segunda fase, de formulación del modelo matemático, abarcó la definición de las variables de decisión, los parámetros, las restricciones y la función objetivo que conforman el modelo de optimización.

La tercera fase, de implementación en entorno de programación y depuración, consistió en trasladar el modelo algebraico a Python mediante la librería Pyomo [6], [7], ejecutándolo de forma incremental (primero 24 horas, después un mes y finalmente el año completo) para verificar que el código funcionaba correctamente antes de evaluar resultados.

La cuarta fase, de simulación y evaluación de resultados, comparó los distintos escenarios para cuantificar el ahorro de cada uno e identificar el funcionamiento óptimo. Incluyó además el ajuste de parámetros como la eficiencia de la batería para evaluar la sensibilidad del sistema.

La quinta fase, de implementación para el año 2026, evolucionó el modelo hacia un escenario de proyección futura, construyendo un año sintético e integrando la generación solar teórica obtenida de PVGIS (Photovoltaic Geographical Information System) [8]. El modelo se ejecutó día a día para simular la toma de decisiones con información imperfecta del futuro.

La sexta y última fase se dedicó a la exposición de resultados y redacción de la memoria.

La distribución temporal y la dedicación de cada fase se recogen en la Tabla 1.1, y se representan gráficamente mediante el diagrama de Gantt de la Figura 1.2.

Tabla 1.1 Distribución de horas por fase del proyecto

<i>Fase</i>	<i>Nombre</i>	<i>Periodo</i>	<i>Horas</i>
1	Análisis y tratamiento de datos	Mediados de febrero – mediados de marzo	30
2	Formulación del modelo matemático	Finales de marzo	15
3	Implementación en entorno de programación y depuración	Abril	25
4	Simulación y evaluación de resultados	Finales de abril	20

5	Implementación para el año 2026	Mayo	25
6	Exposición de resultados y redacción de memoria	Finales de mayo – junio	35




Figura 1.2 Diagrama de Gantt de la planificación temporal del proyecto

1.7 ALINEACIÓN CON LOS OBJETIVOS DE DESARROLLO SOSTENIBLE

El trabajo se alinea de forma natural con varios de los Objetivos de Desarrollo Sostenible (ODS) establecidos por las Naciones Unidas en la Agenda 2030 [9]. Esta agenda, aprobada en 2015, articula a través de diecisiete objetivos un plan de acción global orientado a la sostenibilidad ambiental, social y económica. De entre ellos, el trabajo conecta de manera directa con cuatro.

La contribución más evidente es al ODS 7 (Energía asequible y no contaminante). El modelo desarrollado maximiza el aprovechamiento de la energía solar generada por la vivienda y reduce el coste de la electricidad para el consumidor, lo que incide tanto en el aspecto de asequibilidad como en la de energía limpia que propone este objetivo.

El trabajo se relaciona también con el ODS 13 (Acción por el clima). Al optimizar la gestión del autoconsumo, se desplaza parte de la demanda desde la red hacia la generación renovable propia y hacia las horas de menor coste, que suelen además coincidir con una mayor presencia

de renovables en el sistema al no necesitarse tanta energía. Además, la optimización de la eficiencia económica incentiva la adopción de este tipo de instalaciones, con el que se consigue un efecto positivo sobre las emisiones mejorando por consiguiente la situación climática.

En menor medida, el proyecto contribuye también al ODS 11 (Ciudades y comunidades sostenibles), por su aportación al modelo de generación distribuida al aplanar la curva de demanda mediante el almacenamiento de energía en horas valle e incitación a la integración de los prosumidores en la red urbana, y al ODS 12 (Producción y consumo responsables), al promover un uso más eficiente de un recurso energético.

1.8 ESTRUCTURA DE LA MEMORIA

La memoria se organiza en seis capítulos. Tras esta introducción, el Capítulo 2 trata el estado del arte, el cual abarca el marco regulatorio del autoconsumo en España, las estrategias de control de baterías existentes y el papel de la optimización matemática en la gestión energética, para posicionar la aportación del trabajo. El Capítulo 3 describe la metodología: la instalación analizada, el tratamiento de los datos, la definición de los escenarios de comparación y lo más importante, la formulación matemática del modelo de optimización y su implementación. El Capítulo 4 presenta y discute los resultados, incluyendo la comparativa económica entre escenarios, el análisis del comportamiento del modelo, su validación frente al techo teórico, los análisis de sensibilidad, la proyección al año 2026 y el estudio económico de viabilidad. El Capítulo 5 incluye las conclusiones, las limitaciones del trabajo y las líneas de desarrollo futuro. Finalmente, el Capítulo 6 contiene las referencias bibliográficas y tras él, se finaliza la memoria con los anexos.

Capítulo 2. ESTADO DEL ARTE

Este capítulo sitúa el trabajo en su contexto y es útil para entender la necesidad de este proyecto. Se revisa primero el marco regulatorio que rige el autoconsumo en España, ya que es el que define las reglas económicas del problema y el protagonista del alcance del proyecto. A continuación, se describe la tecnología de almacenamiento empleada, se comenta brevemente cómo se aborda el autoconsumo en otros países, y se repasan las estrategias de gestión de baterías y las técnicas de optimización que se han utilizado en la literatura. Se terminará justificando por qué se ha elegido la programación lineal como herramienta para este trabajo.

2.1 MARCO REGULATORIO DEL AUTOCONSUMO EN ESPAÑA

El autoconsumo eléctrico en España está regulado mayoritariamente por el Real Decreto 244/2019 [4], que establece tanto las condiciones administrativas, como las técnicas y las económicas a las que debe acogerse cualquier instalación de generación para consumo propio. Esta norma supuso un punto de inflexión, ya que llegó poco después de que el Real Decreto-ley 15/2018 [10] derogara el conocido como «impuesto al sol», el cargo que hasta entonces penalizaba económicamente a quien generaba su propia electricidad. A partir de ese momento el autoconsumo dejó de ser una opción marginal y empezó a crecer con rapidez en el sector residencial al propiciar un buen ahorro de gastos para muchas viviendas.

El RD 244/2019 distingue dos grandes modalidades. La primera es el autoconsumo sin excedentes, en la que la instalación no puede verter energía a la red en ningún caso por lo está obligada a incorporar un sistema o una lógica anti vertido. La segunda es el autoconsumo con excedentes, en la que sí se permite inyectar a la red la energía que no se consume. Dentro de esta segunda modalidad, se vuelve a diferenciar de nuevo entre las instalaciones con compensación de excedentes y las que no compensan excedentes. La instalación estudiada en este trabajo pertenece a la modalidad de autoconsumo con excedentes acogida a compensación simplificada, que es la opción habitual para una vivienda particular.

2.1.1 EL PRECIO DE LA ENERGÍA: PVPC Y MERCADO MAYORISTA

Como ya se ha introducido previamente, el coste de la energía para un consumidor de una vivienda que se acoge al PVPC no es constante, sino que sigue hora a hora el precio del mercado mayorista, el cual funciona muy similar al mercado de valores tan conocido. Ese precio se fija mediante un mecanismo en el que todas las tecnologías que entran a cubrir la demanda cobran el precio de la oferta más cara que resulta necesaria, idéntico a cuando hay demanda por una acción, los demandantes van pidiendo precios cada vez mayores para conseguir llevarse la puja y el vendedor casa la operación en el precio más caro. La consecuencia es que el precio varía mucho a lo largo del día y, sobre todo, que puede conocerse con un día de antelación, puesto que el mercado diario casa la oferta y la demanda para el día siguiente. Este último detalle es importante para el presente trabajo, porque significa que un sistema de gestión puede planificar el día siguiente sobre precios ya conocidos y no sobre previsiones inciertas lo cual es una gran ventaja para poder ser capaz de mejorar el rendimiento de los inversores más sencillos.

El PVPC no debe confundirse con el precio del mercado mayorista de la electricidad. Si bien este último constituye uno de sus componentes, el PVPC se determina mediante una metodología regulada que agrega varios términos. Estos son: el coste de la energía en el mercado mayorista, los peajes de acceso a las redes de transporte y distribución, los cargos asociados a los costes del sistema, los costes de los servicios de ajuste y el margen de comercialización [11]. El resultado es un precio final con resolución horaria que el consumidor (pequeño) paga por la energía consumida en cada hora. De todas formas, para este trabajo, lo relevante es que el PVPC ofrece una señal de precio horaria y variable, que es precisamente la que permite al modelo de optimización decidir en qué momentos resulta más conveniente comprar energía de la red.

2.1.2 LA COMPENSACIÓN SIMPLIFICADA DE EXCEDENTES

El mecanismo de compensación simplificada es el que determina cuánto vale la energía que se vierte a la red [4]. Su funcionamiento es sencillo: al final de cada periodo de facturación, el comercializador calcula el valor económico de la energía consumida de la red y le resta el valor de la energía vertida. La diferencia es lo que se paga. Aunque esta compensación tiene un límite.

El valor de los excedentes nunca puede superar al de la energía consumida en ese mismo mes. Es decir, la factura de energía puede llegar a cero, pero nunca volverse negativa. El titular no cobra por la energía sobrante, únicamente puede descontarla de lo que consume.

Esto tiene implicaciones directas sobre el modelo de optimización, ya que el valor que se asigna a un kilovatio-hora vertido depende de si existe consumo contra el que compensarlo. El tratamiento de esta cuestión se detalla en la metodología y se verifica numéricamente en el capítulo de resultados. De todos modos, se verá posteriormente que no va a ser necesario aplicar esta limitación porque, a final de mes, el coste del consumo termina siendo muy superior a la compensación.

2.1.3 LA TARIFA DE ACCESO 2.0TD

Junto al precio de la energía, el consumidor doméstico paga unos peajes de acceso a la red que también dependen de la hora. Desde junio de 2021, la tarifa aplicable a los suministros de baja tensión hasta 15 kW es la 2.0TD, que divide el día en tres periodos con distinto coste [12]. En la Península, el periodo punta (el más caro) ocurre en la franja de 10:00 a 14:00 y de 18:00 a 22:00 mientras que el periodo valle (el más barato) va de 00:00 a 08:00 y el periodo llano (intermedio) ocupa las horas restantes. Los sábados, domingos y festivos nacionales se consideran valle durante las veinticuatro horas. La Figura 2.1 muestra cómo sería una distribución típica de periodos horarios de la tarifa comentada.




Figura 2.1 Periodos horarios de la tarifa de acceso 2.0TD en un día laborable peninsular

Esta estructura de tarifas refuerza la motivación del trabajo. No solo el precio de la energía fluctúa hora a hora, sino que también lo hacen los peajes, de modo que existe un incentivo doble

para desplazar el consumo hacia las horas más baratas, pese a que no se tendrán en cuenta los peajes a la hora de calcular el ahorro. Para un sistema de almacenamiento con capacidad de decidir cuándo cargar y cuándo descargar, esta variabilidad de precios es la fuente del ahorro potencial.

2.2 TECNOLOGÍA DE ALMACENAMIENTO RESIDENCIAL

El almacenamiento usando baterías de litio-ion es hoy la tecnología dominante en las instalaciones de autoconsumo residencial. Su éxito se debe a una combinación de factores: una densidad energética elevada, que permite almacenar bastante energía en poco volumen, una eficiencia de ciclo alta, un número de ciclos de vida razonable y, sobre todo, una caída de costes elevada en la última década, que ha hecho económicamente accesible su instalación en viviendas [13]. La instalación analizada en este trabajo emplea una batería de litio de 3 kWh de capacidad útil, un tamaño típico para una vivienda familiar.

Frente a estas ventajas, las baterías de litio presentan inconvenientes que conviene tener presente. Principalmente, se degradan con el uso. Cada ciclo de carga y descarga reduce ligeramente su capacidad, y esa degradación depende de cómo se opere la batería (profundidad de descarga, temperatura, número de ciclos por día, etc.) [14]. Un sistema de gestión que cicle la batería de forma muy agresiva conseguirá un ahorro mayor a corto plazo, pero acortará la vida útil del equipo. Esta tensión entre ahorro inmediato y durabilidad es relevante para interpretar los resultados y se retoma en el análisis económico y en las conclusiones del trabajo, aunque, como se justificará más adelante, la degradación no se incorporará como factor en la función objetivo ni en restricciones del modelo.

2.3 CONTEXTO INTERNACIONAL DEL AUTOCONSUMO

El modelo regulatorio español no es el mismo que en todas partes. En otros países, la energía vertida a la red recibe un tratamiento distinto y conviene conocerlo para entender donde se sitúa el caso español. Un esquema extendido durante años fue el del balance neto (net metering), empleado por ejemplo en distintos estados de Estados Unidos, en el que la energía vertida se

compensa directamente con la consumida en términos de energía, como si el contador girara hacia atrás. Bajo ese modelo, almacenar energía en una batería resulta menos atractivo, porque la red actúa de hecho como una batería gratuita e ilimitada.

El modelo español, basado en una compensación económica con saldo no negativo, es más restrictivo: incentiva el autoconsumo directo y el almacenamiento, ya que la energía vertida vale menos que la que se evita comprar. Esta diferencia explica por qué la gestión inteligente de la batería tiene, en el contexto español, un valor económico real y una ventaja muy grande en resultados como se verá en el capítulo 4, mientras que en un esquema de balance neto puro como el de EE. UU. su utilidad sería mucho menor.

2.4 ESTRATEGIAS DE CONTROL DE BATERÍAS

La forma en que se decide cuándo cargar y descargar una batería admite distintos niveles de complejidad. Una revisión sistemática de referencia en este ámbito es la de Azuatalam et al. [15], que clasifica las estrategias de gestión de sistemas fotovoltaicos con batería según su dificultad de implementarse, sus requisitos computacionales y la calidad de información que necesitan. Se pueden distinguir tres familias principales.

La primera son las reglas estáticas que están basadas en umbrales fijos programados de antemano (por ejemplo, descargar solo entre las 19:00 y las 22:00, o cargar solo si el SOC baja del 80%). Son sencillas y se cumplen perfectamente, pero no se adaptan a las condiciones cambiantes del precio.

La segunda familia es el control greedy o reactivo, que es el que está implementado en la mayoría de los inversores domésticos y para importancia de este proyecto, el de la instalación estudiada. Esta lógica prioriza el autoconsumo instantáneo almacenando el excedente solar disponible en cada momento y descargando la batería cuando la generación no cubre la demanda. La virtud de esta lógica es que reacciona a la situación energética instantánea real, mientras que la primera no lo hace. Su limitación es que, al no mirar al futuro, no puede

aprovechar la información de precios. Nunca cargará la batería de la red en una hora barata para usarla en una hora cara, porque no sabe que la hora cara va a llegar.

La tercera familia es el control predictivo basado en modelo (MPC, del inglés Model Predictive Control), que utiliza previsiones de generación, demanda y precios para planificar las decisiones sobre un horizonte futuro, reoptimizando a medida que avanza el tiempo y llega nueva información. El MPC es más potente que las reglas reactivas, pero su rendimiento depende de la calidad de las previsiones y su implementación es considerablemente más compleja por lo que muchas veces no sale rentable para la instalación.

La Figura 2.2 recoge información relevante que permite en pocas palabras diferencia bien cada una de las familias de control.

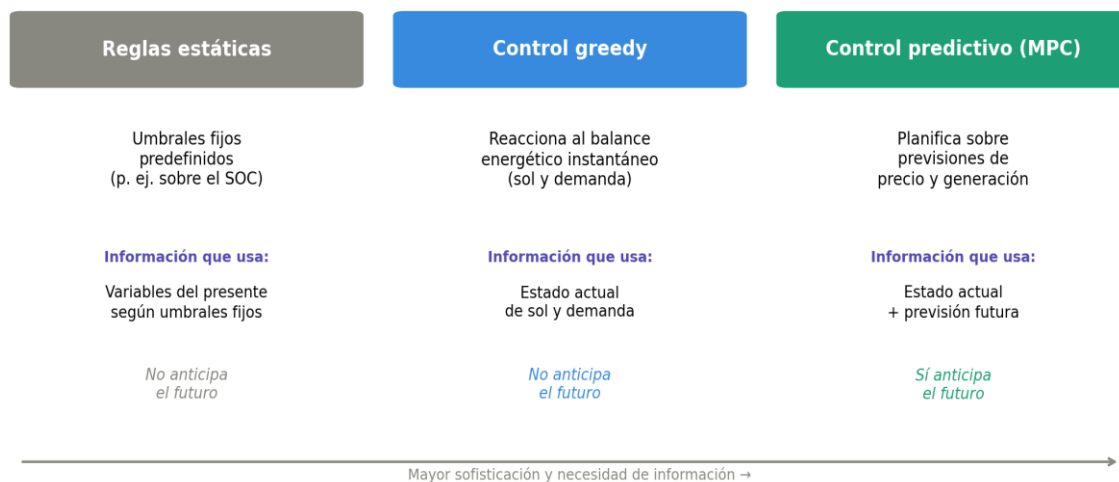


Figura 2.2 Familias de estrategias de control de baterías

2.5 OPTIMIZACIÓN MATEMÁTICA EN LA GESTIÓN ENERGÉTICA

El problema de decidir los flujos de energía de una instalación para minimizar su coste encaja de forma natural en el marco de la optimización matemática. En más detalle, cuando todas las relaciones del sistema (balances de energía, límites de potencia, capacidad de la batería) pueden expresarse mediante ecuaciones e inecuaciones lineales, el problema se formula como un LP,

una de las clases de problemas de optimización mejor estudiadas y para las que existen algoritmos de resolución muy eficientes [16], [17]. Si además se necesitan variables que solo puedan tomar valores enteros o binarios (por ejemplo, para representar el encendido o apagado de un equipo), el problema pasa a ser de MILP que es computacionalmente más costoso y pesado.

La aplicación de estas técnicas a la gestión de baterías está documentada por Ratnam et al [18]. Se plantea un enfoque basado en optimización para programar el almacenamiento de una batería con paneles de energía fotovoltaica, evaluándolo sobre datos reales de clientes residenciales y demostrando el beneficio económico que aporta frente a una operación sin optimizar. Con un trabajo muy parecido al mencionado, Bean y Khan [19] formulan la programación de la batería como un problema lineal sobre un horizonte de veinticuatro horas, empleando predicciones de generación y consumo, y concluyen que, según la tarifa, se pueden prever ahorros de entre el 1 % y el 10 % frente al modo de funcionamiento automático del inversor. Estos antecedentes confirman que la programación lineal es una herramienta adecuada y contrastada para este tipo de problema y sitúan el orden de magnitud del ahorro que se puede esperar.

2.6 POSICIONAMIENTO DEL TRABAJO

Vistas las varias alternativas, conviene justificar la elección metodológica de este trabajo. Se ha optado por la programación lineal por varias razones. La primera es que el problema planteado es lineal por naturaleza: como se verá en la metodología, todas las restricciones del sistema pueden escribirse de forma lineal sin necesidad de variables enteras, de modo que un LP basta y es innecesario recurrir a un MILP más caro y complejo. La segunda es que el LP garantiza encontrar el óptimo global de forma exacta y en un tiempo de cálculo muy reducido, lo que permite resolver el problema repetidamente sobre todo un año de datos, haciendo más sencillo también ejecutar el análisis de sensibilidad.

Frente al MPC, la programación lineal empleada aquí con conocimiento perfecto de los datos persigue un objetivo distinto y complementario. No se trata de proponer un controlador implementable en tiempo real, sino de establecer el techo de ahorro alcanzable para así

encontrar la referencia absoluta contra la que medir cualquier estrategia. Una vez fijado ese techo, el propio modelo se adapta para operar con información limitada a veinticuatro horas lo que sí permite desarrollar una estrategia realista y comparable a la que implementaría un controlador práctico. Se descartan finalmente enfoques basados en aprendizaje por refuerzo ya que, aunque son muy potentes, requieren grandes volúmenes de datos de entrenamiento y ofrecen soluciones más difíciles de interpretar, lo que aleja estos enfoques del objetivo de claridad y defensa que persigue este trabajo.

Capítulo 3. METODOLOGÍA

Este capítulo describe cómo se ha abordado el problema, desde descubrir los detalles de la instalación física hasta el modelo matemático que la representa. Se presenta primero el sistema real y los datos de los que se parte, después la forma en que se han tratado esos datos, los escenarios que se van a comparar y finalmente, como núcleo del capítulo, la formulación del modelo de optimización y su implementación en código. Se termina explicando cómo se ha construido el escenario de proyección a 2026 y la adaptación del modelo para operar con información limitada y con la incertidumbre introducida por el escenario desconocido de 2026.

3.1 DESCRIPCIÓN DE LA INSTALACIÓN

La instalación que se estudia corresponde a una vivienda situada en Madrid, habitada por una familia. Cuenta con paneles fotovoltaicos, una batería de litio de 3 kWh de capacidad útil y un inversor híbrido de 3 kW que gestiona los flujos de energía entre los paneles, la batería, la vivienda y la red eléctrica.

El funcionamiento de este conjunto puede entenderse a partir de los flujos de energía posibles en cada instante. La energía generada por los paneles puede destinarse a tres usos: alimentar directamente el consumo de la vivienda, cargar la batería o verse a la red. La demanda de la vivienda, por su parte, puede cubrirse desde tres orígenes: la propia generación solar, la descarga de la batería o la compra a la red. Finalmente, la batería puede cargarse tanto con excedente solar generado por los paneles como con energía de la red. La Figura 3.1 representa estos flujos de forma esquemática.




Figura 3.1 Esquema de los flujos de energía de la instalación

Estos flujos no son independientes entre sí, sino que dependen uno del otro y están sujetos a una serie de restricciones físicas conocidas: la energía debe conservarse en todo momento, y la batería no puede almacenar más de su capacidad ni cargarse o descargarse a una potencia superior a la del inversor. La traducción de estas restricciones a ecuaciones, que constituye el modelo de programación lineal mencionado, se detalla más adelante en este capítulo.

3.2 ADQUISICIÓN Y TRATAMIENTO DE DATOS

3.2.1 FUENTES DE DATOS

El trabajo se basa en dos tipos de datos. Por un lado, los registros de funcionamiento de la instalación durante el año 2025, obtenidos del propio inversor de la vivienda y que proporcionan el comportamiento real del sistema hora a hora. Por otro lado, se obtienen los precios de la electricidad, descargados de la plataforma ESIOS de Red Eléctrica de España, que publica tanto el precio del PVPC como el precio de compensación de los excedentes. Estos precios se publican con un día de antelación, lo que resulta relevante para el modelo de gestión de 2026, pero esto no es importante para la creación del modelo optimizador ya que se descargan los datos del último año trabajando a posteriori, con información conocida por completo.

3.2.2 VARIABLES ORIGINALES Y DERIVADAS

Los registros del inversor proporcionan cinco magnitudes horarias: la producción de los paneles, la energía con la que la batería se carga desde los paneles, la energía con la que la batería se carga desde la red, la energía que la batería descarga para el consumo y la energía consumida de la red. A partir de estas variables originales se derivan otras de mayor interés para el análisis mediante sumas y restas entre ellas. De aquí se obtienen variables como la demanda total de la vivienda, el estado de carga de la batería en cada momento o la energía vertida a la red además de otras más específicas que son significativas para otros casos que se estudiarán también como se verá más adelante.

Tabla 3.1 Variables registradas y derivadas empleadas en el análisis

<i>Variables originales registradas por el inversor</i>		
Variable	Unidad	Descripción
Producción paneles	kWh	Energía generada por los paneles fotovoltaicos
Batería carga de paneles	kWh	Energía con la que la batería se carga desde los paneles
Batería descarga en consumo	kWh	Energía que la batería entrega al consumo de la vivienda
Batería carga de red	kWh	Energía con la que la batería se carga desde la red
Consumo de red	kWh	Energía total importada de la red

Variables derivadas y datos de mercado

Variable	Unidad	Descripción
Demanda real	kWh	Consumo total de la vivienda, reconstruido por balance energético
Estado de la batería (SOC)	kWh	Energía almacenada en la batería al final de cada hora
Vertido	kWh	Energía excedente inyectada a la red
Precio de consumo (PVPC)	€/kWh	Precio horario de compra de la energía (ESIOS)
Precio de vertido	€/kWh	Precio horario de compensación de los excedentes (ESIOS)

3.2.3 ANÁLISIS DE COHERENCIA DE LOS DATOS

La columna de datos de la demanda no procede de una medición independiente, sino que se reconstruye por balance energético a partir de los flujos del sistema. Es la suma de las aportaciones de los paneles, la batería y la red al consumo. Esto implica que no es posible separar el consumo neto de la vivienda de las posibles pérdidas del sistema de almacenamiento. Esta observación tiene consecuencias sobre el tratamiento de la eficiencia de la batería, que se discutirá con más detalle en el apartado 3.5.

En la parte 1 del proyecto en la cual se hacía un análisis y tratamiento de los datos con las variables vistas en el apartado 3.2.3, se constató que la energía vertida a la red durante 2025 fue nula. El inversor real no inyectó excedentes a la red a lo largo del año, lo que probablemente se atribuya a su configuración, aunque también resulta coherente con el dimensionado de la instalación: la demanda anual (2400kWh) es muy superior a la generación solar (1297kWh) por

lo que es razonable que la mayoría se consuma o se almacene y que por lo tanto no hubiera suficiente energía sobrante como para verter a red por lo que esta opción también es posible. Sin tener la respuesta a esto, en este proyecto se asumirá que es posible verter a red, es decir, que no habrá un impedimento en la configuración del inversor.

3.3 DEFINICIÓN DE LOS ESCENARIOS DE COMPARACIÓN

Para aislar y cuantificar la contribución de cada elemento del sistema al ahorro y por lo tanto poder verificar su necesidad, se definen cuatro escenarios de operación que comparten los mismos datos de demanda, generación y precios, pero difieren en los recursos disponibles y en la forma de gestionarlos.

El escenario A (también mencionado como caso base) representa la vivienda sin instalación fotovoltaica ni batería, que por lo tanto cubre toda su demanda comprando energía directamente desde la red. Es la referencia frente a la que se mide el ahorro total que aporta la instalación y también la que lógicamente tiene los costes energéticos más elevados al no tener ni batería para almacenar energía ni paneles para generarla.

El escenario B incorpora solamente los paneles solares. La generación solar se emplea para cubrir la demanda instantánea ya que no puede almacenarla, y el excedente se vierte a la red. Permite cuantificar el ahorro que aporta la fotovoltaica por sí sola, sin almacenamiento.

El escenario C corresponde al funcionamiento real de la instalación completa (paneles más batería) tal y como lo gestiona el inversor comercial. Se construye directamente a partir de los datos medidos en 2025, por lo que refleja el comportamiento de una estrategia de control real. Es un escenario muy importante ya que permite poder analizar si la inversión de implementar la nueva estrategia de control desarrollada sería rentable.

El escenario D es el modelo de optimización desarrollado en este trabajo, que determina la gestión económicamente óptima de los mismos recursos que el escenario C. Como se ha mencionado, la comparación entre C y D es el núcleo del trabajo, ya que mide cuánto se puede

mejorar la gestión de la energía de la estrategia optimizada respecto a la real mediante una toma de decisiones óptima.

Toda esta información se recoge con mayor brevedad en la Tabla 3.2.

Tabla 3.2 Definición de los escenarios de comparación

<i>Escenario</i>	<i>Recursos Disponibles</i>	<i>Gestión</i>	<i>Disponible en</i>
A – Caso Base	Solo red	Toda la demanda se compra a la red	2025/2026
B – Solo paneles	Paneles + red	Autoconsumo instantáneo, excedente vertido a la red	2025/2026
C – Inversor real	Paneles + batería + red	Gestión real del inversor comercial	2025
D – Optimización	Paneles + batería + red	Gestión óptima mediante programación lineal	2025/2026

3.3.1 EL ESCENARIO C: COMPORTAMIENTO DEL INVERSOR REAL

El escenario C merece una descripción más detallada, por ser la referencia realista contra la que se compara el modelo. Su comportamiento se ha obtenido a partir de los datos registrados, sin realmente conocer la lógica interna de control programada por el fabricante, de ahí la importancia del análisis de datos inicial que se tuvo que hacer. De estos datos se desprende que el inversor prioriza el autoconsumo y emplea la batería de forma activa, pero se ve algo interesante: una parte importante de la energía con la que carga la batería procede de la red y no del excedente solar. Se trata de 721 kWh cargados desde la red frente a 446 kWh cargados desde el excedente solar, por lo que aproximadamente el 60 % de la energía que entra en la batería procede de la red. Esta forma de actuar consiste en almacenar energía de red en

determinados momentos para emplearla más tarde en el consumo, así aprovechando las diferencias horarias de precio. El modelo de optimización opera bajo este mismo principio, con la diferencia de que decide de forma óptima cuándo conviene cargar de la red. La única restricción que los separa, como se detalla más adelante, es que el modelo tiene prohibido verter a la red energía que no proceda de excedente solar real, lo que impide cualquier reventa especulativa.

3.4 FORMULACIÓN MATEMÁTICA DEL MODELO

Como ha sido mencionado previamente, el modelo de optimización se formula como un problema de programación lineal. El horizonte temporal se discretiza en intervalos de una hora y para cada hora el modelo decide cómo repartir la energía entre los distintos flujos posibles, con el objetivo de minimizar el coste total respetando las restricciones físicas y regulatorias del sistema. Para los próximos apartados, se usará la próxima notación de la Tabla 3.3.

Tabla 3.3 Notación del modelo de optimización

<i>Símbolo</i>	<i>Tipo</i>	<i>Unidad</i>	<i>Descripción</i>
D_t	Parámetro	kWh	Demanda de la vivienda en la hora t
G_t	Parámetro	kWh	Generación solar en la hora t
c_t	Parámetro	€/kWh	Precio de compra de la energía
v_t	Parámetro	€/kWh	Precio de compensación de excedentes
η	Parámetro	-	Eficiencia de la batería
P	Parámetro	kW	Potencia nominal del inversor
C	Parámetro	kWh	Capacidad útil de la batería

x_t^{SH}	Variable	kWh	Energía de los paneles al hogar
x_t^{SB}	Variable	kWh	Energía de los paneles a la batería
x_t^{SR}	Variable	kWh	Energía de los paneles a la red (vertido)
x_t^{RH}	Variable	kWh	Energía de la red al hogar
x_t^{RB}	Variable	kWh	Energía de la red a la batería
x_t^{BH}	Variable	kWh	Energía de la batería al hogar
S_t	Variable	kWh	Estado de carga de la batería al final de la hora t

3.4.1 CONJUNTOS, PARÁMETROS Y VARIABLES DE DECISIÓN

El modelo se define sobre un conjunto de instantes temporales, indexados por la hora t , que abarca todo el periodo de estudio que en este caso es un año, 2025. Para cada hora se conocen cuatro parámetros, que constituyen los datos de entrada del problema: la demanda de la vivienda, la generación solar, el precio de compra de la energía y el precio de compensación de los excedentes.

Las decisiones del modelo se representan mediante seis variables de flujo de la energía, todas ellas no negativas y expresadas en kWh, que describen el reparto de la energía en cada hora. Estas variables son:

- la energía de los paneles que se destina directamente al hogar
- la energía de los paneles que carga la batería
- la energía de los paneles que se vierte a la red

- la energía de la red que se destina al hogar
- la energía de la red que carga la batería
- la energía que la batería descarga para el hogar

Estas variables corresponden a las flechas de la Figura 3.1 al tratarse de los flujos de energía.

A estas se añade una séptima variable, el estado de carga de la batería (SOC, del inglés State of Charge), que representa la energía almacenada en la batería al final de cada hora y está acotada entre cero y la capacidad de la batería, por lo que 3kWh. Esta variable es una consecuencia de la optimización de la función objetivo y por lo tanto de las variables de decisión por lo que se le denomina variable de estado. Pese a estar acotada y tener límites, su valor no se decide libremente, sino que es la respuesta matemática a las ecuaciones de balance y las restricciones.

3.4.2 FUNCIÓN OBJETIVO

El objetivo del modelo es minimizar el coste neto de la energía a lo largo de todo el año. Este coste se compone del gasto en la energía comprada a la red (tanto la destinada al hogar como la que carga la batería), del que se resta el ingreso por la energía vertida a la red. Formalmente, la función objetivo es:

$$\min \sum_{t=1}^{8760} (x_t^{RH} + x_t^{RB}) * c_t - x_t^{SR} * v_t \quad (3.1)$$

A esta expresión se añaden dos términos de magnitud insignificante, que no se incluyen en la formulación matemática por carecer de significado económico. Sus valores son tan pequeños (del orden de 10^{-6}) que no alteran ni un solo decimal del coste obtenido. Su única función es servir de criterio de desempate: al tratarse de términos que el optimizador también busca minimizar, inclinan la solución, entre todas las de igual coste, hacia la más natural y físicamente coherente.

El primero es un término negativo que penaliza mínimamente el uso de la energía solar para el autoconsumo directo, lo que, al ser un ahorro ínfimo, lleva al modelo a priorizar ese flujo. El

segundo es un término positivo que penaliza mínimamente la descarga de la batería, evitando que el modelo la utilice cuando no es necesario. La razón de incluirlos es que, al modelar con eficiencia unitaria (por estar las pérdidas ya incluidas en los datos, como se explica en el apartado 3.5), no existe ninguna penalización económica que impida mover energía de forma superflua entre los distintos elementos. Sin estos términos, el modelo realizaba movimientos sin sentido físico que no modificaban el coste pero que en la práctica desgastarían los componentes y aumentarían las pérdidas, como por ejemplo enviar energía de los paneles a la batería y, en esa misma hora, descargar esa misma cantidad de la batería al hogar, en lugar de alimentar el hogar directamente desde los paneles. Con esta minúscula penalización, que nunca llega a pesar en la toma de decisiones económicas del modelo por ser de orden 10^{-6} , se consigue que la solución sea físicamente coherente y que no se produzcan cargas y descargas simultáneas de la batería.

3.4.3 RESTRICCIONES

El modelo está sujeto a un conjunto de restricciones que garantizan la coherencia física del sistema y el cumplimiento de las normativas. Se deben de cumplir para cada hora t del periodo.

La primera es la ecuación de balance de la vivienda: en cada hora, la suma de la energía que llega al hogar desde los paneles, desde la red y desde la batería debe igualar exactamente la demanda.

$$x_t^{SH} + x_t^{RH} + x_t^{BH} = D_t \quad (3.2)$$

La segunda es el balance de los paneles: toda la energía generada por los paneles en cada hora debe repartirse entre el consumo de la vivienda, la carga de la batería y el vertido a la red.

$$x_t^{SH} + x_t^{SB} + x_t^{SR} = G_t \quad (3.3)$$

La tercera restricción es el balance del estado de carga de la batería, que relaciona el SOC de una hora con el de la hora anterior. El nuevo estado de carga es igual al anterior más la energía cargada (desde paneles y desde red) menos la energía descargada de la batería.

$$s_t = s_{t-1} + (x_t^{SB} + x_t^{RB}) * \eta - \frac{x_t^{BH}}{\eta} \quad (3.4)$$

La cuarta y la quinta son los límites de potencia del inversor: ni la potencia de carga (suma de las dos vías de carga) ni la de descarga pueden superar los 3 kW que admite el equipo en una hora.

$$x_t^{SB} + x_t^{RB} \leq P \quad (3.5)$$

$$x_t^{BH} \leq P \quad (3.6)$$

La sexta es el límite de capacidad de la batería, que obliga al estado de carga a mantenerse entre cero y los 3 kWh de capacidad útil.

$$0 \leq s_t \leq P \quad (3.7)$$

La séptima restricción es la que se ha llamado restricción antifraude y es clave en el planteamiento del trabajo. Esta restricción limita la energía vertida a la red en cada hora al excedente solar físico real, es decir, a la diferencia entre la generación solar y la demanda cuando esta es positiva. Es tan importante porque impide que el modelo compre energía barata de la red, la almacene y la vierta después a un precio mayor. Tampoco puede descargar la batería directamente a la red. De este modo se garantiza que toda inyección a la red proceda exclusivamente de generación solar sobrante, en coherencia con la normativa de la regulación de autoconsumo donde solamente el excedente solar real pueda verterse.

$$x_t^{SR} \leq \max(0, G_t - D_t) \quad (3.8)$$

Por supuesto, la octava y última restricción es la más común en problemas de optimización de programación lineal en la cual todas las variables de decisión son no negativas. Si pudieran ser negativas, el solver encontraría soluciones mejoradas con valores negativos, pero esto no tendría sentido físico ya que, si consideramos que las variables son los flujos de un sitio a otro, por ejemplo, de los paneles al hogar, no tiene sentido un valor negativo ya que indicaría un flujo de energía desde la demanda de la casa a los paneles.

$$x_t^{SH}, x_t^{SB}, x_t^{SR}, x_t^{RH}, x_t^{RB}, x_t^{BH} \geq 0 \quad (3.9)$$

3.4.4 NATURALEZA DEL PROBLEMA: UN PROBLEMA LINEAL

Como puede verse en todas las relaciones del modelo (desde la función objetivo hasta las ocho restricciones), estas son lineales y todas las variables son continuas. El problema es, por tanto, un programa lineal puro, y no requiere variables enteras ni binarias por lo que se puede correctamente reducir el coste computacional del proyecto utilizando LP en vez de MILP y también el solver GLPK de pyomo que se explicará posteriormente utilizado para problemas lineales en vez de uno capaz de resolver problemas no lineales también.

Esto no es evidente a primera vista. Podría pensarse que hace falta una variable binaria para impedir que la batería se cargue y se descargue simultáneamente en la misma hora, algo que no tendría sentido físico. Sin embargo, esa situación nunca se produce en la solución óptima. Cuando la eficiencia es inferior a la unidad, cargar y descargar a la vez genera pérdidas, de modo que el propio criterio de minimización de coste la descarta sin necesidad de forzarla con una restricción adicional. En el caso de eficiencia unitaria, en el que ese movimiento simultáneo resultaría indiferente en términos de coste, son los pequeños términos de desempate introducidos en la función objetivo, comentados en el apartado 3.4.2, los que lo eliminan. Al penalizar de forma insignificante la descarga superflua de la batería, garantizan que, entre todas las soluciones de igual coste, el modelo seleccione siempre la que no carga y descarga a la vez. De este modo la condición queda asegurada en cualquier caso sin recurrir a variables binarias, lo que se ha verificado comprobando que la solución resultante no contiene ninguna hora con carga y descarga simultáneas. El hecho de que el problema sea un programa lineal y no uno entero mixto es una ventaja, ya que garantiza encontrar el óptimo global de forma exacta sin necesitar un tiempo de cálculo elevado.

3.5 TRATAMIENTO DE LA EFICIENCIA DE LA BATERÍA

Un aspecto que requiere justificación y atención es el tratamiento de la eficiencia de la batería. En el modelo, el balance del estado de carga se ha planteado con una eficiencia unitaria, es

decir, sin aplicar un factor de pérdidas en la carga y descarga. Esta decisión, que podría parecer una simplificación excesiva, responde en realidad a la naturaleza de los datos disponibles.

Como se señaló en el apartado 3.2.3, los registros del inversor no permiten contabilizar las pérdidas energéticas internas por lo que el balance global entre la energía que entra (solar y red) y la que sale (demanda, vertido y variación del estado de carga) se cumple sin un término residual de pérdidas. Esto puede deberse a que las mediciones se realizan en los bornes de corriente alterna del inversor, donde las pérdidas internas de conversión y de la propia batería no se pueden medir ni observar. Aplicando las ecuaciones de balance de energía vistas en el apartado 3.4.3, los datos cuadran perfectamente lo que nos indica que las pérdidas deben efectivamente estar ya incluidas, sin capacidad de determinarlas. Estas pérdidas se incluyen en el valor de demanda al ser esta una suma de los flujos que llegan al hogar por lo que las pérdidas en el resto de los componentes se verán reflejadas en la llegada al hogar y ese es el valor obtenido como demanda. Por lo tanto, se concluye que las pérdidas ya están implícitamente integradas en la demanda efectiva con la que trabaja el modelo y por lo tanto la optimización se realiza de esta misma forma.

En estas condiciones, aplicar un factor de eficiencia inferior a uno supondría contabilizar las pérdidas dos veces. Además, dado que tanto el escenario real (C) como el modelo de optimización (D) operan sobre esa misma demanda efectiva, la comparación entre ambos es coherente precisamente bajo el supuesto de eficiencia unitaria. No obstante, el efecto que tendría una eficiencia de batería menor sobre los resultados se examina de forma específica en el análisis de sensibilidad del apartado 4.5, donde se interpreta como una cota inferior del ahorro esperable.

3.6 IMPLEMENTACIÓN COMPUTACIONAL

El modelo se ha implementado en Python. El tratamiento y la depuración de los datos se realizaron con la librería pandas, mientras que la formulación del problema de optimización se llevó a cabo con Pyomo, que es una librería de modelado algebraico que permite expresar el problema de sencilla a su formulación matemática [20]. La resolución se hizo mediante el solver

GLPK, un motor de optimización de código abierto especializado en problemas lineales, que es suficiente para el problema de este proyecto [21]. Todo el desarrollo se ejecutó en el entorno Google Colab, lo que facilitó el acceso a los datos y la reproducibilidad de los cálculos.

La elección de estas herramientas responde a la familiarización del autor con ellas durante su año de intercambio en la Universidad de Michigan, donde se emplearon y se mostraron como una de las mejores opciones para la resolución de problemas de optimización. Partiendo del conocimiento previo de Python, su potencia se extrapola de forma natural a Pyomo, una librería a la vez potente, específicamente adaptada a este tipo de problemas y, al mismo tiempo, sencilla de comprender y utilizar.

La implementación se realizó de forma incremental para verificar su correcto funcionamiento, es decir, primero se resolvió un único día de 24 horas en el que se comprobó que todos los resultados fueran coherentes y reflejaran lo que se busca conseguir. Después un mes completo y finalmente el año entero, comprobando en cada paso la coherencia de los resultados antes de pasar a una escala mayor. Es aquí cuando se detectó el error mencionado sobre que a veces lo generado por paneles lo mandaba a la batería y usaba cierta cantidad de la batería para abastecer la demanda. Este funcionamiento por lo tanto fue corregido mediante el valor insignificante incluido en la función objetivo comentada en el apartado 3.4.2.

3.7 DEL TECHO TEÓRICO AL MODELO REALISTA

El modelo descrito hasta ahora, cuando se aplica sobre el año completo de 2025, dispone de conocimiento perfecto de todos los precios y de toda la generación del año. Resuelve, por tanto, un problema en el que el futuro es completamente conocido. El resultado de esta optimización constituye el techo de ahorro al ser este el mejor resultado posible, que ninguna estrategia real podría superar, pero que tampoco es alcanzable en la práctica ni real, ya que es imposible conocer con un año de antelación los precios ni la meteorología.

Para obtener una estrategia realista y operable se ha adaptado el modelo a un esquema de horizonte deslizante (rolling horizon). En lugar de optimizar todo el año a la vez, el problema

se resuelve día a día, empleando únicamente la información disponible para cada día siguiente ya que los precios del día siguiente se conocen con antelación y la generación esperada la hemos obtenido usando la herramienta de PVGIS que se comentará en el próximo apartado. El estado de carga de la batería al final de cada día se traslada como condición inicial del día siguiente, encadenando así las decisiones a lo largo del tiempo.

Esta versión del modelo reproduce las condiciones en las que operaría un controlador real, que debe decidir sin conocer lo que ocurrirá pasado el horizonte de planificación que son las próximas 24 horas. La comparación entre el resultado del horizonte deslizante y el techo teórico permite cuantificar cuánto se pierde por no disponer de información perfecta del futuro y constituye por tanto una de las validaciones centrales del trabajo, ya que indicará si puede ser rentable o no en caso de que diera peores resultados que el funcionamiento actual del inversor (caso C).

3.8 CONSTRUCCIÓN DEL ESCENARIO 2026

Como extensión del proyecto inicial de TFG propuesto, se ha construido un escenario de proyección para el año 2026 para evaluar cómo funciona el modelo construido con información desconocida. Al no disponer de datos reales de ese año, se ha generado un año sintético combinando tres fuentes.

La demanda de 2026 se ha obtenido a partir de la demanda real de 2025 mediante un desplazamiento de calendario, una técnica en la que se reasigna cada día de 2025 a la fecha de 2026 que le corresponde respetando el día de la semana, de modo que un lunes se empareja con un lunes y un domingo con un domingo. El procedimiento preserva también los días festivos, emparejando cada festivo de 2026 con su equivalente de 2025, y contempla los cambios de hora de marzo y octubre, ajustando los días afectados a 23 y 25 horas respectivamente. De este modo, la demanda de 2026 conserva la estructura semanal y estacional del consumo real sin ser una copia exacta. Se quiere esto ya que no se consume lo mismo un lunes que un sábado o que un día festivo y por lo tanto hay que tratar de mantener estos números lo más parecidos posible.

La generación solar de 2026 se ha obtenido de PVGIS (Photovoltaic Geographical Information System), una herramienta de la Comisión Europea que proporciona datos de generación fotovoltaica a partir de registros históricos de irradiación [7]. Para la ubicación de la instalación en Madrid se descargó la generación horaria de siete años no bisiestos comprendidos entre 2015 y 2023 (exceptuando 2016 y 2020, y se calculó, para cada combinación de mes, día y hora, la generación media de esos años. El resultado es un perfil de generación correspondiente a un año meteorológicamente típico, siendo esto lo más aproximado que se puede conseguir pese a que hay incertidumbres cada día como las nubes, aunque si es común que haya en una época, están implícitamente incluidos en los días típicos.

PVGIS pide varios datos e información sobre la instalación fotovoltaica para poder predecir su generación en base a los datos meteorológicos lo cual es muy útil para directamente poder introducirlos en el Excel de datos. Al desconocer esta información de la instalación, se tuvo que estimar todos los parámetros basándose en los datos de 2025 como se recoge en la tabla 3.4. Ciertos detalles como a las horas que más generación hay nos dan información como el ángulo de inclinación, azimut, etc, que al analizar los datos se puede estimar de forma precisa que serán 30° de inclinación y orientación sur al ser la ratio de generación junio/diciembre de 2.19 que corresponde con estos datos, validados por una propia funcionalidad de PVGIS llamada ‘optimizar inclinación y azimut’. La potencia máxima de 0,8455 kWh permite estimar una potencia pico de 1kW. Se conoce que la instalación está en Madrid por lo que se obtienen coordenadas de algún lugar en el centro de Madrid. En cuanto a la tecnología se asume silicio cristalino por ser el más común del mercado en instalaciones residenciales siendo el 95% de las placas de este tipo [22]. En cuanto al tipo, lo más común en España es tener paneles fijos en la cubierta de la vivienda por lo que se ha asumido esto. En cuanto a pérdidas se han estimado un 15% que es lo común para este tipo de placas siendo este el valor propuesto por PVGIS.

Tanto la construcción de la demanda mediante desplazamiento de calendario como la obtención de la generación solar a partir de PVGIS se implementaron mediante sendos scripts en Python, cuyo código se recoge en el Anexo II.

Tabla 3.4 Parámetros de configuración de PVGIS para la generación del año sintético 2026

<i>Parámetro</i>	<i>Valor</i>
Base de datos de radiación	PVGIS-SARAH3 (datos de satélite Meteosat)
Años utilizados	2015, 2017, 2018, 2019, 2021, 2022 y 2023
Criterio de exclusión	Se excluyen 2016 y 2020 por ser bisiestos
Método de síntesis	Media aritmética hora a hora para cada combinación de mes, día y hora
Latitud / longitud	40,413° N / -3,682° E (Madrid)
Potencia pico instalada	1,0 kWp
Tecnología fotovoltaica	Silicio cristalino
Tipo de montaje	Fijo sobre cubierta
Inclinación	30°
Azimut	0° (orientación sur)
Pérdidas del sistema	15 %

Conviene señalar que la generación así obtenida resulta superior a la registrada en 2025. Esto no se debe a un error, sino al hecho de que estos datos son solo estimaciones. Lo importante es tener datos de irradiación distintos y ver cómo se comporta el modelo ante ellos para observar su adaptabilidad. Esta diferencia debe tenerse en cuenta al comparar los resultados de ambos años, como se discute en el apartado correspondiente.

Por último, los precios de compra y de compensación de 2026 se han tomado de los valores reales publicados por ESIOS para ese año, incorporándose día a día a medida que se publican. El escenario de 2026 presenta una particularidad respecto al de 2025: al tratarse de un año sin datos reales del inversor, no existe en él el escenario C, de modo que la comparación se establece únicamente entre el caso base (A), la instalación sin batería (B) y el modelo optimizado (D). Además, al estar en junio, la evaluación de 2026 se hará para los primeros meses (exactamente del 1 de enero al 11 junio incluidos).

Capítulo 4. ANÁLISIS DE RESULTADOS

Ahora, se presentarán y analizarán los resultados obtenidos. Se comienza caracterizando los datos reales de 2025, sobre los que se sustenta todo el análisis. A continuación, se comparan económicamente los cuatro escenarios, se examina el comportamiento del modelo a lo largo de días concretos, se valida la versión realista del modelo frente al techo teórico y se estudia la sensibilidad del modelo a sus principales parámetros. Por último, se presentan los resultados de la proyección a 2026 y el estudio económico de viabilidad.

4.1 CARACTERIZACIÓN DE LOS DATOS DE 2025

Antes de evaluar el modelo conviene describir los datos de partida. A lo largo de 2025 la vivienda consumió 2.400,2 kWh, mientras que los paneles generaron 1.297,1 kWh. La generación, por tanto, cubre algo más de la mitad del consumo anual, por lo que la demanda supera con holgura a la producción propia. Este desequilibrio es relevante porque condiciona los resultados: al haber poco excedente de generación en paneles, la mayor parte del valor del sistema procede de un buen aprovechamiento de la energía generada y almacenada, y no de la venta a la red, aumentando por lo tanto la importancia de tener un inversor optimizado.

El perfil de consumo y generación a lo largo del día muestra el clásico desajuste temporal que justifica el uso de baterías, el elemento más útil que, utilizado correctamente, permite no tener que comprar energía cara. La Figura 4.1 representa el perfil horario medio de ambas magnitudes. La generación se concentra en las horas centrales del día, con un máximo en torno al mediodía (en condiciones climáticas normales, a las 13:00¹), mientras que la demanda presenta sus picos a primera hora de la mañana y, sobre todo, durante la tarde y la noche. La

¹ Los datos proporcionados de 2025 no incluyen referencia horaria por lo que se asume que corresponden a horario español (UTC+1 en invierno y UTC+2 en verano)

energía solar, por tanto, rara vez coincide con el momento en que más se necesita justificando por tanto de nuevo el uso de baterías.

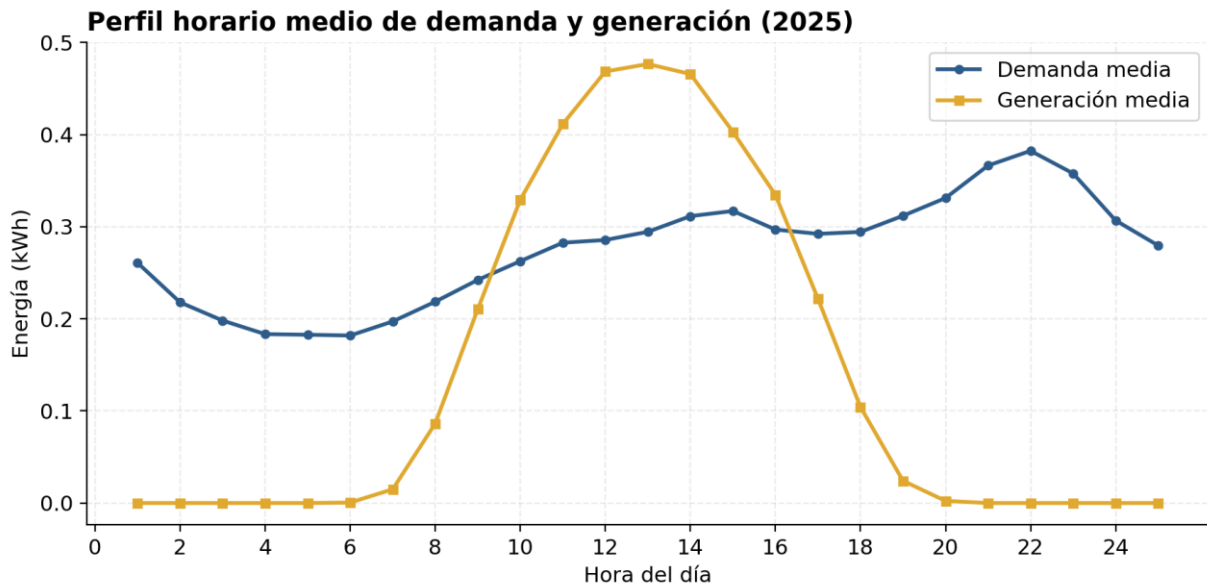


Figura 4.1 Perfil horario medio de demanda y generación en 2025

La distribución mensual de la generación, recogida en la Figura 4.2 evidencia su fuerte estacionalidad. Como se podría prever, los meses de verano producen más del triple de energía solar que los de invierno, pasando de unos 46 kWh en enero a 157 kWh en julio. El resultado es que en invierno la cobertura solar es mínima y la dependencia de la red máxima. La demanda, por su parte, presenta un reparto mensual prácticamente uniforme (en torno a 200 kWh cada mes), posiblemente consecuencia de la forma en que fue reconstruida a partir de los registros del sistema y por este motivo no se representa su distribución mensual ya que no aportaría información relevante. La figura se trata de una distribución casi perfectamente normal.




Figura 4.2 Generación solar mensual en 2025

En cuanto a los precios, el PVPC presentó en 2025 un valor medio de 0,136 €/kWh, pero con bastante variabilidad. El precio horario osciló entre un mínimo de 0,021 €/kWh y un máximo de 0,423 €/kWh. Esta diferencia, superior a un factor de veinte entre las horas más baratas y las más caras, es precisamente la palanca que el modelo de optimización aprovecha para reducir el coste. Supondría un ahorro enorme (del 95% aproximadamente) la diferencia entre comprar cerca del mínimo o cerca del máximo.

4.2 COMPARATIVA ECONÓMICA ANUAL DE ESCENARIOS

El resultado central del trabajo es la comparación del coste anual de la energía en los cuatro escenarios definidos. La Tabla 4.1 recoge estos costes para el año 2025, y la Figura 4.3 los representa gráficamente.

Tabla 4.1 Coste anual de la energía por escenario

<i>Escenario</i>	<i>Coste anual (€)</i>	<i>Ahorro frente a A</i>
A – Solo red	339,99	—
B – Solo paneles	229,74	32,4 %
C – Inversor real	118,14	65,3 %
D – Optimización	97,97	71,2 %

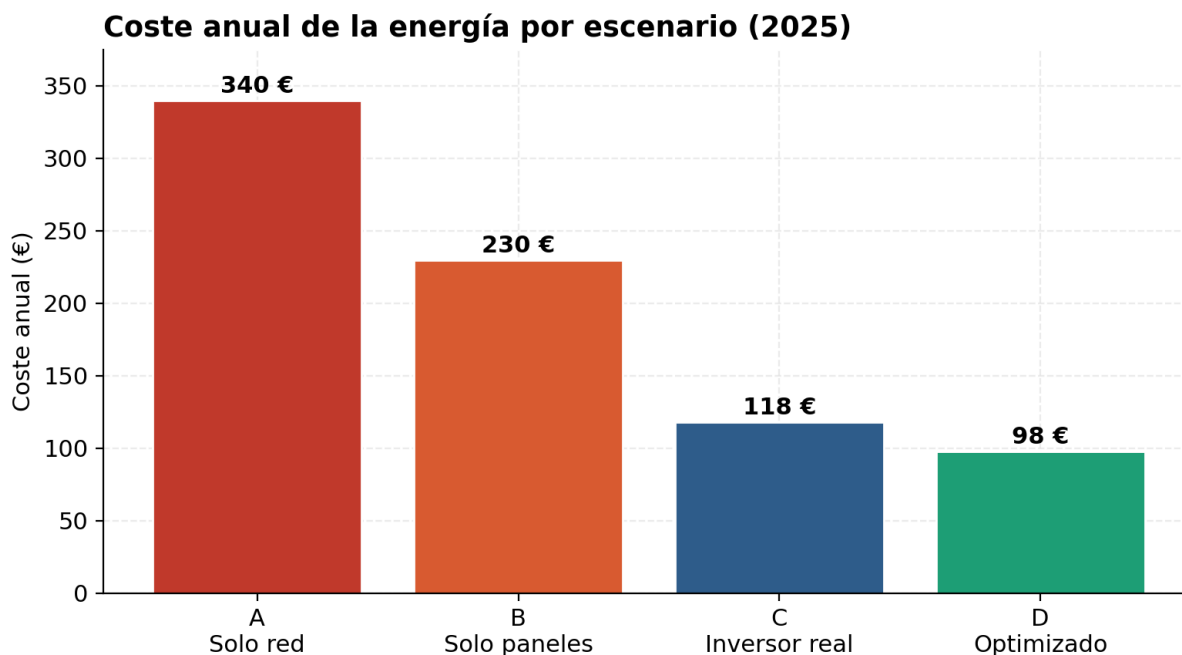


Figura 4.3 Coste anual de la energía por escenario (2025)

Los resultados muestran una progresión clara. La incorporación de los paneles (escenario B) reduce la factura en torno a un tercio respecto al caso base. La adición de la batería gestionada por el inversor comercial (escenario C) supone un salto mucho mayor, situando el coste en 118,14 € haciendo casi obligatorio tener estos dos elementos juntos en cualquier instalación de autoconsumo. Y el modelo de optimización (escenario D) alcanza los 97,97 €, lo que representa un ahorro adicional de 20,17 € anuales sobre el inversor real, equivalente a una mejora del 17,1 %. Aunque puede no parecer un salto tan grande como los que tenemos en los casos B y C, se trata de una mejora por pura optimización, ninguna incorporación de elementos ni nada similar, por lo que considerando que no habría casi costes de instalación para incorporar este caso D, una mejora de un casi 20% se convierte en un descuento muy atractivo para la factura anual de la luz.

Esta última cifra es la que responde a la pregunta que motiva este trabajo: una gestión óptima de la misma batería, con los mismos recursos, permite reducir la factura un 17 % adicional respecto a lo que consigue el inversor comercial. Conviene matizar, no obstante, que este 17,1 % corresponde al techo teórico, obtenido con conocimiento perfecto del futuro. La versión

realista del modelo, evaluada más adelante, alcanza una mejora más modesta pero igualmente positiva.

4.2.1 VERIFICACIÓN DE LA COMPENSACIÓN SIMPLIFICADA MENSUAL

Como se anticipó en la metodología, el modelo trata el vertido hora a hora, mientras que la compensación simplificada opera con un saldo mensual que no puede ser negativo. Para comprobar que esta simplificación no altera los resultados, se calculó el saldo mes a mes del escenario óptimo, verificando si en algún mes el valor de los excedentes vertidos superaba al de la energía comprada.

El resultado es claro, en ningún mes de 2025 el vertido llegó a superar a las compras. El mes de mayor vertido fue junio, con apenas 0,68 € en excedentes frente a 4,49 € de compras. La diferencia entre aplicar o no el tope mensual de saldo no negativo es nulo. Esto confirma que, para esta instalación, el modelo horario y el modelo con compensación mensual son numéricamente idénticos, de modo que la simplificación queda justificada por los propios datos. Al verter solo 30 kWh en todo el año (un 2,3 % de la generación), el sistema nunca se acerca a la situación en que el tope tendría efecto por lo que esta restricción no es un impedimento para la instalación instalada, aunque podría serlo en caso de instalar más paneles o de mayor potencia.

4.3 ANÁLISIS DE COMPORTAMIENTO HORARIO

Los costes acumulados totales muestran cuánto ahorra el modelo al final de año, pero no cómo lo consigue. Para entenderlo conviene examinar su comportamiento a lo largo de días concretos. Se han seleccionado dos días representativos, uno de invierno y otro de verano, que ilustran las dos situaciones extremas de generación para entrar en detalle y ver la distribución de flujos horaria.

La Figura 4.4 muestra un día tipo de invierno. La generación solar es escasa y no basta para cubrir la demanda. Lo más significativo es la decisión que toma el modelo de madrugada donde en torno a las cinco de la mañana, cuando el precio toca su mínimo (0,035 €/kWh), carga la

batería por completo desde la red. Esa energía barata se reserva para las horas de la tarde y la noche, cuando el precio se dispara por encima de 0,27 €/kWh, momento en que la batería se descarga para cubrir la demanda y evitar comprar caro. Este comportamiento, imposible para un inversor reactivo que no anticipa los precios, es la fuente principal del ahorro del modelo y la que se está tratando de probar en este proyecto. Es interesante ver la correlación inversamente proporcional de precio y SOC batería, en la que se ve simplemente con mirar la figura que a medida que aumenta el precio, baja el SOC batería, indicando que se está haciendo uso de esta para evitar comprar caro. Se puede apreciar también que solamente a las 13h la generación es capaz de cubrir toda la demanda, las demás horas está obligado a comprar de red o usar de la

batería. La Tabla 4.2 recoge, hora a hora, la distribución completa de los flujos de ese mismo día, donde pueden consultarse los valores exactos de cada decisión.

Tabla 4.2 Distribución horaria de los flujos de energía en un día tipo de invierno (9 de enero de 2025)

Hora	Precio (€/kWh)	Gen. (kWh)	Dem. (kWh)	Sol → Hog.	Sol → Bat.	Sol → Red	Red → Hog.	Red → Bat.	Bat. → Hog.	SOC (kWh)
1	0.094	–	0.20	–	–	–	0.20	–	–	–
2	0.081	–	0.18	–	–	–	0.18	–	–	–
3	0.072	–	0.17	–	–	–	0.17	–	–	–
4	0.051	–	0.16	–	–	–	0.16	–	–	–
5	0.035	–	0.17	–	–	–	0.17	3.00	–	3.00
6	0.056	–	0.19	–	–	–	0.19	–	–	3.00
7	0.094	–	0.24	–	–	–	0.24	–	–	3.00
8	0.127	–	0.27	–	–	–	0.27	–	–	3.00
9	0.159	–	0.28	–	–	–	–	–	0.27	2.73
10	0.163	0.12	0.29	0.12	–	–	–	–	0.17	2.55
11	0.222	0.24	0.29	0.24	–	–	–	–	0.05	2.50
12	0.214	0.17	0.29	0.17	–	–	–	–	0.12	2.38
13	0.212	0.51	0.30	0.30	0.21	–	–	–	–	2.59
14	0.201	0.26	0.31	0.26	–	–	–	–	0.05	2.54
15	0.134	0.06	0.30	0.06	–	–	0.24	0.34	–	2.88
16	0.142	0.11	0.29	0.11	–	–	–	–	0.18	2.71
17	0.170	0.06	0.30	0.06	–	–	–	–	0.23	2.47
18	0.192	–	0.34	–	–	–	–	–	0.34	2.13
19	0.264	–	0.38	–	–	–	–	–	0.38	1.75
20	0.265	–	0.41	–	–	–	–	–	0.41	1.34
21	0.273	–	0.41	–	–	–	–	–	0.41	0.93
22	0.267	–	0.37	–	–	–	–	–	0.37	0.56
23	0.177	–	0.31	–	–	–	–	–	0.31	0.25
24	0.165	–	0.25	–	–	–	–	–	0.25	–




Figura 4.4 Día tipo de invierno: evolución del estado de carga, demanda, generación y precio

La Figura 4.5, en cambio, muestra un día tipo de verano. Aquí la situación es distinta, la generación solar es abundante y cubre buena parte de la demanda diurna. El modelo prioriza el autoconsumo directo, almacena el excedente solar en la batería y lo emplea durante la noche. La carga desde la red es mucho menor, porque la propia energía solar basta para llenar la batería. Se aprecia, así como el modelo adapta su estrategia a las condiciones de cada estación ya que en invierno explota las diferencias de precio cargando de red al necesitar de ella mientras que en verano maximiza el aprovechamiento del excedente solar. Entre el extra de generación y el aprovechamiento de las horas baratas se ve como los días de verano salen muy baratos al poder cargar la batería de manera casi gratuita y conseguir beneficios por vertimiento alguna vez. La Tabla 4.3 y muestra la distribución horaria de los flujos de este día de verano, donde se observa con detalle el vertido del excedente a las 09:00 (columna denominada Sol → Red) y la carga de la batería desde la red en los momentos de menor precio.

Tabla 4.3 Distribución horaria de los flujos de energía en un día tipo de verano (23 de julio de 2025)

Día tipo de verano (23 de julio de 2025)

Hora	Precio (€/kWh)	Gen. (kWh)	Dem. (kWh)	Sol → Hog.	Sol → Bat.	Sol → Red	Red → Hog.	Red → Bat.	Bat. → Hog.	SOC (kWh)
1	0.146	–	0.29	–	–	–	–	–	0.29	0.73
2	0.139	–	0.24	–	–	–	–	–	0.24	0.48
3	0.133	–	0.22	–	–	–	–	–	0.22	0.26
4	0.130	–	0.20	–	–	–	0.20	0.30	–	0.56
5	0.130	–	0.19	–	–	–	–	–	0.19	0.37
6	0.130	–	0.19	–	–	–	–	–	0.19	0.18
7	0.137	0.03	0.19	0.03	–	–	–	–	0.16	0.02
8	0.148	0.17	0.19	0.17	–	–	–	–	0.02	–
9	0.152	0.33	0.21	0.21	–	0.12	–	–	–	–
10	0.139	0.43	0.23	0.23	0.20	–	–	–	–	0.20
11	0.196	0.54	0.25	0.25	0.29	–	–	–	–	0.48
12	0.188	0.60	0.26	0.26	0.34	–	–	–	–	0.82
13	0.181	0.61	0.28	0.28	0.33	–	–	–	–	1.15
14	0.168	0.61	0.31	0.31	0.30	–	–	–	–	1.45
15	0.095	0.59	0.33	0.33	0.26	–	–	1.09	–	2.80
16	0.097	0.51	0.33	0.33	0.18	–	–	–	–	2.98
17	0.098	0.34	0.33	0.33	0.02	–	–	–	–	3.00
18	0.104	0.16	0.33	0.16	–	–	0.17	–	–	3.00
19	0.174	0.08	0.33	0.08	–	–	–	–	0.26	2.74
20	0.199	0.01	0.33	0.01	–	–	–	–	0.32	2.42
21	0.229	–	0.34	–	–	–	–	–	0.34	2.09
22	0.238	–	0.35	–	–	–	–	–	0.35	1.73
23	0.171	–	0.37	–	–	–	–	–	0.37	1.37
24	0.162	–	0.33	–	–	–	–	–	0.33	1.04

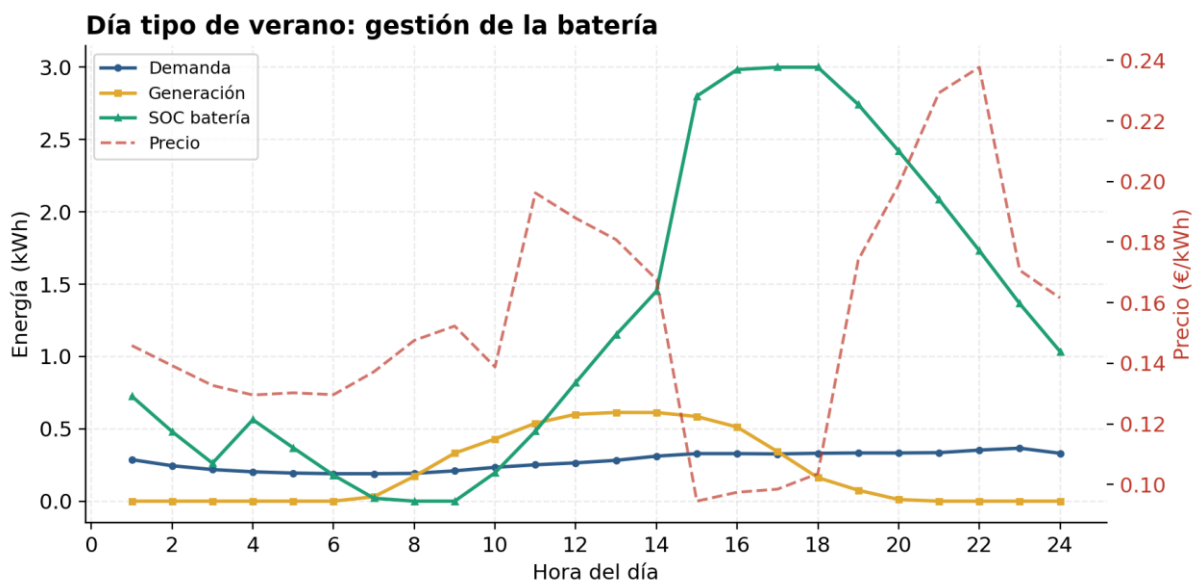


Figura 4.5 Día tipo de verano: evolución del estado de carga, demanda, generación y precio

4.4 VALIDACIÓN DEL MODELO: HORIZONTE FRENTE A PREVISIÓN PERFECTA

El resultado del escenario D presentado hasta ahora corresponde a la optimización con conocimiento perfecto de todo el año, es decir, al techo teórico. Para evaluar una estrategia realista se ejecutó el modelo en su versión de horizonte deslizante de 24 horas, que solo dispone de la información de cada día. Aplicando esta versión sobre los datos reales de 2025 se obtiene el resultado que un controlador operable habría conseguido realmente.

La Tabla 4.4 y la Figura 4.6 comparan los tres valores de referencia.

Tabla 4.4 Comparación entre el inversor real, el modelo realista y el techo teórico (2025)

<i>Caso</i>	<i>Coste anual (€)</i>
C – Inversor real	118,14
D – Horizonte deslizante (24h)	112,77
D – Previsión perfecta (techo)	97,97




Figura 4.6 Validación: inversor real, modelo realista y techo teórico

El resultado es doblemente significativo. Por un lado, el modelo realista (112,77 €) se sitúa entre el inversor real y el techo teórico, lo que confirma que, incluso disponiendo únicamente de la información del día, la optimización mejora la gestión del inversor comercial. El ahorro

realista frente al escenario C es de 5,37 € anuales lo que supone un ahorro del 4,5%. Por otro lado, la diferencia entre el modelo realista y el techo teórico (unos 15 €) cuantifica el coste de no conocer el futuro, es decir, lo que se pierde por operar con información limitada en lugar de con previsión perfecta.

Este análisis responde directamente a uno de los objetivos del trabajo: demuestra que la ventaja de la optimización no es un artificio del conocimiento perfecto, sino que se mantiene, aunque reducida, en condiciones realistas de operación.

4.5 ANÁLISIS DE SENSIBILIDAD

Para evaluar la robustez de los resultados se ha analizado cómo responde el modelo ante variaciones en dos de sus parámetros clave: la eficiencia de la batería y su capacidad.

4.5.1 SENSIBILIDAD DE LA EFICIENCIA DE LA BATERÍA

El modelo se ejecuta con eficiencia unitaria por las razones expuestas en el apartado 3.5, las pérdidas ya están incluidas en los datos medidos. Aun así, para evaluar la robustez del resultado ante una instalación en la que las pérdidas no estuvieran ya contabilizadas, se ha repetido la optimización variando la eficiencia de la batería. Este análisis debe interpretarse como una cota inferior ya que muestra cuánto se reduciría la ventaja del modelo en un escenario desfavorable.

Tabla 4.5 Sensibilidad del modelo a la eficiencia de la batería

<i>Eficiencia η</i>	<i>Coste D (€)</i>	<i>Ahorro frente a C</i>
1,00	97,97	+17,1%
0,95	110,20	+6,7%
0,90	122,42	-3,6%
0,85	134,67	-14,0%

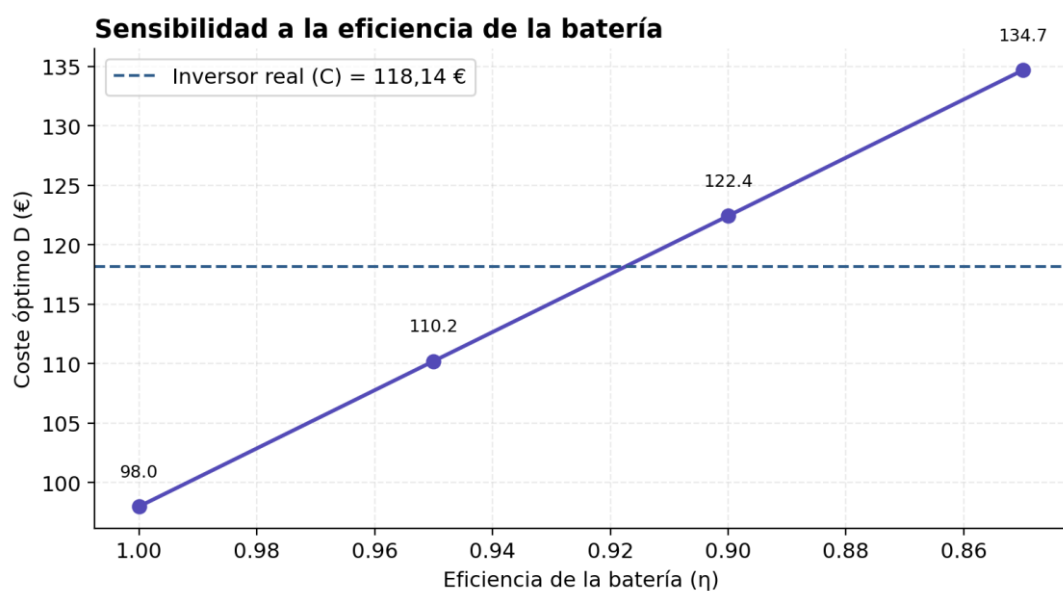


Figura 4.7 Sensibilidad del coste óptimo a la eficiencia de la batería

Como se puede ver tanto en la Tabla 4.5 como en la Figura 4.7, la ventaja del modelo es muy sensible a la eficiencia: ya con un rendimiento del 90 %, el modelo dejaría de ser rentable frente

al inversor real. La explicación reside en la estrategia del modelo, que carga intensamente la batería desde la red (en torno a 877 kWh anuales) para aprovechar las diferencias horarias de precio. Si cada ciclo de carga y descarga conllevara mayores pérdidas, estas se acumularían sobre ese gran volumen de energía y terminarían por anular el beneficio del arbitraje.

Conviene, no obstante, situar estos valores en su contexto real. La eficiencia de las baterías de litio se sitúa en torno al 91-92 %, con valores que alcanzan casi el 98 % en el mejor de los casos y descienden hasta el 88 % en el peor, según el estudio desarrollado por la HTW Berlin [23]. Es importante precisar que esta eficiencia es de ciclo completo, es decir, que ya considera conjuntamente las pérdidas de carga y de descarga. En el análisis aquí ejecutado, en cambio, la eficiencia se aplica a cada conversión por separado, de modo que un rendimiento de 0,95 por sentido equivale en realidad a un rendimiento de ciclo de $0,95^2$, esto es, 0,9025. Aplicando este razonamiento al peor de los casos reportados, una eficiencia de ciclo del 88 % corresponde a un rendimiento por conversión de $\sqrt{0,88}$, aproximadamente 0,938. Llevando ese valor a la Figura 4.7, se comprueba que el modelo seguiría generando ahorro respecto al inversor real.

Por lo tanto, puede asumirse con tranquilidad que, en la gran mayoría de casos en los que la batería conserve una salud razonable, el modelo se mantiene rentable. Solo en situaciones de degradación severa, con rendimientos de ciclo muy por debajo de los habituales, la estrategia de carga desde la red dejaría de compensar.

4.5.2 SENSIBILIDAD A LA CAPACIDAD DE LA BATERÍA

El segundo análisis varía la capacidad de la batería, manteniendo el resto de las condiciones. La Tabla 4.6 y la Figura 4.8 muestran cómo evoluciona el coste óptimo.

Tabla 4.6 Sensibilidad del modelo a la capacidad de la batería

<i>Capacidad (kWh)</i>	<i>Coste D (€)</i>	<i>Ahorro frente a C</i>
2	117,41	+0,6%
3	97,97	+17,1%
5	83,99	+28,9%
10	71,99	+39.1%




Figura 4.8 Sensibilidad del coste óptimo a la capacidad de la batería

El ahorro crece con la capacidad, pero con rendimientos decrecientes. El salto de 2 a 3 kWh es muy pronunciado, mientras que duplicar la capacidad de 5 a 10 kWh aporta una mejora

proporcionalmente menor. Esto se debe a que, una vez la batería es capaz de cubrir el desplazamiento diario de energía, ampliarla más solo sirve para los días de mayor excedente o las mayores diferencias de precio, cuyo aporte marginal es limitado. Esta observación es relevante para el dimensionado de la instalación, ya que sugiere que existe un tamaño de batería a partir del cual la inversión adicional deja de compensar.

4.5.3 INDICADORES TÉCNICOS PARA TENER EN CUENTA

Más allá del coste, conviene caracterizar el comportamiento del sistema mediante algunos indicadores. La tasa de autoconsumo solar (la fracción de generación que se aprovecha en lugar de verse) alcanza el 97,7 % en el modelo óptimo, un valor muy elevado coherente con el escaso vertido observado. En cuanto al uso de la batería, el modelo óptimo realiza 431 ciclos completos al año, frente a los 389 del inversor real. El modelo, por tanto, emplea la batería de forma más intensa, lo que conecta con la cuestión de la degradación que se aborda en el estudio económico. Es algo importante para tener en cuenta ya que como se ha observado en el apartado 4.5.1, la eficiencia de la batería es un factor clave para el coste de la energía total de la instalación, no solo del inversor optimizado, pero de cualquiera.

Conviene precisar qué se entiende por ciclo en este contexto. La carga y la descarga de la batería son procesos graduales que se reparten a lo largo de las horas. Dado que en una hora puede no descargarse toda la energía almacenada previamente, ni cargarse de nuevo hasta su capacidad, no es adecuado contar ciclos físicos completos de carga y descarga. En su lugar se emplea el concepto de ciclo equivalente, definido como la energía total que la batería entrega a lo largo del periodo dividida entre su capacidad nominal. De este modo, un ciclo equivalente representa el haber movido una cantidad de energía igual a la capacidad de la batería, con independencia de cómo se reparta esa energía entre las distintas horas. Bajo esta definición, el modelo realiza 431 ciclos equivalentes a lo largo del año ya que a lo largo del año se descargaron 1293 kWh en total y eso son $1293/3 = 431$ ciclos equivalentes.

4.6 RESULTADOS DE LA PROYECCIÓN A 2026

Como extensión, se aplicó el modelo en su versión de horizonte deslizante sobre el año sintético de 2026 en el periodo comprendido entre el 1 de enero y el 12 de junio. que es el tramo para el que se dispone de precios reales. Dado que se trata de un año sintético sin datos de un inversor real, en esta proyección no existe el escenario C, por lo que la comparación se establece entre el caso base (A), la instalación sin batería (B) y el modelo optimizado (D).

Tabla 4.7 Coste por escenario en la proyección de 2026 (1 de enero a 12 de junio)

<i>Escenario</i>	<i>Coste (€)</i>	<i>Ahorro frente a A</i>
A — Solo red	143,72	—
B — Solo paneles	91,69	36,2 %
D — Optimización	35,19	75,5 %

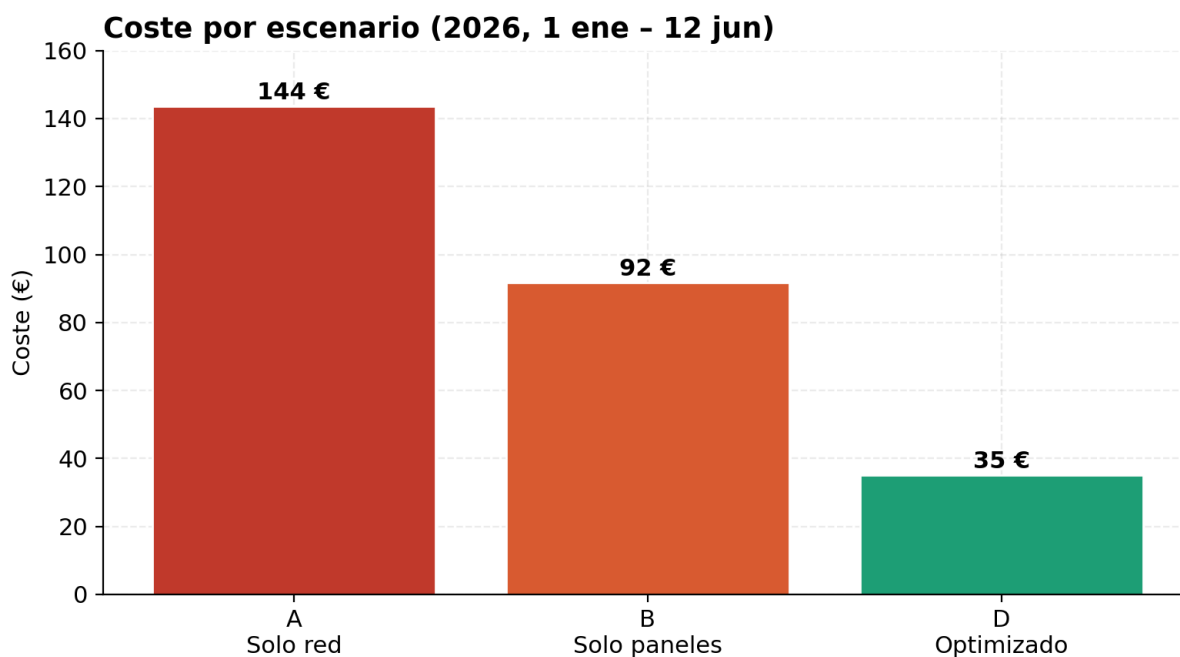


Figura 4.9 Coste por escenario en la proyección de 2026

El modelo mantiene un comportamiento excelente en esta proyección. Reduce la factura un 75,5% frente al caso base y un 61,6% frente a disponer únicamente de paneles. Estos porcentajes son superiores incluso a los de 2025 pero deben interpretarse con cuidado por dos motivos. Primero, el periodo analizado abarca solo hasta el 12 de junio, concentrados por tanto en la parte del año con buena generación solar primaveral. Segundo, la generación del año sintético procede de la media histórica de PVGIS, que resulta un 21,6% superior a la de 2025 ya sea por ser un año con menos irradiación o por pérdidas mayores de las placas. Por ambas razones, los costes absolutos de 2026 no son directamente comparables con los de 2025 y la comparación debe hacerse en términos relativos. En cualquier caso, la proyección confirma que el modelo conserva su capacidad de ahorro al aplicarse sobre datos distintos de aquellos con los que se concibió por lo que elimina la duda de ser un modelo sobreentrenado o solo válido para los datos estudiados.

4.7 ESTUDIO ECONÓMICO Y AMORTIZACIÓN

El último paso es valorar la viabilidad económica de implantar el control inteligente. Conviene partir de una premisa importante: los paneles, la batería y el inversor ya están instalados y son comunes a los escenarios C y D. El único sobrecoste que diferencia al modelo optimizado del inversor real es, por tanto, el del sistema de control óptimo desarrollado. El desarrollo e integración de la lógica de optimización y su conexión con la previsión de precios es el único coste, no se trata de un coste de hardware de generación o almacenamiento, sino de uno de software y control.

Al no disponer de un dato fiable de mercado para este sobrecoste, se ha optado por invertir el planteamiento del análisis. En lugar de suponer un coste y calcular el plazo de amortización, se determina cuál sería el sobrecoste máximo que el control podría tener para resultar rentable, dado el ahorro que genera. Tomando el ahorro realista del modelo en horizonte deslizante, de 5,37 € anuales respecto al inversor real, y considerando una vida útil de referencia de diez años, el sobrecoste del control no debería superar los 54 € para amortizarse en ese plazo. Si se exigiera una amortización más rápida, de cinco años, el margen se reduciría a unos 27 €.

Tabla 4.8 Sobrecoste máximo admisible del control según el plazo de amortización

<i>Plazo de amortización</i>	<i>Ahorro realista (5,37€/año)</i>	<i>Con ahorro teórico (20,17 €/año)</i>
5 años	27 €	101 €
10 años	54 €	202 €

15 años	81 €	303 €
---------	------	-------

Estas cifras conducen a una conclusión honesta. El margen económico que deja la gestión inteligente en una instalación tan pequeña como la estudiada (batería de 3 kWh en una vivienda con poca generación energética por placas) es muy estrecho. Solo tendría sentido implantar el control si su sobre coste fuera de unas pocas decenas de euros, lo que resulta difícil de alcanzar en la práctica para un sistema de optimización con previsión de precios. El análisis de sensibilidad del apartado 4.5 matiza esta conclusión: con baterías de mayor capacidad el ahorro crece de forma considerable, lo que ampliaría proporcionalmente el sobre coste admisible y haría la gestión óptima económicamente más atractiva en instalaciones de mayor tamaño.

A esta consideración económica debe añadirse la cuestión de la degradación de la batería. Como se señaló en el apartado 2.2, el modelo no incorpora el desgaste por ciclado en su función objetivo. Los resultados muestran que el modelo óptimo somete a la batería a 431 ciclos equivalentes anuales lo cual es una cifra algo superior a la del inversor real. Dado que cada ciclo contribuye a la degradación de la batería, una valoración económica completa debería tener en cuenta que la estrategia óptima, al ciclar más intensamente, podría acortar la vida útil del equipo. Esta limitación, junto con su posible incorporación al modelo, se retoma en las conclusiones.

Capítulo 5. CONCLUSIONES Y TRABAJOS FUTUROS

Este último capítulo cierra el trabajo analizando los resultados obtenidos y discutidos en el capítulo anterior, valorando en qué medida se han alcanzado los objetivos planteados, reconociendo cuales han sido las limitaciones del estudio y señalando las líneas en las que podría prolongarse o proponerse futuros proyectos.

5.1 CONCLUSIONES PRINCIPALES

Como se ha comentado durante el trabajo, este nació de una pregunta de interés práctico en el que había un interés inmediato. Se quería estudiar cuánto deja de ahorrar un hogar por el hecho de que su inversor gestionara la batería con una lógica reactiva en lugar de óptima. Para responderla se ha desarrollado un modelo de programación lineal que determina la gestión económicamente óptima de los flujos de energía de la instalación y se ha contrastado con el comportamiento real conocido del inversor sobre los datos medidos de un año completo, de 2025.

El resultado es claro. Sobre los datos reales de 2025, la gestión óptima con conocimiento perfecto de los precios permite reducir la factura un 17,1 % respecto al inversor comercial, pasando de 118,14 € a 97,97 € anuales y mostrando así un claro margen de mejora teórico. Esta cifra representa el techo de ahorro alcanzable, una referencia teórica que ninguna estrategia real puede superar, puesto que presupone un conocimiento perfecto del futuro.

Sin embargo, la aportación más valiosa del trabajo no es ese techo, sino la cuantificación de lo que se consigue en condiciones realistas que se añadió a este trabajo de forma complementaria. Al ejecutar el modelo en un esquema de horizonte deslizante de veinticuatro horas, que como hemos visto en la metodología solo emplea la información disponible de cada jornada, el ahorro frente al inversor real se reduce a 5,37 € anuales. La diferencia entre ambas cifras, de unos quince euros, mide el coste de no conocer el futuro. Aun así, se muestra que muchas veces es suficiente con conocer las próximas horas para poder ahorrar. Que el modelo realista siga

mejorando al inversor comercial, aunque sea de esta forma modesta, confirma que la ventaja de la optimización no es un artificio del conocimiento perfecto, sino un margen real.

De los análisis que se han realizado, se extrae además una conclusión que trasciende el caso concreto y que constituye un descubrimiento que pese a poder ser intuitivo, también es interesante. La rentabilidad de la gestión inteligente está muy ligada a la eficiencia y la capacidad de la batería. El análisis de sensibilidad mostró que, con una eficiencia de la batería baja, el modelo dejaría de ser rentable frente al inversor real ya que su estrategia se apoya en cargar la batería desde la red en las horas baratas y las pérdidas de esa gestión de carga y descarga anularían el beneficio. Aun así, se ha visto que se necesita una salud muy deteriorada de la batería para tener una eficiencia lo suficientemente baja como para que no sea rentable el modelo, al menos para el caso óptimo de la instalación. Sea como sea, el ahorro de la factura energética se basa en una buena batería, por lo que tratar de ahorrar en este elemento puede ser muy contraproducente. En sentido contrario, al aumentar la capacidad de la batería el ahorro crece de manera notable, aunque con rendimientos decrecientes si se busca crecer en gran medida la instalación por lo que puede llegar un punto en el que si crece mucho la instalación puede dejar de ser rentable por el coste de inversión inicial o CAPEX (del inglés, Capital Expenditure). La gestión óptima resulta más atractiva aún por lo tanto cuanto mayor y más eficiente es el sistema de almacenamiento.

5.2 GRADO DE CONSECUCCIÓN DE LOS OBJETIVOS

Los cinco objetivos específicos planteados al inicio se han alcanzado de forma satisfactoria. Se ha modelado matemáticamente el sistema energético de la vivienda, identificando los seis flujos de energía posibles entre paneles, batería, red y consumo, junto con las restricciones físicas y regulatorias que los gobiernan. Se ha formulado el problema como un programa lineal y se ha implementado con las herramientas de código abierto descritas, comprobando que siendo lineal permita resolverlo de forma exacta y eficiente sin recurrir a variables enteras. Se han definido y comparado los cuatro escenarios previstos lo que ha permitido aislar la contribución de los paneles, de la batería y de la gestión óptima al ahorro total. Se ha distinguido claramente el techo teórico de la solución operable mediante la implementación del horizonte deslizante,

cuantificando el efecto de operar con información imperfecta. Y se ha realizado el estudio económico de viabilidad, que ha conducido a una valoración honesta del margen que deja la gestión inteligente.

5.3 LIMITACIONES DEL TRABAJO

La interpretación de los resultados debe tenerse en cuenta junto con las limitaciones que se exponen con total transparencia.

La primera es con relación a los datos de partida. La demanda de la vivienda no procede de una medición independiente, sino que se reconstruye por balance energético a partir de los flujos del sistema. Esto provoca que las eventuales pérdidas de conversión y almacenamiento queden embebidas en la demanda efectiva y obliga a operar el modelo con eficiencia unitaria lo cual hace más complicado y menos preciso el análisis de sensibilidad de eficiencia de batería. La decisión de eficiencia unitaria está justificada ya que aplicar un factor de pérdidas adicional supondría contabilizarlas dos veces, pero aun así condiciona los resultados, como se ha comentado en el análisis de sensibilidad.

La segunda limitación es que el modelo no incorpora la degradación de la batería en su función objetivo ni restricciones, no se tiene en cuenta más que para el razonamiento y conclusiones. Se trata de una decisión deliberada, el objetivo del trabajo es estrictamente optimizar el coste de operación y modelar el desgaste habría exigido asignar un coste de ciclado difícil de estimar, además de complicar la formulación. No obstante, los resultados muestran que la estrategia óptima somete a la batería a 431 ciclos equivalentes anuales, frente a los 389 del inversor real, de modo que cicla el equipo de forma más intensa. Una contabilidad completa debería ponderar el ahorro económico frente a este envejecimiento acelerado, lo cual propone una idea para una posible extensión del proyecto y por ellos es la razón por la cual la cuestión se ha tratado de forma cualitativa.

La tercera limitación afecta a la proyección de 2026, construida con datos sintéticos. Concretamente, a la demanda mediante desplazamiento de calendario y la generación a partir

de la media histórica de PVGIS, que resulta superior a la de un año concreto como 2025. Esta forma es poco ortodoxa, pero es la única posible para construir un año inexistente basándose en algo, en este caso estadística y sucesos pasados. Los resultados de 2026 constituyen una proyección orientativa y no una predicción, y la comparación entre años solo es válida en términos relativos.

Por último, el modelo presupone un conocimiento perfecto de los datos dentro de cada horizonte de optimización. La hipótesis es razonable para los precios, que se publican con un día de antelación, pero la generación solar estaría sujeta en la práctica a un error de previsión que el modelo no contempla.

5.4 APORTACIONES Y VALIDEZ

Más allá de las cifras concretas, el trabajo realiza varias aportaciones. Ofrece una metodología completa y reproducible para evaluar el potencial de ahorro de la gestión óptima de una batería, basada en datos reales. Establece, mediante el techo teórico y el horizonte deslizante, un marco para situar cualquier estrategia de control entre el límite ideal y el comportamiento real. Y aporta, a través del análisis de sensibilidad, una comprensión cualitativa de los factores de los que depende la rentabilidad, que es generalizable más allá de la instalación estudiada.

Conviene precisar que las conclusiones cuantitativas son específicas de esta instalación, de su dimensionado y de los precios de 2025, y que su traslado a otros casos requeriría repetir el análisis con los datos correspondientes, aunque pudiéndose guiar por los razonamientos y análisis incluidos este proyecto. Lo que sí es trasladable es la metodología y las tendencias observadas, en particular la fuerte dependencia del ahorro respecto a la eficiencia y la capacidad del almacenamiento.

5.5 LÍNEAS DE DESARROLLO FUTURO

El trabajo abre varias vías de continuación. La más natural es incorporar la degradación de la batería a la función objetivo, asignando un coste al ciclado que permita al modelo equilibrar el

ahorro con la conservación del equipo. Muy ligada a ella está la extensión del modelo al dimensionado óptimo de la instalación, que determinaría la capacidad de batería que maximiza el beneficio neto considerando conjuntamente el ahorro y el coste del almacenamiento, en lugar de tomar el dimensionado como un dato fijo.

Una tercera línea consistiría en sustituir la hipótesis de previsión perfecta dentro del horizonte por previsiones reales de generación solar, evaluando cómo el error de predicción afecta al ahorro y aproximando así el modelo a un control predictivo plenamente operativo. Finalmente, el modelo podría ampliarse hacia un planteamiento multiobjetivo, incorporando metas adicionales a la puramente económica, como la reducción de las emisiones asociadas al consumo de la red o la maximización de la independencia energética, lo que permitiría además alinearse más aun con los ODS, objetivos que a menudo entran en conflicto con proyectos centrados en ahorro de costes.

Capítulo 6. BIBLIOGRAFÍA

- [1] International Energy Agency, *Electricity 2024: Analysis and Forecast to 2026*. Paris, Francia: IEA, 2024. [En línea]. Disponible: <https://www.iea.org/reports/electricity-2024>.
- [2] Jefatura del Estado, "Real Decreto-ley 19/2021, de 5 de octubre, de medidas urgentes para impulsar la actividad de rehabilitación edificatoria en el contexto del Plan de Recuperación, Transformación y Resiliencia," *Boletín Oficial del Estado*, núm. 239, pp. 123107–123148, 6 oct. 2021.
- [3] J. L. Sancha Gonzalo, "Reducir la factura de la luz con autoconsumo y almacenamiento," *Cuadernos de Energía*, no. 79, marzo 2025.
- [4] Ministerio para la Transición Ecológica y el Reto Demográfico, "Real Decreto 244/2019, de 5 de abril, por el que se regulan las condiciones administrativas, técnicas y económicas del autoconsumo de energía eléctrica," *Boletín Oficial del Estado*, núm. 83, pp. 35674–35719, abr. 2019.
- [5] Red Eléctrica de España, "ESIOS — Sistema de Información del Operador del Sistema," 2025. [En línea]. Disponible: <https://www.esios.ree.es/>.
- [6] M. L. Bynum, G. A. Hackebeil, W. E. Hart, C. D. Laird, B. L. Nicholson, J. D. Sirola, J.-P. Watson y D. L. Woodruff, *Pyomo — Optimization Modeling in Python*, 3ª ed. Cham, Suiza: Springer, 2021. doi: 10.1007/978-3-030-68928-5.
- [7] W. E. Hart, J.-P. Watson y D. L. Woodruff, "Pyomo: modeling and solving mathematical programs in Python," *Mathematical Programming Computation*, vol. 3, núm. 3, pp. 219–260, 2011. doi: 10.1007/s12532-011-0026-8.
- [8] European Commission, Joint Research Centre, "Photovoltaic Geographical Information System (PVGIS)," 2024. [En línea]. Disponible: https://re.jrc.ec.europa.eu/pvg_tools/en/.
- [9] United Nations, "Transforming our world: the 2030 Agenda for Sustainable Development," Resolución A/RES/70/1, Naciones Unidas, Nueva York, EE.UU., 2015. [En línea]. Disponible: <https://sdgs.un.org/2030agenda>.
- [10] Ministerio para la Transición Ecológica y el Reto Demográfico, "Real Decreto-ley 15/2018, de 5 de octubre, de medidas urgentes para la transición energética y la protección de los consumidores," *Boletín Oficial del Estado*, núm. 242, pp. 97430–97527, oct. 2018.

- [11] J. L. Sancha Gonzalo, *Presume de entender (a fondo) las facturas de la luz y del gas*. Madrid, España: Universidad Pontificia Comillas, 2016.
- [12] Comisión Nacional de los Mercados y la Competencia, "Circular 3/2020, de 15 de enero, por la que se establece la metodología para el cálculo de los peajes de transporte y distribución de electricidad," *Boletín Oficial del Estado*, núm. 22, ene. 2020.
- [13] K. Mongird, V. Viswanathan, J. Alam, C. Vartanian, V. Sprenkle y R. Baxter, "2020 Grid Energy Storage Technology Cost and Performance Assessment," Pacific Northwest National Laboratory, Informe técnico DOE/PA-0204, dic. 2020. [En línea]. Disponible: <https://www.energy.gov/energy-storage-grand-challenge/articles/2020-grid-energy-storage-technology-cost-and-performance>.
- [14] J. M. Reniers, G. Mulder y D. A. Howey, "Review and performance comparison of mechanical-chemical degradation models for lithium-ion batteries," *Journal of The Electrochemical Society*, vol. 166, núm. 14, pp. A3189–A3200, 2019. doi: 10.1149/2.0281914jes.
- [15] D. Azuatalam, K. Paridari, Y. Ma, M. Förstl, A. C. Chapman y G. Verbič, "Energy management of small-scale PV-battery systems: A systematic review considering practical implementation, computational requirements, quality of input data and battery degradation," *Renewable and Sustainable Energy Reviews*, vol. 112, pp. 555–570, 2019. doi: 10.1016/j.rser.2019.06.007.
- [16] G. B. Dantzig, *Linear Programming and Extensions*. Princeton, NJ, EE.UU.: Princeton University Press, 1963.
- [17] D. Bertsimas y J. N. Tsitsiklis, *Introduction to Linear Optimization*. Belmont, MA, EE.UU.: Athena Scientific, 1997.
- [18] E. L. Ratnam, S. R. Weller y C. M. Kellett, "An optimization-based approach to scheduling residential battery storage with solar PV: Assessing customer benefit," *Renewable Energy*, vol. 75, pp. 123–134, 2015. doi: 10.1016/j.renene.2014.09.008.
- [19] R. Bean y H. Khan, "Using solar and load predictions in battery scheduling at the residential level," arXiv:1810.11178 [eess.SP], 2018. [En línea]. Disponible: <https://arxiv.org/abs/1810.11178>.
- [20] A. Makhorin, *GLPK (GNU Linear Programming Kit) Reference Manual*, versión 4.65. Free Software Foundation, 2012. [En línea]. Disponible: <https://www.gnu.org/software/glpk/>.
- [21] W. McKinney, "Data structures for statistical computing in Python," en *Proc. 9th Python in Science Conf. (SciPy 2010)*, Austin, TX, EE.UU., 2010, pp. 56–61. doi: 10.25080/Majora-92bf1922-00a.

- [22] IEA Photovoltaic Power Systems Programme, *Trends in Photovoltaic Applications 2021*, IEA PVPS Task 1, Report IEA-PVPS T1-40:2021. Paris, Francia: IEA PVPS, 2022. [En línea]. Disponible: <https://iea-pvps.org/wp-content/uploads/2022/01/IEA-PVPS-Trends-report-2021-4.pdf>
- [23] J. Weniger, J. Bergner, and V. Quaschnig, "Electricity Storage Inspection 2024," HTW Berlin, Berlin, Research Report, Mar. 2024. [Online]. Available: <https://solar.htw-berlin.de/studies/electricity-storage-inspection-2024/>

ANEXO I. ALINEACIÓN CON LOS OBJETIVOS DE DESARROLLO SOSTENIBLE (ODS)

Los Objetivos de Desarrollo Sostenible (ODS), aprobados por las Naciones Unidas en 2015 dentro de la Agenda 2030, constituyen un plan de acción global articulado en diecisiete objetivos orientados a la sostenibilidad ambiental, social y económica [9]. El presente trabajo, centrado en la gestión eficiente de la energía en una vivienda con autoconsumo fotovoltaico, se alinea de forma directa con cuatro de ellos, que se desarrollan a continuación junto con las metas concretas a las que contribuye.

1. ODS 7 — ENERGÍA ASEQUIBLE Y NO CONTAMINANTE

Es el objetivo con el que el trabajo conecta de forma más evidente. El ODS 7 persigue garantizar el acceso a una energía asequible, fiable, sostenible y moderna para todos. El modelo desarrollado contribuye a sus metas en dos sentidos. Por un lado, a la meta 7.1 (acceso universal a servicios energéticos asequibles), ya que reduce el coste de la electricidad para el consumidor doméstico, haciendo más accesible el servicio energético. Por otro, a la meta 7.2 (aumentar la proporción de energía renovable), puesto que maximiza el aprovechamiento de la energía solar generada por la propia vivienda, desplazando consumo desde la red hacia una fuente renovable y limpia.

2. ODS 13 — ACCIÓN POR EL CLIMA

El ODS 13 busca adoptar medidas urgentes para combatir el cambio climático y sus efectos. La contribución del trabajo es indirecta pero real. Al optimizar la gestión del autoconsumo, el modelo desplaza parte de la demanda hacia la generación renovable propia y hacia las horas de menor coste, que con frecuencia coinciden con periodos de mayor presencia de renovables en la red eléctrica. Esto reduce de forma indirecta las emisiones asociadas al consumo de red.

Además, al demostrar el beneficio económico de una gestión eficiente, el trabajo incentiva la adopción de instalaciones de autoconsumo, con el consiguiente efecto positivo sobre la descarbonización. Conecta así con la meta 13.2 (incorporar medidas relativas al cambio climático en las estrategias y la planificación).

3. ODS 11 — CIUDADES Y COMUNIDADES SOSTENIBLES

El ODS 11 busca lograr que las ciudades y los asentamientos humanos sean inclusivos, seguros, resilientes y sostenibles. El trabajo contribuye a la meta 11.6 (reducir el impacto ambiental negativo de las ciudades) a través de su aportación al modelo de generación distribuida. El crecimiento de instalaciones de autoconsumo bien gestionadas integradas en el entorno urbano y residencial favorece un sistema energético más descentralizado y resiliente, en el que el consumidor pasa a ser también productor y gestiona de forma activa su energía.

4. ODS 12 — PRODUCCIÓN Y CONSUMO RESPONSABLES

El ODS 12 promueve modalidades de consumo y producción sostenibles. El trabajo se alinea con su meta 12.2 (uso eficiente de los recursos naturales), ya que el objetivo último del modelo es aprovechar de la forma más eficiente posible un recurso energético que es la energía solar disponible y la capacidad de almacenamiento de la batería. La gestión óptima evita el desperdicio de energía y extrae el máximo valor de los recursos ya instalados, en lugar de requerir nuevos equipos, lo que encaja con el principio de hacer más con menos que propone este objetivo.

5. SÍNTESIS

En conjunto, el trabajo busca aportar a la transición hacia un modelo energético más sostenible, eficiente y descentralizado. Aunque su objetivo inmediato es económico, buscando reducir la factura eléctrica de una vivienda, los medios que emplea para este objetivo (el mejor aprovechamiento de la energía solar y del almacenamiento) lo vinculan con los objetivos de sostenibilidad energética y climática de la Agenda 2030.

ANEXO II. CÓDIGO FUENTE

En este anexo se recoge el código fuente desarrollado en Python para la generación de los datos sintéticos de 2026 y para la resolución del modelo de optimización. Los modelos de optimización se han ejecutado en el entorno Google Colab, empleando la librería Pyomo para la formulación del problema y el solver GLPK para su resolución como ha sido comentado en la memoria mientras que los códigos de generación de demanda y generación fotovoltaica de 2026 se ejecutaron directamente desde Python. Se presentan en primer lugar los dos scripts de construcción del año sintético de 2026 y, a continuación, los modelos de optimización: el modelo anual, que proporciona el techo teórico, y su adaptación al esquema de horizonte deslizando, aplicado tanto a 2025 como a 2026.

1. Generación de la demanda de 2026 (calendar shift)

Construye la plantilla de datos de 2026 a partir de los datos reales de 2025 mediante un desplazamiento de calendario que preserva el día de la semana, los festivos nacionales y los cambios de hora estacionales.

```
"""
Genera la plantilla de datos de 2026 a partir de los datos reales de 2025
mediante un calendar shift que preserva:
- El día de la semana (lunes -> lunes, etc.)
- Los festivos nacionales de España (festivo -> festivo)
- El cambio de hora (DST): un día de 23h en marzo, otro de 25h en octubre

ENTRADA: archivo Excel con datos 2025 (formato del archivo original)
SALIDA: Excel datos_2026.xlsx con columnas Día, Hora, PV, demanda, precio
- demanda: generada por calendar shift desde 2025
- PV y precio: vacíos que se rellenan con el código 2

import pandas as pd
import numpy as np
from datetime import date, timedelta

# === CONFIGURACIÓN ===
RUTA_2025 = 'datos.xlsx'          #para copiar formato
RUTA_SALIDA = 'datos_2026.xlsx'

# === FESTIVOS NACIONALES DE ESPAÑA ===
FESTIVOS_2025 = {
```

```

date(2025, 1, 1): 'Año Nuevo',
date(2025, 1, 6): 'Reyes',
date(2025, 4, 18): 'Viernes Santo',
date(2025, 5, 1): 'Día del Trabajador',
date(2025, 8, 15): 'Asunción',
date(2025, 10, 12): 'Hispanidad',
date(2025, 11, 1): 'Todos los Santos',
date(2025, 12, 6): 'Constitución',
date(2025, 12, 8): 'Inmaculada',
date(2025, 12, 25): 'Navidad',
}

FESTIVOS_2026 = {
  date(2026, 1, 1): 'Año Nuevo',
  date(2026, 1, 6): 'Reyes',
  date(2026, 4, 3): 'Viernes Santo',
  date(2026, 5, 1): 'Día del Trabajador',
  date(2026, 8, 15): 'Asunción',
  date(2026, 10, 12): 'Hispanidad',
  date(2026, 11, 2): 'Todos los Santos (trasladado)',
  date(2026, 12, 7): 'Constitución (trasladado)',
  date(2026, 12, 8): 'Inmaculada',
  date(2026, 12, 25): 'Navidad',
}

# === CAMBIOS DE HORA (DST) ===
# 2025: último domingo de marzo (30 mar, 23h) y último domingo de octubre (26 oct, 25h)
# 2026: último domingo de marzo (29 mar, 23h) y último domingo de octubre (25 oct, 25h)
DST_2025 = {
  date(2025, 3, 30): 23,
  date(2025, 10, 26): 25,
}
DST_2026 = {
  date(2026, 3, 29): 23,
  date(2026, 10, 25): 25,
}

def emparejar_dia(dia_2026, dias_2025_disponibles, festivos_2025, festivos_2026):
    """
    Devuelve el día de 2025 más adecuado para servir como fuente del dia_2026.

    Regla:
    - Si dia_2026 es festivo: elegir el festivo de 2025 con el mismo nombre
      (o el más cercano por fecha si no hay coincidencia exacta).
    - Si dia_2026 NO es festivo: elegir el día de 2025 NO festivo con mismo
      día de la semana y mismo mes (o el mes más cercano si no hay).
    """
    es_festivo_2026 = dia_2026 in festivos_2026

    if es_festivo_2026:
        nombre_destino = festivos_2026[dia_2026]
        # Limpiar el sufijo "(trasladado)" para encontrar coincidencia
        nombre_base = nombre_destino.replace(' (trasladado)', '')

        candidatos = [d for d, n in festivos_2025.items() if n == nombre_base]
        if candidatos:
            return candidatos[0]

        # Si no hay coincidencia exacta, escoger festivo más cercano por fecha
        candidatos = list(festivos_2025.keys())
        d_ref = date(2025, dia_2026.month, min(dia_2026.day, 28))
        return min(candidatos, key=lambda d: abs((d - d_ref).days))

    # No festivo: buscar día de 2025 con mismo dow y mismo mes, NO festivo
    dow = dia_2026.weekday()
    mes = dia_2026.month
    candidatos = [d for d in dias_2025_disponibles

```

```

        if d.weekday() == dow and d.month == mes and d not in festivos_2025]
if candidatos:
    return min(candidatos, key=lambda d: abs(d.day - dia_2026.day))

# Si no hay del mismo mes, buscar mes más cercano
candidatos = [d for d in dias_2025_disponibles
               if d.weekday() == dow and d not in festivos_2025]
if candidatos:
    d_ref = date(2025, mes, min(dia_2026.day, 28))
    return min(candidatos, key=lambda d: abs((d - d_ref).days))

raise ValueError(f"No se encontró día origen para {dia_2026}")

def ajustar_horas(serie_24h, num_horas_destino):
    """
    Ajusta una serie de 24 horas a 23 o 25 horas para el cambio de hora.
    - 23h: se elimina la hora 3 (cambio primavera)
    - 25h: se duplica la hora 3 (cambio otoño)
    - 24h: se devuelve tal cual
    """
    serie = np.asarray(serie_24h, dtype=float)
    if num_horas_destino == 24:
        return serie
    if num_horas_destino == 23:
        return np.concatenate([serie[:2], serie[3:]])
    if num_horas_destino == 25:
        return np.concatenate([serie[:3], [serie[2]], serie[3:]])
    raise ValueError(f"num_horas_destino inválido: {num_horas_destino}")

def generar_demanda_2026(df_2025,
                        festivos_2025=FESTIVOS_2025,
                        festivos_2026=FESTIVOS_2026,
                        dst_2025=DST_2025,
                        dst_2026=DST_2026,
                        columna_demanda='demanda'):
    """
    Genera el DataFrame de demanda de 2026 a partir de los datos de 2025.

    df_2025 debe tener columnas: 'fecha' (datetime/date), 'Hora' (1..24/25), columna_demanda.
    """
    df_2025 = df_2025.copy()
    df_2025['fecha_dia'] = pd.to_datetime(df_2025['fecha']).dt.date
    df_2025 = df_2025.sort_values(['fecha_dia', 'Hora']).reset_index(drop=True)

    dias_2025_disponibles = sorted(df_2025['fecha_dia'].unique())

    filas_2026 = []
    log_emparejamientos = []

    d = date(2026, 1, 1)
    while d <= date(2026, 12, 31):
        # Determinar nº de horas del día destino
        n_horas_destino = dst_2026.get(d, 24)

        # Emparejar con día de 2025
        dia_origen = emparejar_dia(d, dias_2025_disponibles, festivos_2025, festivos_2026)

        # Coger las horas de ese día origen
        df_origen = df_2025[df_2025['fecha_dia'] == dia_origen].sort_values('Hora')
        serie_origen = df_origen[columna_demanda].values
        n_origen = len(serie_origen)

        # Normalizar el día origen a 24h si tenía 23 o 25
        if n_origen == 23:
            serie_24 = np.concatenate([serie_origen[:2],

```

```

        [(serie_origen[1] + serie_origen[2]) / 2],
        serie_origen[2:]]
elif n_origen == 25:
    serie_24 = np.concatenate([serie_origen[:2],
                               [(serie_origen[2] + serie_origen[3]) / 2],
                               serie_origen[4:]]
                               )
elif n_origen == 24:
    serie_24 = serie_origen
else:
    raise ValueError(f"Día {dia_origen} con {n_origen} horas (esperado 23/24/25)")

# Ajustar al nº de horas del día destino
serie_destino = ajustar_horas(serie_24, n_horas_destino)

for h_idx, valor in enumerate(serie_destino, start=1):
    filas_2026.append({
        'Día': d.isoformat(),
        'Hora': h_idx,
        'demanda': float(valor),
    })

log_emparejamientos.append({
    'fecha_2026': d.isoformat(),
    'dow_2026': d.strftime('%A'),
    'es_festivo_2026': d in festivos_2026,
    'fecha_origen_2025': dia_origen.isoformat(),
    'dow_origen': dia_origen.strftime('%A'),
    'era_festivo_2025': dia_origen in festivos_2025,
    'horas_destino': n_horas_destino,
    'horas_origen': n_origen,
})

d += timedelta(days=1)

return pd.DataFrame(filas_2026), pd.DataFrame(log_emparejamientos)

def main():
    print(f"Cargando datos 2025 desde: {RUTA_2025}")
    df = pd.read_excel(RUTA_2025)
    df.columns = [c.strip() for c in df.columns]
    df = df.rename(columns={'Demanda real (kWh)': 'demanda'})
    df['fecha'] = pd.to_datetime(df['Día'])
    df = df.dropna(subset=['fecha']).copy()
    df = df.dropna(subset=['Hora'])
    df['Hora'] = df['Hora'].astype(int)
    df['demanda'] = df['demanda'].fillna(0)

    print(f" Filas 2025: {len(df)}")
    print(f" Demanda total 2025: {df['demanda'].sum():.2f} kWh")

    print("\nGenerando demanda 2026 mediante calendar shift...")
    df_dem_2026, log = generar_demanda_2026(df)
    print(f" Filas 2026: {len(df_dem_2026)}")
    print(f" Demanda total 2026: {df_dem_2026['demanda'].sum():.2f} kWh")

    # Construir DataFrame final con columnas vacías para PV y precio
    df_2026 = df_dem_2026[['Día', 'Hora', 'demanda']].copy()
    df_2026['PV'] = np.nan
    df_2026['precio'] = np.nan
    df_2026 = df_2026[['Día', 'Hora', 'PV', 'demanda', 'precio']]

    # Guardar
    with pd.ExcelWriter(RUTA_SALIDA, engine='openpyxl') as w:
        df_2026.to_excel(w, sheet_name='Datos 2026', index=False)
        log.to_excel(w, sheet_name='Log emparejamientos', index=False)

    print(f"\n¡Listo! Generado: {RUTA_SALIDA}")

```

ANEXO II. CÓDIGO FUENTE

```
print("\nSigüientes pasos:")
print(" 1. Rellena la columna 'PV' con tu producción solar de PVGIS (kWh por hora)")
print(" 2. Rellena la columna 'precio' con los precios horarios 2026 (€/kWh)")
print(" 3. Ejecuta el simulador (main.py) para obtener el caso base")

if __name__ == '__main__':
    main()
```

Código 1. Generación de la demanda de 2026 mediante desplazamiento de calendario

2. Generación de la generación fotovoltaica de 2026 (PVGIS)

Descarga los datos de generación fotovoltaica de la API de PVGIS 5.3 para la ubicación y características de la instalación con los datos vistos en el apartado 3.8, y rellena con ellos la columna de producción solar del año sintético de 2026.

```

"""

Descarga datos de generación fotovoltaica desde la API de PVGIS 5.3
y rellena la columna 'Producción paneles (kWh)' del Excel de 2026 generado en el código 1.

Parámetros del sistema:
- Potencia pico: 1.0 kWp
- Inclinación: 30°
- Azimut: 0° (Sur)
- Pérdidas: 16% (valor por defecto PVGIS)
- Ubicación: Madrid (40.413°N, -3.682°E)
- Tecnología: Silicio cristalino (crystSi)
- Base de datos: PVGIS-SARAH3 (versión 5.3, datos hasta 2023)

Años usados: 2015-2023 excluyendo bisiestos (2016, 2020)
→ 2015, 2017, 2018, 2019, 2021, 2022, 2023 (7 años)

Nota sobre timestamps PVGIS-SARAH3:
PVGIS reporta el timestamp en HH:10 (no HH:00 ni HH:30).
Se trata de que cuadren con los de 2025.
Por tanto NO se aplica conversión de zona horaria.
Se redondea HH:10 → HH:00 con floor para asignar la hora correcta.
"""

import requests
import pandas as pd
import numpy as np
from pathlib import Path

# --- Rutas -----
RUTA_EXCEL_2026 = Path("datos_2026.xlsx")
RUTA_SALIDA = Path("datos_2026_finales.xlsx")

# --- Años no bisiestos disponibles en PVGIS 5.3 (2015-2023) -----
AÑOS_NO_BISIESTOS = [2015, 2017, 2018, 2019, 2021, 2022, 2023]

# --- Parámetros PVGIS -----
PVGIS_URL = "https://re.jrc.ec.europa.eu/api/v5_3/seriescalc"
PARAMS_BASE = {
    "lat": 40.413,
    "lon": -3.682,
    "raddatabase": "PVGIS-SARAH3",
    "outputformat": "json",
    "usehorizon": 1,
    "pvcalculation": 1,
    "pvtechchoice": "crystSi",
    "mountingplace": "free",
    "peakpower": 1.0,
    "loss": 16,
    "angle": 30,
    "aspect": 0,
}

# -----

```

```
# 1. DESCARGA PVGIS AÑO A AÑO
# =====
print("Descargando datos de PVGIS 5.3 (SARAH3)...")
print(f"Años: {AÑOS_NO_BISIESTOS}\n")

dfs = []
for año in AÑOS_NO_BISIESTOS:
    params = {"**PARAMS_BASE", "startyear": año, "endyear": año}
    print(f" Descargando {año}...", end=" ")
    try:
        resp = requests.get(PVGIS_URL, params=params, timeout=120)
        if not resp.ok:
            print(f"ERROR {resp.status_code}: {resp.text[:200]}\n")
            continue
        hourly = resp.json()["outputs"]["hourly"]
        df_año = pd.DataFrame(hourly)
        df_año["gen_kWh"] = df_año["P"] / 1000.0
        # Parsear timestamp sin zona horaria
        df_año["datetime"] = pd.to_datetime(df_año["time"], format="%Y%m%d:%H%M")
        # Redondear HH:10 -> HH:00
        df_año["datetime"] = df_año["datetime"].dt.floor("h")
        dfs.append(df_año[["datetime", "gen_kWh"]])
        print(f"OK -> {df_año['gen_kWh'].sum():.1f} kWh")
    except Exception as e:
        print(f"ERROR: {e}")

if not dfs:
    raise RuntimeError("No se pudieron descargar datos de PVGIS.")

df_pvgis = pd.concat(dfs, ignore_index=True)
print(f"\nTotal descargado: {len(df_pvgis)} filas, {len(AÑOS_NO_BISIESTOS)} años")

# =====
# 2. EXTRAER COMPONENTES HORARIAS
# =====
df_pvgis["month"] = df_pvgis["datetime"].dt.month
df_pvgis["day"] = df_pvgis["datetime"].dt.day
# Convenio 1-24 igual que el Excel de 2026
df_pvgis["hour"] = df_pvgis["datetime"].dt.hour + 1

# Verificación: hora pico en julio debe ser 13 o 14
julio = df_pvgis[df_pvgis["month"] == 7]
hora_pico = julio.groupby("hour")["gen_kWh"].mean().idxmax()
print(f"\nVerificación hora pico julio: hora {int(hora_pico)} (esperado 13 o 14)")
if hora_pico not in [13, 14]:
    print(" ¡AVISO! Hora pico inesperada, revisar timestamps.")

# =====
# 3. PERFIL SINTÉTICO: media por (mes, día del mes, hora)
# =====
print("Calculando perfil sintético (media por mes/día/hora)...")

perfil = (
    df_pvgis
    .groupby(["month", "day", "hour"])["gen_kWh"]
    .mean()
    .reset_index()
    .rename(columns={"gen_kWh": "gen_media_kWh"})
)

gen_sintetica = perfil["gen_media_kWh"].sum()
gen_real_2025 = 1297.1
print(f"\nGeneración anual perfil sintético: {gen_sintetica:.1f} kWh")
print(f"Generación real 2025: {gen_real_2025:.1f} kWh")
print(f"Diferencia: {(gen_sintetica-gen_real_2025)/gen_real_2025*100:+.1f}%")

# =====
# 4. LEER EXCEL 2026 Y RELLENAR GENERACIÓN
# =====
```

```

print(f"\nLeyendo {RUTA_EXCEL_2026}...")
df_2026 = pd.read_excel(RUTA_EXCEL_2026, sheet_name=0)

df_2026["Día"] = pd.to_datetime(df_2026["Día"])
df_2026["_month"] = df_2026["Día"].dt.month
df_2026["_day"] = df_2026["Día"].dt.day
df_2026["_hour"] = df_2026["Hora"].astype(int)

df_merged = df_2026.merge(
    perfil,
    left_on=["_month", "_day", "_hour"],
    right_on=["month", "day", "hour"],
    how="left"
)

sin_match = df_merged["gen_media_kWh"].isna().sum()
if sin_match > 0:
    print(f" Aviso: {sin_match} horas sin match → interpolación lineal.")
    df_merged["gen_media_kWh"] = (
        df_merged["gen_media_kWh"]
        .interpolate(method="linear")
        .fillna(0.0)
    )
else:
    print(" Sin huecos. Todas las horas tienen match.")

df_2026["Producción paneles (kWh)"] = df_merged["gen_media_kWh"].values
df_2026 = df_2026.drop(columns=["_month", "_day", "_hour"])

# =====
# 5. GUARDAR
# =====
print(f"\nGuardando en {RUTA_SALIDA}...")
with pd.ExcelWriter(RUTA_SALIDA, engine="openpyxl") as writer:
    df_2026.to_excel(writer, sheet_name="Datos 2026", index=False)

print(f"\n✓ Completado.")
print(f" Filas: {len(df_2026)}")
print(f" Generación anual 2026: {df_2026['Producción paneles (kWh)'].sum():.1f} kWh")
print(f" Máximo horario: {df_2026['Producción paneles (kWh)'].max():.4f} kWh")
print(f" Horas con generación > 0: {(df_2026['Producción paneles (kWh)'] > 0).sum()}")
print(f"\nArchivo guardado: {RUTA_SALIDA.resolve()}")

```

Código 2. Obtención de la generación fotovoltaica de 2026 a partir de PVGIS

3. Modelo de optimización anual (techo teórico)

Resuelve la gestión óptima de la batería sobre el año completo de una sola vez, con conocimiento perfecto de precios y generación. Su resultado constituye el techo teórico de ahorro.

```

"""
=====
MODELO DE OPTIMIZACIÓN ANUAL (TECHO TEÓRICO)
=====
Resuelve la gestión óptima de la batería sobre el año completo de una sola
vez, con conocimiento perfecto de precios y generación. El resultado
constituye el techo teórico de ahorro: la mejor solución posible, no
alcanzable en la práctica al presuponer conocimiento perfecto del futuro.
=====
"""

import pandas as pd
import pyomo.environ as pyo
from google.colab import drive
import os

# =====
# 1. PREPARACIÓN DEL ENTORNO Y LECTURA DE DATOS
# =====
# Instalación del solver de programación lineal (GLPK)
if os.system('glpk --version') != 0:
    os.system('apt-get install -y -qq glpk-utils')

drive.mount('/content/drive', force_remount=True)
ruta_excel = '/content/drive/MyDrive/TFG/datos.xlsx'
df_raw = pd.read_excel(ruta_excel)

# Se eliminan posibles espacios en los nombres de las columnas
df_raw.columns = df_raw.columns.str.strip()

# Se toman las 8760 horas del año con datos de demanda válidos
df = df_raw.dropna(subset=['Demanda real (kWh)']).head(8760).copy()
df = df.reset_index(drop=True)

# Renombrado de columnas a nombres cortos de trabajo
df = df.rename(columns={
    'Demanda real (kWh)': 'Demanda',
    'Producción paneles (kWh)': 'Solar',
    'Precios consumo (€/kWh)': 'P_Compra',
    'Precio vertido (€/kWh)': 'P_Venta',
    'Consumo de red (kWh)': 'Red_C',
    'Vertido (kWh)': 'Venta_C'
})

# =====
# 2. DEFINICIÓN DEL MODELO DE OPTIMIZACIÓN
# =====
model = pyo.ConcreteModel()
model.T = pyo.Set(initialize=df.index) # Conjunto de horas del año

# --- Parámetros (datos de entrada para cada hora) ---
model.dem = pyo.Param(model.T, initialize=df['Demanda'].to_dict())
model.sol = pyo.Param(model.T, initialize=df['Solar'].to_dict())
model.p_com = pyo.Param(model.T, initialize=df['P_Compra'].to_dict())
model.p_ven = pyo.Param(model.T, initialize=df['P_Venta'].to_dict())
model.Ef = pyo.Param(initialize=1) # Eficiencia de la batería (unitaria)

```

```
# --- Variables de decisión (flujos de energía, en kWh, no negativos) ---
model.sol_hogar = pyo.Var(model.T, domain=pyo.NonNegativeReals) # paneles -> hogar
model.sol_bat   = pyo.Var(model.T, domain=pyo.NonNegativeReals) # paneles -> batería
model.sol_red   = pyo.Var(model.T, domain=pyo.NonNegativeReals) # paneles -> red (vertido)
model.red_hogar = pyo.Var(model.T, domain=pyo.NonNegativeReals) # red -> hogar
model.red_bat   = pyo.Var(model.T, domain=pyo.NonNegativeReals) # red -> batería
model.bat_hogar = pyo.Var(model.T, domain=pyo.NonNegativeReals) # batería -> hogar
model.soc       = pyo.Var(model.T, bounds=(0, 3.0))             # estado de carga (0-3 kWh)

# --- RESTRICCIONES ---

# 1. Balance del hogar: la energía que llega cubre exactamente la demanda
model.c_dem = pyo.Constraint(model.T, rule=lambda m, t:
    m.sol_hogar[t] + m.red_hogar[t] + m.bat_hogar[t] == m.dem[t])

# 2. Balance de los paneles: toda la generación se reparte entre sus destinos
model.c_sol = pyo.Constraint(model.T, rule=lambda m, t:
    m.sol_hogar[t] + m.sol_bat[t] + m.sol_red[t] == m.sol[t])

# 3. Balance del estado de carga: SOC actual = SOC previo + carga - descarga
def soc_bal(m, t):
    carga = m.sol_bat[t] + m.red_bat[t]
    descarga = m.bat_hogar[t]
    if t == 0:
        return m.soc[t] == (carga * m.Ef) - (descarga / m.Ef)
    return m.soc[t] == m.soc[t-1] + (carga * m.Ef) - (descarga / m.Ef)
model.c_soc = pyo.Constraint(model.T, rule=soc_bal)

# 4. Límite de potencia de carga del inversor (3 kW)
model.c_lim_c = pyo.Constraint(model.T, rule=lambda m, t:
    (m.sol_bat[t] + m.red_bat[t]) <= 3.0)

# 5. Límite de potencia de descarga del inversor (3 kW)
model.c_lim_d = pyo.Constraint(model.T, rule=lambda m, t:
    m.bat_hogar[t] <= 3.0)

# 6. Restricción antifraude: solo se vierte el excedente solar físico real,
# impidiendo verter energía procedente de la batería o de la red
model.c_lim_vertido = pyo.Constraint(model.T, rule=lambda m, t:
    m.sol_red[t] <= max(0, m.sol[t] - m.dem[t]))

# --- FUNCIÓN OBJETIVO ---
# Minimiza el coste neto de la energía (compra a la red menos compensación
# por vertido). Incluye dos términos de desempate de magnitud insignificante
# (orden 1e-6, sin efecto sobre el coste) cuya única función es obtener una
# solución físicamente coherente:
# - el término negativo prioriza el autoconsumo solar directo (sol -> hogar)
# - el término positivo penaliza la descarga superflua de la batería,
# evitando cargas y descargas simultáneas bajo eficiencia unitaria
def obj_rule(m):
    return sum((m.red_hogar[t] + m.red_bat[t]) * m.p_com[t]
        - m.sol_red[t] * m.p_ven[t]
        - m.sol_hogar[t] * 1e-6
        + m.bat_hogar[t] * 1e-6
        for t in m.T)
model.objetivo = pyo.Objective(rule=obj_rule, sense=pyo.minimize)

# =====
# 3. RESOLUCIÓN
# =====
pyo.SolverFactory('glpk').solve(model)

# =====
# 4. CÁLCULO DE COSTES POR ESCENARIO
# =====
# A: Caso base (solo red, sin instalación)
total_A = (df['Demanda'] * df['P_Compra']).sum()
```

```
# B: Solo paneles (sin batería); el excedente se vierte
compra_B = (df['Demanda'] - df['Solar']).clip(lower=0) * df['P_Compra']
venta_B = (df['Solar'] - df['Demanda']).clip(lower=0) * df['P_Venta']
total_B = (compra_B - venta_B).sum()

# C: Inversor real (a partir de los datos medidos en 2025)
total_C = (df['Red_C'] * df['P_Compra'] - df['Venta_C'] * df['P_Venta']).sum()

# D: Modelo de optimización (coste neto a partir de los flujos óptimos)
total_D = sum((pyo.value(model.red_hogar[t]) + pyo.value(model.red_bat[t])) * df['P_Compra'][t]
              - pyo.value(model.sol_red[t]) * df['P_Venta'][t] for t in model.T)

print("RESUMEN ECONÓMICO ANUAL (2025)")
print(f"A - Caso base (solo red) : {total_A:8.2f} €")
print(f"B - Solo paneles : {total_B:8.2f} €")
print(f"C - Inversor real : {total_C:8.2f} €")
print(f"D - Optimización (techo) : {total_D:8.2f} €")
print(f"Ahorro D frente a C : {total_C - total_D:8.2f} € "
      f"({(total_C - total_D) / total_C * 100:.1f} %)")
```

Código 3. Modelo de optimización lineal anual

4. Modelo con horizonte deslizante (2025)

Versión realista del modelo. Resuelve el problema día a día empleando únicamente la información de cada jornada, y traslada el estado de carga final de cada día como condición inicial del siguiente. Aplicado sobre los datos reales de 2025, permite compararlo con el inversor real y con el techo teórico.

```

"""
=====
COMPROBACIÓN DEL MODELO: HORIZONTE DESLIZANTE vs TECHO TEÓRICO (2025)
=====
Aplica el modelo de horizonte deslizante (rolling 24 h) sobre los datos
reales de 2025 y compara su resultado con el del techo teórico (optimización
con conocimiento perfecto del año) y con el inversor real. La diferencia
entre el rolling y el techo cuantifica el coste de no conocer el futuro.
=====
"""

import pandas as pd
import pyomo.environ as pyo
from google.colab import drive
import os

# =====
# 1. ENTORNO Y DATOS
# =====
if os.system('glpk --version') != 0:
    os.system('apt-get install -y -qq glpk-utils')

drive.mount('/content/drive', force_remount=True)
df_raw = pd.read_excel('/content/drive/MyDrive/TFG/datos.xlsx')
df_raw.columns = df_raw.columns.str.strip()

df = df_raw.rename(columns={
    'Demanda real (kWh)': 'Demanda',
    'Producción paneles (kWh)': 'Solar',
    'Precios consumo (€/kWh)': 'P_Compra',
    'Precio vertido (€/kWh)': 'P_Venta',
    'Consumo de red (kWh)': 'Red_C',
    'Vertido (kWh)': 'Venta_C'
}).copy()
df = df.dropna(subset=['P_Compra', 'P_Venta', 'Demanda', 'Solar']).reset_index(drop=True)
df['FechaID'] = pd.to_datetime(df['Dia']).dt.date
dias_unicos = df['FechaID'].unique()

# =====
# 2. OPTIMIZACIÓN DE UN DÍA (24 h)
# =====
def optimizar_dia(df_dia, soc_inicial):
    m = pyo.ConcreteModel()
    m.T = pyo.Set(initialize=df_dia.index)
    m.dem = pyo.Param(m.T, initialize=df_dia['Demanda'].to_dict())
    m.sol = pyo.Param(m.T, initialize=df_dia['Solar'].to_dict())
    m.pc = pyo.Param(m.T, initialize=df_dia['P_Compra'].to_dict())
    m.pv = pyo.Param(m.T, initialize=df_dia['P_Venta'].to_dict())
    m.Ef = pyo.Param(initialize=1)
    m.SOC0 = pyo.Param(initialize=soc_inicial)

    m.sol_hogar = pyo.Var(m.T, domain=pyo.NonNegativeReals)
    m.sol_bat = pyo.Var(m.T, domain=pyo.NonNegativeReals)
    m.sol_red = pyo.Var(m.T, domain=pyo.NonNegativeReals)
    m.red_hogar = pyo.Var(m.T, domain=pyo.NonNegativeReals)

```

```

m.red_bat = pyo.Var(m.T, domain=pyo.NonNegativeReals)
m.bat_hogar = pyo.Var(m.T, domain=pyo.NonNegativeReals)
m.soc = pyo.Var(m.T, bounds=(0, 3.0))

t_list = list(df_dia.index); t0 = t_list[0]

m.c_dem = pyo.Constraint(m.T, rule=lambda m, t:
    m.sol_hogar[t] + m.red_hogar[t] + m.bat_hogar[t] == m.dem[t])
m.c_sol = pyo.Constraint(m.T, rule=lambda m, t:
    m.sol_hogar[t] + m.sol_bat[t] + m.sol_red[t] == m.sol[t])
def soc_bal(m, t):
    carga = m.sol_bat[t] + m.red_bat[t]; descarga = m.bat_hogar[t]
    if t == t0:
        return m.soc[t] == m.SOC0 + (carga * m.Ef) - (descarga / m.Ef)
    return m.soc[t] == m.soc[t-1] + (carga * m.Ef) - (descarga / m.Ef)
m.c_soc = pyo.Constraint(m.T, rule=soc_bal)
m.c_lim_c = pyo.Constraint(m.T, rule=lambda m, t: (m.sol_bat[t] + m.red_bat[t]) <= 3.0)
m.c_lim_d = pyo.Constraint(m.T, rule=lambda m, t: m.bat_hogar[t] <= 3.0)
m.c_lim_vertido = pyo.Constraint(m.T, rule=lambda m, t:
    m.sol_red[t] <= max(0, m.sol[t] - m.dem[t]))
m.obj = pyo.Objective(
    rule=lambda m: sum((m.red_hogar[t] + m.red_bat[t]) * m.pc[t]
        - m.sol_red[t] * m.pv[t]
        - m.sol_hogar[t] * 1e-6
        + m.bat_hogar[t] * 1e-6 for t in m.T),
    sense=pyo.minimize)
pyo.SolverFactory('glpk').solve(m)
return {
    'sol_red': [pyo.value(m.sol_red[t]) for t in t_list],
    'red_hogar': [pyo.value(m.red_hogar[t]) for t in t_list],
    'red_bat': [pyo.value(m.red_bat[t]) for t in t_list],
    'soc_final': pyo.value(m.soc[t_list[-1]])
}
# =====
# 3. BUCLE ROLLING HORIZON
# =====
resultados = []
soc_actual = 0.0
for fecha in dias_unicos:
    df_dia = df[df['FechaID'] == fecha].copy()
    r = optimizar_dia(df_dia, soc_actual)
    for j, idx in enumerate(df_dia.index):
        resultados.append({
            'P_Compra': df_dia.loc[idx, 'P_Compra'],
            'P_Venta': df_dia.loc[idx, 'P_Venta'],
            'sol_red': r['sol_red'][j],
            'red_hogar': r['red_hogar'][j],
            'red_bat': r['red_bat'][j],
        })
    soc_actual = r['soc_final']
df_res = pd.DataFrame(resultados)

# =====
# 4. COMPARACIÓN: ROLLING vs INVERSOR REAL
# =====
# Coste del modelo realista (rolling 24h)
total_D_rolling = ((df_res['red_hogar'] + df_res['red_bat']) * df_res['P_Compra']
    - df_res['sol_red'] * df_res['P_Venta']).sum()

# Coste del inversor real (datos medidos)
total_C = (df['Red_C'] * df['P_Compra'] - df['Venta_C'] * df['P_Venta']).sum()

print("COMPROBACIÓN DEL MODELO REALISTA (2025)")
print(f"C - Inversor real : {total_C:8.2f} €")
print(f"D - Horizonte deslizante : {total_D_rolling:8.2f} €")
print(f"Ahorro del rolling frente a C: {total_C - total_D_rolling:8.2f} €")
print("\nNota: el techo teórico (optimización con previsión perfecta) se")
print("obtiene con el modelo anual y permite cuantificar, por diferencia,")
print("el coste de operar sin conocer el futuro.")

```

Código 4. Modelo con horizonte deslizante aplicado a 2025

5. Modelo con horizonte deslizante (proyección 2026)

Aplica el mismo modelo de horizonte deslizante sobre el año sintético de 2026. Al tratarse de un año sin datos de un inversor real, la comparación se establece únicamente entre el caso base, la instalación sin batería y el modelo optimizado.

```

"""
=====
PROYECCIÓN A 2026: MODELO CON HORIZONTE DESLIZANTE (ROLLING 24 h)
=====
Aplica el modelo de horizonte deslizante sobre el año sintético de 2026
(demanda por desplazamiento de calendario, generación de PVGIS y precios
reales de ESIOS), en el periodo del 1 de enero al 12 de junio. Al tratarse
de un año sintético sin datos de un inversor real, no existe escenario C:
la comparación se establece entre el caso base (A), la instalación sin
batería (B) y el modelo optimizado (D).
=====
"""

import pandas as pd
import pyomo.environ as pyo
from google.colab import drive
import os

# =====
# 1. ENTORNO Y DATOS (año sintético 2026)
# =====
if os.system('glpk --version') != 0:
    os.system('apt-get install -y -qq glpk-utils')

drive.mount('/content/drive', force_remount=True)
df_raw = pd.read_excel('/content/drive/MyDrive/TFG/datos_2026_finales.xlsx')
df_raw.columns = df_raw.columns.str.strip()

df = df_raw.rename(columns={
    'Demanda real (kWh)': 'Demanda',
    'Producción paneles (kWh)': 'Solar',
    'Precios consumo (€/kWh)': 'P_Compra',
    'Precio vertido (€/kWh)': 'P_Venta'
}).copy()
# Solo se conservan las horas con precios reales disponibles (1 ene - 12 jun)
df = df.dropna(subset=['P_Compra', 'P_Venta', 'Demanda', 'Solar']).reset_index(drop=True)
df['FechaID'] = pd.to_datetime(df['Día']).dt.date
dias_unicos = df['FechaID'].unique()

# =====
# 2. OPTIMIZACIÓN DE UN DÍA (24 h)
# =====
def optimizar_dia(df_dia, soc_inicial):
    m = pyo.ConcreteModel()
    m.T = pyo.Set(initialize=df_dia.index)
    m.dem = pyo.Param(m.T, initialize=df_dia['Demanda'].to_dict())
    m.sol = pyo.Param(m.T, initialize=df_dia['Solar'].to_dict())
    m.pc = pyo.Param(m.T, initialize=df_dia['P_Compra'].to_dict())
    m.pv = pyo.Param(m.T, initialize=df_dia['P_Venta'].to_dict())
    m.Ef = pyo.Param(initialize=1)
    m.SOC0 = pyo.Param(initialize=soc_inicial)

    m.sol_hogar = pyo.Var(m.T, domain=pyo.NonNegativeReals)
    m.sol_bat = pyo.Var(m.T, domain=pyo.NonNegativeReals)
    m.sol_red = pyo.Var(m.T, domain=pyo.NonNegativeReals)
    m.red_hogar = pyo.Var(m.T, domain=pyo.NonNegativeReals)
    m.red_bat = pyo.Var(m.T, domain=pyo.NonNegativeReals)
    m.bat_hogar = pyo.Var(m.T, domain=pyo.NonNegativeReals)

```

```

m.soc      = pyo.Var(m.T, bounds=(0, 3.0))

t_list = list(df_dia.index); t0 = t_list[0]

m.c_dem = pyo.Constraint(m.T, rule=lambda m, t:
    m.sol_hogar[t] + m.red_hogar[t] + m.bat_hogar[t] == m.dem[t])
m.c_sol = pyo.Constraint(m.T, rule=lambda m, t:
    m.sol_hogar[t] + m.sol_bat[t] + m.sol_red[t] == m.sol[t])
def soc_bal(m, t):
    carga = m.sol_bat[t] + m.red_bat[t]; descarga = m.bat_hogar[t]
    if t == t0:
        return m.soc[t] == m.SOC0 + (carga * m.Ef) - (descarga / m.Ef)
    return m.soc[t] == m.soc[t-1] + (carga * m.Ef) - (descarga / m.Ef)
m.c_soc = pyo.Constraint(m.T, rule=soc_bal)
m.c_lim_c = pyo.Constraint(m.T, rule=lambda m, t: (m.sol_bat[t] + m.red_bat[t]) <= 3.0)
m.c_lim_d = pyo.Constraint(m.T, rule=lambda m, t: m.bat_hogar[t] <= 3.0)
m.c_lim_vertido = pyo.Constraint(m.T, rule=lambda m, t:
    m.sol_red[t] <= max(0, m.sol[t] - m.dem[t]))
m.obj = pyo.Objective(
    rule=lambda m: sum((m.red_hogar[t] + m.red_bat[t]) * m.pc[t]
        - m.sol_red[t] * m.pv[t]
        - m.sol_hogar[t] * 1e-6
        + m.bat_hogar[t] * 1e-6 for t in m.T),
    sense=pyo.minimize)
pyo.SolverFactory('glpk').solve(m)
return {
    'sol_red': [pyo.value(m.sol_red[t]) for t in t_list],
    'red_hogar': [pyo.value(m.red_hogar[t]) for t in t_list],
    'red_bat': [pyo.value(m.red_bat[t]) for t in t_list],
    'soc_final': pyo.value(m.soc[t_list[-1]])
}

# =====
# 3. BUCLE ROLLING HORIZON
# =====
resultados = []
soc_actual = 0.0
for fecha in dias_unicos:
    df_dia = df[df['FechaID'] == fecha].copy()
    r = optimizar_dia(df_dia, soc_actual)
    for j, idx in enumerate(df_dia.index):
        resultados.append({
            'P_Compra': df_dia.loc[idx, 'P_Compra'],
            'P_Venta': df_dia.loc[idx, 'P_Venta'],
            'Demanda': df_dia.loc[idx, 'Demanda'],
            'Solar': df_dia.loc[idx, 'Solar'],
            'sol_red': r['sol_red'][j],
            'red_hogar': r['red_hogar'][j],
            'red_bat': r['red_bat'][j],
        })
    soc_actual = r['soc_final']
df_res = pd.DataFrame(resultados)

# =====
# 4. COSTES POR ESCENARIO (A, B, D - sin C)
# =====
total_A = (df_res['Demanda'] * df_res['P_Compra']).sum()

compra_B = (df_res['Demanda'] - df_res['Solar']).clip(lower=0) * df_res['P_Compra']
venta_B = (df_res['Solar'] - df_res['Demanda']).clip(lower=0) * df_res['P_Venta']
total_B = (compra_B - venta_B).sum()

total_D = ((df_res['red_hogar'] + df_res['red_bat']) * df_res['P_Compra']
    - df_res['sol_red'] * df_res['P_Venta']).sum()

print("PROYECCIÓN 2026 (1 enero - 12 junio)")
print(f"A - Caso base (solo red) : {total_A:8.2f} €")
print(f"B - Solo paneles : {total_B:8.2f} €")
print(f"D - Optimización rolling : {total_D:8.2f} €")
print(f"Ahorro D frente a A : {total_A - total_D:8.2f} € ")

```

ANEXO II. CÓDIGO FUENTE

```
f"({(total_A - total_D) / total_A * 100:.1f} %)"  
print(f"Ahorro D frente a B      : {total_B - total_D:8.2f} € "  
f"({(total_B - total_D) / total_B * 100:.1f} %)")
```

Código 5. Modelo con horizonte deslizando aplicado a la proyección de 2026

ANEXO III. DESCRIPCIÓN DE LOS ARCHIVOS DE DATOS

Este anexo describe la estructura de los archivos de datos empleados en el trabajo. Por su volumen (un registro por cada hora del año, 8 760 filas), el contenido de los archivos no se reproduce aquí; en su lugar se detalla el significado de cada una de sus columnas. Se han utilizado dos archivos: uno con los datos reales de 2025 y otro con los datos sintéticos de 2026. No todas las columnas se utilizan en el archivo de datos reales de 2025, pero sirven para entender el problema y poder dividir casos. Son columnas que fueron muy útiles para la parte 1 del proyecto de análisis y tratamiento de datos.

1. Archivo de datos reales de 2025 (datos.xlsx)

Contiene el registro horario real de la instalación durante 2025, obtenido a partir de las mediciones del inversor, junto con los precios horarios de la electricidad y una serie de columnas de cálculo empleadas en el análisis de los distintos escenarios. Sus columnas son las siguientes:

Día: fecha del registro.

Hora: hora del día, de 1 a 24.

Producción paneles (kWh): energía generada por los paneles fotovoltaicos en esa hora.

Batería carga de paneles (kWh): energía con la que los paneles han cargado la batería.

Batería descarga en consumo (kWh): energía que la batería ha entregado al consumo de la vivienda.

Batería carga de red (kWh): energía con la que la red ha cargado la batería.

Consumo de red (kWh): energía total tomada de la red en esa hora.

Demanda real (kWh): demanda eléctrica de la vivienda, reconstruida por balance energético a partir de los flujos del sistema.

Estado batería (kWh): estado de carga de la batería al final de la hora.

ANEXO III. DESCRIPCIÓN DE LOS ARCHIVOS DE DATOS

Vertido (kWh): energía excedentaria vertida a la red.

Precios consumo (€/kWh): precio de compra de la electricidad (PVPC) en esa hora.

Precio vertido (€/kWh): precio de compensación de los excedentes vertidos a la red en esa hora.

Coste acum con todo (€): coste acumulado del escenario real (con paneles y batería), sumando hora a hora.

Consumo solo Red (kWh): energía que la vivienda tomaría de la red en el escenario A, sin instalación.

Consumo Red habiendo paneles (kWh): energía tomada de la red en el escenario B, con paneles, pero sin batería.

Consumo Red, puro hogar, habiendo todo (kWh): energía tomada de la red destinada exclusivamente al consumo del hogar, en el escenario con paneles y batería.

Consumo Red, carga bat, habiendo todo (kWh): energía tomada de la red destinada a cargar la batería, en el escenario con paneles y batería.

Aportacion paneles a consumo (kWh): parte de la demanda cubierta directamente por los paneles.

Aportación batería a consumo (kWh): parte de la demanda cubierta por la descarga de la batería.

Carga bat con paneles (kWh): energía con la que los paneles cargan la batería.

Coste Coste/h solo consumo: coste horario del escenario A (solo red).

Coste Carga/h paneles: coste horario del escenario B (con paneles).

Vertida caso B: energía vertida a la red en el escenario B (paneles sin batería).

Coste Carga/h paneles + bat: coste horario del escenario con paneles y batería.

Coste acum solo consumo (€): coste acumulado del escenario A a lo largo del año.

Coste acum paneles (€): coste acumulado del escenario B a lo largo del año.

Costo acum paneles + batería (€): coste acumulado del escenario con paneles y batería a lo largo del año.

2. Archivo de datos sintéticos de 2026 (datos_2026_finales.xlsx)

Contiene el año sintético construido para la proyección de 2026, con las columnas estrictamente necesarias para alimentar el modelo:

Día: fecha del registro.

Hora: hora del día, de 1 a 24.

Producción paneles (kWh): generación fotovoltaica horaria, obtenida de la herramienta PVGIS para la ubicación y características de la instalación.

Demanda real (kWh): demanda de la vivienda, construida mediante desplazamiento de calendario a partir de los datos reales de 2025.

Precios consumo (€/kWh): precio de compra de la electricidad (PVPC), obtenido de ESIOS para las fechas con datos reales disponibles (del 1 de enero al 12 de junio de 2026).

Precio vertido (€/kWh): precio de compensación de los excedentes vertidos a la red, obtenido igualmente de ESIOS para el mismo periodo.

A diferencia del archivo de 2025, este no contiene columnas de flujos de batería ni de consumo desde la red, ya que dichos flujos no proceden de un inversor real, sino que son precisamente el resultado que el modelo de optimización calcula.

ANEXO IV. MANUAL DE USO DE PYOMO/COLAB

Este anexo describe las herramientas empleadas en la implementación del modelo y proporciona una guía de uso pensada para un lector que no esté familiarizado con el entorno Google Colab ni con la librería de optimización Pyomo. El objetivo es que cualquier persona pueda comprender cómo está construido el programa y reproducir su ejecución.

1. Entorno de ejecución: Google Colab

Google Colab (Colaboratory) es un servicio gratuito de Google que permite escribir y ejecutar código Python directamente en el navegador, sin necesidad de instalar nada en el ordenador. El código se organiza en celdas que se ejecutan de forma independiente, y los cálculos se realizan en servidores de Google, sin depender por lo tanto de la potencia del ordenador ni de problemas en la instalación de herramientas.

Se eligió Colab por tres motivos principales: no requiere instalación local, incorpora ya instaladas la mayoría de las librerías científicas de Python y permite conectar directamente con Google Drive para leer y guardar archivos mientras que también se puede trabajar desde cualquier sitio.

Nociones básicas de uso:

Una celda de código se ejecuta pulsando el botón de reproducción situado a su izquierda, o con la combinación de teclas Mayúsculas + Intro. Las celdas deben ejecutarse en orden, ya que las variables definidas en una quedan disponibles para las siguientes.

La conexión con Google Drive se realiza mediante las dos líneas iniciales del programa, que montan el disco del usuario en el entorno. Al ejecutarlas, Colab solicita autorización para acceder a la cuenta de Google y, una vez concedida, los archivos del Drive quedan accesibles como si fueran carpetas locales:

```
from google.colab import drive
drive.mount('/content/drive')
```

A partir de ese momento, un archivo guardado en Drive se referencia mediante su ruta, por ejemplo `'/content/drive/MyDrive/TFG/datos.xlsx'`.

2. Librerías empleadas

El programa se apoya en tres librerías principales de Python:

Pandas [21] es la librería estándar para el manejo de datos en forma de tabla. Se utiliza para leer el archivo Excel con los datos horarios, organizar la información en una estructura llamada DataFrame y realizar operaciones sobre columnas completas, como sumar costes o filtrar por fechas. Una columna del DataFrame se comporta como una lista de valores sobre la que se pueden hacer cálculos de forma directa.

Pyomo [6], [7] es la librería de modelado de optimización, en torno a la cual gira todo el trabajo. Permite expresar un problema de optimización (variables, restricciones y función objetivo) en lenguaje Python, de una forma muy próxima a su formulación matemática, y enviarlo después al solver para su resolución. Se describe en detalle en el apartado siguiente.

GLPK (GNU Linear Programming Kit) [20] es el solver, es decir, el motor matemático que resuelve efectivamente el problema de programación lineal planteado con Pyomo. Pyomo no resuelve el problema por sí mismo, sino que lo traslada a GLPK, que aplica los algoritmos de optimización y devuelve la solución. Al no venir preinstalado en Colab, el programa lo instala automáticamente en su primera línea mediante una orden del sistema.

3. Estructura de un modelo en Pyomo

Un modelo de optimización en Pyomo se construye siempre con los mismos elementos, que se corresponden de forma directa con los componentes de un problema de programación

matemática. A continuación, se explican con los nombres y funciones tal como aparecen en el código de este trabajo.

El modelo se inicializa creando un objeto que contendrá todos los elementos:

```
model = pyo.ConcreteModel()
```

El conjunto es el índice sobre el que se define el problema. En este trabajo, el conjunto representa las horas del periodo analizado, de modo que cada variable y cada restricción existirá una vez por cada hora:

```
model.T = pyo.Set(initialize=df.index)
```

Los parámetros son los datos de entrada, valores conocidos y fijos que el modelo no puede modificar. En este caso son la demanda, la generación solar y los precios de compra y venta de cada hora:

```
model.dem = pyo.Param(model.T, initialize=df['Demanda'].to_dict())
```

Las variables de decisión son las incógnitas que el solver debe determinar. Aquí representan los flujos de energía entre los elementos del sistema (paneles, batería, red y hogar) en cada hora. Se declaran como no negativas, ya que la energía no puede fluir en sentido contrario al definido:

```
model.sol_hogar = pyo.Var(model.T, domain=pyo.NonNegativeReals)
```

Las restricciones son las condiciones que toda solución debe cumplir: los balances de energía, los límites de potencia y capacidad de la batería y la restricción regulatoria de vertido. Cada restricción se define mediante una regla que se aplica a cada hora del conjunto:

```
model.c_dem = pyo.Constraint(model.T, rule=lambda m, t:  
m.sol_hogar[t] + m.red_hogar[t] + m.bat_hogar[t] == m.dem[t])
```

La función objetivo es la expresión que el solver debe minimizar; en este trabajo, el coste neto de la energía a lo largo de todo el periodo:

```
model.objetivo = pyo.Objective(rule=obj_rule, sense=pyo.minimize)
```

Finalmente, la resolución se invoca indicando el solver que debe emplearse:

```
pyo.SolverFactory('glpk').solve(model)
```

Una vez resuelto el modelo, el valor óptimo de cada variable se consulta con la función `pyo.value()`, que devuelve el número calculado por el solver para esa variable en una hora concreta:

```
energia = pyo.value(model.sol_hogar[t])
```

4. Funciones y construcciones principales utilizadas

Además de los elementos propios de Pyomo, el programa emplea algunas construcciones de Python y pandas que conviene conocer para seguir el código.

La lectura de datos se realiza con `pd.read_excel(ruta)`, que carga el contenido de un archivo Excel en un DataFrame. A continuación, `df.rename()` asigna nombres cortos y manejables a las columnas, y `df.dropna()` descarta las filas que no contienen datos completos.

Las reglas de las restricciones y de la función objetivo se escriben con frecuencia mediante expresiones lambda, que son funciones sin nombre y compactas. Por ejemplo, la expresión lambda `m, t: ...` define la regla que se aplicará a cada hora `t` del modelo `m`.

La función `sum()` recorre todas las horas del conjunto y acumula una expresión, lo que permite escribir sumas sobre el periodo completo, como el coste total a minimizar, de forma análoga al sumatorio de la formulación matemática.

En el modelo de horizonte deslizante, el programa no resuelve un único problema, sino uno por cada día, dentro de un bucle `for` que recorre las fechas. El estado de carga final de cada día se almacena en una variable y se transmite como dato inicial del día siguiente, encadenando así las soluciones.

5. Fuentes de datos

El programa se nutre de tres fuentes de datos de entrada. Los precios horarios de compra y de compensación de excedentes se obtienen de la plataforma ESIOS de Red Eléctrica de España [5]. La generación fotovoltaica del año sintético de 2026 procede de la herramienta PVGIS de la Comisión Europea [8]. Por último, el registro horario de demanda, generación y flujos reales de la instalación durante 2025 se encuentra en el archivo Excel de datos, elaborado a partir de las mediciones del propio sistema.

6. Pasos para ejecutar el programa

Para reproducir la ejecución del modelo, basta con seguir estos pasos:

En primer lugar, debe disponerse del archivo de datos (por ejemplo, datos.xlsx) en una carpeta de Google Drive, y ajustar en el código la ruta a dicha carpeta. A continuación, se abre el cuaderno en Google Colab y se ejecutan las celdas en orden, comenzando por la que instala el solver y monta el Drive. Colab solicitará autorización para acceder a la cuenta de Google, que debe concederse. Una vez ejecutadas todas las celdas, el programa muestra por pantalla el coste de cada escenario y, en el caso del modelo de horizonte deslizante, guarda los resultados horarios en un nuevo archivo Excel en la misma carpeta de Drive. Durante la elaboración del TFG, se hacía un print de todos los resultados hora por hora, pero esto suponía un gran aumento de líneas de código y un gran incremento en el tiempo de ejecución, por lo que se ha decidido quitar para reducir el espacio y, además, ya se han demostrado y comentado ejemplos de días tipo.

El tiempo de cálculo es reducido al ser un solver no lineal y no tener que imprimir resultados hora por hora. El modelo anual completo se resuelve en pocos segundos, mientras que el modelo de horizonte deslizante, al resolver un problema independiente por cada día del periodo, tarda algo más.

ANEXO V. USO IA EN ESTE PROYECTO

Cumpliendo con las directrices sobre la transparencia en el uso de herramientas de inteligencia artificial en el TFG, se declara a continuación el uso que se ha hecho de estas herramientas durante la elaboración del presente trabajo, así como el alcance y los límites de dicha asistencia.

Las herramientas de inteligencia artificial se han empleado como apoyo puntual en tres ámbitos concretos, siempre bajo la supervisión, el criterio y la revisión del autor, que asume toda la responsabilidad sobre el contenido del trabajo.

En primer lugar, se han utilizado como apoyo a la redacción. En determinados párrafos, la herramienta ha contribuido a corregir errores gramaticales y de estilo y a mejorar la claridad y la fluidez de la expresión. En todos los casos, las ideas, los argumentos y las conclusiones son originales del autor y el texto resultante ha sido revisado y validado por el autor también para por supuesto asegurar que se refleja fielmente su intención y su razonamiento y que los cambios han sido tan solo de redacción.

En segundo lugar, se ha empleado como ayuda en la generación de algunas de las figuras del documento, facilitando su elaboración a partir de los datos y los criterios definidos por el autor. Al aportar con los resultados obtenidos de los códigos, se pudieron generar gráficas de manera sencilla.

En tercer lugar, se ha usado como apoyo en determinadas tareas de programación. Esta asistencia ha estado en todo momento estrechamente monitorizada y ha sido revisada de forma exhaustiva por el autor, que ha verificado el correcto funcionamiento del código y la validez de los resultados obtenidos, asegurándose sobre todo que el código ejecuta hace exactamente lo que se busca. El apoyo fue más relevante en los scripts de generación de los datos sintéticos de 2026, tanto en la construcción de la demanda como en la obtención de la generación solar. Al no disponer de información detallada de la instalación para ese año, la herramienta ayudó a

obtener dichos datos tomando como base los parámetros de la instalación real estudiada vistos en el 3.8.

En ningún caso se ha empleado la inteligencia artificial para generar conclusiones, interpretar resultados o tomar decisiones metodológicas, tareas que han correspondido en su totalidad al autor con ayuda del director del proyecto. El uso de estas herramientas se ha limitado a un papel de asistencia y apoyo y todo el contenido del trabajo ha sido comprendido, revisado y asumido como propio.

Declaración de originalidad

Declaro bajo mi responsabilidad que el Proyecto presentado con el título **Programación matemática para la optimización de la gestión de una batería en una instalación fotovoltaica de autoconsumo** e la ETS de Ingeniería – ICAI de la Universidad Pontificia Comillas en el curso académico **cuarto del Grado de Ingeniería en Tecnologías Industriales (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 Artificial²

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:

Las herramientas de inteligencia artificial se han empleado como apoyo puntual en tres ámbitos concretos, siempre bajo la supervisión, el criterio y la revisión del autor, que asume toda la responsabilidad sobre el contenido del trabajo.

En primer lugar, se han utilizado como apoyo a la redacción. En determinados párrafos, la herramienta ha contribuido a corregir errores gramaticales y de estilo y a mejorar la claridad y la fluidez de la expresión. En todos los casos, las ideas, los argumentos y las conclusiones son originales del autor y el texto resultante ha sido revisado y validado por el autor también para por supuesto asegurar que se refleja fielmente su intención y su razonamiento y que los cambios han sido tan solo de redacción.

² 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...)

En segundo lugar, se ha empleado como ayuda en la generación de algunas de las figuras del documento, facilitando su elaboración a partir de los datos y los criterios definidos por el autor. Al aportar con los resultados obtenidos de los códigos, se pudieron generar gráficas de manera sencilla.

En tercer lugar, se ha usado como apoyo en determinadas tareas de programación. Esta asistencia ha estado en todo momento estrechamente monitorizada y ha sido revisada de forma exhaustiva por el autor, que ha verificado el correcto funcionamiento del código y la validez de los resultados obtenidos, asegurándose sobre todo que el código ejecuta hace exactamente lo que se busca. El apoyo fue más relevante en los scripts de generación de los datos sintéticos de 2026, tanto en la construcción de la demanda como en la obtención de la generación solar. Al no disponer de información detallada de la instalación para ese año, la herramienta ayudó a obtener dichos datos tomando como base los parámetros de la instalación real estudiada vistos en el 3.8.

En ningún caso se ha empleado la inteligencia artificial para generar conclusiones, interpretar resultados o tomar decisiones metodológicas, tareas que han correspondido en su totalidad al autor con ayuda del director del proyecto. El uso de estas herramientas se ha limitado a un papel de asistencia y apoyo y todo el contenido del trabajo ha sido comprendido, revisado y asumido como propio.



Firmado (alumno): José Antonio Álvarez Solanas

Fecha: 23/6/2026

Autorización para la entrega del Proyecto

ANEXO V. USO IA EN ESTE PROYECTO

<i>El Director del Proyecto</i>	<i>El co-Director del Proyecto (si aplica)</i>
 <p>Fdo. José Luis Sancha Gonzalo</p>	
Fdo: José Luis Sancha Gonzalo	Fdo:
Fecha: 23 de junio de 2026	Fecha: