



Universidad
Zaragoza

Trabajo Fin de Grado

Diseño y Optimización de una Cámara de Secado
mediante un Gemelo Digital

Design and Optimization of a Drying Chamber as a
Cold Battery Using a Digital Twin

Autor

Yasin Mebrour Ezzahraoui

Director

Julio A. Sangüesa Escorihuela

ESCUELA UNIVERSITARIA POLITÉCNICA
TERUEL (UNIVERSIDAD DE ZARAGOZA)
2025

AGRADECIMIENTOS

Quisiera expresar mi más sincero agradecimiento a todas las personas e instituciones que han hecho posible la realización de este trabajo.

A mi madre, mi padre, mi hermano y mi hermana, por su cariño incondicional, su apoyo constante y por confiar siempre en mí.

A mi pareja, por acompañarme a lo largo de toda esta travesía, por su paciencia, comprensión y aliento en los momentos más exigentes.

Al grupo de investigación Smart Data and Networks, por su implicación, orientación y ayuda técnica, fundamentales para el desarrollo de este proyecto.

A Quesos Hontanar, por brindarme la oportunidad de realizar el Trabajo Fin de Grado con ellos, por confiar en mí y proporcionarme todos los recursos necesarios.

A mi director de TFG, por su dedicación, guía y disponibilidad durante todo el proceso.

Y a mis compañeros del curso, por el compañerismo, el apoyo mutuo y por compartir esta etapa académica.

A todos, gracias.

RESUMEN

La electricidad es uno de los recursos más importantes en la sociedad actual. Su uso eficiente no solo reduce costes, sino que también ayuda a limitar el impacto ambiental. En un momento en el que los precios de la energía varían a lo largo del día y la demanda sigue creciendo, contar con sistemas que permitan balancear y reducir el consumo se vuelve cada vez más necesario.

En los entornos industriales, las cámaras de frío y de secado juegan un papel clave en la producción y mantenimiento de muchos productos. Se trata de equipos que consumen una cantidad considerable de energía, por lo que mejorar su gestión puede suponer un ahorro importante. Actualmente, este control suele hacerse de forma manual, basándose en la experiencia del operario o en horarios fijos, sin tener en cuenta el estado real del sistema ni los cambios en el precio de la electricidad. Aunque existen herramientas que permiten ver el estado de la cámara, pocas ayudan a planificar el funcionamiento de forma automática y adaptada a cada situación.

Este trabajo presenta un sistema digital conectado a la cámara de secado, que permite planificar su funcionamiento teniendo en cuenta el precio de la luz, el estado de la cámara, las tarifas contratadas y el consumo general de la planta. Para lograrlo, se ha usado un modelo que aprende a partir de datos reales y es capaz de anticipar cómo se comportará la cámara en las próximas horas.

Además de planificar el uso de energía, el sistema permite monitorizar su estado, detectar fallos y guardar un historial completo del funcionamiento. El modelo utilizado combina distintos tipos de predicción y consigue un error medio entre el 5 y el 10 % para un día completo.

Las pruebas realizadas muestran que el sistema puede reducir el gasto energético de la cámara hasta en un 35 %, tanto en simulaciones como en pruebas reales.

PALABRAS CLAVE

Ahorro energético, Gemelo digital, Cámara de secado, Predicción, Planificación, Supervisión, Detección de fallos.

ABSTRACT

Electricity is one of the most important resources in modern society. Using it efficiently not only reduces costs but also helps mitigate environmental impact. As energy prices fluctuate throughout the day and demand continues to grow, systems that help balance and reduce consumption are becoming increasingly necessary.

In industrial settings, drying and refrigeration chambers play a key role in the production and preservation of many products. These systems consume a significant amount of energy, so improving their management can lead to substantial savings. Currently, control is often performed manually, based on the operator's experience or fixed schedules, without considering the actual state of the system or variations in electricity prices. Although some tools allow the monitoring of the chamber's status, few offer automated and adaptive operation planning.

This work presents a digital system connected to the drying chamber, capable of planning its operation based on electricity prices, the internal state of the chamber, contracted tariffs, and the overall consumption of the plant. To achieve this, a model has been employed that learns from real data and can anticipate the chamber's behavior over the coming hours.

In addition to energy planning, the system enables remote monitoring, fault detection, and the storage of a complete operational history. The model combines different types of predictive strategies and achieves an average error between 5% and 10% over a full 24-hour period.

Experimental results show that the system can reduce the energy consumption of the drying chamber by up to 35%, both in simulations and real-world tests.

KEYWORDS

Energy saving, Digital twin, Drying chamber, Prediction, Planning, Monitoring, Fault detection.

Tabla de Contenidos

1. Introducción, motivación y objetivos	1
1.1. Introducción	1
1.2. Motivación	3
1.3. Objetivos	4
2. Estado del arte	6
2.1. Gemelos digitales en entornos industriales	6
2.2. Protocolos de comunicación HMI-PLC	7
2.3. Modelos de predicción de condiciones ambientales	8
3. Gemelo digital camara de secado	9
3.1. Arquitectura general del sistema	9
3.1.1. Comunicacion PLC	11
3.1.2. Base de datos InfluxDB	13
3.2. Predicción del comportamiento del sistema	14
3.3. Backend del sistema	15
3.3.1. FastAPI	15
3.3.2. Celery, Redis y tareas en segundo plano	16
3.3.3. Monitorización continua y gestión de eventos	17
3.3.4. Módulo de inferencia	17
3.3.5. Seguridad e Identidad	18

3.3.6.	Base de datos PostgreSQL	18
3.4.	Interfaz web del sistema	19
3.4.1.	Gemelo digital	21
3.4.2.	Planificador	22
3.4.3.	Dashboard	23
3.4.4.	Configuración	23
3.4.5.	Gestión de acceso y roles de usuario	24
4.	Módulo de predicción	26
4.1.	Análisis Exploratorio de los Datos	26
4.1.1.	Análisis de la función de autocorrelación sobre la variable humedad	30
4.1.2.	Análisis del periodograma sobre la variable humedad	32
4.2.	Entrenamiento del modelo	34
4.3.	Evaluación del modelo	37
4.4.	Conclusion	42
5.	Resultados y Validación	44
5.1.	Impacto de la Optimización sobre el Consumo y el Coste Energético . .	44
5.2.	Evolución Mensual del Coste Eléctrico	46
5.3.	Supervisión Operativa y Detección de Eventos	48
6.	Conclusiones	50
7.	Bibliografía	51
	Anexos	53

I. Anexo I: Criterios de selección de la variable humedad	54
II. Entorno de entrenamiento	56
III. Endpoints Backend	57
IV. Manual de Usuario	60

Lista de Figuras

1.	Arquitectura de red del sistema	9
2.	Tráfico de red, comunicación mediante protocolo FINS	12
3.	Mapa de calor del consumo durante toda la semana.	16
4.	Interfaz del planificador del modo ahorro.	19
5.	Interfaz del módulo principal del gemelo digital.	20
6.	Depuración de Consumo (IQR y runs constantes)	27
7.	Depuración de Humedad (IQR y runs constantes)	27
8.	Depuración de Temperatura (IQR y runs constantes)	28
9.	Número de registros por día	28
10.	Consumo tras depuración, re-muestreo e interpolación	29
11.	Humedad tras depuración, re-muestreo e interpolación	29
12.	Temperatura tras depuración, re-muestreo e interpolación	29
13.	Autocorrelacion 6 horas	30
14.	Autocorrelacion 24 horas	31
15.	Relacion humedad modo ahorro 24 horas entre semana	32
16.	Periodograma de la humedad (18-04-2025, día laborable con modo ahorro).	33
17.	Periodograma de la humedad (19-04-2025, día sin modo ahorro).	33
18.	Esquema del proceso de <i>boosting</i> en XGBoost	36
19.	Consumo medio horario: comparación entre datos reales y predicción (modelo inicial).	38

20.	Comparación de consumo predicho y real	41
21.	Comparación de consumo predicho y real en kWh agrupado por hora	42
22.	Interfaz de selección de franjas horarias para la planificación de consumo energético.	44
23.	Comparativa del coste energético diario bajo distintas planificaciones: actual, optimizada y sin modo ahorro.	45
24.	Relación entre precios horarios de energía y priorización del algoritmo de optimización en presencia de peajes.	45
25.	Distribución horaria del coste energético para las tres estrategias de planificación: actual, optimizada y personalizada.	46
26.	Comparativa mensual de coste eléctrico horario: consumo real vs optimizado	47
27.	Periodo sin datos registrado debido a fallo de comunicación con el PLC.	48
28.	Comparativa entre la interfaz HMI original y su réplica digitalizada.	49
29.	Evolución normalizada de humedad, temperatura y consumo.	54
30.	Gemelo Digital.	60
31.	Gemelo Digital, Scrol Inferior.	60
32.	Planificador Diario.	63
33.	Planificador Semanal.	64
34.	Planificador Optimizado.	65
35.	Dashboard.	67
36.	Configuración Tarifas y Peajes.	69
37.	Configuración Usuarios.	71
38.	Configuración Eventos.	72

39. Configuración de Predicciones.	74
--	----

Lista de Tablas

1. Direcciones de memoria asociadas a los slots de programación por día . 13
2. Comparación de métricas de rendimiento para los modelos evaluados en el conjunto de validación. 43

Capítulo 1 Introducción, motivación y objetivos

1.1. Introducción

La electricidad desempeña un papel fundamental en la vida cotidiana y en el funcionamiento de los sistemas industriales modernos. Su disponibilidad condiciona no solo la actividad cotidiana, sino también la operaciones de numerosos procesos industriales que dependen de un suministro fiable, constante y económico. En su camino hacia un modelo energético más sostenible, España está incorporando cada vez más fuentes renovables. Aunque los precios de la electricidad cambian de forma natural a lo largo del día por el equilibrio entre la oferta y la demanda, el uso creciente de energías como la solar o la eólica, que dependen del tiempo que haga, hace que estas variaciones sean aún más marcadas.

La importancia de gestionar el consumo eléctrico de forma responsable radica en la volatilidad del precio de la electricidad a lo largo del día. Esta variabilidad afecta directamente a las empresas y, en consecuencia, a los precios de los productos que llegan a la sociedad. Un uso más inteligente de la energía permite reducir costes, evitar desperdicios y aprovechar mejor los recursos disponibles, algo cada vez más necesario en un contexto donde la demanda energética sigue creciendo y la producción depende cada vez más de fuentes no constantes como el sol o el viento.

El desafío de reducir los costes operativos no se resuelve adecuadamente con los sistemas actuales. Las interfaces tradicionales (HMI, por sus siglas en inglés Human-Machine Interface) disponen únicamente de un planificador en el que se definen los períodos de activación del modo ahorro, configurados manualmente en función de los peajes asignados a cada día según las tarifas 3.0. Sin embargo, el sistema carece de una lógica inteligente que permita planificar con antelación el uso del modo ahorro, teniendo en cuenta los precios dinámicos de la electricidad o la energía disponible en las baterías.

Como consecuencia, no se aprovecha de forma óptima la energía almacenada en las baterías y tampoco se reacciona adecuadamente en situaciones críticas en las que

se produce un exceso de generación que supera los límites permitidos. Esta falta de adaptación genera ineficiencias en la planificación, que se traducen en un mayor consumo energético y, por ende, en un aumento de los costos económicos.

La implementación de una planificación inteligente permite resolver los problemas anteriormente expuestos, optimizando el uso de la energía y reduciendo el gasto asociado. Además, facilita la trazabilidad de los datos, permitiendo un análisis más preciso y detallado que, a su vez, contribuye a mejorar la calidad del producto final.

En este trabajo se plantea el desarrollo de un modelo que permita anticipar el comportamiento de una cámara de secado a partir de los datos recogidos por sensores. Esta solución se enmarca dentro del concepto de gemelo digital, entendido como una representación virtual de un sistema físico que reproduce su funcionamiento en tiempo real mediante datos y modelos predictivos. La utilidad de este enfoque radica en su capacidad para detectar desviaciones, optimizar procesos y facilitar el análisis sin intervenir directamente sobre el sistema real.

Aplicado al entorno industrial, el gemelo digital ofrece una herramienta eficaz para mejorar la planificación energética y reducir los costes operativos. Frente a los métodos tradicionales, permite anticipar situaciones críticas, evaluar diferentes escenarios de funcionamiento y realizar ajustes de forma informada. Todo ello sin necesidad de replicar las complejidades físicas exactas del sistema, sino a partir del análisis de su comportamiento observado históricamente.

Utilizar un gemelo digital en la industria del secado cobra especial relevancia debido a la variabilidad en los precios de la electricidad, influenciada por factores como la producción renovable y la demanda. Esta variabilidad afecta directamente a los costes operativos y, por tanto, a la competitividad de las empresas. Entre sus beneficios principales, destaca su capacidad para detectar fallos en tiempo real y anticiparse a posibles incidentes, permitiendo actuar de forma preventiva y evitando consecuencias más graves. Además, el gemelo digital ofrece un entorno seguro para experimentar con diferentes configuraciones sin afectar al producto real, registrando todos los cambios y acciones, lo que no solo permite realizar auditorías, sino también evaluar y justificar las mejoras implementadas en el sistema. Otro de los beneficios de un gemelo digital es la posibilidad de monitorizar la cámara de secado de forma remota, permitiendo conocer su estado en cualquier momento y desde cualquier ubicación.

Para desarrollar un gemelo digital de la cámara existen distintas aproximaciones. Una de ellas consiste en crear una simulación exacta del comportamiento físico del

sistema, teniendo en cuenta todas las variables que influyen en el proceso. Sin embargo, esta opción resulta altamente compleja y costosa, ya que requeriría conocer con precisión factores como las dimensiones de la cámara, el tipo y cantidad de producto, su estado de maduración, la evolución del producto en el tiempo, las condiciones físicas internas como temperatura y humedad en cada punto de la cámara, y otras variables ambientales o de proceso que podrían influir.

Dado que modelar físicamente todo el sistema resulta demasiado complejo, se ha optado por usar los datos recogidos por los sensores instalados en la cámara para entender su comportamiento. Estos sensores registran aspectos clave como el uso del modo ahorro, la apertura de puertas, el consumo eléctrico o la activación del ventilador, entre otros. Aunque no se puede replicar con exactitud el funcionamiento físico del sistema, sí es posible predecir su evolución y optimizar su uso mediante modelos entrenados con estos datos. Este enfoque es el que da forma al gemelo digital desarrollado.

1.2. Motivación

Las interfaces tradicionales de control energético en cámaras de secado no disponen de un sistema capaz de generar planificaciones inteligentes y optimizadas para cada día. Aunque es previsible que en los próximos años surjan versiones avanzadas que incorporen variables como los precios eléctricos u otros factores externos, la incorporación de un gemelo digital aporta ventajas adicionales. Al estar basado en datos históricos del sistema, el gemelo no solo permite una planificación más precisa, sino que además puede integrarse con el sistema tradicional sin sustituirlo, aportando funcionalidades como la monitorización remota del estado actual de la cámara.

Por otro lado, las HMI utilizadas en entornos industriales suelen tener un coste elevado y están diseñadas para gestionar múltiples sistemas de forma genérica, sin capacidades específicas de planificación inteligente adaptadas a cada tipo de proceso. Las soluciones HMI especializadas para un solo sistema, además de ser más costosas, fragmentan el control global, dificultando la centralización y supervisión unificada.

El gemelo digital propuesto está diseñado para convivir con la infraestructura centralizada existente, actuando como un módulo auxiliar que mejora las decisiones de planificación energética. Su implementación es sencilla, ya que aprovecha el protocolo de comunicación ya existente entre la HMI y el controlador de la cámara (PLC, por sus

siglas en inglés Programmable Logic Controller), y su diseño modular lo hace fácilmente adaptable a otros sistemas industriales con características similares.

1.3. Objetivos

El presente Trabajo de Fin de Grado tiene como objetivo principal el desarrollo de un sistema inteligente para la optimización del consumo eléctrico en cámaras de secado. Este sistema se basa en la capacidad de predecir el comportamiento futuro de la cámara a partir de condiciones operativas relevantes, tales como la activación del modo ahorro, los precios horarios de la electricidad, el consumo eléctrico global de la fábrica, la generación fotovoltaica y el estado de carga de las baterías.

Para ello, se plantea la implementación de un gemelo digital que represente de forma aproximada el comportamiento del sistema real. Esta réplica virtual no solo permite automatizar la planificación energética, sino también realizar simulaciones seguras y evaluaciones sin riesgos de afectar al producto.

El gemelo digital propuesto aborda las limitaciones de los sistemas tradicionales, que se apoyan en interfaces HMI con funcionalidades restringidas a la programación manual. A través del uso de datos históricos recopilados por sensores distribuidos estratégicamente, el sistema permite anticipar y optimizar el funcionamiento de la cámara bajo distintos escenarios operativos.

Para alcanzar este propósito, se establecen los siguientes objetivos específicos:

1. Establecer un canal de comunicación entre el gemelo digital y el sistema real de la cámara de secado.
2. Recolectar, depurar y preparar los datos históricos necesarios para entrenar el sistema predictivo.
3. Diseñar e implementar un modelo de predicción capaz de anticipar el comportamiento de la cámara en función de variables claves.
4. Desarrollar una plataforma de gestión centralizada que integre las funcionalidades del sistema inteligente con el entorno de producción real.
5. Diseñar una interfaz visual que facilite la supervisión del sistema, el análisis histórico y la comparación entre diferentes planificaciones energéticas.

6. Diseñar y desarrollar un algoritmo de optimización que, teniendo en cuenta restricciones operativas y condiciones externas (como precios dinámicos, demanda energética o disponibilidad de energía renovable), permita generar planificaciones que minimicen el coste energético sin comprometer la calidad del proceso.
7. Asegurar la consistencia e integridad de los datos intercambiados entre el gemelo digital y el sistema físico, mediante validaciones, sincronización continua y estrategias de detección de discrepancias.
8. Garantizar la seguridad del sistema, aplicando mecanismos de autenticación, autorización y protección de datos tanto en la comunicación como en el almacenamiento y procesamiento de la información.

Entre las capacidades clave que proporciona el gemelo digital se destacan:

- Detección temprana y prevención de fallos: la simulación continua del sistema permite detectar anomalías y anticipar situaciones críticas, lo que habilita acciones preventivas que reducen tiempos de inactividad y pérdidas.
- Optimización energética dinámica: integrando los precios horarios de la electricidad, la disponibilidad energética interna y la generación renovable, el sistema elabora planificaciones automáticas orientadas a minimizar los costes energéticos.
- Entorno seguro para experimentación: la virtualización del sistema permite probar nuevas estrategias operativas sin riesgos para la producción, fomentando la mejora continua.
- Monitorización remota y trazabilidad operativa: el acceso remoto al sistema facilita el seguimiento en tiempo real y permite auditar decisiones pasadas, garantizando una trazabilidad completa.
- Enfoque ágil y adaptable: al centrarse en datos históricos y modelos ajustables, el gemelo digital ofrece una alternativa más flexible y económica que los modelos físicos complejos, facilitando su adaptación a nuevas condiciones y requisitos.

Capítulo 2 Estado del arte

El desarrollo de sistemas de planificación energética basados en gemelos digitales requiere integrar diversos componentes tecnológicos y metodológicos. En este capítulo se revisan los principales trabajos relacionados en las áreas de gemelos digitales industriales, comunicación entre sistemas de control y modelos predictivos aplicados a variables ambientales.

2.1. Gemelos digitales en entornos industriales

En el contexto de la transformación digital impulsada por la iniciativa Industrial 4.0, los sistemas industriales han comenzado a evolucionar hacia arquitecturas más inteligentes, conectadas y autónomas. En este nuevo paradigma, los gemelos digitales se han consolidado como una de las tecnologías clave para vincular el mundo físico con su representación virtual, permitiendo la supervisión, simulación y optimización de procesos en tiempo real. Esta tecnología consiste en una réplica digital de un sistema físico que permite recoger, analizar y simular datos del entorno real con el objetivo de mejorar su rendimiento operativo [1].

La implementación de gemelos digitales se apoya en la integración de diversas tecnologías propias de la Industria 4.0, como los sistemas ciberfísicos (CPS), la inteligencia artificial (IA), el Internet de las Cosas (IoT) y la computación en la nube. Su integración permite desarrollar capacidades avanzadas de monitoreo, diagnóstico, predicción y toma de decisiones automatizadas, lo que contribuye a un control más eficiente, flexible y adaptativo de los sistemas de producción [1].

Una revisión reciente sobre su papel en la industria de procesos destaca su utilidad para la toma de decisiones en tiempo real, gracias a la integración de modelos dinámicos, datos operativos y herramientas de análisis. A diferencia de las simulaciones tradicionales, el gemelo digital actúa como un sistema virtual con capacidad de actualización continua, estimación de estados y optimización operativa. Asimismo, se ha propuesto una arquitectura modular basada en modelos estructurales, eventos y procesos, y se ha demostrado su aplicabilidad en casos reales, como la gestión de redes de hidrógeno en refinerías, donde ha mostrado beneficios en términos de eficiencia energética, planificación de la producción y supervisión operativa [2].

Este enfoque resulta especialmente relevante para el presente trabajo, ya que el gemelo digital desarrollado para la cámara de secado persigue objetivos análogos: optimizar su funcionamiento en función del consumo energético y del contexto dinámico de la planta, incorporando capacidades de predicción, simulación y análisis en tiempo real.

2.2. Protocolos de comunicación HMI–PLC

La comunicación entre interfaces hombre-máquina (HMI) y controladores lógicos programables (PLC) es un componente esencial en sistemas de automatización industrial. Diversos fabricantes, como OMRON, ofrecen soluciones comerciales que permiten establecer esta comunicación mediante protocolos estándar como Modbus o FINS, dependiendo del modelo y la arquitectura del sistema [3].

El protocolo Modbus, en sus variantes RTU y ASCII, ha sido ampliamente utilizado en entornos industriales por su simplicidad y fiabilidad, especialmente en arquitecturas maestro-esclavo. En el modo ASCII, los datos se transmiten en formato de texto legible, lo que facilita el diagnóstico y la depuración de errores [4].

Se han propuesto protocolos alternativos para la comunicación entre dispositivos en entornos embebidos o con restricciones de recursos. Uno de ellos es AMASP (ASCII Master-Slave Protocol), una protocolo ligero y altamente personalizable, basada en el intercambio de mensajes en formato ASCII o binario. AMASP está diseñado para funcionar en sistemas maestro-esclavo [5].

En el ámbito de las soluciones abiertas y orientadas al software, plataformas como Node-RED han sido incorporadas en entornos industriales para la supervisión y el control de procesos mediante la comunicación con PLCs. Existen nodos específicos diseñados para el protocolo FINS, empleado habitualmente en controladores de OMRON, los cuales permiten el acceso a variables internas del PLC a través de redes Ethernet [6]. Este tipo de soluciones representa una alternativa flexible y extensible frente a las arquitecturas tradicionales, facilitando la integración de sistemas industriales convencionales en entornos modernos, como aquellos basados en gemelos digitales.

2.3. Modelos de predicción de condiciones ambientales

En los últimos años, varios estudios han abordado la predicción de variables ambientales como la temperatura y la humedad en entornos cerrados, mediante diferentes enfoques de modelado.

Un ejemplo de modelado conjunto de temperatura y humedad se encuentra en el ámbito de los invernaderos, donde se ha utilizado un enfoque híbrido basado en modelos ARIMA, ARTFIMA y máquinas de vectores de soporte (SVM) para mejorar la precisión de las predicciones [7]. Esta combinación permite capturar tanto las tendencias lineales como las relaciones no lineales presentes en los datos. Aunque es preciso a corto plazo, pierde eficacia en horizontes largos por acumulación de errores, lo que limita su aplicabilidad en sistemas donde se requiere una planificación anticipada.

El trabajo descrito en [8] emplea el algoritmo XGBoost para predecir variables ambientales en exteriores, logrando predicciones satisfactorias en horizontes de hasta tres horas. Investigaciones más recientes [9, 10] han explorado el uso de XGBoost en combinación con redes neuronales como LSTM o con técnicas de optimización, demostrando que su rendimiento puede mejorar significativamente al integrarse en arquitecturas híbridas.

En esta misma línea, [11] presenta un modelo CNN-LSTM para la predicción horaria de la temperatura, que combina la capacidad de las redes convolucionales para extraer características relevantes con la de las LSTM para capturar dependencias temporales. Los resultados obtenidos muestran una mejora sustancial frente a modelos clásicos, aunque a costa de un mayor requerimiento computacional.

Finalmente, la arquitectura Temporal Fusion Transformer (TFT) ha sido empleada recientemente en la predicción de variables ambientales en entornos cerrados, destacando por su capacidad para capturar relaciones de corto y largo plazo, así como por integrar múltiples entradas mediante mecanismos de atención [12], pero su alto coste computacional y complejidad la hacen poco viable en entornos con recursos limitados o exigencias de tiempo real.

En resumen, si bien existen múltiples propuestas para la predicción de temperatura y humedad en entornos cerrados, no se ha identificado ningún proyecto que combine dichas técnicas con un sistema de planificación energética inteligente.

Capítulo 3 Gemelo digital camara de secado

En este capítulo se detalla el diseño completo del sistema propuesto, incluyendo la arquitectura general del gemelo digital, los protocolos de comunicación, el módulo de predicción, la implementación del backend y sus componentes asociados, así como la interfaz web desarrollada para la monitorización y gestión operativa.

3.1. Arquitectura general del sistema

El gemelo digital desarrollado se ha diseñado para integrarse en la red de automatización existente de la quesería, respetando su operativa actual y garantizando la compatibilidad con los equipos ya instalados. Su arquitectura general se representa en la Figura 1.

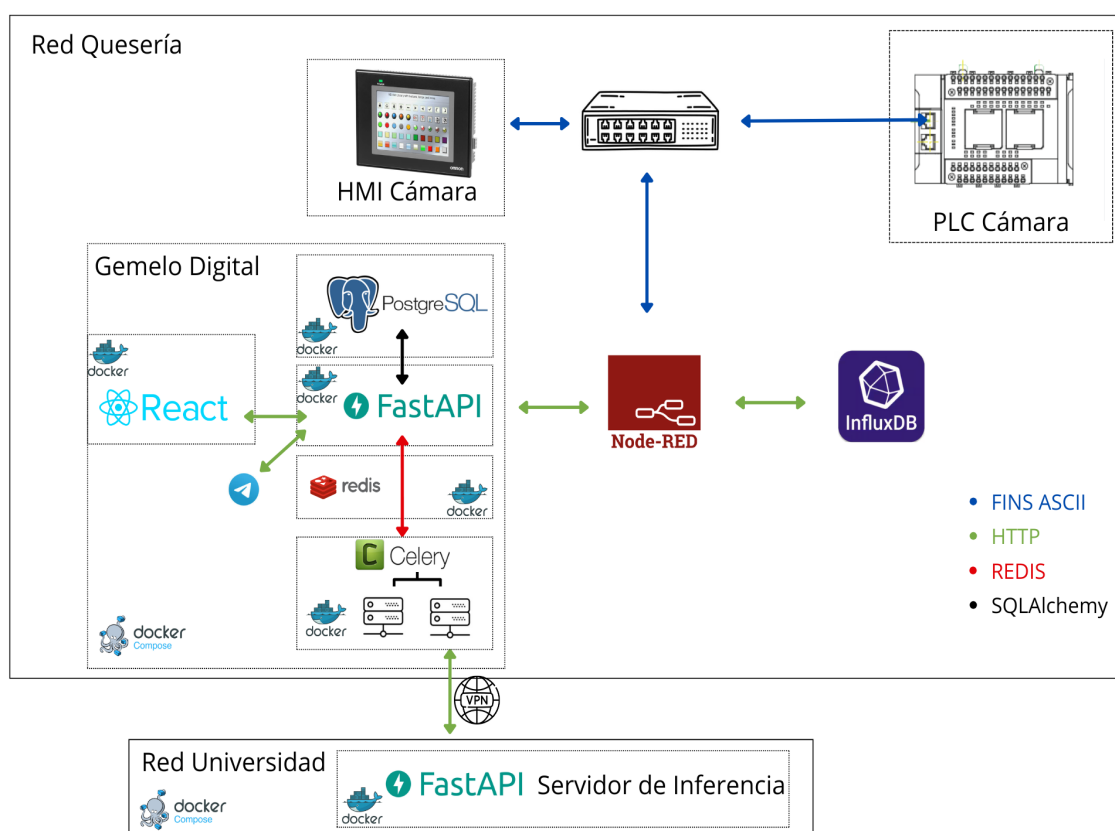


Figura 1: Arquitectura de red del sistema

Como se puede observar, se ha introducido un switch de red entre el HMI y el PLC de la cámara, lo que permite incorporar un subsistema paralelo sin interferir en la comunicación industrial establecida. Este subsistema incorpora un servidor donde se ejecuta Node-RED, que establece la comunicación con el PLC mediante el protocolo FINS (Factory Interface Network Service), descrito en la Sección 3.1.1.

A través de esta conexión, Node-RED accede directamente a las direcciones de memoria del PLC, donde obtiene el estado de los sensores instalados en la cámara de secado. Estos sensores registran variables críticas como la temperatura, la humedad y el estado del modo ahorro. La información recopilada se almacena localmente en una base de datos InfluxDB, quedando disponible tanto para el análisis histórico como para el procesamiento en tiempo real por parte del gemelo digital. Asimismo, Node-RED gestiona la planificación del modo ahorro accediendo a las posiciones de memoria correspondientes en el PLC, permitiendo tanto su lectura como su escritura.

Node-RED actúa adicionalmente como intermediario en la arquitectura, facilitando la transferencia de datos entre el PLC y el núcleo lógico del gemelo digital.

El núcleo funcional del sistema está constituido por un backend desarrollado en FastAPI, encargado de gestionar una base de datos PostgreSQL donde se almacena información estructural del sistema, incluyendo usuarios, tarifas eléctricas, peajes, planificaciones horarias y eventos históricos de operación.

Para la ejecución de tareas asíncronas y operaciones en segundo plano, el sistema integra Celery, utilizando Redis como intermediario de mensajería. Esta elección responde a la necesidad de desacoplar procesos que requieren un mayor tiempo de cómputo, como la sincronización periódica de eventos o la actualización de planificaciones energéticas, evitando que afecten al tiempo de respuesta del backend principal.

El backend expone una API de tipo REST, que es consumida por una interfaz web desarrollada en React. A través de esta interfaz, los usuarios pueden consultar datos históricos, supervisar el estado operativo de la instalación, ajustar los parámetros de funcionamiento, generar estrategias de optimización energética en función de los precios eléctricos y peajes vigentes, y visualizar el comportamiento estimado de la cámara a partir de los modelos predictivos integrados.

El sistema de inferencia se encuentra desplegado en un servidor dedicado, ubicado en una red independiente y accesible únicamente mediante VPN. Este servidor dispone de

capacidades de cómputo superiores, lo que permite ejecutar los modelos de predicción de forma eficiente, garantizando además el aislamiento y la seguridad del entorno de inferencia respecto al resto de los componentes.

Dentro de esta misma red de cómputo dedicada se ha incorporado un módulo adicional responsable del reentrenamiento periódico de los modelos predictivos. Este módulo accede de forma controlada a los datos históricos almacenados en el sistema, aplicando los procesos de preprocesamiento y validación necesarios para actualizar los modelos según el comportamiento real de la cámara de secado a lo largo del tiempo. Tras completar el entrenamiento, las nuevas versiones de los modelos son evaluadas mediante métricas de rendimiento específicas y, en caso de superar los umbrales establecidos, son incorporadas al servidor de inferencia de forma automática. Este mecanismo garantiza que el sistema mantiene su capacidad de adaptación ante posibles variaciones en las condiciones de operación sin afectar al funcionamiento continuo del gemelo digital.

Finalmente, toda la solución software se encuentra desplegada en contenedores Docker, gestionados de forma conjunta mediante Docker Compose. Esta estrategia facilita la portabilidad, el despliegue reproducible y el mantenimiento centralizado del sistema, tanto en entornos de desarrollo como en producción.

3.1.1. Comunicación PLC

Para implementar un sistema inteligente de planificación del consumo eléctrico, es fundamental comprender la infraestructura de comunicación existente entre el HMI y los PLCs responsables del control de los procesos industriales. Por ello, se ha analizado la documentación técnica del HMI de OMRON, donde se describen los mecanismos de comunicación soportados entre el terminal y los autómatas programables [13].

En particular, el manual de la pantalla táctil OMRON NB5Q-TW01B detalla el procedimiento para configurar la conexión con un PLC genérico mediante el protocolo Modbus, en el que la HMI actúa como maestro y el PLC como esclavo [3].

No obstante, tras revisar los protocolos compatibles con dispositivos OMRON y realizar un análisis del tráfico de red mediante un sniffer, se ha determinado que la comunicación real en el sistema analizado no se realiza mediante Modbus. Como se muestra en la Figura 2, el protocolo detectado corresponde a FINS (Factory Interface Network Service), un protocolo propietario de OMRON orientado a la comunicación entre PLCs, HMIs y otros dispositivos de automatización [14].

FINS opera sobre UDP y permite el intercambio de datos a través de codificación en ASCII, de forma análoga a otros protocolos de tipo maestro-esclavo como el AMASP (ASCII Master-Slave Protocol). Ambos comparten similitudes estructurales con Modbus ASCII, aunque presentan diferencias particulares en cuanto al direccionamiento y la estructura de comandos, propias de la arquitectura OMRON.

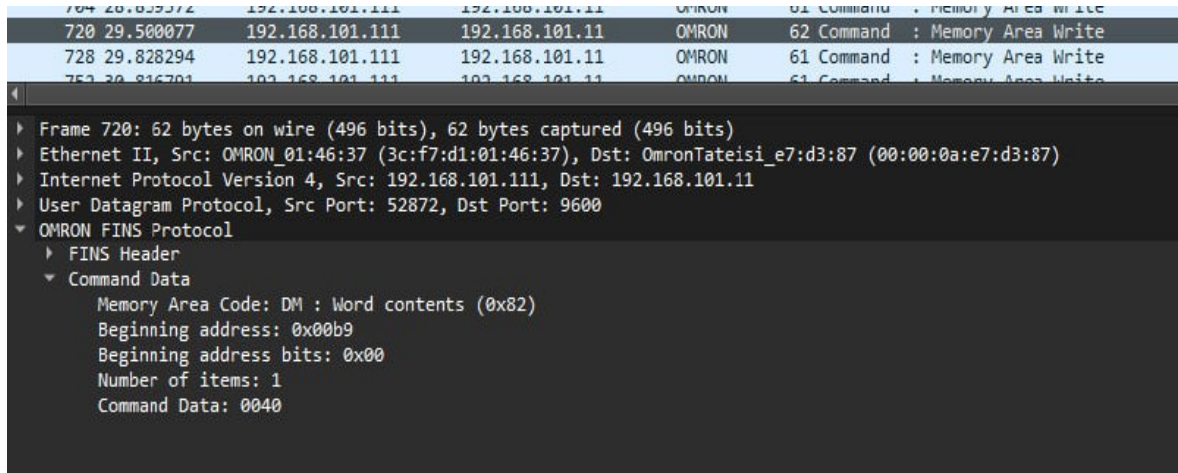


Figura 2: Tráfico de red, comunicación mediante protocolo FINS

Una vez identificado el protocolo de comunicación (FINS) y comprendida la arquitectura de tipo maestro-esclavo entre el HMI y el PLC, es necesario determinar las direcciones de memoria involucradas en la lectura y escritura de datos.

En este contexto, el HMI actúa como maestro y el PLC como esclavo, siendo este último el encargado de almacenar la información en una tabla interna de memoria. Para identificar las direcciones de escritura asociadas al modo ahorro, se ha realizado una prueba controlada en la que se introdujeron valores manualmente desde la HMI, monitorizando posteriormente el tráfico de red mediante un sniffer para determinar las posiciones de memoria afectadas. Dado que esta prueba requería acceso físico a la instalación y equipamiento de análisis dentro de la red industrial, su ejecución fue realizada por el grupo de investigación, facilitando posteriormente los resultados necesarios para el desarrollo de este trabajo.

Como resultado de este proceso, se ha podido mapear el conjunto de direcciones de escritura utilizado por el sistema para registrar los valores de planificación energética. Estas direcciones están organizadas por día de la semana y se dividen en tres “slot” por día, cada uno con una dirección de inicio de modo ahorro y fin de modo ahorro. La Tabla 1 resume esta asignación.

Día	Slot	Dirección inicio	Dirección fin
Lunes	Slot 1	0x02EE	0x02EF
	Slot 2	0x02F0	0x02F1
	Slot 3	0x02F2	0x02F3
Martes	Slot 1	0x02F4	0x02F5
	Slot 2	0x02F6	0x02F7
	Slot 3	0x02F8	0x02F9
Miércoles	Slot 1	0x02FA	0x02FB
	Slot 2	0x02FC	0x02FD
	Slot 3	0x02FE	0x02FF
Jueves	Slot 1	0x0300	0x0301
	Slot 2	0x0302	0x0303
	Slot 3	0x0304	0x0305
Viernes	Slot 1	0x0306	0x0307
	Slot 2	0x0308	0x0309
	Slot 3	0x030A	0x030B
Sabado	Slot 1	0x030C	0x030D
	Slot 2	0x030E	0x030F
	Slot 3	0x0310	0x0311
Domingo	Slot 1	0x0312	0x0313
	Slot 2	0x0314	0x0315
	Slot 3	0x0316	0x0317

Tabla 1: Direcciones de memoria asociadas a los slots de programación por día

3.1.2. Base de datos InfluxDB

Los datos procedentes del PLC y de los sensores instalados por el grupo de investigación Smart Data and Networks son recogidos mediante Node-RED y almacenados directamente en InfluxDB, una base de datos orientada a series temporales, optimizada para el registro y consulta eficiente de datos con marca de tiempo. Esta arquitectura evita la sobrecarga en el sistema de control, ya que impide que múltiples módulos accedan directamente al PLC, centralizando la lectura en un único punto y distribuyendo la información de forma asincrónica.

Dado que la infraestructura de adquisición y almacenamiento de datos ya se encontraba previamente configurada por el grupo de investigación, en el presente trabajo se ha partido de la estructura de almacenamiento ya establecida en InfluxDB.

Para la recogida y almacenamiento de las variables generadas por la cámara de secado, se ha utilizado un bucket denominado `CAMARA_2`, desde el cual se realizan consultas en lenguaje Flux. Estas consultas permiten filtrar por `measurement` y `field`, y aplicar funciones agregadas como `aggregateWindow(every: 1s, fn: last)` para recuperar el valor más reciente de cada variable dentro de una ventana temporal de un segundo.

Las variables monitorizadas de forma principal incluyen la temperatura, la humedad relativa, el consumo eléctrico y el estado del modo ahorro. Estas mediciones permiten tanto la visualización en tiempo real como su posterior análisis por el sistema de predicción y optimización.

Es importante señalar que los registros en InfluxDB están almacenados en horario UTC+00 (Tiempo Universal Coordinado), sin aplicar desplazamientos horarios. Aunque se ha configurado una ventana de agregación de 1 segundo, la frecuencia de muestreo real no está garantizada por los dispositivos de origen, por lo que puede presentar irregularidades.

Por esta razón, en la etapa de Análisis Exploratorio de los Datos (véase la Sección 4.1) se lleva a cabo un procesamiento adicional, que incluye la interpolación o re-muestreo de los datos, con el objetivo de estandarizar la frecuencia y garantizar una resolución temporal constante de un segundo exacto.

3.2. Predicción del comportamiento del sistema

La planificación óptima del funcionamiento de la cámara requiere anticipar su evolución bajo distintos escenarios. Para ello, el sistema incorpora un módulo de predicción diseñado para estimar, con antelación, la humedad interna, la temperatura y el consumo energético, en función del estado actual y de variables contextuales como el modo ahorro y la hora del día.

Este módulo se basa en modelos de aprendizaje automático entrenados sobre datos históricos recopilados por sensores del sistema, y ha sido específicamente diseñado para capturar tanto la dinámica interna del proceso como el impacto de las acciones externas de control.

El modelo principal, implementado con el algoritmo XGBoost mediante una arquitectura híbrida que combina predicción recursiva y directa, ha logrado un error medio absoluto inferior al 5 % en la estimación del consumo diario acumulado. Este

nivel de precisión ha sido validado tanto en escenarios simulados como en condiciones reales de funcionamiento, confirmando su utilidad como base para la toma de decisiones energéticas.

El desarrollo del módulo predictivo, incluyendo el análisis exploratorio de datos, el diseño y entrenamiento del modelo, así como la evaluación de resultados se detalla en el Capítulo 4.

3.3. Backend del sistema

El backend del gemelo digital está compuesto por dos elementos complementarios: un servidor desarrollado con FastAPI y una instancia de Node-RED que actúa como puente de integración entre el entorno físico y la lógica de supervisión. FastAPI gestiona la lógica central, ofrece endpoints para consultas y modificaciones, y se comunica con las bases de datos. Node-RED maneja la integración directa con sensores y PLC mediante protocolos industriales. Adicionalmente, el backend incorpora Celery como sistema para tareas asíncronas intensivas o periódicas, con Redis como sistema intermediario de mensajería.

3.3.1. FastAPI

El backend principal se ha desarrollado usando FastAPI, un framework de Python que permite construir APIs RESTful estructuradas. La compatibilidad con OpenAPI genera documentación automática, facilitando desarrollo e integración. La descripción completa de endpoints se encuentra en el Anexo III.

FastAPI constituye el núcleo lógico del gemelo digital. Orquesta procesos internos, gestiona peticiones externas y expone endpoints HTTP para consultar y modificar parámetros del sistema desde la interfaz web. Esto incluye la selección del modo operativo, configuración de tarifas y consultas del estado de la cámara de secado.

Además, FastAPI ejecuta una tarea diaria programada que genera el plan energético del día siguiente. Este plan considera exclusivamente precios futuros de electricidad desde InfluxDB y tarifas definidas en PostgreSQL, sin depender directamente de variables físicas como temperatura o humedad. Esta decisión surge de la estabilidad observada en el perfil de consumo durante días sin actividad productiva, como fines de semana, ilustrada en la Figura 3. En esta figura se muestra un mapa de calor que representa la distribución horaria del consumo energético durante una

semana completa. Se observa claramente cómo durante los días sábado y domingo el consumo presenta menor variabilidad, permaneciendo constante y relativamente bajo en comparación con los días laborables. Esta estabilidad confirma la conveniencia de basar la planificación energética únicamente en criterios económicos.




Figura 3: Mapa de calor del consumo durante toda la semana.

La planificación energética calcula el coste horario según la expresión:

$$C_t = P_t \cdot (1 + T_t)$$

donde P_t es el precio base de electricidad y T_t es el factor del peaje aplicado. Los tramos más costosos identificados se recomiendan para activar el modo ahorro, almacenándose dicha planificación en la base de datos para consultas futuras.

3.3.2. Celery, Redis y tareas en segundo plano

El sistema Celery permite gestionar tareas asíncronas, especialmente operaciones intensivas o recurrentes que se realizan en segundo plano. Redis actúa como intermediario de mensajería entre FastAPI y Celery, facilitando operaciones desacopladas y robustas.

Las tareas gestionadas por Celery incluyen principalmente procesos predictivos y el reentrenamiento periódico de modelos de inteligencia artificial. Estas operaciones se delegan mediante peticiones HTTP a un backend de inferencia especializado, optimizado para ejecutar inferencias sobre modelos entrenados y actualizar algoritmos con datos recientes.

Gracias a esta arquitectura, FastAPI puede centrarse en operaciones de control y coordinación, delegando cálculos intensivos o repetitivos a procesos específicos que

garantizan eficiencia y estabilidad del sistema global.

3.3.3. Monitorización continua y gestión de eventos

FastAPI también actúa como un sistema supervisor en tiempo real, realizando cada minuto un proceso continuo de monitorización. Este mecanismo consulta datos recientes desde InfluxDB para evaluar el estado operativo del sistema, detectando eventos internos definidos por condiciones lógicas configurables desde la interfaz de usuario.

Entre los eventos actualmente gestionados se incluyen: exceso de consumo en la fábrica, batería completamente cargada, activación o desactivación del modo ahorro, activación del plan optimizado, cambios en el origen de planificación y recepción de nuevos datos del estado de la cámara. Estos eventos se registran en PostgreSQL junto con su marca temporal y tipo, transmitiéndose inmediatamente al frontend mediante WebSockets. Además, existe la posibilidad de configurar el envío automático de notificaciones por Telegram, lo que permite alertar a los usuarios ante situaciones críticas sin necesidad de supervisión constante desde la interfaz.

Para estas operaciones, el backend combina el uso de PostgreSQL (almacenamiento de configuración, historiales y definiciones) e InfluxDB (mediciones en tiempo real del entorno físico). Asimismo, FastAPI mantiene una comunicación HTTP directa con Node-RED, permitiendo una integración síncrona con sensores y actuadores mediante protocolos industriales como FINS.

Finalmente, FastAPI ofrece interfaces REST al frontend desarrollado en React, facilitando la visualización en tiempo real, consultas históricas y ajustes remotos desde la interfaz gráfica del usuario.

3.3.4. Módulo de inferencia

El módulo de inferencia constituye el componente responsable de ejecutar las predicciones energéticas bajo distintos escenarios de planificación. A través de un servicio REST expuesto desde el backend, permite calcular de forma anticipada el consumo eléctrico previsto para un día completo, partiendo de la definición de un rango horario donde el modo ahorro estaría activo. Esta funcionalidad resulta clave para evaluar de forma rápida el impacto de distintas estrategias de programación antes de aplicarlas sobre el sistema real.

Además del servicio de predicción bajo demanda, el módulo implementa un procedimiento automatizado de mantenimiento del modelo. Cada mes, se lanza un proceso de reentrenamiento que incorpora los datos más recientes recogidos por el sistema. Una vez entrenado el nuevo modelo, se procede a una fase comparativa de validación. Si el modelo actualizado presenta un rendimiento superior al anterior, evaluado mediante métricas previamente definidas, pasa a ser desplegado como modelo activo. En caso contrario, el sistema mantiene el modelo vigente, descartando la versión que no aporta mejoras. Este mecanismo garantiza una actualización continua del sistema manteniendo la robustez predictiva y evitando degradaciones accidentales debidas a sobreajustes o cambios transitorios en los datos.

3.3.5. Seguridad e Identidad

El sistema incorpora un esquema de autenticación mediante tokens JWT (JSON Web Token), lo que permite identificar de forma segura a cada usuario en cada interacción con el backend. La protección de endpoints se realiza en función del rol asignado, diferenciando entre usuarios editores y visualizadores. Mientras que los primeros tienen acceso completo a las funcionalidades del sistema, incluidos los módulos de configuración y gestión, los visualizadores únicamente pueden consultar datos históricos, acceder a predicciones y explorar visualizaciones, sin capacidad para alterar ningún parámetro del sistema. Además, se ha habilitado un mecanismo de recuperación de contraseña automatizado mediante el envío de un correo electrónico a través del servicio de Gmail, garantizando así la continuidad del acceso en caso de pérdida de credenciales.

3.3.6. Base de datos PostgreSQL

El almacenamiento persistente de la información del sistema se gestiona actualmente mediante una base de datos PostgreSQL. Aunque el sistema está diseñado como una aplicación de ámbito reducido y orientada a un único usuario concurrente, la migración a PostgreSQL ha sido necesaria para resolver las limitaciones de concurrencia inherentes de SQLite, especialmente al desplegar el backend en entornos distribuidos con múltiples procesos o contenedores.

PostgreSQL proporciona un motor de base de datos relacional robusto, plenamente transaccional y con soporte nativo para conexiones simultáneas. Esta capacidad resulta esencial para garantizar la integridad de los datos y la estabilidad del sistema cuando distintos servicios acceden concurrentemente a las tablas. A pesar de su mayor

complejidad en comparación con SQLite, PostgreSQL permite mantener un esquema de despliegue sencillo, al centralizar el almacenamiento de datos estructurados sin comprometer el rendimiento ni la portabilidad del sistema.

Al igual que en la arquitectura inicial, todas las operaciones de lectura y escritura sobre la base de datos son gestionadas exclusivamente desde el backend. No se permite el acceso directo desde el cliente, lo que preserva la seguridad, el aislamiento lógico de los datos y la coherencia transaccional. La integración con FastAPI a través de SQLAlchemy se mantiene, facilitando un acceso estructurado, controlado y coherente a los datos persistentes.

Cabe destacar que PostgreSQL almacena únicamente los datos estructurados relacionados con la configuración del sistema, la planificación energética, las predicciones generadas, los costes, las tarifas o los registros de eventos. Por su parte, la información temporal de alta frecuencia, como las series de temperatura, humedad o consumo eléctrico, sigue gestionándose en InfluxDB, más adecuada para almacenar series temporales de gran volumen. Este reparto funcional optimiza la gestión de datos según la naturaleza de cada conjunto de información.

3.4. Interfaz web del sistema

La interfaz web constituye el componente visual y operativo a través del cual el usuario interactúa con el gemelo digital. Aunque el presente trabajo no aborda en detalle los aspectos de desarrollo frontend, resulta necesario presentar su arquitectura general y la función que desempeña dentro del sistema global. Para una descripción completa de su funcionamiento desde el punto de vista del usuario final, se remite al manual de usuario recogido en el Anexo IV.

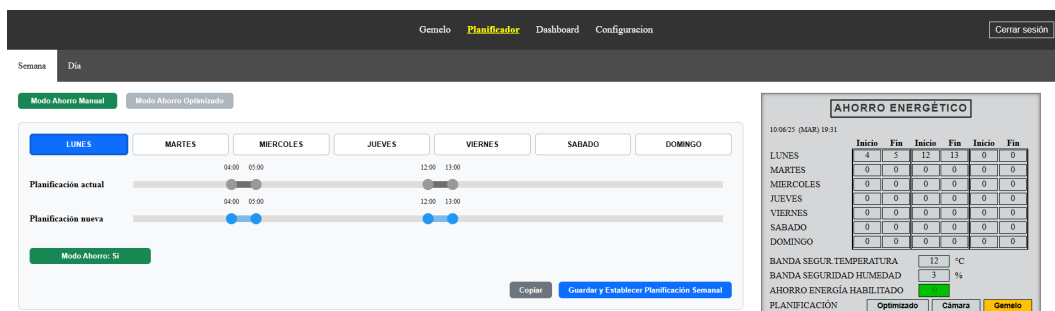


Figura 4: Interfaz del planificador del modo ahorro.

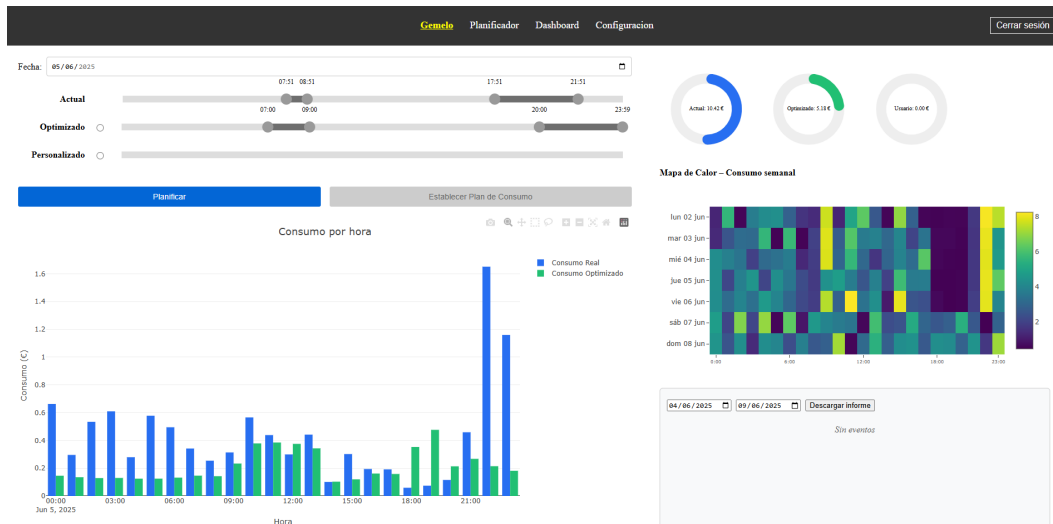


Figura 5: Interfaz del módulo principal del gemelo digital.

Desde el punto de vista tecnológico, el frontend se ha desarrollado utilizando React, un marco de trabajo moderno basado en componentes que permite construir interfaces dinámicas y altamente reactivas. Este frontend consume los datos y funcionalidades expuestos por el backend desarrollado en FastAPI, estableciendo la comunicación a través de peticiones HTTP RESTful y, en aquellos módulos donde se requiere comunicación en tiempo real, mediante WebSocket.

Funcionalmente, la interfaz no se limita a representar datos, sino que constituye el núcleo operativo desde el que se supervisa, configura y controla la cámara de secado. Permite al usuario consultar el estado actual del sistema, anticipar el comportamiento futuro mediante las predicciones generadas, analizar escenarios de planificación energética y actuar en consecuencia. Este flujo de información ofrece soporte directo a la toma de decisiones, facilitando tanto el control manual como la operación automática de la cámara, según los parámetros definidos.

El sistema proporciona, además, un acceso centralizado a las herramientas necesarias para validar predicciones, configurar tarifas y peajes, gestionar eventos operativos y supervisar en tiempo real las principales variables de proceso, como humedad, temperatura, consumo eléctrico y estado del modo de ahorro. Esta integración funcional en un único entorno interactivo mejora la usabilidad global, permitiendo que los usuario dispongan de los controles y la información adaptados a sus necesidades específicas.

3.4.1. Gemelo digital

El módulo denominado Gemelo Digital constituye la representación operativa principal de la cámara de secado. A través de este entorno interactivo, el usuario dispone de todos los elementos necesarios para visualizar, planificar y validar el funcionamiento futuro del sistema, integrando en un único espacio tanto los datos reales como los escenarios generados por el optimizador.

En la parte superior del módulo se encuentran los controles de planificación, organizados en varios bloques diferenciados. Por un lado, se presentan dos controles deslizantes que permiten comparar visualmente el plan de funcionamiento ejecutado actualmente por la cámara frente al plan optimizado calculado por el sistema. Estos deslizadores permiten identificar de forma rápida las diferencias existentes entre ambos escenarios horarios.

Adicionalmente, se ofrece un tercer control deslizante destinado al usuario, mediante el cual puede definir manualmente su propia planificación personalizada. Una vez seleccionado un plan, la interfaz dispone de dos botones de acción inmediata: uno permite calcular el consumo previsto asociado al plan propuesto, y el otro redirige directamente al módulo Planificador para realizar una edición detallada del horario de funcionamiento.

Debajo de estos controles, se presenta un primer conjunto de visualización gráfica basado en la librería Plotly, un paquete de código abierto diseñado para la creación de gráficos interactivos y representaciones visuales dinámicas en aplicaciones web [15]. Esta herramienta permite generar de forma eficiente visualizaciones flexibles directamente embebidas en la interfaz, facilitando así la exploración de los datos en tiempo real por parte del usuario. En este área se muestran, de forma comparativa y por horas, los consumos estimados correspondientes a cada una de las planificaciones disponibles (real, optimizada y manual). Esta representación facilita al usuario evaluar de forma visual el impacto energético de cada configuración.

A la izquierda de esta visualización se ubican tres gráficas radiales que muestran el consumo total acumulado en el periodo analizado para cada plan, ofreciendo así una referencia cuantitativa global adicional.

Inmediatamente por debajo se sitúa un mapa de calor que representa el consumo horario correspondiente a la semana actual, lo que permite detectar patrones repetitivos o identificar jornadas atípicas de un solo vistazo. A continuación, se presenta un

resumen de los eventos operativos registrados durante el día actual, ofreciendo una visión rápida de las transiciones o incidencias recientes del sistema.

En la parte inferior de la vista, conforme el usuario desciende por la página, se despliega una línea de seguimiento que representa los costes asociados al peaje eléctrico para la jornada actual, permitiendo evaluar los periodos de mayor coste tarifario.

A continuación, se presentan de forma consecutiva varias gráficas que muestran la evolución temporal prevista de las principales variables operativas. En primer lugar, se representa la predicción de los precios eléctricos para las siguientes jornadas, junto con la planificación horaria activa. Seguidamente, se muestra el perfil de consumo eléctrico real correspondiente al periodo seleccionado, ofreciendo así una referencia directa sobre la demanda actual del sistema. Por su parte, las predicciones de humedad y de consumo estimado bajo diferentes escenarios solo se habilitan cuando el usuario ha establecido una nueva planificación manual. Estas gráficas permiten al usuario validar de forma visual el impacto potencial de las distintas planificaciones propuestas, evaluando la coherencia del modelo predictivo frente a los ajustes introducidos.

Ejemplos de uso y capturas de pantalla correspondientes a este módulo se recogen en el Manual de Usuario en la Sección IV.

3.4.2. Planificador

El módulo de Planificador constituye la herramienta principal para la definición y ajuste de los escenarios de funcionamiento de la cámara de secado. A través de esta interfaz, el usuario dispone de diversas opciones para establecer la planificación horaria, adaptándose tanto a patrones fijos como a situaciones específicas o escenarios optimizados.

El sistema permite, en primer lugar, definir un plan genérico semanal, donde se especifica el horario de funcionamiento para cada día de lunes a domingo. Esta configuración ofrece al usuario un control base sobre el patrón de operación habitual de la cámara.

Adicionalmente, el Planificador permite establecer planificaciones específicas para un día concreto, sobrescribiendo de forma puntual la configuración semanal en función de las necesidades operativas energéticas particulares.

Por último, el usuario tiene la opción de delegar el control de la planificación

en el sistema de optimización integrado, permitiendo que el gemelo digital calcule automáticamente el plan óptimo en función de las predicciones de precios, consumo y condiciones operativas actuales. Esta modalidad permite maximizar el ahorro energético sin necesidad de intervención directa.

Una vez enviada la planificación seleccionada, el sistema refleja de forma inmediata el resultado en la réplica visual de la pantalla de control de la cámara, permitiendo al usuario comprobar cómo quedará establecida la programación de ahorro energético para la semana siguiente.

Ejemplos de uso y capturas de pantalla correspondientes a este módulo se recogen en el Manual de Usuario en la Sección IV.

3.4.3. Dashboard

El módulo Dashboard proporciona una interfaz flexible e interactiva para visualizar los datos almacenados en InfluxDB. El usuario puede seleccionar y configurar dinámicamente qué variables desea consultar, generando gráficos adaptados a cada análisis. Para optimizar la experiencia de uso, las consultas realizadas se almacenan temporalmente en caché, garantizando así fluidez en la interacción incluso cuando se gestionan grandes volúmenes de información.

Ejemplos de uso y capturas de pantalla correspondientes a este módulo se recogen en el Manual de Usuario en la Sección IV.

3.4.4. Configuración

El módulo de Configuración proporciona al usuario acceso a los principales parámetros que definen el comportamiento interno del gemelo digital. A diferencia de otros módulos orientados a la operación diaria, esta sección agrupa las opciones de ajuste estructural del sistema, permitiendo adaptar su funcionamiento a las condiciones reales de la planta y a las particularidades de cada escenario energético.

Entre los apartados disponibles, se encuentra la gestión de tarifas eléctricas y peajes, donde el usuario puede definir tanto los bloques horarios de precios como los costes asociados a la potencia contratada y los periodos tarifarios vigentes. Esta información es fundamental para el cálculo de costes energéticos y la posterior optimización de los planes de ahorro.

En el área de eventos, el usuario puede establecer condiciones lógicas sobre las variables de proceso, configurando los umbrales y reglas que permiten al sistema detectar situaciones de interés operativo, como excesos de consumo, cargas de batería, activación o desactivación del modo ahorro, o transiciones relevantes en la planificación.

El módulo incluye también la gestión de usuarios, donde se administran los perfiles y permisos de acceso al sistema. Además, cada usuario puede configurar la recepción de notificaciones operativas a través de Telegram, vinculando su cuenta con el bot oficial del sistema mediante el identificador de chat y el token correspondiente del bot, o bien utilizando un proceso automatizado que obtenga dichos datos. Esta funcionalidad, integrada mediante la API de Telegram, permite recibir alertas en tiempo real ante eventos críticos o situaciones destacadas, sin necesidad de acceder constantemente a la interfaz web.

Por último, se incorpora una herramienta auxiliar de cálculo de pre-ahorro, que permite al usuario estimar de forma rápida los posibles ahorros energéticos derivados de la activación del modo de ahorro en función de las condiciones actuales.

Ejemplos de uso y capturas de pantalla correspondientes a este módulo se recogen en el Manual de Usuario en la Sección IV.

3.4.5. Gestión de acceso y roles de usuario

El sistema implementa un control de acceso centralizado que restringe el uso de la plataforma únicamente a usuarios autenticados. Todo el acceso a la interfaz web es privado, exigiendo registro y validación previa de credenciales para cualquier interacción con el gemelo digital.

El sistema distingue entre dos perfiles de usuario con permisos diferenciados: visualizadores y editores. Los usuarios con perfil visualizador disponen de acceso en modo consulta a los datos históricos, predicciones, eventos y estado de la cámara, pero no pueden modificar parámetros ni realizar planificaciones. Por su parte, los usuarios con perfil editor (administradores) tienen habilitada la capacidad de editar configuraciones, establecer nuevas planificaciones, definir eventos operativos, ajustar tarifas, peajes y usuarios, así como intervenir directamente en el control operativo de la cámara.

La gestión de la autenticación se basa en el uso de tokens JWT (JSON Web Tokens), lo que permite validar la identidad del usuario de forma segura y mantener sesiones

autenticadas sin necesidad de credenciales persistentes. Adicionalmente, el sistema proporciona un mecanismo de recuperación de contraseña a través de correo electrónico, permitiendo restablecer el acceso de forma controlada y segura ante posibles pérdidas de credenciales.

A nivel de navegación interna, las rutas de la interfaz web están protegidas mediante validadores de permisos que discriminan el acceso según el rol del usuario autenticado. Así, los módulos de visualización (como el Dashboard o el Gemelo Digital) son accesibles para todos los usuarios autenticados, mientras que los módulos de planificación y configuración requieren permisos administrativos específicos.

Capítulo 4 Módulo de predicción

El módulo de predicción se encarga de anticipar el comportamiento futuro de la cámara de secado en términos de consumo eléctrico, humedad y temperatura. Para ello, se ha desarrollado una arquitectura basada en modelos de aprendizaje automático entrenados con datos históricos recogidos por sensores. En el [Anexo II] se especifica el entorno preparado para entrenar el modelo.

4.1. Análisis Exploratorio de los Datos

El punto de partida del análisis consistió en la extracción de las cuatro variables principales desde la base de datos InfluxDB: temperatura, humedad, consumo eléctrico y estado del modo ahorro. Aunque estas señales se registraban de forma continua, no compartían una frecuencia de muestreo común, lo que dificultaba cualquier tratamiento conjunto. Para resolver esta inconsistencia, se definió una malla temporal uniforme de un dato por minuto, aplicando un proceso de re-muestreo adaptado a la naturaleza de cada variable. Las señales continuas, como temperatura, humedad y consumo, se interpolaron o promediaron dentro de cada intervalo, mientras que las variables discretas, como el estado de ahorro, se sincronizaron mediante propagación del último valor registrado. Este procedimiento garantizó una estructura temporal coherente, preservando la dinámica de cada serie y permitiendo su posterior análisis conjunto en los modelos predictivos.

A continuación, se llevó a cabo el proceso de depuración de los datos con el fin de garantizar la validez de los registros antes de cualquier análisis estadístico o entrenamiento de modelos. En primer lugar, se descartaron las entradas sin una marca temporal válida o con fechas que no pudieron interpretarse correctamente. A continuación, se eliminaron duplicados, valores nulos y registros anómalos en las variables numéricas, aplicando un filtrado basado en el rango intercuartílico (IQR, por sus siglas en inglés). Este método emplea los cuartiles de la distribución para establecer un rango estadísticamente aceptable de valores, definido como:

$$\text{IQR} = Q_3 - Q_1$$

donde Q_1 y Q_3 corresponden al primer y tercer cuartil, respectivamente. Se

identifican como valores atípicos aquellas observaciones que se encuentran por debajo de $Q_1 - 1,5 \times IQR$ o por encima de $Q_3 + 1,5 \times IQR$, las cuales fueron automáticamente excluidas sin necesidad de establecer umbrales arbitrarios. Además, se eliminaron secuencias constantes superiores a 60 minutos, habitualmente asociadas a bloqueos en los sensores. La Figura 6 muestra el resultado de este proceso aplicado a los registros de consumo, mientras que la Figura 8 ilustra su efecto sobre la temperatura.

En el caso específico de la humedad, el filtrado no se basó en la distribución estadística, sino en los valores de histéresis configurados por el usuario, que actúan como límites operativos definidos manualmente. La Figura 7 muestra el efecto de esta configuración sobre los datos de humedad.




Figura 6: Depuración de Consumo (IQR y runs constantes)




Figura 7: Depuración de Humedad (IQR y runs constantes)




Figura 8: Depuración de Temperatura (IQR y runs constantes)

Una vez completada la depuración inicial, se evaluó la integridad diaria del conjunto. Dado que el sistema opera con un muestreo teórico de un dato por minuto, cada día debería contener exactamente 1.440 registros. Sin embargo, como muestra la Figura 9, se identificaron jornadas con pérdidas significativas de registros. Para preservar la mayor cantidad posible de datos útiles, se eliminaron únicamente los segmentos afectados por ausencias extensas, mientras que registros cercanos con interrupciones inferiores a 5 minutos fueron interpolados estimando la diferencia total entre los extremos y repartiendo proporcionalmente dicho incremento entre los valores faltantes. El resto de los registros válidos fueron conservados para su posterior análisis.




Figura 9: Número de registros por día

Como resultado de este proceso completo de depuración, re-muestreo y reconstrucción parcial de lagunas, se obtuvo un conjunto depurado y estructurado, listo para su uso en el entrenamiento de los modelos supervisados. Las Figuras 10, 11 y 12 presentan el aspecto final de cada una de las variables tras el tratamiento aplicado.




Figura 10: Consumo tras depuración, re-muestreo e interpolación




Figura 11: Humedad tras depuración, re-muestreo e interpolación




Figura 12: Temperatura tras depuración, re-muestreo e interpolación

Con el conjunto depurado, se llevó a cabo un análisis específico de la variable humedad, considerada la variable principal del sistema debido a su influencia tanto en el consumo energético como en la temperatura interna [Anexo I]. Para ello, se emplearon herramientas de análisis de series temporales como la función de autocorrelación (ACF) y el periodograma, lo que permitió caracterizar la estructura cíclica de la señal.

4.1.1. Análisis de la función de autocorrelación sobre la variable humedad

El estudio de la función de autocorrelación aplicado a la señal de humedad permite identificar dependencias temporales que no resultan evidentes a simple vista. Esta herramienta cuantifica el grado de correlación entre los valores actuales y pasados de la serie, revelando así la existencia de estructuras periódicas o retardos característicos. En el caso de la cámara de secado, la humedad muestra una dependencia estructurada que combina la dinámica interna del sistema con los efectos del control automático.

Como se observa en la Figura 13, se analizó una ventana de aproximadamente 6 horas y 40 minutos, correspondiente a un periodo sin intervención del modo ahorro. Durante este intervalo, el ventilador opera bajo una lógica autónoma basada en histéresis, un mecanismo de control en el que se definen dos umbrales distintos para encendido y apagado. Así, el ventilador no responde a un único valor fijo, sino que permanece encendido o apagado según el rango en el que se encuentra la humedad, lo que evita conmutaciones constantes y permite estabilizar el sistema. Esta lógica introduce una oscilación periódica en la señal, que se refleja en el patrón sinusoidal de la autocorrelación. El periodo dominante, en torno a 72 minutos, coincide con el tiempo característico entre encendidos y apagados del ventilador, modulados por la inercia térmica del sistema. Este comportamiento demuestra que, incluso en ausencia de control externo programado, la evolución de la humedad sigue una dinámica cíclica estable y no aleatoria.

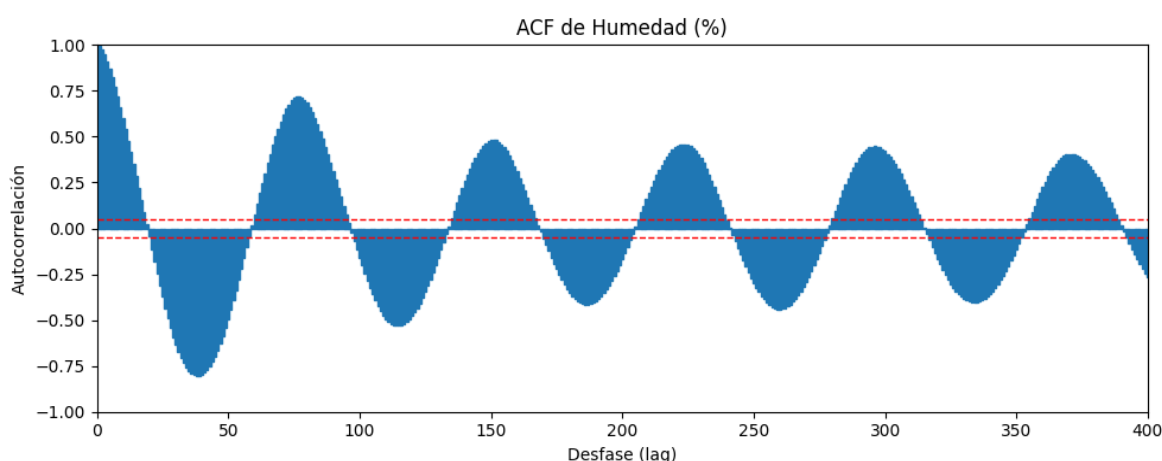


Figura 13: Autocorrelacion 6 horas

Por otro lado, al considerar un periodo más amplio, como se muestra en la Figura 14, donde se representa la autocorrelación a lo largo de 24 horas, se identifican dos escalas adicionales de comportamiento. En primer lugar, se confirma la fuerte inercia

del sistema en los primeros minutos, con valores de autocorrelación elevados para desfases cercanos a cero. En segundo lugar, se observa una recurrencia positiva en desfases comprendidos entre los 600 y 750 minutos (10 a 12 horas), lo que sugiere la presencia de un ciclo semidiario. Esta oscilación de mayor amplitud no puede atribuirse únicamente al comportamiento interno de la cámara, sino que se asocia directamente con la activación periódica del modo ahorro, que sigue una lógica de funcionamiento en franjas horarias recurrentes.

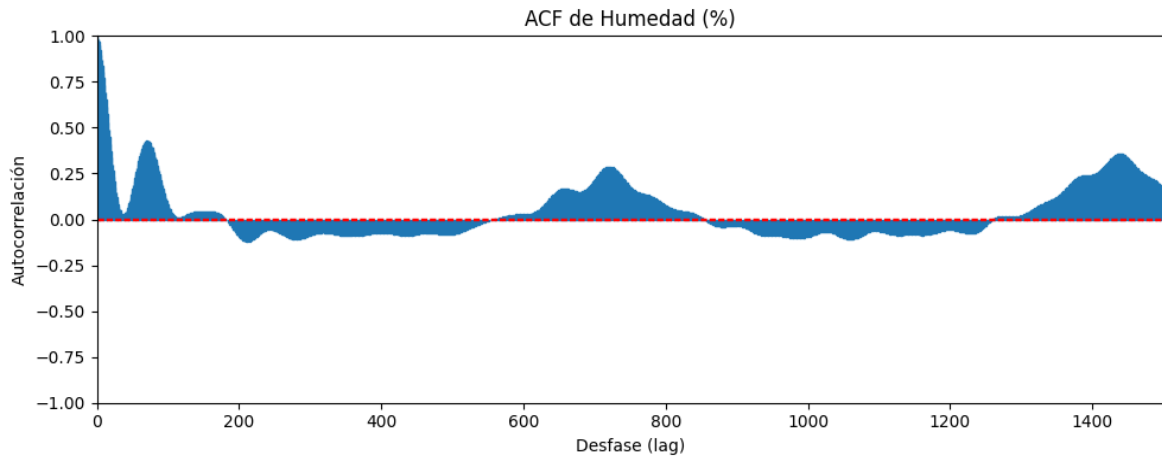


Figura 14: Autocorrelacion 24 horas

La influencia del modo ahorro sobre la evolución de la humedad se aprecia claramente en la Figura 15. Durante los intervalos en los que el modo ahorro está activado (valor 1), se observa un incremento de la humedad, como resultado de la acción forzada del sistema de ventilación. En cambio, cuando el modo ahorro está desactivado (valor 0), la humedad presenta un comportamiento oscilante de tipo “diente de sierra”, consecuencia del control automático del ventilador basado en histéresis. Esta oscilación refleja una alternancia entre fases de incremento y descenso, inducida por el umbral de activación y desactivación definido. Además, el sistema exhibe una respuesta retardada tras cada conmutación de estado, lo que evidencia la inercia térmica de la cámara.

En conjunto, estos resultados confirman la necesidad de modelar conjuntamente tanto la dinámica interna del sistema como las acciones externas del control. Para ello, se incluirá el estado del modo ahorro como variable explicativa en la predicción de la humedad, reflejando su influencia directa sobre la evolución de la señal. Además, se incorporarán retardos temporales, también llamados rezagos, que consisten en valores anteriores de la propia variable para capturar efectos de memoria del sistema. En concreto, se utilizarán rezagos de corto plazo, de hasta 30 minutos, para representar la inercia inmediata, así como rezagos más amplios, en torno a 72 minutos, que recogen la oscilación cíclica observada incluso en ausencia de control programado. Esta




Figura 15: Relacion humedad modo ahorro 24 horas entre semana

combinación permitirá al modelo representar con mayor fidelidad tanto los mecanismos físicos internos como las perturbaciones inducidas por la lógica de control.

4.1.2. Análisis del periodograma sobre la variable humedad

El periodograma estima la densidad espectral de potencia de una serie temporal e indica cuánta varianza se concentra en cada frecuencia. Su utilidad fundamental radica en descubrir periodicidades ocultas en el dominio temporal: cada pico señala un ciclo dominante y su altura cuantifica la importancia relativa de dicho ciclo. Conocer estas frecuencias facilita el diseño de modelos predictivos, ya que los picos relevantes pueden incorporarse como variables sinusoidales o rezagos concretos, reduciendo la complejidad del modelo y mejorando su capacidad de generalización.

La Figura 16 muestra el periodograma de la humedad para el 18-04-2025 (día laborable con modo ahorro programado). Se distinguen tres picos principales:

- $f_1 \simeq 2,31 \times 10^{-5} \text{ Hz} \Rightarrow T \approx 720 \text{ min} (\approx 12 \text{ h})$. Representa la suma de los dos intervalos prolongados sin ahorro (10:00–18:00 y 22:00–08:00 UTC+2).
- $f_2 \simeq 4,63 \times 10^{-5} \text{ Hz} \Rightarrow T \approx 360 \text{ min} (6 \text{ h})$. Corresponde al tramo de ahorro continuo entre las 18:00 y las 22:00 UTC+2, reforzado por la cola de descenso y ascenso de humedad.
- $f_3 \simeq 1,97 \times 10^{-4} \text{ Hz} \Rightarrow T \approx 85 \text{ min}$. Refleja la oscilación intrínseca generada por la histéresis del ventilador cuando el modo ahorro está desactivado.

El reparto de potencia confirma que la dinámica diaria está controlada por la programación del modo ahorro (ciclos de 12 h y 6 h) superpuesta al ciclo natural de $\approx 1,5$ h.




Figura 16: Periodograma de la humedad (18-04-2025, día laborable con modo ahorro).

La Figura 17 corresponde a un día sin modo ahorro (19-04-2025, fin de semana).




Figura 17: Periodograma de la humedad (19-04-2025, día sin modo ahorro).

En este caso, la energía espectral se concentra casi exclusivamente en un conjunto de picos situados en frecuencias más elevadas:

$$f \simeq \{1,50 \ 1,74 \ 2,20\} \times 10^{-4} \text{ Hz} \implies T \approx \{111, 96, 76\} \text{ min.}$$

Estos valores describen la oscilación intrínseca del sistema de ventilación, en forma de ciclos automáticos de encendido y apagado controlados por histéresis. La ausencia de potencia significativa por debajo de 10^{-4} Hz indica que, en ausencia del modo ahorro, no se generan ciclos prolongados de ventilación continua ni largos periodos de inactividad.

El análisis espectral revela la coexistencia de dos escalas fundamentales: Ciclos de 6–12 h inducidos por el modo ahorro, que desplazan gran parte de la varianza hacia frecuencias muy bajas en los días laborables. Un ciclo intrínseco de ≈ 80 –110 min; producto de la histéresis del ventilador, presente en todos los días del año.

Para construir un modelo de predicción robusto, es imprescindible capturar ambas escalas. Esto se logra mediante la incorporación de variables exógenas que reflejen el estado del modo ahorro y de componentes sinusoidales (o rezagos específicos) que

recojan la oscilación natural de alrededor de aproximadamente 90 minutos.

Con esta estrategia, el modelo podrá representar simultáneamente las variaciones lentas impuestas por la lógica de control programada y las oscilaciones rápidas inherentes al sistema físico.

4.2. Entrenamiento del modelo

El objetivo principal del sistema es anticipar el consumo energético de la cámara, algo que depende de forma no lineal de la evolución reciente de la humedad interna. Por ello, se optó por desarrollar un modelo predictivo multivariado centrado en esta variable como eje estructural, incluyendo además la temperatura y el consumo eléctrico como salidas simultáneas. Esta configuración permite capturar relaciones causales y temporales entre las magnitudes, mejorando la estabilidad del modelo al aprovechar sus interdependencias.

El proceso comenzó con la construcción del conjunto de datos supervisado a partir del dataset depurado descrito en la Sección 4.1, ya preprocesado y estructurado tras las etapas de filtrado, limpieza e interpolación. Las variables disponibles fueron: humedad, temperatura, consumo eléctrico y modo ahorro. Para enriquecer el contexto temporal de cada muestra, se añadieron las horas y minutos, codificadas mediante funciones seno y coseno. Esta transformación permitió representar la estructura cíclica de los días, haciendo posible que el modelo identificara los patrones horarios asociados a la activación del modo ahorro. Dado que este modo se activa en franjas temporales específicas que se repiten diariamente, dicha codificación fue clave para que el modelo aprendiera las transiciones periódicas.

Para transformar la serie temporal en un problema de aprendizaje supervisado, se empleó la técnica de retardos (lags). Esta consiste en generar, para cada instante temporal, un conjunto de variables que reflejan el comportamiento reciente del sistema. En lugar de utilizar únicamente el valor actual de las variables de entrada, se incluyen también sus valores en instantes anteriores ($t - 1, t - 2, \dots$), lo que permite capturar la inercia y las dependencias temporales del proceso.

El resultado es un conjunto de datos donde cada fila contiene una secuencia histórica de las variables relevantes y las etiquetas correspondientes al estado futuro que se desea predecir. Esta formulación es especialmente adecuada para problemas multivariados en los que el valor futuro de una variable está condicionado por la evolución previa

de otras. En el caso de este trabajo, el uso de retardos permite al modelo identificar dinámicas internas del sistema, como la influencia de la humedad reciente sobre el consumo energético o la respuesta del sistema a la activación del modo ahorro.

Como algoritmo base se seleccionó XGBoost(XGBRegressor) [16], un método de aprendizaje automático basado en árboles de decisión. Estos árboles permiten dividir el espacio de datos en regiones homogéneas mediante reglas simples, facilitando la predicción de variables continuas. XGBoost emplea una estrategia conocida como boosting, que consiste en construir varios árboles de forma secuencial, donde cada uno corrige los errores cometidos por los anteriores. El esquema general de este mecanismo se ilustra en la Figura 18. Esta combinación de precisión en la modelización de relaciones no lineales, junto con tiempos de entrenamiento reducidos incluso en conjuntos de datos voluminosos, lo convierte en una opción especialmente adecuada para los requerimientos computacionales y de precisión del sistema desarrollado.

Dado que el objetivo es predecir simultáneamente tres magnitudes interrelacionadas (humedad, temperatura y consumo energético), se empleó la clase MultiOutputRegressor de scikit-learn [17]. Esta clase permite entrenar un conjunto de modelos independientes, uno por cada variable objetivo, todos ellos compartiendo el mismo conjunto de entradas. Esta configuración preserva la independencia de los estimadores, pero aprovecha la correlación implícita entre las salidas al utilizar una representación común del sistema.

Este enfoque resulta especialmente útil cuando existe una dependencia funcional entre las salidas. En este caso, el consumo energético está condicionado por la evolución de la humedad, y ambas magnitudes se ven afectadas por el modo ahorro. Aprenderlas de forma conjunta mejora la coherencia interna de las predicciones y refuerza la calidad general del modelo.

Antes del entrenamiento, se realizó una división estratégica del conjunto de datos con dos propósitos diferenciados. En primer lugar, se reservó una semana completa del histórico como conjunto de evaluación externa, sin participación alguna en las fases de aprendizaje ni de validación intermedia. Esta separación permite evaluar el modelo en condiciones más realistas, simulando su comportamiento en un entorno operativo.

El 80 % final del histórico disponible se destinó al desarrollo del modelo, dividiéndose internamente en dos conjuntos: un 80 % para el entrenamiento efectivo y un 20 % para la validación interna. Esta separación se realizó sin barajado, con el




Figura 18: Esquema del proceso de *boosting* en XGBoost

fin de respetar la naturaleza secuencial de los datos. El conjunto de validación no se utilizó para ajustar los parámetros del modelo, sino para monitorizar su rendimiento sobre muestras no vistas durante el aprendizaje. Con ello, fue posible aplicar la técnica de *early stopping*, que interrumpe el entrenamiento cuando el error de validación deja de mejorar tras un número determinado de iteraciones. El 20 % restante del histórico original se reservó como conjunto de test, mantenido completamente aislado hasta la fase final de evaluación.

Este mecanismo evita que el modelo continúe ajustando los datos de entrenamiento más allá del punto óptimo, reduciendo así el riesgo de *sobreajuste*. Además, contribuye a optimizar el tiempo de entrenamiento al identificar automáticamente el número ideal de árboles a construir.

El entrenamiento se abordó mediante dos estrategias complementarias:

- Estrategia recursiva: se entrenó un único modelo para predecir un paso adelante ($t + 1$) y se reutilizó iterativamente. En cada iteración, las predicciones anteriores se incorporan como nuevos retardos, permitiendo que condicionen los pasos siguientes.
- Estrategia directa: se entrenó un modelo independiente para cada instante del

horizonte de predicción $(t + 1, t + 2, \dots, t + h)$. A diferencia de las estrategias autorregresivas, en este caso no se utilizaron valores pasados de la variable objetivo como entrada. Cada modelo realiza una predicción directa utilizando únicamente variables externas y contextuales. Esta técnica evita la acumulación de errores entre pasos sucesivos, aunque incrementa el coste computacional al requerir un modelo distinto para cada instante.

Ambas estrategias se implementaron y conservaron para su posterior comparación cuantitativa en la fase de evaluación. La estructura de los datos, la definición de las etiquetas y las secuencias de entrada se mantuvieron consistentes entre ambas, garantizando una base común para el entrenamiento.

Finalmente, los modelos entrenados se almacenaron en un formato serializado y compacto, lo que permite su reutilización directa sin necesidad de repetir el proceso completo de ajuste.

4.3. Evaluación del modelo

La evaluación del modelo de predicción se ha abordado de forma progresiva, partiendo de un análisis inicial con los hiperparámetros por defecto y refinando posteriormente el rendimiento mediante un procedimiento de ajuste y validación.

En una primera fase, se entrenó el modelo base de tipo XGBoost [18] con los valores predeterminados de sus hiperparámetros, generando predicciones sobre un conjunto de validación semanal. Estas primeras simulaciones permitieron verificar la capacidad general del modelo para seguir la evolución temporal de las tres variables objetivo (humedad, temperatura y consumo eléctrico) bajo diferentes condiciones operativas.

Aunque el modelo mostró un seguimiento razonable de las tendencias principales, se identificaron ciertas desviaciones acumulativas, especialmente cuando el modo ahorro estaba activo. La Figura 19 representa el consumo medio horario de valores reales y predichos. Como se observa, el modelo sí es capaz de diferenciar los ciclos de consumo entre el modo ahorro activo y desactivado, presentando una diferencia global de consumo del 38,84% distribuida a lo largo del día. Aunque a simple vista podría interpretarse como una predicción errónea, en realidad refleja que el modelo comprende parcialmente el funcionamiento cíclico del sistema. Sin embargo, para un gemelo digital orientado a la gestión energética de una cámara de secado, esta capacidad resulta todavía insuficiente.




Figura 19: Consumo medio horario: comparación entre datos reales y predicción (modelo inicial).

Debido a las características particulares del problema (predicción de consumo eléctrico horario condicionado por el modo ahorro) se optó por implementar un enfoque híbrido de predicción. Por un lado, se aplicó un esquema recursivo para la mayoría de horizontes temporales, permitiendo que el modelo propague su propia salida como entrada sucesiva. No obstante, para los primeros minutos posteriores a cada transición de modo ahorro, se incorporó un modelo de predicción directa. Esta estrategia mixta permitió captar mejor los efectos inmediatos de la inercia térmica tras los cambios de operación, sin sacrificar el contexto histórico a largo plazo que aporta la predicción recursiva.

Para cuantificar de manera objetiva el desempeño del modelo, se emplearon como métricas principales el MAPE (Error Porcentual Absoluto Medio) y el SMAPE (Error Porcentual Absoluto Medio Simétrico). Estas métricas permiten evaluar la precisión relativa de las predicciones de forma porcentual, ofreciendo una primera referencia general del margen de mejora alcanzado.

El MAPE se define como:

$$\text{MAPE} = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|$$

donde A_t representa el valor real observado en el instante t , F_t el valor predicho, y n el número total de observaciones. Esta métrica expresa el error medio en porcentaje respecto al valor real, facilitando su interpretación directa. Por ejemplo, un MAPE del 5 % indica que, en promedio, las predicciones presentan una desviación del 5 % respecto

al dato real.

Sin embargo, el MAPE presenta ciertas limitaciones cuando los valores reales tienden a cero, ya que pequeñas desviaciones pueden amplificarse desproporcionadamente por la división. Dado que en la variable consumo es habitual encontrar tramos de consumo bajo o incluso nulo (por ejemplo, durante las fases de reposo de la cámara), se recurrió adicionalmente al SMAPE, definido como:

$$\text{SMAPE} = \frac{100\%}{n} \sum_{t=1}^n \frac{|F_t - A_t|}{(|A_t| + |F_t|)/2}$$

Esta variante normaliza el error respecto a la media de los valores real y predicho, lo que permite obtener un error porcentual estabilizado incluso en presencia de valores bajos. Además, penaliza de forma simétrica tanto sobreestimaciones como subestimaciones, resultando más robusto en escenarios donde las magnitudes pueden oscilar de forma significativa, como ocurre en la predicción de consumo horario de la cámara.

Una vez evaluado el modelo inicial, se procedió al ajuste iterativo de los hiperparámetros con el objetivo de optimizar su rendimiento. Este ajuste se llevó a cabo mediante un esquema combinado de búsqueda, implementado con los módulos GridSearchCV y RandomizedSearchCV de la biblioteca scikit-learn [19]. En primer lugar, se exploró de forma exhaustiva un conjunto reducido de combinaciones iniciales de hiperparámetros, delimitando así un espacio viable de partida. A continuación, se amplió la búsqueda mediante muestreo aleatorio dentro de un rango más amplio de configuraciones, permitiendo evaluar regiones del espacio de parámetros potencialmente más prometedoras. Todo el proceso de validación se integró con esquemas de validación cruzada adaptados a series temporales, utilizando el método TimeSeriesSplit, garantizando el respeto de la secuencia cronológica de los datos y evitando cualquier fuga de información entre los subconjuntos de entrenamiento y validación.

El espacio de búsqueda incluyó parámetros clave del modelo XGBoost, como el número de árboles (`n_estimators`), la profundidad máxima de los árboles (`max_depth`), la tasa de aprendizaje (`learning_rate`), los factores de regularización (`reg_alpha`, `reg_lambda`), el muestreo de filas (`subsample`) y de columnas (`colsample_bytree`), así como la penalización por complejidad de nodos (`gamma`).

Tras el proceso de ajuste, se identificó como configuración óptima la combinación

de 300 árboles, una profundidad máxima de 7 niveles, tasa de aprendizaje de 0.1, sin penalización por complejidad, muestreo completo de datos, y una regularización moderada ($\text{reg_alpha}=1$, $\text{reg_lambda}=2$). Bajo estos parámetros, el modelo alcanzó un error cuadrático medio negativo de $-0,4385$ durante la validación cruzada.

Este valor corresponde a un MSE positivo de 0.4385, lo que implica un error cuadrático medio de aproximadamente 0.66 kWh al tomar la raíz cuadrada (RMSE). Considerando que los valores de consumo energético que gestiona el gemelo digital oscilan entre 0 y 8 kWh, el error relativo se sitúa alrededor del 8% respecto al rango máximo de operación. Este nivel de precisión resulta adecuado para los objetivos del sistema, ya que permite anticipar de forma fiable las tendencias de consumo y sustenta la toma de decisiones en los procesos de planificación energética y optimización de costes. No obstante, se mantiene un margen de mejora en futuras iteraciones del modelo, especialmente en la reducción de errores durante transiciones rápidas y periodos de fuerte variabilidad operativa.

Paralelamente al ajuste de hiperparámetros, se analizaron los efectos del preprocesamiento de datos, evaluando distintos métodos de escalado. Se compararon transformaciones habituales en aprendizaje automático, incluyendo normalización por rango (MinMaxScaler), estandarización clásica (StandardScaler) y escalado robusto basado en estadísticos de dispersión (RobustScaler), implementadas mediante la biblioteca scikit-learn [19]. Asimismo, se evaluó el entrenamiento directo sin aplicar ningún tipo de escalado previo. Finalmente, se optó por prescindir de cualquier transformación, dado que el modelo mostró un mejor comportamiento al trabajar directamente con las variables en sus unidades físicas originales, evitando distorsiones en las magnitudes absolutas de consumo, humedad y temperatura.

Otro aspecto analizado fue la resolución temporal de las series de entrada. Se probaron muestreos a 1, 5 y 10 minutos, observándose que el modelo obtenía mejores resultados al conservar la resolución original de 1 minuto. Esta elección permitió capturar con mayor precisión las transiciones rápidas del sistema, a costa de un mayor coste computacional en entrenamiento y predicción.

El resultado de aplicar estas técnicas se muestra en la Figura 20. Como puede apreciarse, el modelo mejora significativamente su capacidad para seguir las variaciones de consumo.

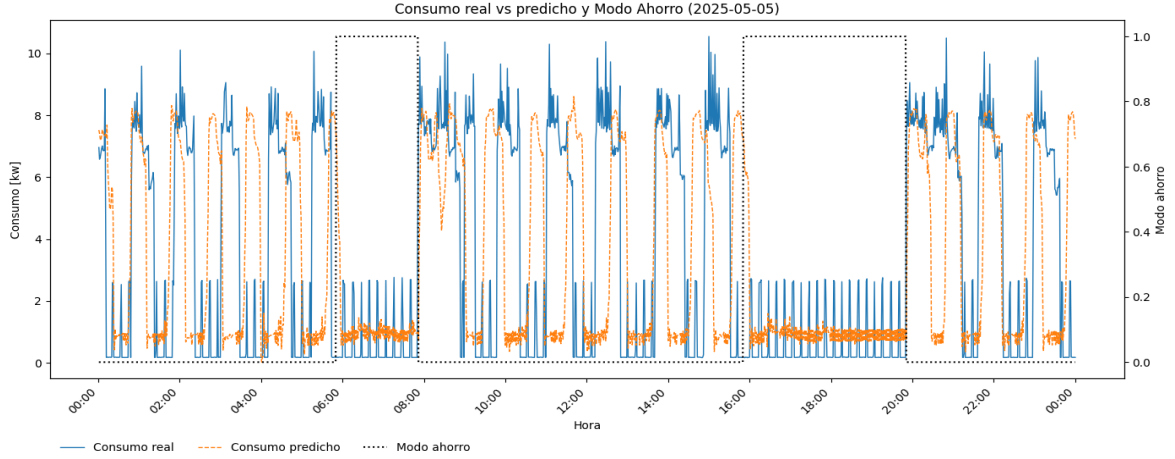


Figura 20: Comparación de consumo predicho y real

Si bien las métricas tradicionales (MAE, RMSE, MAPE, SMAPE) fueron útiles durante el proceso de ajuste, se detectó que no siempre reflejaban adecuadamente el impacto de ciertos errores en escenarios de planificación energética. Por esta razón, se introdujo una métrica específica adicional denominada error de perfil horario, diseñada para evaluar la capacidad del modelo de reproducir el patrón agregado de consumo diario.

El cálculo de esta métrica consiste en comparar el consumo total acumulado por hora entre las predicciones y los datos reales, aplicando el siguiente criterio:

$$\text{MAE}_{\text{hora}} = \frac{1}{24} \sum_{h=0}^{23} \left| \sum_{i \in h} \hat{y}_i - \sum_{i \in h} y_i \right|$$

donde \hat{y}_i y y_i representan respectivamente las predicciones y los valores reales de consumo eléctrico en cada instante i , y la suma se realiza sobre todas las muestras correspondientes a cada hora h .

Esta métrica permitió identificar modelos que, pese a mostrar un error bajo en términos absolutos, tendían a desajustar sistemáticamente el perfil horario, especialmente en los periodos de mayor demanda, lo que resulta crítico en los procesos de optimización diaria de costes.

La Figura 21 muestra un ejemplo representativo de la comparación entre el consumo predicho y el real, agregados en franjas horarias, una vez aplicado el modelo ajustado final.




Figura 21: Comparación de consumo predicho y real en kWh agrupado por hora

4.4. Conclusion

Tras el proceso completo de ajuste, validación y experimentación, se ha logrado finalmente construir un modelo predictivo basado en XGBoost con arquitectura híbrida, combinando predicción recursiva y directa. El modelo, optimizado mediante búsqueda de hiperparámetros y adaptado específicamente a la dinámica de la cámara, presenta un error global medio del 5% en términos de consumo diario acumulado, tomando como referencia la comparación directa de consumo horario real y predicho. Este resultado se obtiene al realizar la agregación horaria de las predicciones (Figura 20), permitiendo compensar los pequeños desplazamientos temporales que se observan en la predicción minuto a minuto, pero manteniendo de forma robusta el patrón global de consumo diario.

Este nivel de precisión permite al gemelo digital anticipar de forma fiable el comportamiento energético de la cámara bajo distintos escenarios de planificación y optimización, manteniendo un margen de error suficientemente bajo para la toma de decisiones operativas y económicas.

Durante el desarrollo se evaluaron múltiples alternativas al modelo híbrido de XGBoost. Las redes LSTM no lograron generalizar correctamente los patrones diarios de 24 horas, mostrando una alta inestabilidad y un coste computacional elevado. Este bajo rendimiento se reflejó en las métricas obtenidas, con un MAE de 0.89 kWh y un RMSE de 1.15 kWh, los más altos de todos los modelos considerados (Tabla 2). Además, sus errores relativos también fueron significativos, con un MAPE del 10.23% y un SMAPE del 9.87%, lo que indica una incapacidad para capturar adecuadamente

la estructura de los datos horarios.

Los modelos RandomForest tampoco ofrecieron un buen rendimiento. Aunque con menor error que LSTM, sus predicciones mostraron una escasa sensibilidad a los cambios de consumo asociados al modo ahorro, lo que se tradujo en resultados planos e imprecisos. Esto se refleja en un MAE de 0.72 kWh y un MAPE del 8.45 %, claramente superiores a los obtenidos por XGBoost. Por su parte, LightGBM y las estrategias de stacking lograron un rendimiento intermedio (por ejemplo, LightGBM con MAE de 0.58 kWh y SMAPE del 6.54 %), pero sin superar la precisión y robustez del modelo base.

La Tabla 2 resume estos resultados comparativos. XGBoost obtuvo el mejor rendimiento en todas las métricas: MAE de 0.45 kWh, RMSE de 0.66 kWh, MAPE del 5.12 % y SMAPE del 4.98 %. Estos valores confirman su capacidad para capturar tanto las tendencias generales como las variaciones dinámicas asociadas al modo ahorro, justificando su elección como núcleo del sistema predictivo del gemelo digital.

Modelo	MAE (kWh)	RMSE (kWh)	MAPE (%)	SMAPE (%)
XGBoost	0.45	0.66	5.12	4.98
RandomForest	0.72	0.98	8.45	8.12
LSTM	0.89	1.15	10.23	9.87
LightGBM	0.58	0.79	6.78	6.54
Stacking	0.65	0.85	7.32	7.09

Tabla 2: Comparación de métricas de rendimiento para los modelos evaluados en el conjunto de validación.

En resumen, el enfoque adoptado ha permitido construir un modelo sólido, preciso y operativo para el control del gemelo digital de la cámara de secado, combinando técnicas de ingeniería de características, adaptación del horizonte de predicción, validación cruzada temporal y ajuste fino de hiperparámetros, logrando así un sistema predictivo robusto en un escenario de elevada variabilidad y dependencia temporal.

Capítulo 5 Resultados y Validación

En este capítulo se presentan los principales resultados obtenidos tras el desarrollo e implementación del gemelo digital. Se analiza su capacidad para optimizar la planificación energética de la cámara, así como las funcionalidades adicionales relacionadas con la supervisión operativa, la detección temprana de fallos y la auditoría continua del sistema.

5.1. Impacto de la Optimización sobre el Consumo y el Coste Energético

Como parte de los resultados, se presenta la capacidad del gemelo digital para evaluar el impacto de una configuración inadecuada del modo ahorro, mostrando que una planificación incorrecta puede conducir a incrementos en el consumo energético. Para este análisis, se ha empleado la herramienta de predicción integrada, la cual permite simular distintos escenarios de planificación sobre días históricos. En concreto, se comparan tres situaciones: el consumo real registrado, el consumo estimado aplicando un plan optimizado y el escenario sin aplicación del modo ahorro. La Figura 22 muestra la interfaz utilizada para definir las franjas horarias de cada escenario de simulación.

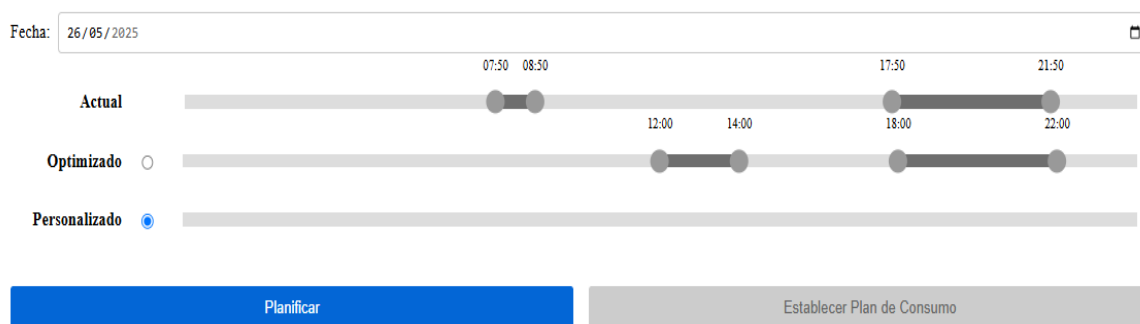


Figura 22: Interfaz de selección de franjas horarias para la planificación de consumo energético.

Los resultados obtenidos, representados en la Figura 23, evidencian que para el día analizado la cámara registró un gasto eléctrico de 8,60 € bajo la planificación actualmente aplicada. Si no se hubiese aplicado ningún modo ahorro (es decir, manteniendo el funcionamiento continuo de la cámara), el coste estimado sería de

7,24 €, lo que ya indica que la planificación actual no solo no genera ahorro, sino que puede incrementar el consumo. Por su parte, la planificación optimizada propuesta por el algoritmo presenta un coste estimado de 5,74 €, lo que representa un ahorro de aproximadamente 2,86 € respecto a la configuración actual.



Figura 23: Comparativa del coste energético diario bajo distintas planificaciones: actual, optimizada y sin modo ahorro.

Este comportamiento pone de manifiesto cómo una configuración subóptima del modo ahorro puede generar ineficiencias. La planificación actual desplaza el funcionamiento de la cámara fuera de las horas con peajes elevados, pero no tiene en cuenta el precio horario de la energía. Sin embargo, el algoritmo optimizado evalúa conjuntamente tanto los peajes como el precio del mercado eléctrico, penalizando aquellas horas donde el coste total (suma de energía y peaje ponderado) es más elevado. De este modo, puede establecer el modo ahorro incluso en horarios con peajes bajos si el precio de la electricidad es particularmente alto, ajustando dinámicamente su estrategia para minimizar el coste global. La interacción entre precios, peajes y decisiones de optimización puede observarse en la Figura 24, donde se representan los perfiles horarios de precio real y la planificación optimizada resultante.




Figura 24: Relación entre precios horarios de energía y priorización del algoritmo de optimización en presencia de peajes.

Adicionalmente, la Figura 25 muestra la distribución horaria del coste en euros correspondiente a cada una de las planificaciones evaluadas: consumo real, planificación optimizada y planificación personalizada (introducida manualmente por el usuario).

Puede observarse cómo el algoritmo tiende a redistribuir el consumo hacia las horas de menor precio, evitando a su vez los periodos donde existe riesgo de aplicar peajes elevados. Como resultado, el perfil optimizado presenta una distribución más equilibrada y continua a lo largo del día, reduciendo la aparición de picos de gasto característicos del consumo real.

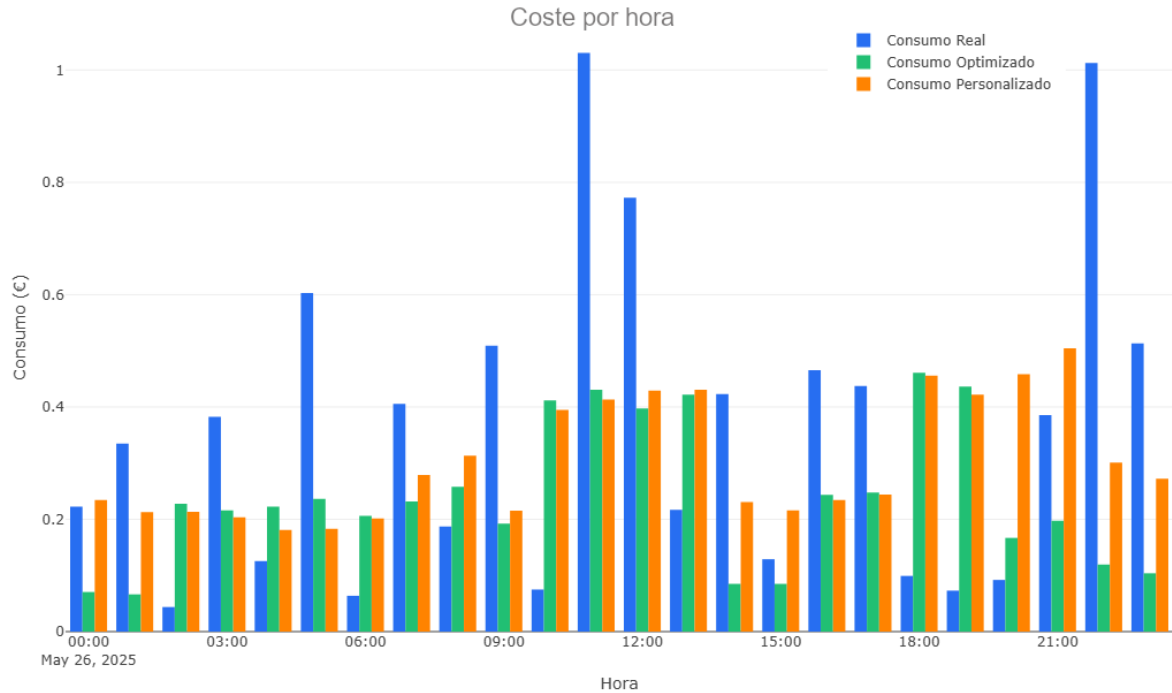


Figura 25: Distribución horaria del coste energético para las tres estrategias de planificación: actual, optimizada y personalizada.

Por último, es importante señalar que las simulaciones realizadas se apoyan en los resultados del modelo predictivo, cuya precisión se ha validado previamente en la Sección 4.3. Según dicho análisis, el margen de error estimado sobre el consumo real se mantiene en torno al 5% en condiciones habituales, considerando un umbral conservador de hasta un 10% para reflejar posibles variabilidades adicionales. No obstante, incluso incorporando este posible desvío, las diferencias de coste entre las distintas planificaciones mantienen su magnitud, validando la robustez de la estrategia optimizada frente a configuraciones manuales o estáticas.

5.2. Evolución Mensual del Coste Eléctrico

Al margen del análisis generado de forma automática por la interfaz de la herramienta, se ha llevado a cabo un estudio específico sobre los costes energéticos, comparando el escenario real frente al optimizado en el horizonte mensual. Los

resultados de este análisis se muestran en la Figura 26.

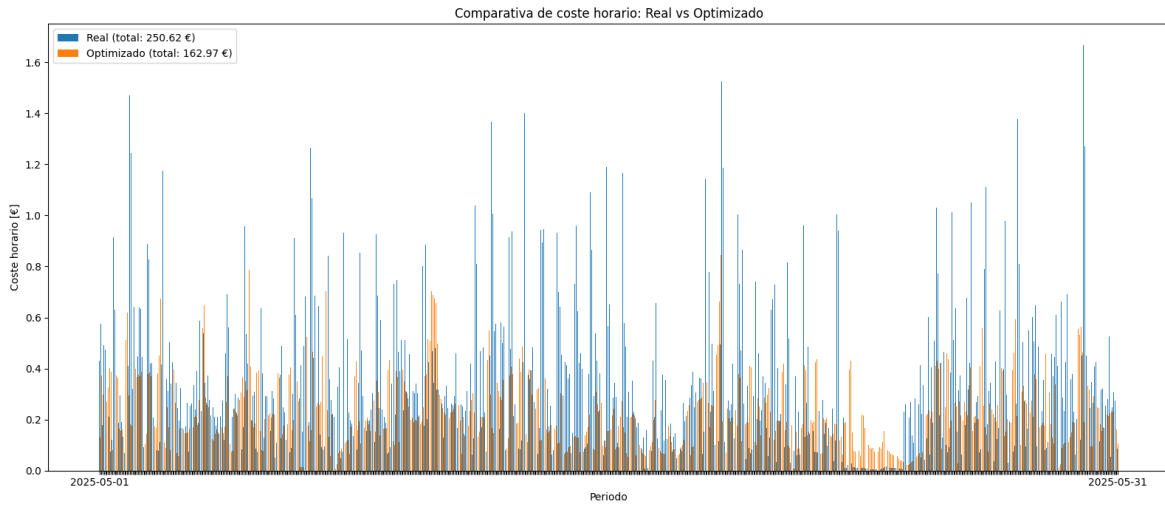


Figura 26: Comparativa mensual de coste eléctrico horario: consumo real vs optimizado

La figura presentada muestra la evolución del coste horario de la cámara de secado a lo largo de un mes completo, comparando dos escenarios: el coste real registrado (en azul) frente al coste estimado bajo un plan de operación optimizado (en naranja). En el eje X se representa el periodo analizado, que abarca desde el 1 hasta el 31 de mayo de 2025, mientras que el eje Y recoge el coste energético acumulado en cada hora, expresado en euros.

Visualmente, se aprecia que los valores asociados al escenario real presentan una mayor dispersión, con picos recurrentes de coste horario que alcanzan valores superiores al euro por hora en varias ocasiones. En contraste, el escenario optimizado mantiene la mayoría de las barras dentro de un rango inferior, limitando los picos y reduciendo sensiblemente la media horaria. Esta diferencia de comportamiento se traduce en una reducción significativa del coste total mensual: mientras que el sistema operando bajo las condiciones reales alcanza un gasto acumulado de 250,62 €, la operación bajo el plan optimizado reduce este importe a 162,97 €, lo que supone un ahorro de aproximadamente el 35 % sobre el periodo considerado.

Como se muestra en la Figura 26, la estrategia de optimización no solo disminuye los costes puntuales más elevados, sino que consigue suavizar el perfil horario, distribuyendo la demanda de forma más uniforme y evitando los periodos de mayor penalización tarifaria. Este comportamiento confirma la capacidad del gemelo digital para identificar patrones de consumo subóptimos y proponer planes operativos que contribuyen de manera directa a la reducción del gasto energético.

5.3. Supervisión Operativa y Detección de Eventos

Una de las funcionalidades adicionales más relevantes del gemelo digital es la capacidad de detección temprana de anomalías y la auditoría continua del sistema. Gracias a la monitorización permanente de los valores de los sensores, el gemelo es capaz de identificar irregularidades en el funcionamiento, como por ejemplo, la detección de un fallo en el propio PLC.

En un determinado momento, el PLC dejó de operar correctamente, interrumpiendo el registro de datos de proceso, lo que provocó un intervalo sin valores disponibles. Tal como se observa en la Figura 27, este comportamiento quedó reflejado en la serie temporal. A raíz de este incidente, se implementó un nuevo evento de supervisión que verifica periódicamente la variación de los datos durante la última hora; en caso de detectar ausencia de cambios, el sistema emite una notificación automática al usuario.


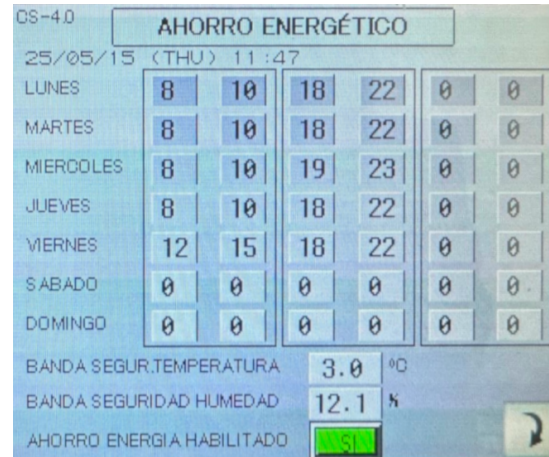


Figura 27: Periodo sin datos registrado debido a fallo de comunicación con el PLC.

Adicionalmente, el diseño del gemelo digital se ha orientado hacia la operatividad directa por parte del usuario final. Para ello, se ha incorporado una réplica de la interfaz HMI, como se muestra en la Figura 28, permitiendo así que el usuario trabaje en un entorno visualmente familiar y pueda visualizar en tiempo real las modificaciones aplicadas sobre el sistema. Cabe señalar que las capturas correspondientes al sistema real y a la réplica digitalizada fueron tomadas en fechas distintas, motivo por el cual los valores y configuraciones mostrados en pantalla no son idénticos.



(a) Réplica HMI gemelo digital.



(b) Interfaz HMI de la cámara real.

Figura 28: Comparativa entre la interfaz HMI original y su réplica digitalizada.

Capítulo 6 Conclusiones

La incorporación de un gemelo digital en el proceso de secado permite disponer de un control mucho más exhaustivo sobre la producción, proporcionando tanto una visualización en tiempo real del estado actual de la cámara como una herramienta de análisis para evaluar posibles escenarios de mejora. Esta capacidad de monitorización y simulación se traduce directamente en una mayor eficiencia operativa, optimizando tanto los consumos energéticos como la calidad final del producto.

El desarrollo del gemelo digital ha demostrado cómo, a partir de los datos ya existentes en la planta, es posible generar información de alto valor añadido. A lo largo de esta memoria se ha demostrado que, mediante la integración de modelos predictivos, módulos de planificación y herramientas de supervisión, es factible transformar simples registros de sensores en un sistema de soporte a la decisión, capaz de anticipar problemas, proponer ajustes y mejorar el rendimiento global del proceso.

El sistema desarrollado representa de forma clara el funcionamiento de la cámara de secado y resulta útil para apoyar decisiones en el entorno industrial. Se ha buscado un equilibrio entre lo que es técnicamente posible y lo que realmente se necesita en la práctica, logrando una solución eficaz y fácil de aplicar.

En definitiva, el gemelo digital no solo actúa como un sistema de monitorización, sino que se convierte en una herramienta activa de mejora continua, facilitando la optimización energética, la trazabilidad operativa y el aprendizaje sobre el propio proceso de secado.

Capítulo 7 Bibliografía

- [1] Flávia Pires, Ana Cachada, José Barbosa, António Paulo Moreira, and Paulo Leitão. Digital twin in industry 4.0: Technologies, applications and challenges. In *2019 IEEE 17th international conference on industrial informatics (INDIN)*, volume 1, pages 721–726. IEEE, 2019.
- [2] César de Prada, Santos Galán-Casado, Jose L Pitarch, Daniel Sarabia, Anibal Galán, and Gloria Gutiérrez. Gemelos digitales en la industria de procesos. *Revista Iberoamericana de Automática e Informática industrial*, 19(3):285–296, 2022.
- [3] Omron. *NB-Series Host Connection Manual*. Omron Corporation, 2024.
- [4] Sadik Tamboli, Mallikarjun Rawale, Rupesh Thoraiet, and Sudhir Agashe. Implementation of modbus rtu and modbus tcp communication using siemens s7-1200 plc for batch process. In *2015 international conference on smart technologies and management for computing, communication, controls, energy and materials (ICSTM)*, pages 258–263. IEEE, 2015.
- [5] Andre Luiz Delai, Alberto Noboru Miyadaira, and Tania Cristina Lima. Amasp (ascii master slave protocol): a lightweight modbus based customizable communication protocol for general applications. *Journal of Communication and Information Systems*, 34(1):1–11, 2019.
- [6] Node-RED Contributors. node-red-contrib-omron-fins. <https://flows.nodered.org/node/node-red-contrib-omron-fins>, 2024. Accedido el 27 de mayo de 2025.
- [7] MR Seba, D Seba, A Berkani, and B Mekhloufi. Hybrid approach for prediction of temperature and moisture in greenhouses using arima, artfima and svm methods. *Applied Ecology & Environmental Research*, 21(6), 2023.
- [8] Xiaoming Ma, Cong Fang, and Junping Ji. Prediction of outdoor air temperature and humidity using xgboost. In *IOP conference series: earth and environmental science*, volume 427, page 012013. IOP Publishing, 2020.
- [9] Hassan Oukhouya, Hamza Kadiri, Khalid El Himdi, and Raby Guerbaz. Forecasting international stock market trends: Xgboost, lstm, lstm-xgboost, and

- backtesting xgboost models. *Statistics, Optimization & Information Computing*, 12(1):200–209, 2024.
- [10] Chen Sun, Zhibin Chen, Yishuang Qin, and Bebe Wang. Multi-step time series forecasting based on informer-xgboost-ga. In *Journal of Physics: Conference Series*, volume 2333, page 012009. IOP Publishing, 2022.
- [11] Jingwei Hou, Yanjuan Wang, Ji Zhou, and Qiong Tian. Prediction of hourly air temperature based on cnn-lstm. *Geomatics, Natural Hazards and Risk*, 13(1):1962–1986, 2022.
- [12] Miguel López Santos, Xela García-Santiago, Fernando Echevarría Camarero, Gonzalo Blázquez Gil, and Pablo Carrasco Ortega. Application of temporal fusion transformer for day-ahead pv power forecasting. *Energies*, 15(14):5232, 2022.
- [13] Omron. Omron nb5q-tw01b - pantalla hmi. <https://industrial.omron.es/es/products/NB5Q-TW01B>, 2024. Acceso en mayo de 2025.
- [14] Omron. *FINS Commands*. Omron Corporation, Revised June 2001.
- [15] Plotly Technologies Inc. Plotly: The interactive graphing library for python. <https://plotly.com/python/>, 2015.
- [16] Tianqi Chen, Tong He, Michael Benesty, Vadim Khotilovich, Yuan Tang, Hyunsu Cho, Kailong Chen, Rory Mitchell, Ignacio Cano, Tianyi Zhou, et al. Xgboost: extreme gradient boosting. *R package version 0.4-2*, 1(4):1–4, 2015.
- [17] scikit-learn developers. `sklearn.multioutput.multioutputregressor`, 2024. Consultado el 11 de mayo de 2025.
- [18] Tianqi Chen and Carlos Guestrin. Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794, 2016.
- [19] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, Jake Vanderplas, Alexandre Passos, David Cournapeau, Matthieu Brucher, Matthieu Perrot, and Édouard Duchesnay. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.

Anexos

Anexo I Criterios de selección de la variable humedad

La decisión de centrar el análisis de periodicidad y autocorrelación exclusivamente en la variable humedad responde a criterios tanto funcionales como estructurales del sistema bajo estudio.

En primer lugar, la humedad representa la variable clave del proceso de secado, ya que refleja el estado interno de la cámara y está directamente relacionada con la eficiencia del proceso. Aunque la temperatura tiene una influencia directa sobre la humedad, especialmente en condiciones de equilibrio térmico, es esta última la que condiciona de forma más directa la demanda energética: el consumo eléctrico responde principalmente a las acciones necesarias para reducir o mantener el nivel de humedad dentro de los márgenes deseados.

Como se observa en la Figura 29, los cambios en temperatura provocan variaciones en la humedad, mientras que los niveles de humedad marcan el perfil de consumo asociado al funcionamiento del sistema.

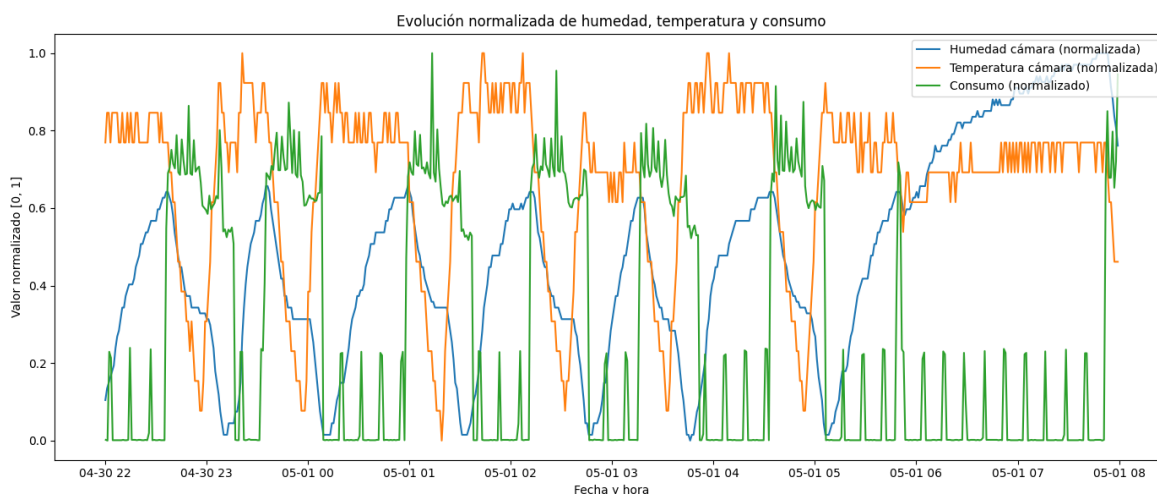


Figura 29: Evolución normalizada de humedad, temperatura y consumo.

Desde este punto de vista, la humedad actúa como una variable intermedia entre la temperatura (que se regula directamente) y el consumo energético (que se desea optimizar), lo que la convierte en la mejor candidata para modelar el comportamiento global del sistema. Así, si se desea anticipar con precisión el perfil de consumo, es

imprescindible comprender y predecir la evolución de la humedad.

Además, desde el punto de vista estadístico, la señal de humedad presenta patrones más regulares, una dinámica cíclica más marcada y menor ruido exógeno que el consumo, lo que facilita su análisis mediante autocorrelación y espectros de potencia. Estas propiedades permiten establecer con mayor precisión la longitud de las ventanas temporales necesarias para entrenar modelos de predicción robustos.

Por estos motivos, se ha optado por estudiar la variable de humedad como referencia estructural del sistema, priorizando su análisis frente a otras magnitudes cuyo comportamiento es derivado o más errático.

Anexo II Entorno de entrenamiento

Con el objetivo de entrenar y comparar distintos modelos de predicción, se han evaluado diversas arquitecturas y algoritmos, entre los que se incluyen LSTM, XGBoost, Random Forest, Prophet y ARIMA. Dado que uno de los objetivos era analizar la eficiencia computacional entre ellos, se optó por crear un entorno de desarrollo controlado mediante un entorno virtual de Python ejecutado sobre un sistema operativo Linux, concretamente a través de Windows Subsystem for Linux (WSL).

Esta configuración permite aprovechar la aceleración por GPU, lo cual resulta especialmente relevante para modelos como LSTM, que requieren tiempos de entrenamiento significativamente mayores en comparación con los métodos más clásicos. De este modo, se reduce el tiempo de entrenamiento y se optimiza el proceso de experimentación.

Para habilitar esta infraestructura, se instalaron las siguientes herramientas:

- WSL 2: subsistema de Linux para Windows, utilizado como base para la ejecución de entornos nativos de desarrollo.
- Ubuntu 20.04.6 LTS: distribución de Linux empleada como entorno principal dentro de WSL.
- Python 3.12.3 junto con pipenv: herramientas utilizadas para la gestión de entornos virtuales y dependencias del proyecto.
- NVIDIA CUDA Toolkit 12.3 y controladores correspondientes: necesarios para habilitar la aceleración por GPU en operaciones de cálculo intensivo.
- cuDNN 8.9.5.30 (CUDA Deep Neural Network library): librería de alto rendimiento para el entrenamiento de redes neuronales profundas.
- TensorFlow 2.18.0: framework empleado para el desarrollo y entrenamiento del modelo LSTM.

Anexo III Endpoints Backend

Endpoints del sistema

Backend principal

Método	URI	Parámetros de entrada	Parámetros de salida	Auth	Descripción
GET	/	–	message	Ninguna	Comprobación de estado de la API
POST	/auth/login	username, password (form)	access_token	Ninguna	Obtiene token JWT
POST	/auth/forgot-password	email	msg	Ninguna	Envío de código de recuperación
POST	/auth/reset-password	email, code, new_password	msg	Ninguna	Restablece la contraseña
POST	/users/	cuerpo UsuarioCreate	UsuarioRead	Admin	Crea usuario
GET	/users/	skip, limit	lista UsuarioRead	Admin	Lista usuarios
PUT	/users/{id}/role	is_editor	UsuarioRead	Admin	Modifica rol de usuario
DELETE	/users/{id}	–	– (204)	Admin	Elimina usuario
GET	/users/me	–	UsuarioRead	Usuario	Usuario autenticado
GET	/fechas/disponibles	–	start, end	Usuario	Rango de fechas aceptadas
GET	/consumo/real	fecha	datos y total_cost_eur	Usuario	Consumo real de un día
POST	/consumo/pre-diccion/manual	JSON schedule, start_date	datos, coste y humedad	Usuario	Coste para planificación dada
POST	/consumo/pre-diccion/ia	– (placeholder)	datos vacíos	Usuario	Predicción IA planificada
GET	/consumo/optimizado	fecha	datos y total_cost_eur	Usuario	Consumo optimizado
GET	/consumo/comparativo	fecha_inicio, fecha_fin	consumo real/optimizado	Usuario	Comparativa de rangos
WS	/eventos/ws	token	flujo de eventos	Usuario	Eventos críticos en tiempo real

GET	/reglas/	-	lista EventRule	Usuario	Obtiene reglas de eventos
POST	/reglas/	cuerpo EventRuleCreate	EventRule	Admin	Crea regla de evento
PUT	/reglas/{id}	cuerpo EventRuleUpdate	EventRule	Admin	Actualiza regla
DELETE	/reglas/{id}	-	- (204)	Admin	Elimina regla
GET	/banda_pre_a horro/	start, end	banda y datos	Usuario	Cálculo previo de banda de ahorro
GET	/config/	-	ConfigBandaRead	Usuario	Configuración de ahorro
POST	/config/	cuerpo ConfigBandaCreate	ConfigBandaRead	Admin	Guarda configuración y relanza cálculo óptimo
GET	/planificaci on/semana	-	WeekSchema	Usuario	Semana tipo almacenada
POST	/planificaci on/semana	cuerpo SemanaConOrigenIn	- (204)	Admin	Sobrescribe la semana tipo
GET	/planificaci on/lista	-	lista de días planificados	Usuario	Lista de días con planificación establecida
POST	/planificaci on/dias	lista DiaPlanificacionIn	- (204)	Admin	Guarda varios días personalizados
GET	/planificaci on/diaEstabl ecido	start_date	DaySchedule	Usuario	Planificación establecida de un día
GET	/planificaci on/dia	start_date	DaySchedule	Usuario	Planificación real de un día
GET	/planificaci on/optimizada	start_date	DaySchedule	Usuario	Planificación optimizada
WS	/planificaci on/ws/planif icacion	token	notificaciones	Usuario	Avisos de cambios de planificación
GET	/planificaci on/panel_con trol	-	estructura de panel	Usuario	Información para el panel de control
POST	/tarifas	cuerpo TarifasFestivos	- (204)	Admin	Sobrescribe tarifas y relanza recálculo óptimo
GET	/tarifas	-	TarifasFestivos	Admin	Obtiene tarifas, festivos y peajes
GET	/tarifas/dia	start_date	DiaTarifa	Usuario	Tarifa horaria de un día concreto

GET	/influx/buckets	-	buckets	Usuario	Lista de buckets InfluxDB
GET	/influx/measurements	bucket	measurements	Usuario	Measurements en un bucket
GET	/influx/fields	bucket, measurement	fields	Usuario	Fields de un measurement
GET	/influx/meta-data	bucket, measurement?	medidas/fields	Usuario	Metadata de InfluxDB
GET	/influx/data	bucket, measurement, field, start, stop	datos crudos	Usuario	Consulta de datos a InfluxDB

Backend IA

Método	URI	Parámetros de entrada	Parámetros de salida	Auth	Descripción
GET	/	-	message	Ninguna	Comprobación de estado del servicio IA
POST	/consumo/prediccion	JSON schedule, start_date	datasets, humedad	Ninguna	Predicción de consumo (24 h) mediante XGBoost

Anexo IV Manual de Usuario

Gemelo digital

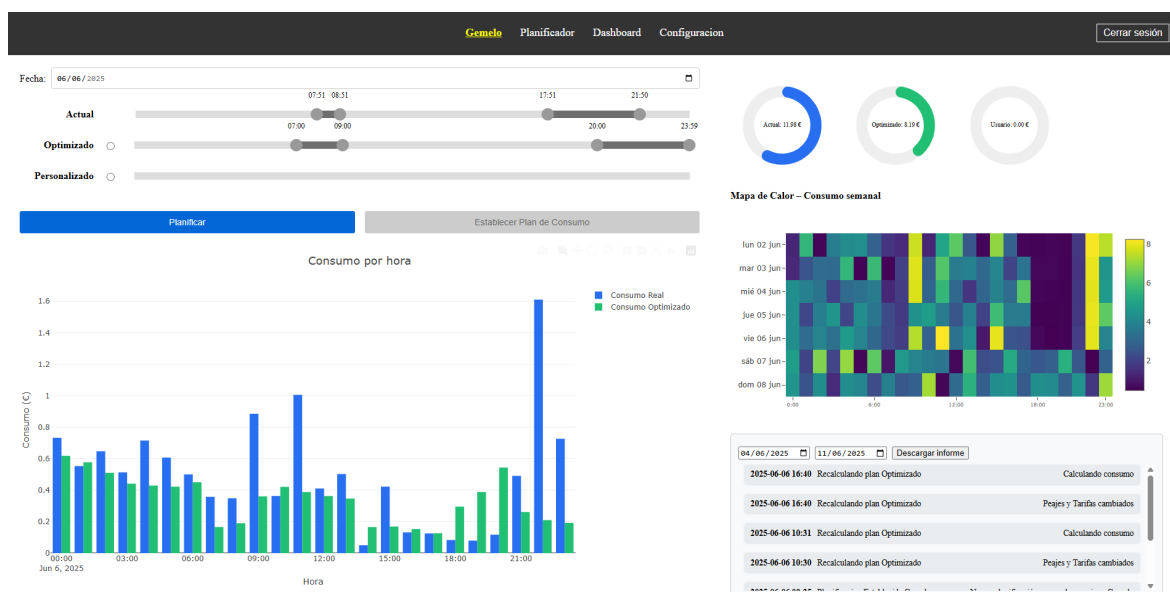


Figura 30: Gemelo Digital.




Figura 31: Gemelo Digital, Scrol Inferior.

Propósito y funcionalidades principales

Ofrece una visualización completa del consumo energético real, optimizado y personalizado del Gemelo Digital. Permite simular escenarios, enviar predicciones

manuales y consultar eventos críticos. Es el punto central para analizar datos diarios y validar estrategias de ahorro.

Elementos de la interfaz

Nº	Componente	Descripción	Operaciones permitidas	Consejo de uso
1	Selector de fecha	Define la jornada que se desea analizar.	Elegir fecha dentro del rango disponible.	Si no hay datos, verifique las fechas ofrecidas.
2	MultiInterval Slider	Tres barras (“Actual”, “Optimizado” y “Personalizado”).	Ajustar manualmente solo la barra “Personalizado”.	Seleccione el plan con los botones de opción.
3	Botón “Planificar”	Envía la configuración personalizada al servidor para obtener una predicción.	Ejecutar cálculo manual.	Espere el mensaje de confirmación antes de cambiar de fecha.
4	Botón “Establecer Plan de Consumo”	Abre el planificador semanal para aplicar la planificación desde esta vista.	Navegar al Planificador con los intervalos actuales.	Disponible únicamente para usuarios con rol de editor.
5	Gráfica de barras	Muestra el coste por hora de los distintos planes.	Desplazar o ampliar con la interfaz de Plotly.	Compare visualmente los tres planes para detectar ahorros.
6	Indicadores radiales	Totales diarios de coste para cada plan.	Solo lectura.	Pase el cursor para ver los valores exactos.
7	Heatmap y eventos	Información adicional sobre activaciones y alertas relevantes.	Consultar eventos críticos.	Útil para correlacionar consumos y condiciones ambientales.

Flujo paso a paso típico

1. Seleccione la fecha en el control superior.
2. Revise las barras de consumo actual y optimizado.
3. Ajuste la barra “Personalizado” si desea una predicción manual.
4. Pulse “Planificar” y espere a que aparezcan los nuevos resultados.
5. Si los valores son adecuados, utilice “Establecer Plan de Consumo” para llevar la planificación al Planificador.

Preguntas frecuentes (FAQ) específicas

- ¿Por qué algunas barras aparecen vacías? No existen datos disponibles para ese plan o la fecha seleccionada.
- ¿Puedo modificar el plan Optimizado? No. Solo el plan “Personalizado” es editable manualmente.
- ¿Qué representan los círculos radiales? El coste total diario de cada modalidad (Actual, Optimizado y Personalizado).

Errores comunes y solución

Mensaje	Causa	Remedio
“Error consumo_real” u otros similares	Fallo al recuperar datos del servidor	Reintente o verifique la conexión con la API.

Atajos y trucos avanzados

- Mantenga pulsado el botón izquierdo y arrastre para desplazar el gráfico en la vista de barras.
- Seleccione directamente la fecha de hoy o mañana para acceder rápidamente a las predicciones más recientes.

Planificador - vista diaria

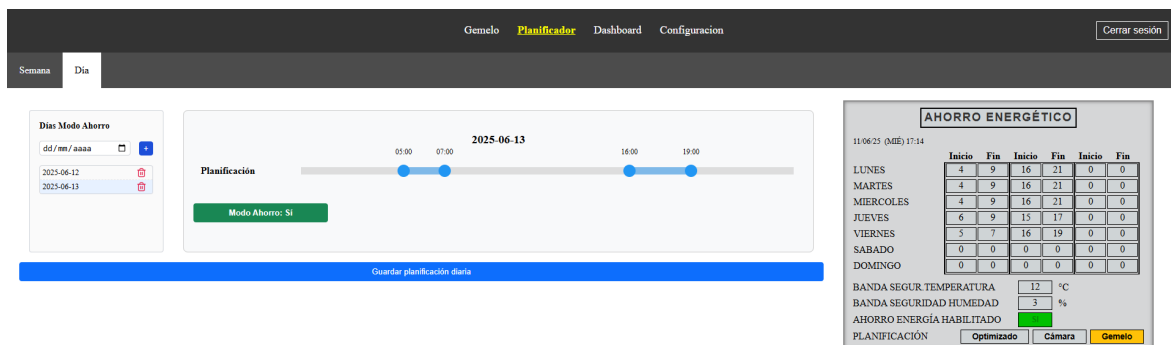


Figura 32: Planificador Diario.

Propósito y funcionalidades principales

Permite programar días concretos con intervalos de modo ahorro para el Gemelo Digital. Resulta útil cuando se necesita ajustar fechas puntuales sin modificar la planificación semanal completa. Ofrece una lista de días configurados y un editor con deslizadores para cada intervalo.

Elementos de la interfaz

Nº	Componente	Descripción	Operaciones permitidas	Consejo de uso
1	Selector de fecha	Campo de calendario para añadir un nuevo día.	Escoger una fecha futura y pulsar el botón “+”.	Evite duplicados; las fechas existentes no se repiten.
2	Lista de días	Muestra los días planificados con opción de eliminar.	Seleccionar un día para editar o pulsar el icono de papelera.	Haga clic en la fecha para activar su edición.
3	SingleDaySlider	Barra para definir rangos horarios de ahorro.	Arrastrar los extremos o crear nuevos intervalos.	Use bloques contiguos para cubrir periodos amplios.
4	Interruptor “Modo Ahorro”	Activa o desactiva la planificación para el día actual.	Cambiar el estado con un clic.	Al desactivar, los intervalos se vacían automáticamente.
5	Botón “Guardar planificación diaria”	Envía todos los cambios al servidor.	Guardar o actualizar la lista de días.	Verifique cada intervalo antes de guardar.

Flujo paso a paso típico

1. Vaya a la pestaña “Día” del Planificador.
2. Seleccione una fecha y pulse “+” para añadirla.
3. Elija el día de la lista y edite los intervalos con el slider.
4. Active o desactive el modo ahorro según corresponda.
5. Repita con otras fechas si es necesario.
6. Presione “Guardar planificación diaria” para confirmar.

Preguntas frecuentes (FAQ) específicas

- ¿Puedo modificar un día pasado? No. Solo se permiten fechas iguales o posteriores al día actual.
- ¿Cómo elimino un día de la lista? Pulse el icono de papelera junto a la fecha que desea borrar.

Errores comunes y solución

Mensaje	Causa	Remedio
Al guardar no ocurre nada	Falta seleccionar un día válido o hay intervalos vacíos	Revise que exista al menos un intervalo y que la fecha sea correcta.

Atajos y trucos avanzados

Si necesita varios días idénticos, añádalos y ajuste un día primero; luego copie los intervalos manualmente en los demás.

Planificador - vista semanal

The screenshot shows the 'Planificador' interface for the week of June 23rd. The main area displays a timeline for each day from Monday to Sunday. The 'Planificación actual' (current plan) shows a grey bar from 04:00 to 21:00. The 'Planificación nueva' (new plan) shows a blue bar from 04:00 to 21:00. A 'Modo Ahorro: SI' button is visible. On the right, the 'AHORRO ENERGÉTICO' panel shows a table of energy saving settings for each day, with values for 'Inicio' and 'Fin' times, and a 'BANDA SEGUR' section with 'TEMPERATURA' at 12 °C and 'HUMEDAD' at 3 %.

Figura 33: Planificador Semanal.

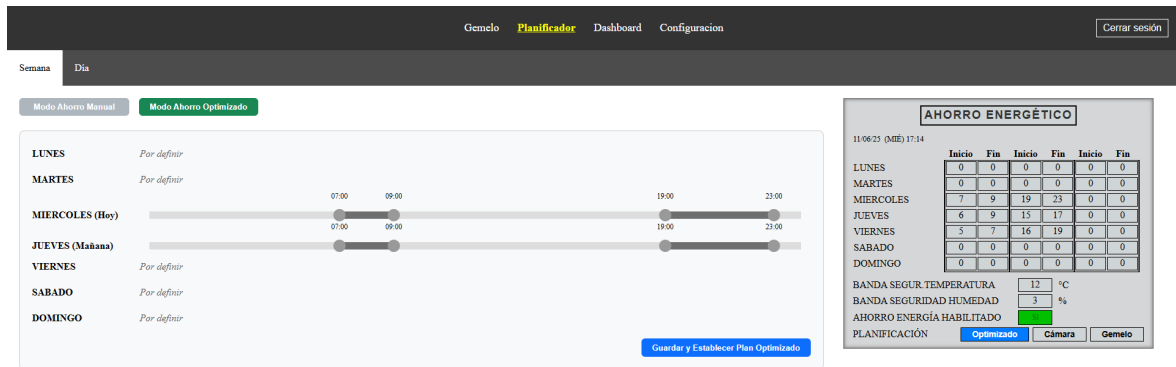


Figura 34: Planificador Optimizado.

Propósito y funcionalidades principales

Gestiona la programación completa de la semana, permitiendo elegir entre modo manual y modo optimizado. Facilita la copia de intervalos a varios días y muestra la planificación actual para comparación. Es la herramienta principal para definir el plan semanal de ahorro energético.

Elementos de la interfaz

Nº	Componente	Descripción	Operaciones permitidas	Consejo de uso
1	Botones “Manual” y “Optimizado”	Seleccionan el origen de la planificación.	Cambiar de modo con un clic.	Solo los editores pueden modificar valores.
2	Selector de días de la semana	Botones etiquetados (LUNES, MARTES, etc.).	Elegir el día a editar.	El día activo aparece resaltado.
3	Slider “Planificación nueva”	Editor de intervalos para el día seleccionado.	Crear, mover o borrar intervalos.	Utilice los extremos para ajustar al minuto.
4	Botón “Copiar”	Copia la planificación del día actual.	Seleccionar otros días destino y aplicar.	Útil para replicar configuraciones similares.
5	Panel Control	Vista compacta de la planificación en vigor.	Solo lectura.	Verifique aquí que los cambios se hayan aplicado.
6	Botón “Guardar y Establecer Planificación Semanal”	Envía la semana completa al sistema.	Guardar datos y activar la planificación.	Confirme que todos los días estén configurados antes de guardar.

Flujo paso a paso típico

1. Ingrese en la pestaña “Semana”.
2. Seleccione “Manual” u “Optimizado”.
3. Haga clic en un día y modifique los intervalos mediante el slider.
4. Si lo desea, copie la planificación y péguela en otros días.
5. Active o desactive el modo ahorro con el botón correspondiente.
6. Pulse “Guardar y Establecer Planificación Semanal”.

Preguntas frecuentes (FAQ) específicas

- ¿Qué diferencia hay entre los modos Manual y Optimizado? El modo Manual utiliza intervalos definidos por el usuario, mientras que el Optimizado aplica un cálculo automático.
- ¿Puedo ver la planificación real sin editar? Sí. El Panel Control muestra la configuración vigente en modo solo lectura.

Errores comunes y solución

Mensaje	Causa	Remedio
“Hubo un error guardando la semana”	Fallo en la comunicación con el servidor	Revise su conexión e intente nuevamente.

Atajos y trucos avanzados

Utilice la función de copiar y pegar para configurar varios días a la vez y ahorrar tiempo.

Dashboard

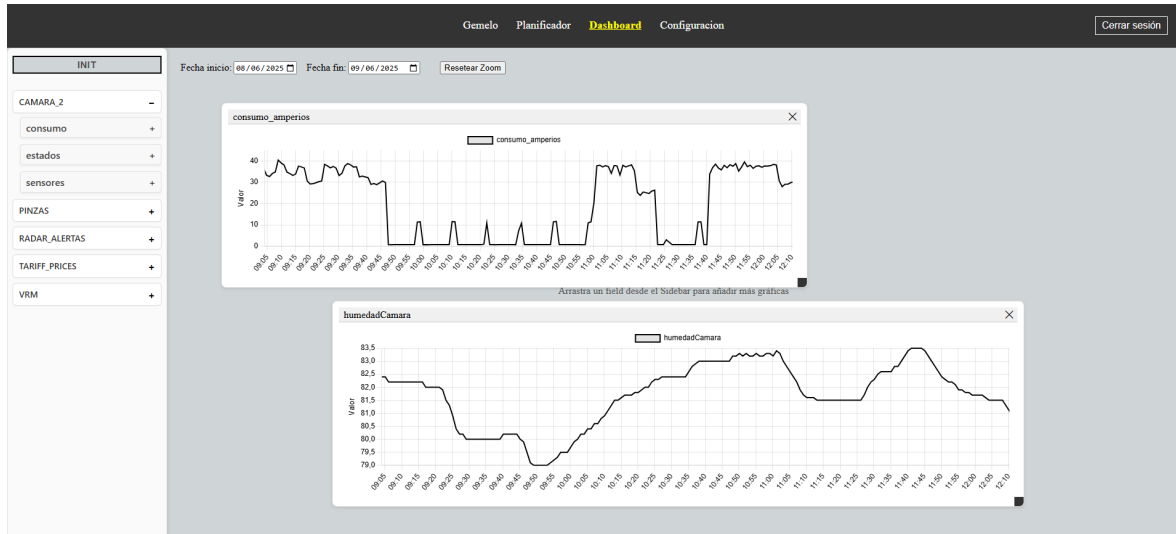


Figura 35: Dashboard.

Propósito y funcionalidades principales

Esta página permite crear y visualizar gráficos personalizados con datos históricos del Gemelo Digital. Proporciona un área de trabajo donde arrastrar campos desde la barra lateral y configurar rangos de fechas para analizar tendencias o incidencias. Es útil para inspeccionar de forma rápida distintos parámetros y conservar la disposición de las gráficas entre sesiones.

Elementos de la interfaz

Nº	Componente	Descripción	Operaciones permitidas	Consejo de uso
1	Barra lateral	Lista de buckets, measurements y fields disponibles.	Expandir, colapsar y arrastrar campos.	Seleccione primero el bucket y measurement adecuados.
2	Área de gráficos	Zona donde se sueltan los campos para crear nuevas tarjetas.	Soltar, mover y redimensionar tarjetas; hacer zoom y pan.	Mantenga pulsada la tecla Shift para realizar un zoom por arrastre.
3	Controles de fecha	Dos calendarios para definir el intervalo de descarga de datos.	Cambiar fecha inicial y final.	Pulse “Resetear Zoom” para ajustar la vista al nuevo rango.

4	Tarjetas de gráfico	Contenedor individual con el gráfico, un asa para moverlo y un botón de cierre.	Mover, cambiar tamaño o eliminar la tarjeta.	Use la esquina inferior derecha para redimensionar.
5	Mensajes de ayuda	Indicaciones sobre arrastrar campos o ausencia de datos.	—	Consulte estos mensajes si no aparecen gráficas.

Flujo paso a paso típico

1. Ingrese al Dashboard.
2. Abra un bucket y measurement desde la barra lateral.
3. Arrastre un field hasta el área de gráficos.
4. Ajuste el rango de fechas si necesita datos específicos.
5. Explore la gráfica con zoom o pan.
6. Añada más tarjetas repitiendo el proceso.
7. Al terminar, puede cerrar las tarjetas innecesarias.

Preguntas frecuentes (FAQ) específicas

- ¿Cómo elimino una gráfica? Haga clic en el botón «X» de la tarjeta correspondiente.
- ¿Se guardan mis configuraciones? Sí, pero solo durante la sesión. La posición y tamaño de las tarjetas se almacenan en cache.
- ¿Qué sucede si no aparece información? Compruebe que el rango de fechas contenga datos disponibles.

Errores comunes y solución

Mensaje	Causa	Remedio
“Error: ...” al cargar datos	Fallo de comunicación con el servidor o campo inexistente	Revise la conexión y la selección de bucket/measurement/field.

Atajos y trucos avanzados

- Use la rueda del ratón sobre una gráfica para acercarse o alejarse rápidamente.
- Mantenga Shift y arrastre para definir un área de zoom más precisa.

Configuración - Tarifas y peajes

Propósito y funcionalidades principales

Permite definir las tarifas eléctricas por hora, asignar peajes y gestionar días festivos. Esta configuración es esencial para calcular adecuadamente los costes de consumo según la temporada y el tipo de día.

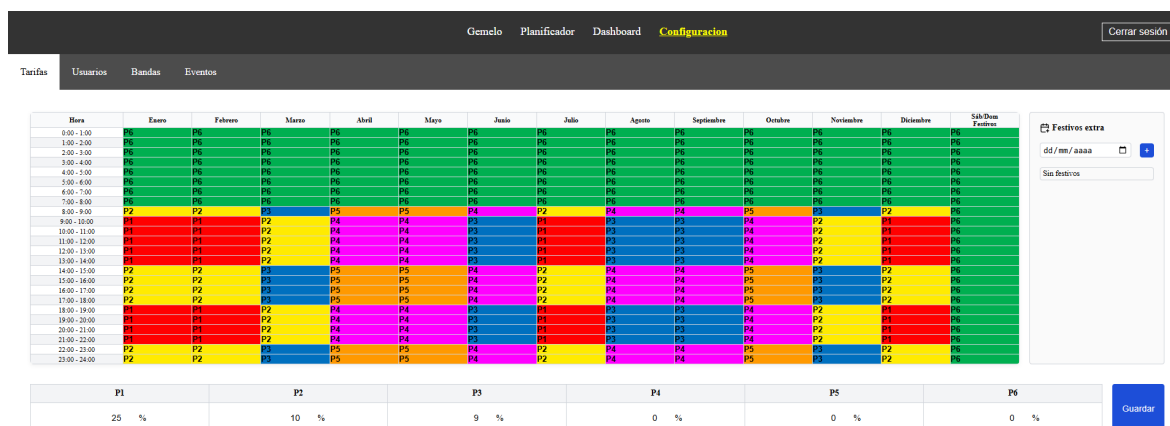


Figura 36: Configuración Tarifas y Peajes.

Elementos de la interfaz

Nº	Componente	Descripción	Operaciones permitidas	Consejo de uso
1	Tabla de tarifas	Matriz de horas frente a meses y días especiales (columnas).	Seleccionar la tarifa P1-P6 en cada celda.	Utilice la última columna para sábados, domingos y festivos.
2	Panel de festivos	Lista de fechas adicionales consideradas festivas.	Añadir o eliminar días festivos.	Ingrese la fecha y pulse “+” para agregarla.
3	Tabla de peajes	Porcentaje de peaje para cada tarifa.	Introducir valores numéricos y guardarlos.	Escriba el porcentaje sin el símbolo “%”.
4	Botón “Guardar”	Guarda la configuración actual en el servidor.	Confirmar cambios en tarifas y peajes.	Espere a que finalice el mensaje de guardado.

5	Indicador de carga	Texto “Cargando...” mientras se obtienen los datos.	Solo lectura.	Si permanece mucho tiempo, revise la conexión con la API.
---	--------------------	---	---------------	---

Flujo paso a paso típico

1. Abra el apartado “Tarifas y peajes” en Configuración.
2. Modifique las celdas de la tabla para cada hora y mes.
3. Añada festivos específicos si corresponde.
4. Ajuste los porcentajes de peaje.
5. Pulse “Guardar” para almacenar los cambios.

Preguntas frecuentes (FAQ) específicas

- ¿Qué significan las etiquetas P1...P6? Son los distintos tramos tarifarios definidos por la compañía eléctrica.
- ¿Cómo elimino un festivo? Pulse el botón de la papelera junto a la fecha correspondiente.
- ¿Puedo copiar tarifas de un mes a otro de forma masiva? No, actualmente cada celda debe editarse de manera individual.

Errores comunes y solución

Mensaje	Causa	Remedio
“Error guardando la configuración”	Fallo de la API o datos incompletos	Revise que todas las celdas tengan valores válidos y vuelva a intentar.

Atajos y trucos avanzados

Una vez configurado un mes, utilice la rueda del ratón sobre la tabla para desplazarse rápidamente y revisar el resto de meses.

Configuración - Usuarios

Propósito y funcionalidades principales

Gestiona las cuentas de acceso al sistema. Desde aquí se crean nuevos usuarios, se asignan roles (editor o visualizador) y se administran sus credenciales para recibir alertas.

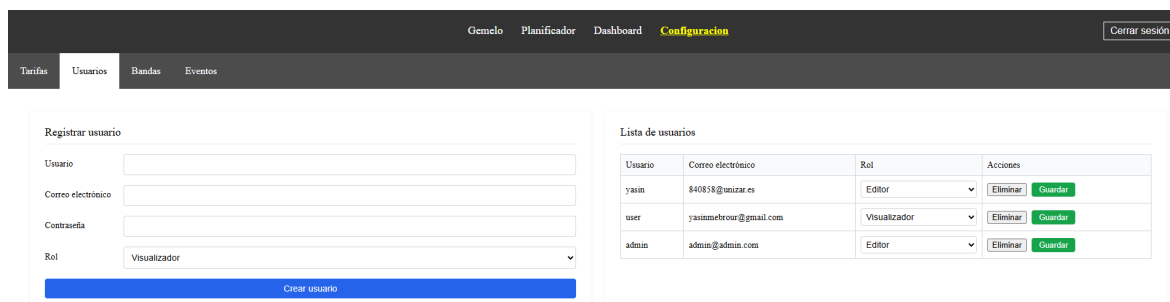


Figura 37: Configuración Usuarios.

Elementos de la interfaz

Nº	Componente	Descripción	Operaciones permitidas	Consejo de uso
1	Formulario de registro	Campos de usuario, correo, contraseña y rol.	Introducir datos y enviar el formulario.	Utilice contraseñas de al menos cinco caracteres.
2	Botón "Crear usuario"	Agrega la cuenta a la base de datos.	Confirmar la creación de un nuevo usuario.	Revise los mensajes de error en caso de datos duplicados.
3	Tabla de usuarios	Lista existente con su rol actual.	Cambiar rol, guardar o eliminar usuarios.	Pulse "Guardar" tras modificar el rol.
4	Botón "Eliminar"	Borra un usuario seleccionado.	Confirmar la eliminación definitiva.	No se puede deshacer, verifique antes de borrar.

Flujo paso a paso típico

1. Complete el formulario con los datos del nuevo usuario.
2. Haga clic en "Crear usuario".
3. Revise la tabla para confirmar que aparece la nueva cuenta.
4. Si necesita cambiar el rol, elija la opción adecuada y pulse "Guardar".

5. Para eliminar un usuario, utilice el botón correspondiente.

Preguntas frecuentes (FAQ) específicas

– ¿Qué diferencia hay entre editor y visualizador? El editor puede modificar planificaciones y configuraciones; el visualizador solo consulta datos.

Errores comunes y solución

Mensaje	Causa	Remedio
“Error al borrar”	Fallo al comunicarse con el servidor	Compruebe la conexión y vuelva a intentarlo.
Lista vacía tras cargar	No se pudieron recuperar los usuarios	Recargue la página o revise las credenciales.

Atajos y trucos avanzados

No se aplican atajos especiales en esta sección.

Configuración - Eventos

Propósito y funcionalidades principales

Sirve para definir reglas que generan eventos de alerta cuando se superan ciertos umbrales en los datos del Gemelo. Cada regla especifica el origen del dato, una condición y la frecuencia de evaluación. También permite configurar el bot de Telegram.

Tarifas Usuarios Bandas **Eventos**

Crear regla

Bucket: CAMARA_2

Measurement: Selección measurement

Field: Selección field

Descripción:

Operador: Mayor que

Valor:

Ventana: 1 min

Frecuencia: 1 min

Activa:

Crear

Reglas

ID	Measurement	Field	Descripción	Oper.	Valor	Ventana	Frecuencia	Estado	Acciones
Sin reglas									

Configurar Telegram

Chat ID:

Bot Token:

Guardar

Figura 38: Configuración Eventos.

Elementos de la interfaz

Nº	Componente	Descripción	Operaciones permitidas	Consejo de uso
1	Formulario de reglas	Campos para bucket, measurement, field y parámetros de comparación.	Crear o actualizar una regla.	Rellene todos los campos antes de guardar.
2	Casilla “Activa”	Indica si la regla se encuentra habilitada.	Marcar o desmarcar según sea necesario.	Desactive temporalmente una regla sin eliminarla.
3	Tabla de reglas	Resumen de todas las reglas configuradas.	Editar o eliminar cada entrada.	Use “Editar” para cargar los valores en el formulario.
4	Botones de acción	“Crear/Guardar”, “Cancelar”, “Eliminar”.	Confirmar o descartar cambios.	Al editar, pulse “Cancelar” para restaurar el formulario.
5	Indicadores de error	Mensajes en rojo sobre el formulario.	Mostrar problemas de validación o de API.	Revise la información ingresada cuando aparezcan errores.
6	Opciones de Telegram	Chat ID, token del bot.	Escribir y habilitar el envío de alertas.	Asegúrese de que el bot tenga permisos para escribir al chat.

Flujo paso a paso típico

1. Seleccione un bucket y measurement disponibles.
2. Elija el campo que desea monitorizar.
3. Complete la condición (operador, valor, ventana, frecuencia).
4. Marque si la regla debe estar activa.
5. Pulse “Crear” para guardarla o “Guardar” si está editando.
6. Use la tabla para modificar o eliminar reglas existentes.

Preguntas frecuentes (FAQ) específicas

- ¿Qué son “ventana” y “frecuencia”? “Ventana” indica cuánto tiempo se analiza para comprobar la condición; “frecuencia” define cada cuánto se realiza la

evaluación.

- ¿Puedo pausar una regla sin borrarla? Sí, desmarque la casilla “Activa” y guarde los cambios.

Errores comunes y solución

Mensaje	Causa	Remedio
“Error al borrar”	No se pudo eliminar la regla en el servidor	Intente nuevamente o verifique la conexión.

Atajos y trucos avanzados

No se aplican atajos específicos en esta sección.

Configuración - Predicciones

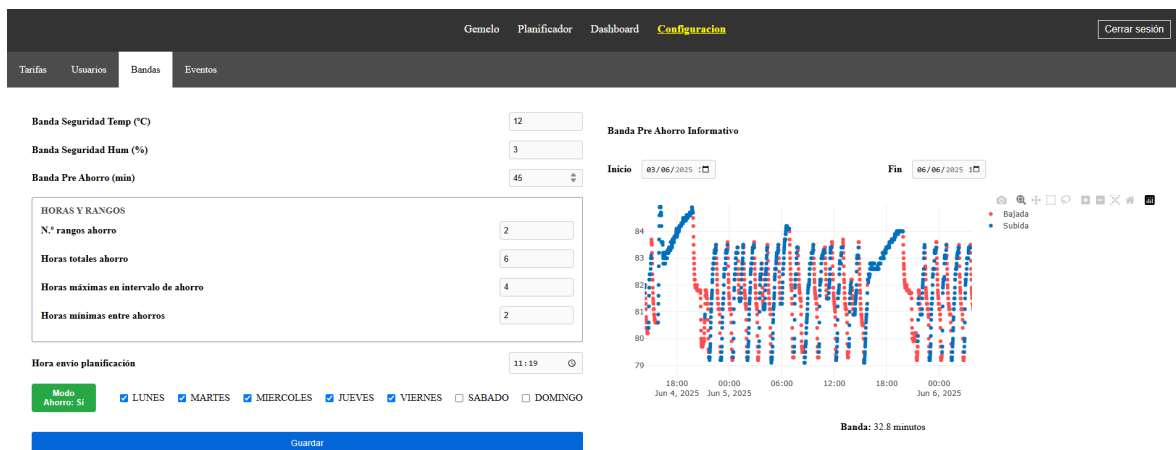


Figura 39: Configuración de Predicciones.

Propósito y funcionalidades principales

Esta sección ajusta los parámetros que influyen en los algoritmos de predicción y en la generación automática de planes de ahorro. Permite definir bandas de seguridad, límites de horas, pesos entre métodos y programar los días de envío de la planificación.

Elementos de la interfaz

Nº	Componente	Descripción	Operaciones permitidas	Consejo de uso
----	------------	-------------	------------------------	----------------

1	Parámetros numéricos	Valores de bandas de temperatura y humedad, horas máximas y rangos.	Introducir números y validar restricciones.	Revise los mensajes de error si los valores son incoherentes.
2	Sliders de pesos únicos	Asignan prioridad a los planes Manual, Optimizado y Semanal.	Mover los deslizadores (1-5) intercambiando posiciones.	No permita que dos planes tengan el mismo valor final.
3	Lista de días de ahorro	Selección de los días de la semana donde se aplica el modo ahorro.	Marcar o desmarcar cada día.	Al activar el modo ahorro se rellenan los días por defecto.
4	Controles de banda pre	Campos de fecha “start” y “end” y gráfico resultante.	Consultar la banda previa y su gráfica.	Útil para verificar la evolución histórica de las condiciones.
5	Botón “Guardar”	Envía toda la configuración al servidor.	Almacenar cambios de forma definitiva.	Confirme que no haya errores antes de guardar.

Flujo paso a paso típico

1. Ajuste las bandas de seguridad y los límites horarios según las necesidades.
2. Modifique los pesos únicos para cada tipo de plan.
3. Seleccione los días de la semana donde se aplicará el modo ahorro.
4. Si desea revisar la banda pre, defina el rango de fechas y observe el gráfico.
5. Pulse “Guardar” para registrar la configuración.

Preguntas frecuentes (FAQ) específicas

- ¿Para qué sirven los pesos únicos? Determinan la prioridad relativa entre los planes Manual, Optimizado y Semanal en los cálculos de predicción.
- ¿Qué sucede si introduzco horas incoherentes? El sistema mostrará un mensaje de error y no permitirá guardar hasta corregir los valores.

Errores comunes y solución

Mensaje	Causa	Remedio
---------	-------	---------

“Las horas totales deben ser al menos igual. . .”	Restricciones lógicas no cumplidas	Revise los campos de horas y rangos para cumplir la condición.
Error al guardar	Fallo en la API o datos incorrectos	Valide todos los campos y repita la acción.

Atajos y trucos avanzados

Aproveche el gráfico de banda pre para identificar periodos con mejores condiciones y ajustar los parámetros en consecuencia.