

Jornadas de Automática

Control predictivo de la demanda en prosumidores de Comunidades Energéticas

A. Marcos Trujillo-Trujillo^{a,*}, Juan A. Méndez-Pérez^a, Santiago Torres-Álvarez^a, Jose M. Gonzalez-Cava^a, Alberto Hamilton-Castro^a

^aDepartamento de Ingeniería Informática y de Sistemas, Universidad de La Laguna (ULL). Camino San Francisco de Paula, 19. 38200 La Laguna (Tenerife), España.

To cite this article: A. Marcos Trujillo-Trujillo, Juan A. Méndez-Pérez, Santiago Torres-Álvarez, Jose M. Gonzalez-Cava, Alberto Hamilton-Castro. 2025. Predictive demand control at prosumers in Energy Communities. Jornadas de Automática, 46. <https://doi.org/10.17979/ja-cea.2025.46.12034>

Resumen

Este artículo presenta una estrategia basada en Control Predictivo por Modelo (MPC) para la gestión de recursos energéticos locales en comunidades energéticas (CE). El sistema propuesto sigue un perfil de red definido por un controlador superior que optimiza la eficiencia energética y minimiza costes e intercambios con la red externa mediante el uso de sistemas de almacenamiento. Las comunidades energéticas están transformando el sector eléctrico con esquemas descentralizados de producción y consumo que fomentan la participación ciudadana activa, donde la gestión del almacenamiento resulta clave. La creciente integración de fuentes renovables intermitentes plantea desafíos de estabilidad en las redes. Los resultados muestran que este enfoque permite una utilización más eficiente de los recursos energéticos dentro de las CE, reduce la dependencia de la red convencional y favorece una disminución de costes respecto a sistemas sin almacenamiento o convencionales basados en reglas, ayudando a mitigar los problemas de inestabilidad asociados a la generación distribuida y la variabilidad de las fuentes renovables.

Palabras clave: Sistemas de gestión de la energía, Control predictivo basado en Modelo, Modelado de sistemas de energía, Diseño de sistemas de control, Redes energéticas inteligentes.

Predictive demand control at prosumers in Energy Communities

Abstract

This paper presents a strategy based on Model Predictive Control (MPC) for managing local energy resources in energy communities (ECs). The proposed system follows a grid profile defined by a higher-level controller that optimizes energy efficiency and minimizes costs and exchanges with the external grid through the use of storage systems. Energy communities are transforming the electricity sector with decentralized production and consumption schemes that promote active citizen participation, where storage management plays a key role. The increasing integration of intermittent renewable sources poses stability challenges to power networks. Results show that this approach enables more efficient use of energy resources within ECs, reduces dependence on the conventional grid, and supports cost reduction compared to systems without storage or conventional rule-based systems, while also helping to mitigate stability issues associated with distributed generation and the variability of renewable sources.

Keywords: Energy Management Systems, Model Predictive Control, Modelling of energy systems, Control system design, Smart grids.

*Autor para correspondencia: atrujilt@ull.edu.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

1. Introducción

La gestión eficiente de la energía constituye un pilar fundamental en la transición hacia un sistema energético más sostenible y resiliente. En este contexto, las comunidades energéticas (CE) se perfilan como un modelo innovador con un papel estratégico en el impulso de dicha transformación en Europa (Ahmed et al., 2024). Estas iniciativas, conformadas por ciudadanos, empresas y entidades locales, promueven esquemas descentralizados de producción, distribución y consumo energético, fomentando una mayor autonomía y sostenibilidad a nivel local. Además, se alinean con los objetivos europeos de eficiencia energética, al incentivar un uso más racional y flexible de la energía por parte de los consumidores activos, lo cual contribuye a aliviar la carga sobre las infraestructuras eléctricas convencionales (Teng et al., 2025).

A pesar del potencial de las comunidades energéticas para mitigar los problemas asociados a la intermitencia de las fuentes renovables, surgen importantes desafíos técnicos y operativos. Uno de los mayores obstáculos es la coordinación eficiente de las distintas fuentes de energía distribuidas, así como la optimización de su uso para maximizar los beneficios económicos y ambientales (Kyriakopoulos, 2022). Las comunidades energéticas deben gestionar no solo la variabilidad de la generación renovable, sino también los perfiles de consumo dispares de sus miembros, lo cual requiere una planificación detallada y sistemas de control avanzados. Además, la integración de tecnologías de almacenamiento de energía y la gestión de flujos bidireccionales de electricidad entre los miembros de la comunidad plantea complejidades adicionales, especialmente en términos de costos, eficiencia y fiabilidad (Aghmadi and Mohammed, 2024). Estos retos hacen que la optimización de la operación de la comunidad energética sea un área clave de investigación, donde se necesita una gestión avanzada que pueda adaptarse tanto a las fluctuaciones de la generación renovable como a los cambios en los patrones de consumo. En este sentido, el aprovechamiento de la flexibilidad de la demanda en comunidades energéticas nos permitiría obtener múltiples beneficios, como una mayor integración de energías renovables, reducción de costes operativos y, fundamentalmente, una participación más activa de los usuarios finales en la transición energética (Sangaré et al., 2023).

Gestionar una Comunidad de la Energía (CE) requiere la toma de decisiones a múltiples niveles, incluyendo la distribución óptima de la cuota de energía renovable entre los miembros participantes, así como la operación y supervisión adecuada de los sistemas de almacenamiento de baterías (BESS, Battery Energy Storage System por sus siglas en Inglés). En la literatura especializada se ha implementado una arquitectura de control jerárquica que comprende, por una parte, un controlador global encargado de diseñar estrategias para equilibrar adecuadamente la curva de demanda entre los diferentes integrantes de la comunidad, y por otra, un conjunto de controladores locales que ejecutan las directrices globales mediante la interacción directa con la red interna y el BES local (Vivas et al., 2025). Esta estructura de control distribuido permite optimizar tanto los objetivos comunitarios como las necesidades específicas de cada prosumidor.

En la actualidad, los sistemas de almacenamiento de energía en baterías (BESS) desempeñan un papel fundamental

en la integración de prosumidores a la red eléctrica, permitiendo una gestión avanzada y flexible de la demanda energética. Más allá de los sistemas de gestión de baterías (BMS, Battery Management System), la integración de BESS aporta ventajas significativas tanto para los usuarios como para el sistema eléctrico en su conjunto (Li et al., 2023).

Sin embargo, a pesar de las ventajas que supone la integración de sistemas de almacenamiento (BESS) en las comunidades energéticas, persisten numerosos retos. Uno de los principales es la imprevisibilidad de las fuentes renovables cuya dependencia de las condiciones meteorológicas provoca desequilibrios frecuentes entre oferta y demanda. A ello se suma la variabilidad de los precios de la energía, que dificulta la toma de decisiones óptimas sobre cuándo almacenar o consumir energía. Un reto adicional y crítico es la falta de estrategias de control adaptativas y eficientes, dado que muchos sistemas actuales se basan en reglas estáticas que no consideran adecuadamente el contexto operativo en tiempo real. Estas limitaciones pueden conducir a un funcionamiento ineficiente de las baterías, comprometiendo tanto la vida útil de los dispositivos como los objetivos de reducción de costes y minimización del uso de la red.

Para abordar estos desafíos, este trabajo propone un *modelo de control predictivo* que optimiza la gestión energética de cada prosumidor, guiado por un perfil de potencia en red definido por un controlador global. Dicho perfil tiene como objetivo minimizar los costes energéticos y preservar el estado de salud (SoH, State of Health por sus siglas en inglés) de la batería a largo plazo. En este esquema jerárquico, el controlador local actúa como un regulador que adapta el plan energético definido por el nivel superior a las condiciones específicas y las limitaciones técnicas de cada prosumidor.

El controlador local está basado en un enfoque de Control Predictivo Basado en Modelo (MPC), implementado en MATLAB. Este tipo de control opera bajo el principio de horizonte deslizante, resolviendo en cada instante un problema de optimización sobre un horizonte temporal finito y actualizando las decisiones conforme se dispone de nueva información (Schwenzer et al., 2021). El algoritmo tiene en cuenta previsiones de generación fotovoltaica, demanda eléctrica, precios horarios de la energía y las restricciones técnicas de la batería, como el estado de carga (SoC, State of Charge), la corriente máxima y la profundidad de descarga (DoD, Depth of Discharge).

Para validar el funcionamiento del controlador y analizar su rendimiento en un contexto representativo, se desarrolló un modelo de comunidad energética. Este modelo integra perfiles reales o simulados de generación y consumo, baterías con sus características técnicas y precios energéticos variables, ofreciendo un entorno de simulación realista que permite probar la estrategia de control propuesta.

Este artículo se organiza de la siguiente manera: en la *Sección 2* se presenta una visión general de la metodología empleada, describiendo el modelo de comunidad energética y el algoritmo de control desarrollado. La *Sección 3* expone y analiza los principales resultados obtenidos. Finalmente, la *Sección 4* recoge las conclusiones del estudio y plantea posibles líneas de mejora y trabajos futuros.

2. Metodología

El sistema propuesto se basa en una estrategia de control jerárquico multinivel. En el nivel superior se encuentra el controlador global, responsable de generar un perfil óptimo de potencia de red para la comunidad, teniendo en cuenta objetivos económicos y restricciones técnicas globales. Este perfil debe ser alcanzable por los distintos miembros de la comunidad, de acuerdo con sus capacidades individuales.

En el nivel inferior se sitúan los controladores locales, cuya función es gestionar el uso de la energía a nivel de cada prosumidor, siguiendo el perfil de red definido por el nivel superior. Estos controladores tienen en cuenta las condiciones particulares de cada usuario, como la generación renovable, el perfil de demanda y las características del sistema de almacenamiento.

Este trabajo se centra exclusivamente en el desarrollo y evaluación del controlador local. La Figura 1 muestra la arquitectura general de control, así como la interacción entre el nivel global y los niveles locales.

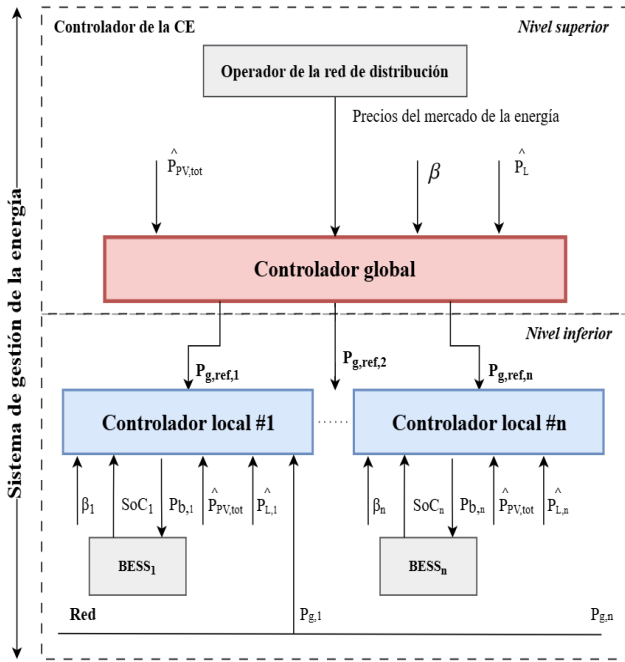


Figura 1: Arquitectura general de control.

Donde:

- $P_{g,ref}$ es la potencia de referencia a intercambiar con la red, establecida por el controlador global (kW).
- P_g es la potencia real intercambiada con la red por el prosumidor (kW).
- P_b es la potencia de carga o descarga de la batería (kW). Valor positivo indica carga y negativo, descarga.
- P_L es la potencia demandada por el edificio o prosumidor (kW).
- $P_{PV,tot}$ es la potencia total generada por la comunidad (kW).

- β es el coeficiente de reparto, es decir, el porcentaje de la generación fotovoltaica total asignado a cada miembro de la comunidad (%).
- SoC es el estado de carga de la batería (%).

Tras presentar la arquitectura general del sistema, los siguientes subapartados describen en detalle el enfoque seguido para el desarrollo del modelo de comunidad energética, el diseño del sistema de control propuesto y los escenarios considerados para su evaluación.

2.1. Modelo de Comunidad Energética

El modelo desarrollado representa de manera detallada el funcionamiento de una comunidad energética (EC), permitiendo simular la distribución y gestión de la energía entre los distintos miembros que la integran. Para ello, se ha adoptado un enfoque modular y orientado a objetos en el entorno MATLAB, estructurando el sistema a partir de cinco clases principales: Site, Battery, PV, Load y Controller. Cada una de estas clases cumple una función específica dentro del sistema, conformando un marco integral para la simulación de las dinámicas propias de una comunidad energética.

La interacción entre estas clases permite simular de forma realista el comportamiento energético, tanto a nivel individual como colectivo dentro de la comunidad. Aunque el modelo contempla todos los componentes principales de una comunidad, el presente trabajo se centra principalmente en el desarrollo e implementación del controlador, elemento clave para la gestión eficiente de la energía de cada miembro de la comunidad. La Figura 2 muestra la arquitectura del modelo de comunidad energética empleada.

2.2. Control Predictivo Local Basado en Modelo (MPC)

El controlador local implementa una estrategia de *Control Predictivo Basado en Modelo*, cuyo objetivo es gestionar la operación del sistema de almacenamiento de cada miembro de la comunidad. El MPC es una técnica de control automático que utiliza un modelo matemático del sistema para prever su comportamiento futuro y optimizar las acciones de control, garantizando el cumplimiento de restricciones tanto en las variables manipuladas como en las variables controladas, es decir, consiste en la resolución de un problema de optimización para todo el horizonte de predicción en cada instante de muestreo (Sicilia et al., 2023).

En este caso, se ha definido un horizonte de predicción de 8 horas, que se desplaza a lo largo de una semana con un instante de muestreo de 15 minutos. La función principal del controlador es calcular la potencia óptima de la batería como variable de salida, de modo que el sistema pueda seguir la curva de referencia establecida por el controlador global.

El uso de MPC en la gestión de sistemas de almacenamiento energético ha demostrado ser eficaz para maximizar la eficiencia operativa y minimizar los costes energéticos asociados, así como para garantizar el cumplimiento de las diversas restricciones y responder de manera proactiva a las demandas del sistema (Roudnil et al., 2025).

La Figura 3 muestra la estructura básica necesaria para implementar la estrategia del MPC.

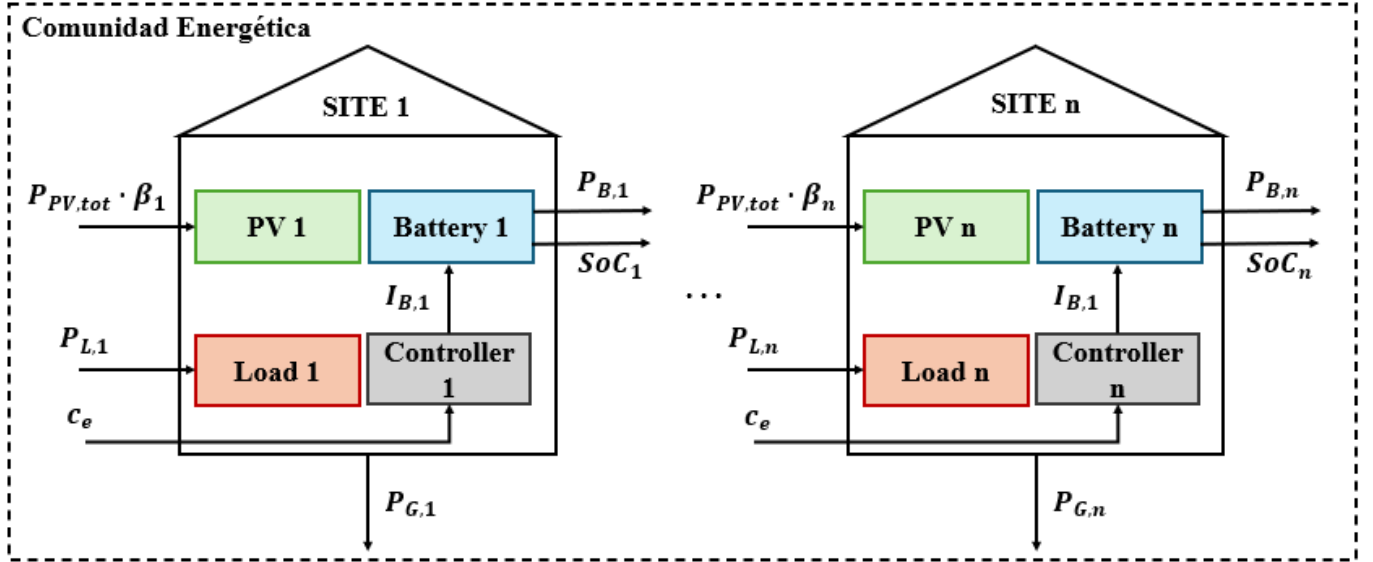


Figura 2: Representación esquemática del modelo de CE .

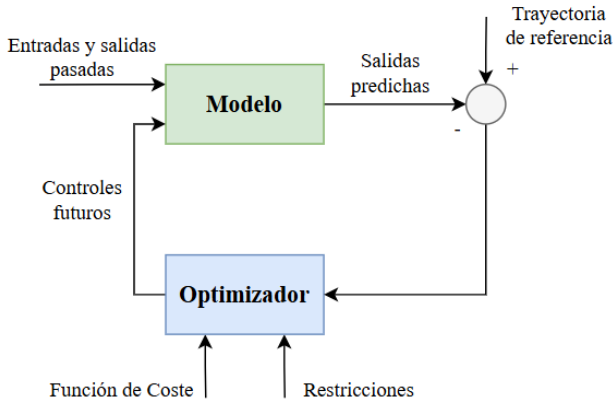


Figura 3: Estructura básica del MPC.

Para formalizar el problema de control, es necesario definir tanto la función objetivo como las restricciones que describen el comportamiento del sistema ya que permiten obtener las acciones de control a aplicar. La función de coste utilizada por el controlador MPC en nuestro caso tiene como objetivo minimizar el desvío respecto al perfil de potencia de red previamente establecido por el controlador global. Este perfil ya ha sido optimizado a nivel comunitario para reducir los costes energéticos y maximizar el aprovechamiento de la generación renovable disponible.

Por tanto, el problema de optimización se formula de la siguiente manera:

$$\min_{P_b} \sum_{t=k}^{k+H_p} (P_g(t) - P_{g,ref}(t))^2 \quad (1)$$

donde $P_b = \{P_b(k), P_b(k+1), \dots, P_b(k+H_p)\}$ representa el vector de decisiones de potencia de la batería a lo largo del horizonte de predicción.

En esta expresión, $P_g(t)$ denota la potencia neta intercambiada con la red en el instante t , mientras que $P_{g,ref}(t)$ corresponde al perfil de potencia de referencia proporcionado por el

controlador global. El parámetro H_p define la longitud del horizonte de predicción. La variable de decisión $P_b(t)$ indica la potencia de carga (cuando es positiva) o descarga (cuando es negativa) aplicada a la batería en cada instante.

Definido el problema de optimización, este se resuelve sujeto a las restricciones mostradas en (2), válidas para todo $t \in [k, k+H_p-1]$:

$$SoC_{\min} \leq SoC(t+1) \leq SoC_{\max} \quad (2a)$$

$$P_{b,\min} \leq P_b(t) \leq P_{b,\max} \quad (2b)$$

$$P_g(t) = P_L(t) - \beta(t) \cdot P_{PV,tot}(t) + P_b(t) \quad (2c)$$

Donde:

- $P_{b,\min}$ y $P_{b,\max}$ son los valores máximos y mínimos que soporta la batería (kW).

La ecuación (2a) impone los límites de operación del estado de carga (SoC) de la batería, garantizando que se mantenga dentro de los valores mínimos y máximos permitidos. La restricción (2b) asegura que la potencia intercambiada con la batería no supere los valores máximos admisibles, previniendo así un deterioro prematuro del sistema de almacenamiento. Finalmente, la ecuación (2c) establece el balance energético de cada miembro de la comunidad, indicando que la potencia neta intercambiada con la red es igual al consumo instantáneo del edificio menos la fracción de generación renovable asignada, más la potencia suministrada o absorbida por la batería según el criterio de signos adoptado.

Para poder anticipar el comportamiento del sistema durante las próximas 8 horas, el controlador MPC necesita disponer de estimaciones de tres variables clave: (a) la potencia demandada por el edificio, (b) la fracción de generación renovable asignada al prosumidor, y (c) la generación total fotovoltaica disponible. En este trabajo, tanto los perfiles de demanda como los de generación se basan en predicciones generadas previamente mediante modelos externos de predicción, es decir, el MPC no tiene acceso a los valores reales futuros, sino

que opera sobre perfiles anticipados. Por su parte, el coeficiente de reparto de la generación renovable, representado por el parámetro β , se fija antes de cada optimización y permanece constante durante el horizonte de predicción.

Por otro lado, el cálculo del estado de carga en el siguiente instante de tiempo se realiza mediante la ecuación (3), la cual representa la evolución del SoC en forma discreta. Esta ecuación contempla las pérdidas asociadas a los procesos de carga y descarga, aplicando las correspondientes eficiencias en función del modo de operación de la batería (carga o descarga), y permite actualizar el valor del SoC en cada etapa del horizonte de predicción.

$$\text{SoC}(t+1) = \text{SoC}(t) + \begin{cases} \frac{\eta_c \cdot P_b(t) \cdot \Delta t}{Q_b}, & \text{si } P_b(t) > 0 \\ \frac{P_b(t) \cdot \Delta t}{\eta_d \cdot Q_b}, & \text{si } P_b(t) < 0 \end{cases} \quad (3)$$

Donde:

- η_c y η_d son las eficiencias de carga y descarga, respectivamente.
- Δt es el tamaño del paso temporal.
- Q_b es la capacidad de la batería, expresada Ah.

2.3. Escenarios planteados

Con el objetivo de evaluar el desempeño del controlador se definió el escenario que se muestra en la Figura 4. Este escenario corresponde a una situación con generación fotovoltaica moderada y demanda relativamente estable, lo que da lugar a un balance energético con fluctuaciones suaves y una alternancia clara entre excedentes y déficits energéticos.




Figura 4: Escenario de simulación.

El análisis de desempeño se centró en cuatro métricas principales. En primer lugar, se calculó el error cuadrático medio (RMSE) entre el perfil de potencia en red generado por el controlador local y el perfil de referencia definido por el controlador global. Posteriormente, se evaluaron el coste total asociado al uso de la red eléctrica, el intercambio neto de energía con la red y la fracción de energía renovable no aprovechada.

Por otro lado, con el objetivo de comparar el rendimiento del controlador predictivo propuesto, se consideraron dos estrategias de referencia: un sistema basado en reglas (RBS) y otro sin almacenamiento energético (NoBAT).

EL RBS implementa una lógica determinista que actúa únicamente en función de la situación energética instantánea

del prosumidor. No considera precios de la energía ni planificación futura. La estrategia toma decisiones en cada paso temporal siguiendo un conjunto de reglas definidas por las condiciones mostradas en el Algoritmo 1:

Algoritmo 1: Control basado en reglas (RBS)

Input: $P_L, P_{PV,tot}, \beta, SoC, SoC_{min}, SoC_{max}, I_{b,min}, I_{b,max}, I_{surplus}, I_{charge}, I_{discharge}$

Output: I_b

```

1 if  $P_L \leq \beta \cdot P_{PV,tot}$  then
  // Excedente de energía
2   if  $SoC < SoC_{max}$  then
3      $I_b \leftarrow \min(I_{surplus}, I_{charge}, I_{b,max})$ ;
4   else
5      $I_b \leftarrow 0$ ;
6   end
7 else
  // Déficit de energía
8   if  $SoC > SoC_{min}$  then
9      $I_b \leftarrow \max(I_{surplus}, I_{discharge}, I_{b,min})$ ;
10  else
11     $I_b \leftarrow 0$ ;
12  end
13 end
14 return  $I_b$ 

```

Por otro lado, la otra estrategia de referencia asume que el prosumidor no dispone de sistema de almacenamiento. Toda la energía generada que no se consume de forma instantánea se vierte a la red, y cualquier déficit se suple directamente desde la red externa. Esta estrategia representa el caso base más simple, permitiendo evaluar los beneficios de incorporar un sistema de gestión de baterías.

3. Resultados

La Tabla 1 resume los resultados obtenidos en el Escenario propuesto para los tres enfoques evaluados: el controlador predictivo propuesto (MPC), un sistema basado en reglas simples (RBS) y un sistema sin almacenamiento energético (NoBAT). Se analizan tres métricas clave: el coste total energético, el consumo desde la red y la energía renovable vertida.

El cálculo del *coste total energético* asociado al uso de la red cada instante de tiempo viene del producto entre la energía importada desde la red, el precio horario de la electricidad y la duración del intervalo. Solo se consideran los valores positivos de la potencia neta intercambiada con la red (es decir, aquellos instantes en los que se importa energía). La expresión empleada es la siguiente:

$$C_E(t) = \max(P_g(t), 0) \cdot c_e(t) \cdot \Delta t \quad (4)$$

Donde:

- C_E el coste que supone la energía demandada (en €).
- c_e el coste horario de la energía (en €/kWh).

El coste total acumulado ($C_{E,tot}$) se obtiene como la suma de los costes individuales en cada instante de tiempo:

$$C_{E,tot} = \sum_{t=1}^T C_E(t) \quad (5)$$

Tabla 1: Comparativa de resultados.

Métrica	MPC	RBS	NoBAT
Coste total energético (€)	24,15	27,94	33,78
Consumo desde la red (kWh)	163,42	203,09	167,50
Energía vertida a la red (kWh)	273,87	310,23	2191,93

Como se observa, el controlador MPC presenta un desempeño superior en términos de eficiencia energética y aprovechamiento renovable. En particular, logra una reducción del coste total energético del 13,6 % respecto al sistema RBS y del 28,5 % frente al sistema sin almacenamiento de energía. Asimismo, se consigue una menor dependencia de la red en comparación con el RBS, y una drástica disminución de la energía renovable vertida respecto al NoBMS, lo que evidencia una mejor gestión de los recursos locales.

Además, se evaluó la capacidad del controlador local para seguir el perfil de potencia en red generado por el controlador global. La Figura 5 muestra, además de dicha comparación, la evolución temporal del estado de carga (SOC) y de la potencia de la batería durante el horizonte simulado. Aunque el controlador local dispone de perfiles de generación y consumo ligeramente diferentes a los utilizados por el controlador global, el sistema logra reproducir de forma efectiva el comportamiento de referencia. El error cuadrático medio (RMSE) entre ambas curvas fue de 225,10 W, lo que demuestra una elevada precisión incluso con información parcial.

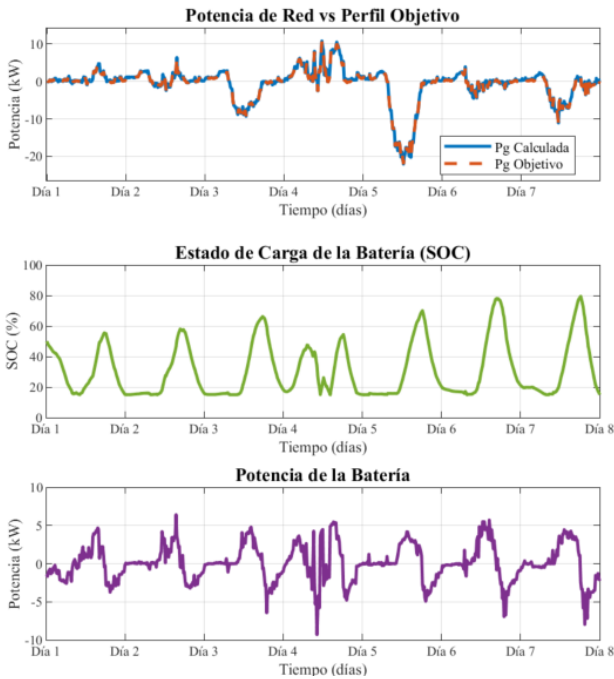


Figura 5: Evolución del perfil de potencia de red, del estado de carga (SOC) y de la potencia de la batería.

4. Conclusiones y líneas futuras de trabajo

Los resultados obtenidos confirman que el sistema de control predictivo basado en modelo (MPC) propuesto proporciona ventajas significativas en la gestión energética de prosumidores dentro de comunidades energéticas. La arquitectura jerárquica implementada ha demostrado ser efectiva, permitiendo reducir los costes energéticos en un 28,5 % respecto a sistemas sin almacenamiento y en un 13,6 % frente a controles basados en reglas simples. El controlador local consigue seguir con precisión los perfiles de potencia establecidos por el nivel superior, manteniendo un error cuadrático medio de apenas 225,10 W, lo que evidencia su robustez incluso ante información parcial.

La capacidad del sistema para estabilizar los intercambios con la red contribuye significativamente a mitigar los problemas asociados a la variabilidad de las renovables, como fluctuaciones de tensión o congestiones en la distribución, funcionalidad especialmente valiosa en el contexto actual de creciente penetración de energías renovables distribuidas.

El trabajo actual abre múltiples vías de investigación. La integración de una estrategia multicontrol coordinada constituye una de las líneas más prometedoras, permitiendo intercambios de información en tiempo real entre prosumidores y facilitando decisiones colaborativas sin depender exclusivamente del controlador global.

Por otro lado, la incorporación de técnicas de aprendizaje por refuerzo representa otra área de desarrollo crucial, permitiendo que el sistema mejore progresivamente sus estrategias de control al adaptarse a los patrones específicos de cada usuario y a las condiciones cambiantes del sistema. Estos algoritmos podrían identificar patrones no evidentes para los modelos tradicionales y optimizar el rendimiento a lo largo del tiempo, especialmente en escenarios con alta variabilidad.

Además, la validación del sistema en entornos reales constituye un paso necesario para su adopción generalizada, permitiendo identificar limitaciones prácticas y oportunidades de mejora no evidentes en entornos simulados.

Finalmente, sería interesante diseñar e implementar mecanismos de mercado interno dentro de la comunidad energética, que incentiven comportamientos beneficiosos para el conjunto, así como estrategias específicas para mejorar la resiliencia ante contingencias como fallos en la red principal o en sistemas locales. Estos desarrollos contribuirían a construir comunidades energéticas más autónomas, eficientes y preparadas para los desafíos del futuro modelo energético descentralizado.

Agradecimientos

Este trabajo cuenta con el apoyo del proyecto Sustainable Atlantic Communities (SATComm) EAPA 0019/2022 cofinanciado por la Unión Europea a través de la convocatoria Interreg Espacio Atlántico. Agradecemos su apoyo a nuestro investigación.

Referencias

Aghmadi, A., Mohammed, O. A., 1 2024. Operation and coordinated energy management in multi-microgrids for improved and resilient distributed

- energy resource integration in power systems. *Electronics* (Switzerland) 13.
DOI: 10.3390/electronics13020358
- Ahmed, S., Ali, A., D'Angola, A., 2024. A review of renewable energy communities: Concepts, scope, progress, challenges, and recommendations. *Sustainability* 16 (5).
DOI: 10.3390/su16051749
- Kyriakopoulos, G. L., 2022. Energy communities overview: Managerial policies, economic aspects, technologies, and models. *Journal of Risk and Financial Management* 15 (11).
DOI: 10.3390/jrfm15110521
- Li, F., Wang, D., Liu, D., Yang, S., Sun, K., Liu, Z., Yu, H., Qin, J., 6 2023. A comprehensive review on energy storage system optimal planning and benefit evaluation methods in smart grids.
DOI: 10.3390/su15129584
- Roudnil, S., Zadeh, S. G., Feyzi, M. R., Ghavifekr, A. A., 5 2025. A real-time two-step multi-objective planning framework for resilience improvement of islanded microgrids based on mpc. *Journal of Energy Storage* 119.
DOI: 10.1016/j.est.2025.116343
- Sangaré, M., Bourreau, E., Fortz, B., Pachurka, A., Poss, M., 12 2023. Loads scheduling for demand response in energy communities. *Computers and Operations Research* 160.
DOI: 10.1016/j.cor.2023.106358
- Schwenzer, M., Ay, M., Bergs, T., Abel, D., 11 2021. Review on model predictive control: an engineering perspective.
DOI: 10.1007/s00170-021-07682-3
- Sicilia, A. R., Estévez, B. E., Costa-Castelló, R., 8 2023. Gestión de energía, mediante control predictivo, de un vehículo de pila de combustible. *Servizo de Publicacións. Universidade da Coruña*, pp. 358–363.
DOI: 10.17979/spudc.9788497498609.358
- Teng, Q., Wang, X., Hussain, N., Hussain, S., 2 2025. Maximizing economic and sustainable energy transition: An integrated framework for renewable energy communities. *Energy* 317.
DOI: 10.1016/j.energy.2025.134544
- Vivas, F. J., Pajares, A., Blasco, X., Herrero, J. M., Segura, F., Andújar, J. M., 4 2025. A novel energy management system based on two-level hierarchical economic model predictive control for use in microgrid control. *Energy Conversion and Management: X* 26.
DOI: 10.1016/j.ecmx.2025.101027