

Integración de tecnologías Blockchain en un esquema de control predictivo distribuido y jerárquico para comunidades energéticas

Manuel Sivianes^a, Pablo Velarde^{b,*}, Ascensión Zafra-Cabeza^a, Carlos Bordons^a

^aDepartamento de Ingeniería de Sistemas y Automática, Universidad de Sevilla (España).

^bDepartamento de Ingeniería, Universidad Loyola Andalucía (España).

To cite this article: Sivianes, M., Velarde, P., Zafra-Cabeza, A., Bordons, C., 2025. Integration of Blockchain Technologies in a Distributed and Hierarchical Predictive Control Scheme for Energy Communities. Revista Iberoamericana de Automática e Informática Industrial 22, 33-44. <https://doi.org/10.4995/riai.2024.21330>

Resumen

En este estudio se introduce una plataforma de gestión energética jerárquica que incorpora la tecnología *blockchain* para eliminar la dependencia de un coordinador centralizado. La plataforma está diseñada para operar en comunidades energéticas afectadas por incertidumbres estocásticas. La estrategia se divide en dos niveles: en el nivel superior, donde se resuelve un problema de optimización de control predictivo distribuido estocástico, en el que todos los hogares de la comunidad participan para determinar las acciones de control de manera horaria. En este nivel, se utiliza un contrato inteligente como intermediario entre los hogares, encargado de realizar tareas de control e intercambio de información. Por otro lado, en el nivel inferior, cada hogar resuelve de manera local e independiente un problema de optimización de control predictivo para seguir las referencias establecidas después del consenso alcanzado por la capa superior, a una frecuencia significativamente mayor. La validez de esta plataforma para optimizar el funcionamiento económico de la comunidad y cumplir con las restricciones probabilísticas se ha validado con diferentes simulaciones.

Palabras clave: Sistemas de gestión y distribución de energía, blockchain, control estocástico, control predictivo.

Integration of Blockchain Technologies in a Distributed and Hierarchical Predictive Control Framework for Community Energy Networks.

Abstract

This study introduces a hierarchical energy management platform that leverages blockchain technology to eliminate the need for a centralized coordinator. The platform is designed to operate in energy communities facing stochastic uncertainties. The approach is divided into two levels: at the upper level where a stochastic distributed model predictive control problem is solved by all households in the community to determine control actions on an hourly basis. A smart contract serves as a bridge between households, performing control tasks and facilitating information exchange. In contrast, at the lower level, each household independently solves a model predictive control problem locally to track the references established after consensus is reached by the upper layer, at a much higher frequency. The effectiveness of the platform in optimizing the community's economic performance and adhering to probabilistic constraints is demonstrated through extensive simulations.

Keywords: Energy management and distribution systems, blockchain, stochastic control, model predictive control.

1. Introducción

La gestión energética se ha establecido como un asunto crucial en los tiempos actuales, marcados por una notable transfor-

mación en el ámbito energético. Este cambio se caracteriza por el paso de un modelo centralizado tradicional a uno más descentralizado y versátil. Tal evolución es impulsada por el aumen-

*Autor para correspondencia: pavelarde@uloyola.es

Nomenclatura	Significado	Nomenclatura	Significado
CC-MPC	Control Predictivo con Restricciones de Probabilidad	p^{bc}	Potencia de carga
CE	Comunidad Energética	p^{bd}	Potencia de descarga
CI	Capa Inferior	p^{bt}	Potencia de comercio
CS	Capa Superior	p^{ug}	Potencia necesaria de la red eléctrica
DMPC	Control Predictivo Distribuido	p^{ugs}	Potencia vendida a la red eléctrica
VE	Vehículo Eléctrico	p^{ev}	Potencia de carga del vehículo eléctrico
FC-MPC	Feasible Cooperation-based MPC	p^{pv}	Potencia fotovoltaica
ISE	Integración de Sistemas Energéticos	p^l	Potencia de carga local
MPC	Control Predictivo Basado en Modelo	Π	Matriz de intercambio entre los agentes
P2P	Peer-to-Peer	e^b	Energía almacenada en la batería
RE	Red Eléctrica	e^{ev}	Energía en el vehículo eléctrico
SMPC	Control Predictivo Estocástico	max	Valor máximo
Δt	Intervalo de tiempo	ω	Perturbaciones estocásticas
η	Eficiencia de conversión	t	Tiempo
σ	Desviación estándar de la radiación solar	i, j	Agentes
Φ	Flujo de potencia	—	Límite superior
ξ	Parámetro binario de disponibilidad de carga	—	Límite inferior
θ	Parámetro estocástico	n	Cantidad de agentes
μ	Media de una distribución		

to en la participación de diversos agentes energéticos distribuidos e independientes. En este entorno en constante cambio, las fuentes de energía renovables adquieren un rol esencial, brindando a los usuarios la oportunidad de reducir su dependencia de las redes eléctricas tradicionales, particularmente cuando se combinan con sistemas de almacenamiento de energía mediante baterías. Sin embargo, la integración y operación eficaz de estos sistemas variados representa un desafío considerable. En este contexto, el concepto de integración de sistemas energéticos (ISE) se vuelve especialmente significativo. Como se describe en O'Malley et al. (2016), la ISE implica la coordinación de sistemas energéticos a lo largo de diferentes rutas y ubicaciones para asegurar una oferta de servicios energéticos fiable y asequible, minimizando el impacto en el medio ambiente.

En el ámbito de la gestión de microredes energéticas, donde existen tanto consumidores como productores de energía, la relevancia de la ISE es indiscutible. Actúa como un marco esencial para la integración efectiva de estos sistemas heterogéneos. En este contexto, el Control Predictivo Basado en Modelos (*Model Predictive Control*, MPC) es una técnica de control utilizada en los sistemas de energía eléctrica, gracias a su habilidad para manejar no linealidades, retardos y restricciones en las variables de entrada y salida (Olivares et al., 2015). No obstante, los controladores MPC convencionales no abordan adecuadamente el manejo de incertidumbres, resultando en el desarrollo de diversas estrategias de MPC (Bordons et al., 2020) para gestionar variables estocásticas. Para abordar estas incertidumbres y perturbaciones, se han desarrollado varias técnicas de MPC estocástico (*stochastic MPC*, SMPC) (Velarde et al., 2017). Una variante de SMPC es el Control Predictivo con Restricciones de Probabilidad (*Chance-constrained MPC*, CC-MPC) (Grosso et al., 2014). El CC-MPC ha demostrado ser efectivo en una variedad de aplicaciones, incluyendo los sistemas energéticos, como se evidencia en múltiples estudios (Vergara-Dietrich et al., 2019; Márquez et al., 2021; Velarde et al., 2024).

Los sistemas geográficamente distribuidos, como son los sistemas energéticos, enfrentan algunos desafíos al implemen-

tar estrategias de MPC centralizadas (Maestre and Negenborn, 2013). En este contexto, una Comunidad Energética (CE) se establece como una red colaborativa de agentes, que pueden ser tanto prosumidores como consumidores, compartiendo sus recursos energéticos. Las CEs juegan un papel importante en el fortalecimiento de la cohesión comunitaria y en el fomento de prácticas energéticas sostenibles (Inês et al., 2020).

Para abordar la complejidad de estos sistemas, el sistema se divide en subsistemas, también conocidos como agentes, cada uno controlado por su propio controlador local en un enfoque de MPC Distribuido (DMPC). Esta configuración proporciona varias ventajas comparadas con el MPC centralizado. Sin embargo, coordinar múltiples controladores requiere un intercambio de información considerable, lo que puede plantear problemas de seguridad y privacidad (Maestre et al., 2021). En estas circunstancias, se busca un equilibrio entre la autonomía local y la coordinación a nivel global, un elemento clave para una gestión eficiente en las CEs (Gui et al., 2017).

En el ámbito de la gestión segura de la energía, la tecnología *blockchain* surge como una solución prometedora, particularmente para sistemas que requieren una comunicación segura entre agentes. La estructura transaccional de *peer-to-peer* (P2P) de *blockchain*, combinada con su arquitectura descentralizada para el almacenamiento de datos, refuerza el sistema contra posibles amenazas malintencionadas. Una característica notable de *blockchain* es la implementación de contratos inteligentes, que son fundamentales para facilitar la coordinación en las CEs. Estos contratos son programas que ejecutan automáticamente reglas preestablecidas, eliminando la necesidad de intermediarios. El potencial de *blockchain* en el contexto de microredes y la gestión de CEs ha sido ampliamente investigado, como se evidencia en (van Leeuwen et al., 2020; Sivianes et al., 2022). La integración de *blockchain* en la ISE mejora la integridad de los datos, la seguridad y la capacidad de auditoría, sin depender de terceros.

Adicionalmente, el control jerárquico es una técnica empleada en sistemas energéticos para manejar la complejidad de las redes. Esta técnica implica estructurar el sistema mediante

una arquitectura en capas, lo que permite una gestión modular y facilita la integración de diversas estrategias (Zafra-Cabeza et al., 2020). En este contexto, este trabajo introduce un enfoque jerárquico y distribuido para la operación de un ISE, incluso en presencia de incertidumbres. La idea central de este enfoque es prescindir de un coordinador centralizado y sustituirlo por un contrato inteligente basado en tecnología *blockchain*.

Este trabajo introduce un enfoque jerárquico diseñado para mejorar el manejo de perturbaciones mediante una formulación estocástica con base en investigaciones previas (Sivianes et al., 2022, 2023a,b). El sistema completo adopta una estrategia de DMPC para la gestión de un ISE, involucrando a múltiples agentes que enfrentan incertidumbres asociadas con variables estocásticas. Es importante destacar que este enfoque incorpora la tecnología *blockchain*, asegurando así que todas las operaciones sean transparentes y seguras.

El resto de este documento se organiza de la siguiente manera. La Sección 2 establece la descripción de la estructura jerárquica de la CE que se utilizará en este trabajo. La Sección 3 proporciona una descripción detallada de la capa superior (CS), incluyendo la metodología de CC-MPC, el proceso de negociación para variables acopladas distribuidas y la implementación de *blockchain*. La descripción de los controladores de CPM implementados en la capa inferior (CI) se discute en la Sección 4. Los principales resultados y su discusión se muestran en la Sección 5. Finalmente, la Sección 6 presenta las conclusiones y líneas futuras.

2. Esquema jerárquico de la comunidad energética

La CE descrita en este trabajo presenta una estructura jerárquica con dos capas claramente diferenciadas:

- Una capa superior, CS, donde se resuelve un problema de optimización MPC distribuido, y del cual se obtienen las variables de decisión a aplicar durante un amplio horizonte de predicción con un tiempo de muestreo horario. En esta capa, los hogares hacen uso de un contrato inteligente desplegado en una *testnet* de Ethereum que ejerce el rol de un coordinador distribuido, permitiendo la ejecución del algoritmo distribuido sin necesidad de terceras partes externas a la CE.
- Una capa inferior, CI, donde cada hogar, de manera individual e independiente al resto, resuelve un problema MPC para cumplir con las directrices obtenidas de la capa superior con un horizonte de predicción y tiempo de muestreo inferior al de la capa superior.

En la Figura 1 se muestra el esquema jerárquico planteado, donde se muestran los intercambios de información entre el contrato inteligente en la capa superior; y los enlaces de potencia en la capa inferior.

2.1. Formulación de la capa superior

La topología de la CE en la capa superior corresponde a un grafo completo, en los hogares se encuentran conectados de manera bidireccional a través de enlaces de potencia. Además, cada hogar está conectado al Punto de Acoplamiento Común

(PAC), que es el punto de entrada de energía de la red eléctrica externa (RE) a un coste variable en el tiempo, representado por c_t^{ug} [€/kWh]. Asimismo, existe la posibilidad de vender energía a la RE a una tarifa identificada como c_t^{ugs} [€/kWh], donde $c_t^{ugs} < c_t^{ug}$. El conjunto de hogares se caracteriza mediante el conjunto $\mathcal{H} = \{1, \dots, N\}$, el cual se divide en dos subconjuntos: el conjunto de prosumidores \mathcal{P} , que incluye hogares con acceso a recursos energéticos distribuidos (RED) como baterías, paneles solares y vehículos eléctricos; y el conjunto de consumidores \mathcal{C} , cuyos integrantes desempeñan un papel pasivo dentro de la comunidad. Puesto que los consumidores carecen de cualquier RED, deben satisfacer sus demandas importando energía de la RE a coste c_t^{ug} o de otros hogares. Por el contrario, los prosumidores asumen un papel más activo gracias a su capacidad para obtener energía de fuentes renovables, como la generación solar, y, en última instancia, participar en el comercio de energía dentro de la CE a una tarifa c_t^{EC} [€/kWh].

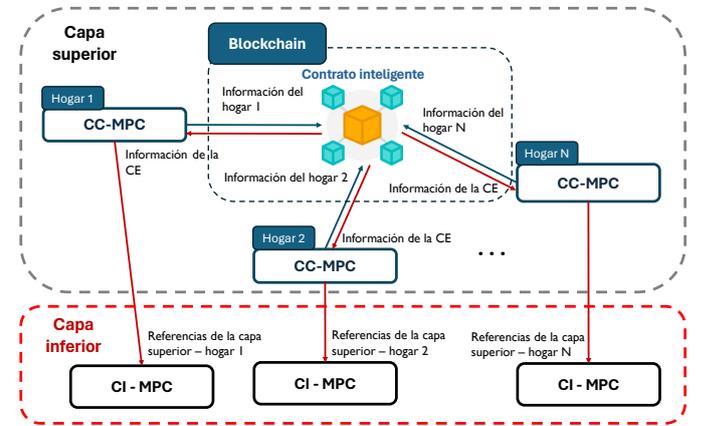


Figura 1: Esquema jerárquico de la comunidad energética.

Un elemento crucial es que la CE se ve afectada por dos variables estocásticas: la irradiancia solar $\theta_{i,t}$ [W/m²] $\forall i \in \mathcal{P}$ y la demanda variable de los hogares $p_{i,t}^1$ $\forall i \in \mathcal{H}$. Dada la reducida extensión geográfica de la CE, especialmente en comparación con la variabilidad espacial de $\theta_{i,t}$, se asume que $\theta_{i,t}$ afecta de manera uniforme a todos los prosumidores $\forall i \in \mathcal{P}$ en cada instante t , es decir, $\theta_{i,t} \cong \theta_t$. En consecuencia, la generación fotovoltaica $p_{i,t}^{pv}$ se determina por:

$$p_{i,t}^{pv} = \sigma_i \eta^{pv} \theta_t, \quad \forall i, t, \quad (1)$$

donde σ_i [m²] representa el área de los paneles solares instalados y η^{pv} es la eficiencia de conversión fotovoltaica solar. Toda la potencia generada por los paneles solares es directamente almacenada en la batería, donde posteriormente podrá ser utilizada con cualquier propósito.

Las baterías cumplen una triple función dentro del sistema, permitiendo almacenar energía para su uso futuro, como facilitar su comercio con la CE o su venta a la RE. La energía almacenada en la batería del agente i se representa como $e_{i,t}^b$ y se calcula de la siguiente manera:

$$e_{i,t}^b = e_{i,t-1}^b + (\eta_c^b p_{i,t}^{bc} - \frac{p_{i,t}^{bd}}{\eta_d^b} - \sum_{j \neq i} \frac{p_{ij,t}^1}{\eta_{bt}^b}) \Delta t + p_{i,t}^{pv} \Delta t - p_{i,t}^{ugs} \Delta t, \quad \forall i, t, \quad (2)$$

donde $p_{i,t}^{bc}$, $p_{i,t}^{bd}$ y $p_{i,t}^{bt}$ representan la potencia de carga, descarga y comercio, respectivamente; $p_{i,t}^{ugs}$ es la potencia vendida a la RE; y Δt es el intervalo de tiempo. Parámetros como η_c^b , η_d^b y η_t^b indican las eficiencias de carga, descarga y comercio de la batería, respectivamente. Es importante destacar que $p_{i,t}^{bd}$ representa la potencia suministrada por la batería para satisfacer la demanda local, y el término $\sum_{j \neq i}^N \frac{p_{j,t}^{bt}}{\eta_t^{bt}}$ en la Ecuación (2) denota la potencia transferida del agente i a la CE. En este contexto, tanto la energía almacenada en las baterías como la potencia de las baterías están sujetas a restricciones:

$$\underline{e}_i^b \leq e_{i,t}^b \leq \overline{e}_i^b, \quad \forall i, t, \quad (3)$$

$$0 \leq p_{i,t}^{bc} \leq \overline{p}_i^{bc}, \quad \forall i, t, \quad (4)$$

$$0 \leq p_{i,t}^{bd} \leq \overline{p}_i^{bd}, \quad \forall i, t, \quad (5)$$

$$0 \leq p_{ij,t}^{bt} \leq \overline{p}_{ij}^{bt}, \quad \forall i, j, t, \quad (6)$$

donde las barras superior e inferior hacen referencia a los límites máximos y mínimos, respectivamente. Los vehículos eléctricos se conceptualizan como cargas flexibles que permiten controlar el tiempo y la potencia de carga $p_{i,t}^{ev}$. La acumulación de energía en los vehículos eléctricos $e_{i,t}^{ev}$ se calcula y restringe de la siguiente manera:

$$e_{i,t}^{ev} = e_{i,t-1}^{ev} + \eta_c^{ev} p_{i,t}^{ev} \Delta t, \quad \forall i, t, \quad (7)$$

$$\underline{e}_{i,t}^{ev} \leq e_{i,t}^{ev} \leq \overline{e}_{i,t}^{ev}, \quad \forall i, t, \quad (8)$$

donde el parámetro η_c^{ev} es la eficiencia de carga del vehículo eléctrico (VE). Dado que los VE solo se pueden cargar mientras estén físicamente en el área de carga, la potencia de carga del VE se restringe de la siguiente manera:

$$0 \leq p_{i,t}^{ev} \leq \xi_{i,t} \overline{p}_i^{ev}, \quad \forall i, t. \quad (9)$$

En este contexto, ξ es un parámetro binario indicando la disponibilidad de carga del vehículo eléctrico, y \overline{p}_i^{ev} representa la máxima potencia de carga del VE. Es importante destacar que cada agente sigue un horario de carga predefinido para su vehículo eléctrico $\mathcal{E}_i = [\xi_{1,i}, \dots, \xi_{\text{end},i}]$, indicando cuándo el vehículo eléctrico estará en el punto de carga del agente. Además, se incorpora el requisito diario de carga de energía del VE, designado como $e_{i,t}^{ev, \text{daily}}$, de la siguiente manera:

$$e_{i,1}^{ev} + \sum_t^{N_h} \eta_c^{ev} p_{i,t}^{ev} \Delta t = e_{i,\text{daily}}^{ev}, \quad \forall i \in \mathcal{E}, \quad (10)$$

donde \mathcal{E} representa el conjunto de agentes que poseen un VE, y N_h es el horizonte temporal sobre el cual se debe cumplir el requisito diario de energía del VE. Nótese que $e_{i,\text{daily}}^{ev}$ debe elegirse cuidadosamente de acuerdo con el horario de carga del VE del agente.

Cada hogar debe lograr la ecuación de balance de potencia (11), de la cual se deriva la potencia necesaria que debe importarse de la RE, denotada por $p_{i,t}^{ug}$, para hacer frente a la demanda de la siguiente manera:

$$p_{i,t}^{ug} = p_{i,t}^{bc} - p_{i,t}^{bd} - \sum_{j \neq i}^N p_{j,t}^{bt} + p_{i,t}^{ul} + p_{i,t}^{ev}, \quad \forall i, t, \quad (11)$$

$$p_{i,t}^{ug} \geq 0, \quad \forall i, t. \quad (12)$$

Aquí, el término $\sum_{j \neq i}^N p_{j,t}^{bt}$ refleja la suma total de potencia que se comercia desde la CE al agente i , lo que significa que (11) es una restricción de acoplamiento.

Finalmente, estas ecuaciones pueden ser agrupadas como un sistema lineal invariante discreto de la siguiente manera:

$$x_{t+1} = A \cdot x_t + B \cdot u_t + D \cdot \omega_t, \quad (13)$$

con:

$$x_t = \begin{bmatrix} \hat{p}_t^{ug} \\ \hat{e}_t^{ev} \\ \hat{e}_t^b \end{bmatrix}, \quad u_t = \begin{bmatrix} \hat{p}_t^{bc} \\ \hat{p}_t^{bd} \\ \hat{p}_t^{bt} \\ \hat{p}_t^{ugs} \\ \hat{p}_t^{ev} \end{bmatrix}, \quad \omega_t = \begin{bmatrix} \hat{\theta}_t^1 \end{bmatrix},$$

$$A = \begin{bmatrix} \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & I_N & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & I_N \end{bmatrix}, \quad D = \begin{bmatrix} \mathbf{0} & I_N \\ \mathbf{0} & \mathbf{0} \\ \eta_c^b \Delta t I_N & \mathbf{0} \end{bmatrix},$$

$$B = \begin{bmatrix} I_N & -I_N & -\Pi & \mathbf{0} & I_N \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \eta_c^{ev} \Delta t I_N \\ \eta_c^b \Delta t I_N & -\frac{\Delta t}{\eta_d^b} I_N & -\frac{\Delta t}{\eta_t^b} \Pi & -\Delta t I_N & \mathbf{0} \end{bmatrix}.$$

Aquí, x , u y ω representan los estados, entradas y perturbaciones específicas de la CE, respectivamente. La notación $\hat{\cdot}$ se utiliza para agrupar estados, entradas o perturbaciones a través de los N agentes; por ejemplo, si $\cdot \in \mathbb{R}^{s \times 1}$, entonces $\hat{\cdot} \in \mathbb{R}^{ns \times 1}$. Además, $\Pi \in \mathbb{R}^{N \times N(N-1)}$ está estructurado como una matriz mayormente compuesta por ceros, con la excepción de $N-1$ elementos en cada fila que toman el valor de uno, indicando los posibles intercambios que el agente i recibe de sus $N-1$ vecinos de la CE.

Para facilitar la nomenclatura en los siguientes apartados, se definen los poliedros cerrados \mathcal{X} y \mathcal{U} para agrupar las restricciones de estado (3), (8), (12); y las restricciones de control (4)-(6), (9), (10), respectivamente. Estas restricciones se expresan como

$$x_{t+1} \in \mathcal{X}, \quad (14a)$$

$$u_t \in \mathcal{U}. \quad (14b)$$

2.2. Formulación de la capa inferior

En la capa inferior, se presenta el modelo de bajo nivel en el que los intercambios energéticos, $p_{i,t}^t$, dejan de ser variables de decisión y pasan a ser constantes fijadas por la capa superior.

Las baterías en la CI siguen el modelo lineal de la Ecuación (2) sustituyendo las variables originales por las correspondientes de la capa inferior:

$$e_{i,t}^{bcI} = e_{i,t-1}^{bcI} + (\eta_c^b p_{i,t}^{bcI} - \frac{p_{i,t}^{bdI}}{\eta_d^b} - \sum_{j \neq i}^N \frac{p_{j,t}^{tcs}}{\eta_t^b}) \Delta t^{CI} + p_{i,t}^{pv} \Delta t^{CI} - p_{i,t}^{ugsI} \Delta t^{CI}, \quad \forall i, t. \quad (15)$$

De manera análoga, los VEs en el modelo de la capa inferior siguen la dinámica de la Ecuación (7):

$$e_{i,t}^{evCI} = e_{i,t-1}^{evCI} + \eta_c^{ev} p_{i,t}^{evCI} \Delta t^{CI}, \quad \forall i, t. \quad (16)$$

Es importante considerar que la CS establece los futuros valores de $e_{i,t}^{bc}$ y $e_{i,t}^{evcs}$, por lo que estos valores se convierten en restricciones terminales en la CI:

$$e_{i,N_{CI}}^{bc} = e_i^{bc} \quad \forall i, \quad (17)$$

$$e_{i,N_{CI}}^{evcs} = e_i^{evcs} \quad \forall i. \quad (18)$$

donde N_{CI} es el horizonte de predicción del bajo nivel, por lo que las restricciones expresadas en (17) y (18) garantizan que la CI siga las referencias establecidas por la CS.

La ecuación de balance de potencia de la CI incluye la variable de holgura $p_{i,t}^{sci}$ en comparación con la Ecuación (11). La razón de esta inclusión radica en que los consumidores no poseen baterías, lo que les impide vender energía a la RE a través de $p_{i,t}^{ugsci}$. Por lo tanto, esta variable tiene como objetivo permitir la venta de energía a la RE por parte de los consumidores:

$$p_{i,t}^{ugci} = p_{i,t}^{bc} - p_{i,t}^{bd} - \sum_{j \neq i} p_{j,t}^{bc} + p_{i,t}^{ulci} + p_{i,t}^{evci} + p_{i,t}^{sci} \quad \forall i, t, \quad (19)$$

$$p_{i,t}^{sci} \geq 0, \quad \forall i, t. \quad (20)$$

Organizando las Ecuaciones (15), (16), y (19), se obtiene la siguiente representación del modelo en espacio de estados de la CI:

$$x_{t+1}^{CI} = A^{CI} \cdot x_t^{CI} + B^{CI} \cdot u_t^{CI} + D^{CI} \cdot \omega_t^{CI}, \quad (21)$$

donde las matrices A^{CI} , B^{CI} , y D^{CI} se derivan de las ecuaciones mencionadas anteriormente, $x_t^{CI} = [e_{i,t}^{bc}, p_{i,t}^{ugci}, e_{i,t}^{evci}]^T$, $u_t^{CI} = [p_{i,t}^{bc}, p_{i,t}^{bd}, p_{i,t}^{ugsci}, p_{i,t}^{evci}, p_{i,t}^{sci}]^T$ y $\omega_t^{CI} = [\theta_t^{CI}, p_t^{ulci}]^T$. Los poliedros cerrados de la capa inferior \mathcal{X}^{CI} y \mathcal{U}^{CI} incluyen las restricciones de estado (3), (8), (12), (17), (18); y restricciones de entrada (4),(5), (9), (20), respectivamente, como se muestra en:

$$x_{t+1}^{CI} \in \mathcal{X}^{CI}, \quad (22a)$$

$$u_t^{CI} \in \mathcal{U}^{CI}. \quad (22b)$$

3. Algoritmo distribuido de la capa superior

La capa superior del esquema jerárquico se caracteriza por la resolución de un algoritmo de MPC distribuido con restricciones de probabilidad (CC-DMPC) coordinado por un contrato inteligente implementado en una red *blockchain*. La inclusión del contrato inteligente reside en que permite prescindir de un tercero que gestione el proceso distribuido. En la capa superior, el algoritmo CC-DMPC se resuelve cada hora para coincidir con la tasa de refresco del precio de compra en el mercado diario eléctrico, y comprende los siguientes elementos: el problema de optimización energético, el algoritmo distribuido y la implementación en *blockchain*.

3.1. Optimización de la gestión energética de la CE en la capa superior

La estrategia de control empleada para abordar el desafío de gestión energética en la CE es el MPC. Este método implica resolver un problema de optimización con el objetivo de minimizar una función objetivo a lo largo de un horizonte de

predicción. Se basa en un modelo lineal en tiempo discreto para prever la dinámica del sistema, sujeto a restricciones tanto en las entradas como en las salidas, con el fin de llevar el sistema hacia una referencia deseada. En cada instante de muestreo, se calcula una secuencia de acciones de control, pero solo se aplica el primer elemento al sistema en el tiempo actual, mientras que las restantes son descartadas. Luego, el problema de optimización se repite en el siguiente instante de tiempo, siguiendo una estrategia de horizonte finito deslizante (Camacho and Bordons, 2007; Maciejowski, 2002).

3.1.1. Formulación del MPC

En este contexto, el primer elemento a considerar es la definición de la función objetivo, denotada como $J(U)$, donde $U = [u_1, u_2, \dots, u_{N_h}]$. J está diseñada para equilibrar la minimización del coste económico incurrido al comprar p^{ug} de la RE, la penalización al sobrepasar las cotas inferiores o superiores de la batería, y el esfuerzo de control ejercido:

$$J(U) = \sum_{t=1}^{N_h} (c_t^{ug} \hat{p}_t^{ug} \Delta t + \psi(\bar{e}_t^b, \hat{e}_t^b) + \psi(\underline{e}_t^b, \hat{e}_t^b)) + u_t^T R_t u_t + c_{N_h+1}^{ug} \hat{p}_{N_h+1}^{ug} \Delta t + \psi(\bar{e}_{N_h+1}^b, \hat{e}_{N_h+1}^b) + \psi(\underline{e}_{N_h+1}^b, \hat{e}_{N_h+1}^b). \quad (23)$$

El primer término hace referencia al coste asociado a la compra de energía de la RE en cada intervalo; los términos que contienen la función ψ representan la penalización asociada al incumplimiento de la restricción (3), que establecen las cotas superiores e inferiores entre las que debe estar el estado de las baterías. La función ψ es una función convexa que presenta la siguiente estructura:

$$\psi(a, b) = \frac{1}{2}(a + b + ((a - b)^2)), \quad (24)$$

y tiene un comportamiento equivalente a $\max(a, b)$, de modo que $\psi(\bar{e}_t^b, \hat{e}_t^b)$ toma valores positivos cuando \hat{e}_t^b supera la cota máxima \bar{e}_t^b , y el valor cero en caso contrario; bajo la misma lógica, se emplea para la cota inferior pero con el orden invertido. La matriz R_t se dimensiona de manera apropiada para aplicar costes a las variables de los VEs y las baterías, al mismo tiempo que incorpora el factor $-c_t^{ug}$ como un estímulo para la venta de p^{ug} a la RE. Es importante señalar que, dado que $c_t^{ug} < c_t^{ug}$, los hogares buscarán activamente asistir a sus vecinos a cubrir sus déficits de energía antes de considerar la venta de energía excedente a la red eléctrica mediante p^{ug} , a una tasa descontada del $100(1 - c_t^{ug}/c_t^{ug})\%$, en comparación con p^{ug} . Además, N_h representa el horizonte de predicción.

Finalmente, el controlador MPC calcula la secuencia de control óptima U que minimiza $J(U)$, a partir del estado inicial del sistema $x_{inicial}$, como:

$$\arg \min_U J(U), \quad (25)$$

sujeto a

$$x_1 = x_{inicial},$$

$$\text{Ec. (13)}, \quad \forall t \in \{1, \dots, N_h\},$$

$$\text{Ec. (14b)}, \quad \forall t \in \{1, \dots, N_h\},$$

$$\text{Ec. (14a)}, \quad \forall t \in \{1, \dots, N_h + 1\}.$$

3.1.2. Formulación del CC-MPC

Debido a la presencia de incertidumbres que afectan a la CE, se ha implementado un esquema de programación estocástica para gestionar esta variabilidad. En particular, se utiliza un tipo de SMPC centrado en abordar las perturbaciones con naturaleza probabilística: el CC-MPC, presenta una estrategia de control que combina las ventajas del MPC tradicional, unido a la posibilidad de considerar restricciones probabilísticas. En este enfoque, las restricciones afectadas por incertidumbres son reformuladas como restricciones equivalentes deterministas asumiendo un cierto nivel de riesgo de incumplimiento de éstas. Además, la función objetivo nominal se reemplaza por su esperanza matemática.

Las incertidumbres en la radiación solar, denotadas como $\theta_{i,t}$, y la demanda de energía, representada por $p_{i,t}^{ul}$, tienen un impacto en la variable de estado $e_{i,t}^b$, que representa la energía almacenada en las baterías, como se puede ver en la Ecuación (2). Es importante notar que $p_{i,t}^{ul}$ tiene una influencia indirecta en $e_{i,t}^b$ al sustituir $p_{i,t}^{bc}$ de la Ecuación (11) en (2). En consecuencia, la Ecuación (3) se puede escribir como una restricción probabilística. Esto significa que la restricción se cumple con cierta probabilidad, utilizando el riesgo de violar la restricción denotado como δ_x . Se expresa como:

$$\mathbb{P} \left[\underline{e}_i^b \leq e_{i,t}^b \leq \bar{e}_i^b \right] \geq 1 - \delta_x. \quad (26)$$

La Ecuación (26) asegura que la probabilidad de que $e_{i,t}^b$ esté dentro de los límites \underline{e}_i^b y \bar{e}_i^b sea mayor o igual a $1 - \delta_x$, donde $\mathbb{P}[\cdot]$ representa el operador de probabilidad. Las variables estocásticas, $\eta^{pv} \sigma_i \theta_i \Delta t$ y $p_{i,t}^{ul} \Delta t$, se representan utilizando funciones de distribución acumulada (fda) conocidas.

El equivalente determinista de la restricción de probabilidad se formula como:

$$\begin{aligned} \mathbb{P} \left[e_{i,t}^b \geq \underline{e}_i^b \right] \geq 1 - \delta_x &\Leftrightarrow \mathbb{P} \left[e_{i,t}^b \leq \underline{e}_i^b \right] \leq \delta_x \Leftrightarrow \\ \phi_i \left(\underline{e}_i^b - e_{i,t}^b \right) \leq \delta_x &\Leftrightarrow \underline{e}_i^b - e_{i,t}^b \leq \phi_i^{-1} (\delta_x) \Leftrightarrow \\ e_{i,t}^b \geq \underline{e}_i^b + \phi_i^{-1} (1 - \delta_x). &\quad (27) \end{aligned}$$

Se sigue un procedimiento análogo para expresar la restricción de probabilidad determinista equivalente para el límite superior, como se indica en la Ecuación (28). En este contexto, ϕ_i representa la función de distribución acumulada (fda) de la variable aleatoria asociada a cada agente de la CE. La función de distribución acumulada puede obtenerse de una fda estocástica conocida o a partir de datos históricos.

$$\begin{aligned} \mathbb{P} \left[e_{i,t}^b \leq \bar{e}_i^b \right] \geq 1 - \delta_x &\Leftrightarrow \phi_i \left(\bar{e}_i^b - e_{i,t}^b \right) \geq 1 - \delta_x \Leftrightarrow \\ \bar{e}_i^b - e_{i,t}^b \geq \phi_i^{-1} (1 - \delta_x) &\Leftrightarrow e_{i,t}^b \leq \bar{e}_i^b - \phi_i^{-1} (1 - \delta_x). \quad (28) \end{aligned}$$

Finalmente, en este trabajo las perturbaciones estocásticas son representadas por distribuciones normales con media μ y desviación estándar σ , es decir, $\phi_i = \mathcal{N}(\mu_i, \sigma_i^2)$.

Por lo tanto, el problema de optimización resultante del controlador CC-MPC es el siguiente:

$$\arg \min_{u[t:t+N_h-1]} \mathbb{E} [J], \quad (29)$$

sujeto a (8), (12), (13), (14b), (27) y (28). Aquí, $\mathbb{E}[J]$ representa el valor esperado de la función objetivo definida en la Ecuación (23).

3.2. Algoritmo CC-MPC Distribuido

Para abordar la formulación del controlador CC-MPC de manera distribuida, se emplea el algoritmo *Feasible cooperation-based MPC* (FC-MPC) introducido por Venkat et al. (2005). En este enfoque, cada agente resuelve un problema de optimización en el que la función objetivo es común, y dicha función objetivo se define, normalmente, como una suma convexa de las funciones objetivos individuales J_i de cada agente $\forall i \in \mathcal{A}$ que evalúa el rendimiento global del sistema. De este modo, una posible opción para la función objetivo global J sería definirla como la suma ponderada de las funciones de coste individuales de los agentes J_i , es decir,

$$J = \sum_{i=1}^N \alpha_i J_i, \quad (30)$$

donde $\alpha_i > 0$ y $\sum_{i=1}^N \alpha_i = 1$. Una propiedad muy interesante del algoritmo FC-MPC es que asegura que las iteraciones intermedias son factibles. Esto significa que, incluso si el tiempo de cálculo excede el tiempo necesario para la convergencia global, la secuencia de control calculada durante la última iteración sigue siendo factible para todo el sistema.

La formulación del MPC distribuido se calcula para cada agente $\forall i \in \mathcal{A}$ a lo largo de un número de iteraciones p , como

$$U_i^* \in \arg(\text{FC-MPC}_i), \quad (31)$$

donde

$$\begin{aligned} \text{FC-MPC}_i \triangleq \min_{u_i} \frac{1}{N} \sum_{t=1}^{N_h} (c_i \hat{p}_t^{\text{ug}} + \delta^b (\bar{e}_t^b - \hat{e}_t^b)) &+ \delta^{\text{ev}} (\bar{e}_{N_h+1}^{\text{ev}} - \hat{e}_{N_h+1}^{\text{ev}}) + c_{N_h+1} \hat{p}_{N_h+1}^{\text{ug}} \\ + \delta^b (\bar{e}_{N_h+1}^b - \hat{e}_{N_h+1}^b) &+ \delta^{\text{ev}} (\bar{e}_{N_h+1}^{\text{ev}} - \hat{e}_{N_h+1}^{\text{ev}}) + \sum_{t=1}^{N_h} u_t^T R u_t, \quad (32) \end{aligned}$$

sujeto a

$$x_i(t+1) = A \cdot x_i(t) + B \cdot u_i(t) + D \cdot w(t), \forall t \in \{1, \dots, N_h\}, \quad (33)$$

$$x_i(1) = x_{i,\text{inicial}},$$

$$x_{t+1} \in \mathcal{X}, \quad \forall t \in \{1, \dots, N_h\}, \quad (34)$$

$$u_t \in \mathcal{U}, \quad \forall t \in \{1, \dots, N_h\}. \quad (35)$$

En este contexto, U_i^* comprende la secuencia de control óptima $u_i(t)$ para todos los instantes de tiempo t dentro del rango $\{1, \dots, N_h\}$. El sistema lineal invariante discreto de la Ecuación (33) es equivalente al sistema descrito en la Ecuación (13), con la diferencia de que el estado y las entradas ahora son representadas como x_i y u_i , respectivamente. Tanto x_i como u_i contienen el mismo número de elementos que los vectores x y u originales, sin embargo, solo las variables correspondientes al agente i son optimizadas, mientras que las restantes, la de los vecinos, son constantes con el valor de la iteración anterior.

Los pasos para resolver el algoritmo FC-MPC se detallan en el Algoritmo 1, donde el superíndice p representa la p -ésima iteración. El objetivo principal reside en garantizar que cada agente calcule un conjunto de secuencias de estado y control a lo largo del horizonte $(x_i^p; U_i^p)$ que no difieran más allá del error permisible \varkappa respecto a los calculados en la iteración previa. El error entre dos iteraciones consecutivas del agente i se define como ϑ_i^p . De manera resumida, los pasos del Algoritmo 1 consisten en que cada agente resuelva el problema descrito en (31) considerando la información proporcionada por sus vecinos durante la iteración pasada, lo que da lugar al cálculo de la secuencia de control óptima U_i^* . Posteriormente, $x_i^{p,*}$, que es la secuencia de estados óptima, se obtiene al sustituir $U_i^{p,*}$ y $U_{j \neq i}^{p,*}$ en (33). Las secuencias de estado y control consensuadas $(x_i^p; U_i^p)$, se determinan mediante una combinación lineal de $(x_i^{p-1}, x_i^{p,*}; U_i^{p-1}, U_i^{p,*})$. Finalmente se calcula el error ϑ_i^p . Si $\forall \vartheta_i^p \leq \varkappa$, se cumple la condición de finalización.

Algoritmo 1: Algoritmo FC-MPC.

Dados $u_i^0, x^0, c_i \geq 0, p^{\max} > 0, \varkappa > 0, p \leftarrow 1, \forall \vartheta_i^1 \gg 1, \phi_i, i \in \mathcal{A}$.

while $\vartheta_i^p > \varkappa$ para algún $i \in \mathcal{A}$ y $p \leq p_{\max}$ **do**

for $i \in \mathcal{A}$ **do**

$U_i^{p,*} \in \arg(\text{FC-MPC}_i, \text{Ec. (31)})$

end for

for $i \in \mathcal{A}$ **do**

$x_i^{p,*} \leftarrow x_i^{(u_i^{p,*}, u_{j \neq i}^{p,*}, x^0)}$ en Ec. (33)

$(x_i^p, u_i^p) = \frac{1}{N}(x_i^{p,*}, u_i^{p,*}) + (1 - \frac{1}{N})(x_i^{p-1}, u_i^{p-1})$

$\vartheta_i^p = \|(x_i^p, u_i^p) - (x_i^{p-1}, u_i^{p-1})\|$

end for

$p \leftarrow p + 1$

end while

3.3. Implementación de blockchain

El empleo del algoritmo distribuido presentado en la sección 3.2 requiere de ciertas tareas de coordinación que, en un esquema tradicional, serían realizadas por un coordinador centralizado. Este coordinador tendría la posibilidad de no llevar a cabo de manera lícita el cálculo de los pasos descritos en el algoritmo, pudiendo potencialmente perjudicar o favorecer a distintos hogares. Para evitar esta dependencia, se emplea el uso de un contrato inteligente con los pasos descritos en el Algoritmo 1. Ethereum (Buterin et al., 2013), que es una *blockchain* pública y sin permisos, es decir, cualquiera puede formar parte de ella, a diferencia con las *blockchain* privadas o de consorcio, ofrece la creación de contratos inteligentes Turing completos mediante el uso del lenguaje de programación Solidity (<https://docs.soliditylang.org/en/develop/index.html>), que está diseñado para interactuar con la Máquina Virtual de Ethereum (<https://ethereum.org/en/developers/docs/evm/>). Debido a que se busca que el contrato inteligente ejerza el papel de un coordinador descentralizado, sus funciones abarcan desde el almacenamiento e intercambio de información entre hogares, hasta la gestión del flujo de control del algoritmo distribuido. Dada la naturaleza inmutable de la tecnología *blockchain*, los contratos inteligentes, una vez implementados, no pueden ser alterados. Esta

característica asegura que las secuencias de control codificadas permanezcan inalteradas, simplificando así la revisión y auditoría del proceso. De forma resumida, la tecnología *blockchain* se implementa como una tecnología de soporte que codifica un algoritmo de control. Tradicionalmente, este tipo de algoritmo necesitaría de una tercera parte para gestionar y actualizar las variables de control en cada iteración. No obstante, gracias a *blockchain*, se garantiza que la información proporcionada por los agentes no puede ser alterada y se procesa de manera íntegra y confiable.

A continuación se describen las herramientas utilizadas para implementar la aplicación descentralizada basada en *blockchain*. En primer lugar, se utiliza la red de prueba Rinkeby de Ethereum (<https://ethereum.org/en/developers/docs/networks/>), destinada a la realización de pruebas. Para interactuar con el contrato inteligente, se desarrolla una interfaz gráfica de usuario utilizando React (<https://es.reactjs.org/>) y web3.js. Web3.js (<https://web3js.readthedocs.io/en/v1.3.4/>) es un conjunto de bibliotecas destinadas a permitir la conexión con un nodo de Ethereum, y se utiliza Infura (<https://docs.infura.io/infura/>) como proveedor de nodo de Ethereum. Metamask se utiliza como cartera Ethereum y firmante de transacciones. El diagrama de conexión de estas herramientas se muestra en la Figura 2.

El Algoritmo 1 se ha modificado para incorporar el contrato inteligente en el problema de optimización distribuida, dando lugar al Algoritmo 2. Las diferencias clave respecto al Algoritmo 1 radican en que, en este nuevo algoritmo, los agentes deben cargar tanto el estado actual como una secuencia de control inicial viable en el contrato inteligente antes de iniciar la primera iteración. Además, a lo largo de las iteraciones, los agentes interactúan con el contrato inteligente para cargar u_i^p y obtener $u_j^{p,*}$ para todos los agentes j en el conjunto $\mathcal{A} - i$. Al final de cada iteración, el contrato inteligente evalúa el cumplimiento de la condición de terminación.

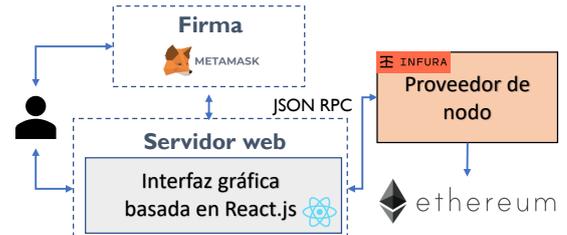


Figura 2: Interconexión de los elementos implicados en la aplicación descentralizada desarrollada en *blockchain*.

4. Control de la capa inferior

La CI, tal y como se observa en la Figura 1, está compuesta por un controlador MPC local en cada hogar. El consenso alcanzado de manera cooperativa en la CS se convierte en la referencia a seguir por los controladores MPC en la CI, que funcionan de manera aislada respecto a la CE. Por lo tanto, el objetivo principal del MPC de la CI es cumplir con los intercambios de energía acordados dentro del algoritmo CC-DMPC, al mismo tiempo que minimiza los costos operativos del agente y cumple con las restricciones propias de los equipos físicos.

Mientras que el algoritmo CC-MPC de la CS trabaja a una frecuencia horaria, el tiempo de muestreo del controlador MPC de la CI es mucho menor, lo que le permite reaccionar ante posibles discrepancias entre las previsiones y las perturbaciones en tiempo real. Por todo ello, las características de la CI son las siguientes:

- **Prioridad en los Intercambios de Energía:** el enfoque principal en este nivel es asegurar el cumplimiento de los intercambios de energía determinados por la gestión de nivel superior. Dado que los problemas MPC en esta capa son resueltos por cada agente de forma aislada respecto a sus vecinos, las transacciones de energía decididas en la capa superior son consideradas constantes, es decir, no son variables de optimización.
- **Objetivos de Energía para Baterías y Vehículos Eléctricos:** la CI también se enfoca en alcanzar los niveles de energía esperados para el siguiente intervalo de tiempo de nivel superior en la batería (e^b) y el VE (e^{ev}). El objetivo es rastrear con precisión estos niveles de energía, asegurando que se alineen con las previsiones y objetivos de nivel superior.
- **Modelo de Hogar de Nivel Inferior:** el modelo se ajusta finamente para abordar los requisitos específicos del problema de optimización de la CI.

4.1. Escala temporal del bajo nivel

Debido a que el CI-MPC opera un número de veces durante cada intervalo horario del CC-DMPC, existen una serie de elementos temporales que sólo afectan al bajo nivel:

- **Frecuencia de Ejecución del CI-MPC:** el CI-MPC se ejecuta entre cada solución del CC-DMPC $N_1 = \Delta t / \Delta t^{CI}$ veces, donde Δt^{CI} es el paso de tiempo entre dos instantes de muestreo en la CI. Merece la pena destacar la importancia de escoger un Δt^{CI} apropiado, pues un valor muy elevado daría lugar a una limitada capacidad de reacción ante perturbaciones; y un valor muy pequeño podría no ser respetado atendiendo a restricciones computacionales.
- **Índice de Tiempo del CI-MPC, t^{CI} :** indica el paso del tiempo entre cada solución del CI-MPC. Comienza en $t^{CI} = 1$, y cada valor de t^{CI} corresponde a una sola solución del CI-MPC. El proceso continúa hasta que $t^{CI} = N_1$, lo que resulta en una secuencia de valores de t^{CI} que abarcan $[1, \dots, N_1]$.
- **Horizonte de Predicción del CI-MPC:** El CI-MPC utiliza un horizonte de predicción de N_{CI} , con $N_{CI} < N_1$.

Algoritmo 2: Algoritmo FC-MPC basado en *blockchain*.

Dados $c_i \geq 0, p^{\max} > 0, \varkappa > 0, p \leftarrow 1, \forall \vartheta_i^1 \gg 1, \phi_i, i \in \mathcal{A}$.

while $\vartheta_i^p > \varkappa$ para algún $i \in \mathcal{A}$ y $p \leq p_{\max}$ **do**

if $p = 1$ **then**

for $i \in \mathcal{A}$ **do**

• Calcular FC-MPC $_i$ con $p_{i,j,t}^b |_{u=0} = 0$.

• Actualizar $u_i^{1,*}$ y x_i^1 hacia el contrato inteligente.

• Obtener $u_j^{1,*}$ y $x_j^1 \forall j \in \mathcal{A} - i$ desde el contrato inteligente.

end for

Contrato inteligente:

for $i \in \mathcal{A}$ **do**

• Recolectar $u_i^{1,*}$ y x_i^1 .

end for

• Cálculo de las matrices globales $U^{1,*}$ y x^1 .

else

for $i \in \mathcal{A}$ **do**

• Calcular FC-MPC $_i$.

• Actualizar $u_i^{p,*}$ hacia el contrato inteligente.

• Obtener $u_j^{p,*} \forall j \in \mathcal{A} - i$ desde el contrato inteligente.

• Calcular:

$x_i^{p,*} \leftarrow x_i^{(u_i^{p,*}, u_{j \neq i}^{p,*}, x^1)}$ en Ec. (33)

$(x_i^p, u_i^p) = \frac{1}{N} (x_i^{p,*}, u_i^{p,*}) + (1 - \frac{1}{N}) (x_i^{p-1}, u_i^{p-1})$

$\vartheta_i^p = \| (x_i^p, u_i^p) - (x_i^{p-1}, u_i^{p-1}) \|$

• Actualizar ϑ_i^p hacia el contrato inteligente.

end for

Contrato inteligente:

for $i \in \mathcal{A}$ **do**

• Recolectar ϑ_i^p .

end for

• Verificar la condición de terminación.

• $p = p + 1$.

end if

end while

4.2. MPC de bajo nivel

El controlador de MPC de bajo nivel busca seguir las referencias de alto nivel. Por lo tanto, la función objetivo $J_{r^{CI}}^{CI}$ se define de la siguiente manera:

$$\begin{aligned}
 J_{r^{CI}}^{CI} &= \sum_{t=1}^{N_1} (c_t^{ug} p_t^{ug_{CI}} + (x_t^{CI} - \phi_{r^{CI}}^{CI})^T M (x_t^{CI} - \phi_{r^{CI}}^{CI})) \\
 &+ c_{N_1+1}^{ug} p_{N_1+1}^{ug_{CI}} + (x_{N_1+1}^{CI} - \phi_{r^{CI}}^{CI})^T M (x_{N_1+1}^{CI} - \phi_{r^{CI}}^{CI}) \\
 &+ \sum_{t=1}^{N_1} (u_t^{CI})^T R^{CI} u_t^{CI}, \quad (36)
 \end{aligned}$$

donde $\phi_{r^{CI}}^{CI}$ representa las trayectorias de referencia que deben de seguir los estados de bajo nivel, con $\forall t^{CI} \in [1, \dots, N_1]$; M es una matriz semidefinida positiva de tamaño adecuado para dirigir los estados hacia $\phi_{r^{CI}}^{CI}$; y la matriz R^{CI} opera de manera análoga a R en la Ecuación (23) imponiendo costes positivos tanto en las variables del VE como en las variables de la batería, y ofreciendo incentivos de $-c_t^{ugs}$ para la venta de energía a la red eléctrica a través de $p_{i,t}^{ugs_{CI}}$ y $p_{i,t}^{s_{CI}}$.

El controlador MPC de bajo nivel determina la secuencia de control óptima de bajo nivel U^{Cl} que minimiza J_{Cl}^{Cl} sujeto a (21), (22b) y (22a) $\forall t \in \{1, \dots, N_h\}$.

5. Resultados y discusión

En esta sección se presenta un caso práctico y se evalúan los resultados del problema de optimización en bucle cerrado CC-DMPC descrito en la Sección 3, y el seguimiento en bajo nivel descrito en la Sección 4. Inicialmente, se ofrece una descripción general de la CE propuesta, así como las características de los agentes. Posteriormente, se presentan los detalles esenciales relativos a las distintas simulaciones escogidas, índices de rendimiento y los parámetros de control. Por último, se describen y analizan los resultados obtenidos.

5.1. Configuración de la CE

La CE escogida está compuesta por 10 agentes, donde 4 de ellos son prosumidores, y 6 consumidores. Los prosumidores de la CE cuentan con baterías, paneles solares y VEs, en cambio, los consumidores no cuentan con ningún RED, por lo que deben de obtener la energía necesaria a través de la compra de ésta de la RE o mediante intercambios en la CE. El precio al cual la energía es comprada de la RE, c_i^{ug} , se obtiene del Mercado Eléctrico Ibérico (MIBEL); y la venta de energía en la CE, c_i^{ugs} se efectúa al 50 % de descuento de la RE, $c_i^{ugs} = 0,5c_i^{ug}$.

5.1.1. Vehículos Eléctricos

Los VEs reciben una carga de energía comprendida en el rango [7,45, 8,25] kWh, durante el lapso de 24 horas entre las [0, 23] horas de cada día. Los EVs son cargas flexibles que pueden o pueden no estar en el punto de carga para un instante dado. Este comportamiento se genera a través de un horario de disponibilidad que se obtiene de forma aleatoria para cada hogar. La potencia máxima de carga se establece en 2,5 kW y con una eficiencia asociada de 0,95.

5.1.2. Baterías

Las baterías de los hogares cuentan con una capacidad que oscila entre [3,3, 3,9] kWh. En términos de eficiencia, presentan un 94.5 % para la carga y descarga, mientras que la eficiencia vinculada al intercambio de energía en la CE se fija en 93 %. Para el control del estado de carga de las baterías se establecen los límites $e_i^b=28\%$ y $e_i^c=87\%$ de la capacidad máxima de energía.

5.2. Perturbaciones

La radiación solar y la demanda de energía son modeladas como funciones de distribución normal. Los perfiles de consumo horario de los agentes se generan a partir de datos obtenidos de (Palacios-Garcia et al., 2018) para un año. Estos datos se utilizan para crear distribuciones normales bimensuales para cada hora. Se dividen los datos anuales en 6 grupos de 2 meses consecutivos cada uno, y se generan distribuciones normales para cada subconjunto, definidas como

$$\phi_{i,t,m}^{p^{ul}} = \mathcal{N}(\mu_i^{\Omega^{p^{ul}}}, \sigma_i^{2\Omega^{p^{ul}}}), \forall t \in \{1, \dots, 24\}.$$

Los mismos procedimientos se repiten para la radiación solar, donde los datos se obtienen del Sistema de Información Geográfica Fotovoltaica PVGIS (European Union Science Hub, June 2, 2022), lo que lleva a $\phi_{i,t,m}^{\sigma} = \mathcal{N}(\mu_i^{\Omega^{m,t}}, \sigma_i^{2\Omega^{m,t}}) \forall t \in \{1, \dots, 24\}$.

5.3. Configuración de las simulaciones

Las simulaciones comienzan a las 12 p.m. y cada una de las configuraciones detalladas a continuación se lleva a cabo en dos meses diferentes: enero y julio. Esto se realiza con el fin de introducir una mayor variabilidad en las perturbaciones.

Para evaluar la incidencia de las perturbaciones en el algoritmo CC-DMPC y su rendimiento, se simulan varios escenarios en los que la radiación global horizontal y la demanda de los hogares exhiben distintos comportamientos:

- Baja radiación y alto consumo (BRAC).
- Alta radiación y bajo consumo (ARBC).
- Previsión perfecta de las perturbaciones (PPP).

La elección de los tres escenarios de perturbaciones, para cada uno de los dos meses simulados, atiende a observar los resultados del algoritmo cuando las perturbaciones se comportan tal y como se espera (exhiben un valor exacto a la media de la distribución normal correspondiente para cada instante); y cuando las perturbaciones exhiben valores que se desvían de la media en más de una unidad de la desviación típica.

Por otra parte, cada uno de los escenarios de perturbaciones propuestos son simulados para dos configuraciones de control: CC-DMPC, que hace referencia al algoritmo descrito en la Sección 3; y DMPC determinista es igual con la diferencia de que las restricciones probabilísticas no han sido reescritas a través de sus equivalentes deterministas. Con estos escenarios de control se busca identificar la influencia del control basado en probabilidad en el resultado final frente a un controlador MPC determinista.

Finalmente, se emplean los siguientes índices clave de rendimiento (KPIs) para evaluar el desempeño de cada configuración de simulación y control: **coste de la compra de energía de la RE** (KPI_1 [€]) que representa el coste de adquisición de electricidad de la RE; **venta de energía a la RE** (KPI_2 [€]) que indica los ingresos generados por la venta de energía a la RE; **compra/venta de energía en la función objetivo de la capa superior** (KPI_3 [€]) que muestra la variación entre el coste de compra de energía (KPI_1) y las ganancias por su venta (KPI_2); **función objetivo de la capa superior** (KPI_4 [€]) que valor total de la función objetivo descrita en la Ecuación (23), que incluye el aspecto económico derivado de la compra/venta de la energía, y la penalización derivada del incumplimiento de las restricciones probabilísticas asociadas a las baterías; **intercambio de energía intracomunitario** (KPI_5 [kWh]) que refleja la energía transferida entre los hogares de la CE; **energía vendida a la red** (KPI_6 [kWh]) que cuantifica la energía vendida de vuelta a la red eléctrica; **compras de energía a la red** (KPI_7 [kWh]) que indica la cantidad total de electricidad adquirida de la RE; **compras de energía por parte de consumidores** (KPI_8 [kWh]) que mide la electricidad obtenida de la RE por parte de

los consumidores; **compras de energía por parte de prosumidores** (KPI_9 [kWh]) que evalúa la energía obtenida de la red eléctrica por parte de los prosumidores.

5.4. Configuración de los parámetros de control

Las simulaciones en el nivel superior abarcan un día completo, es decir, $N_h = 24$, y se escoge $\Delta t = 1$ hora debido que es el tiempo de actualización de los precios eléctricos del MIBEL. Para permitir que el controlador de bajo nivel pueda corregir las desviaciones entre el tiempo real con las estimaciones del problema de alto nivel, se establece un paso de tiempo $\Delta t^{CI} = 30$ s, lo que da lugar a $N_l = 120$ ejecuciones de bajo nivel por cada ejecución de alto nivel. El riesgo de incumplimiento de las restricciones probabilísticas δ_x se establece en un 5%, lo que garantiza el cumplimiento de éstas en el 95% de las posibles realizaciones.

5.5. Simulaciones y discusión

Las simulaciones se realizaron en un sistema operativo Windows 11, utilizando un ordenador con un procesador AMD Ryzen 7 5800H, 16 GB de RAM y un SSD de 1 TB. Se empleó MATLAB R2022b y el solver Gurobi 9.5.2. El tiempo medio de ejecución del algoritmo no ha sido calculado al ser muy dependiente del número de agentes involucrados y de la implementación *blockchain* escogida. Los resultados de las simulaciones son detallados en la Tabla 1, la cual muestra los valores numéricos de los KPIs considerados en este estudio. La nomenclatura escogida para identificar a cada simulación utiliza las bases P , D y E , para hacer referencia a los escenarios de perturbación PPP, BRAC y ARBC, respectivamente; los exponentes CC , y D , para hacer referencia a las configuraciones de control CC-DMPC y DMPC determinista, respectivamente; y los subíndices v e i , para hacer referencia a las estaciones verano, e invierno, respectivamente. Se presentan las Figuras 3, 4, 5 y 6, que muestran las simulaciones Ev^{CC} , Ev^D , Dv^{CC} y Dv^D , respectivamente. A modo de ejemplo y para ilustrar el comportamiento de los hogares a bajo nivel, las Figuras 7 y 8 ilustran las variables de control en bajo nivel de los prosumidores y consumidores, respectivamente, para la simulación P_v^{CC} al mediodía, cuyo objetivo es cumplir con los acuerdos alcanzados en el alto nivel al mediodía.

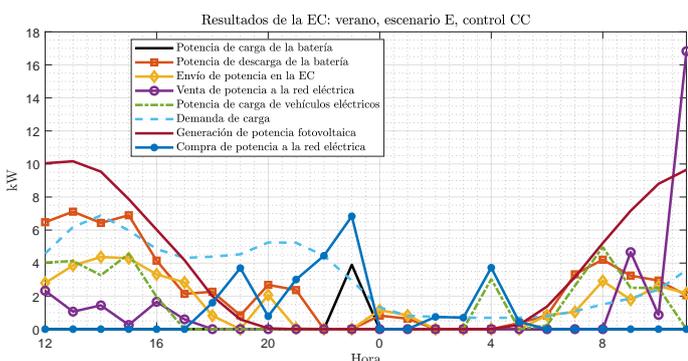


Figura 3: Resultados de la simulación Ev^{CC} .

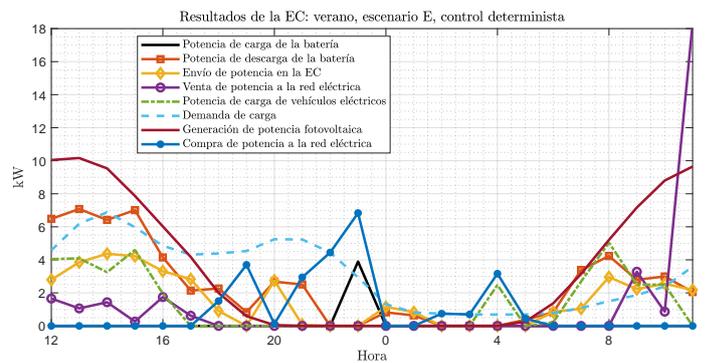


Figura 4: Resultados de la simulación Ev^D .

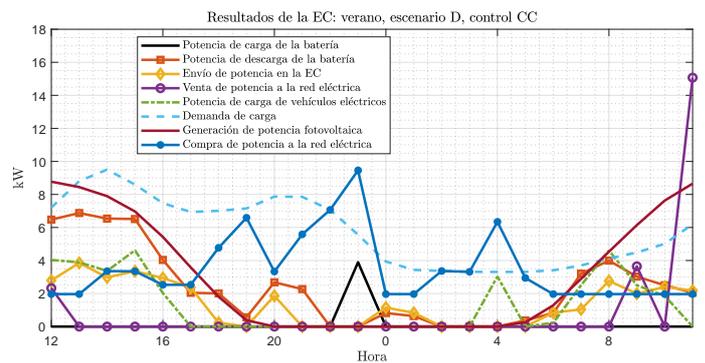


Figura 5: Resultados de la simulación Dv^{CC} .

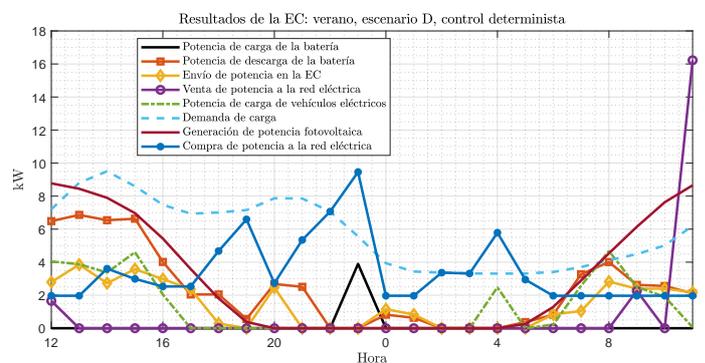


Figura 6: Resultados de la simulación Dv^D .

Comenzando por el índice económico KPI_1 , se observa que en cada estación, los valores más bajos se obtienen en los escenarios $Ev, i^{CC,D}$, donde las perturbaciones dan lugar a una mayor generación solar y menor consumo, seguidos por $Pv, i^{CC,D}$, con valores medios de perturbaciones, mientras que los mayores valores se obtienen en los escenarios $Dv, i^{CC,D}$, donde la radiación es menor y el consumo es superior a lo esperado. El índice KPI_2 muestra la influencia de la radiación solar en la venta de energía a la red externa, observándose valores similares para los escenarios de perturbaciones P y D , aunque inferiores en D , mientras que son superiores en los escenarios E , gracias al exceso de radiación solar. KPI_3 , que evalúa el rendimiento económico de la CE considerando solo las transacciones energéticas y excluyendo las penalizaciones relacionadas con la batería, alcanza los valores más bajos en cada estación para los

Tabla 1: Índices clave de rendimiento.

KPIs	Escenarios											
	Verano						Invierno					
	P_{V}^{CC}	P_{V}^{D}	D_{V}^{CC}	D_{V}^{D}	E_{V}^{CC}	E_{V}^{D}	P_{i}^{CC}	P_{i}^{D}	D_{i}^{CC}	D_{i}^{D}	E_{i}^{CC}	E_{i}^{D}
KPI ₁ (€)	11.41	10.81	29.70	29.10	9.08	8.56	22.55	22.32	35.49	35.26	19.43	19.27
KPI ₂ (€)	4.86	4.78	4.60	4.44	8.02	7.98	0	0	0	0	0.99	1.03
KPI ₃ (€)	6.55	6.03	25.10	24.66	1.06	0.58	22.55	22.32	35.49	35.26	18.43	18.24
KPI ₄ (€)	6.55	6.03	25.19	29.56	4.77	23.11	22.55	22.32	35.54	36.35	20.34	29.31
KPI ₅ (kWh)	37.90	38.99	33.58	34.69	37.73	38.87	18.82	19.34	18.82	19.34	19.82	20.11
KPI ₆ (kWh)	22.28	21.72	21.04	20.14	39.74	39.41	0	0	0	0	5.29	5.44
KPI ₇ (kWh)	32.59	30.99	84.18	82.59	25.96	24.59	69.92	69.45	106.48	106.02	60.20	59.89
KPI ₈ (kWh)	18.12	17.30	48.55	47.90	13.76	12.98	26.80	26.28	47.44	46.92	21.99	21.77
KPI ₉ (kWh)	14.47	13.70	35.64	34.68	12.20	11.61	43.12	43.17	59.04	59.10	38.22	38.12

escenarios con la configuración más favorable de perturbaciones, es decir, E, seguidos de P, y en última posición D.

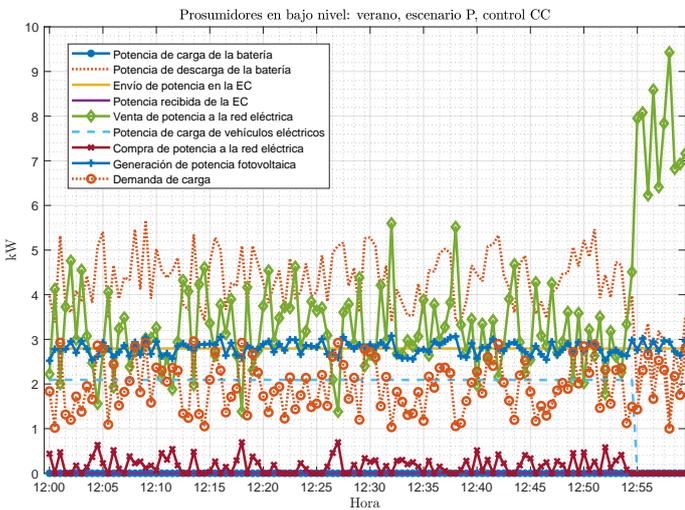


Figura 7: Resultados de los prosumidores, simulación P_V^{CC} a las 12 del mediodía.

Poniendo ahora el foco en la configuración de control, y la tríada de índices KPI₁, KPI₂ y KPI₃, se aprecia cómo, para cada configuración de perturbaciones, se obtienen distintos valores en función de si el controlador es CC-DMPC o determinista. Específicamente, se observa cómo los resultados económicos son ligeramente superiores en los enfoques en los que el controlador CC-DMPC no está activado, lo cual es lógico ya que en estos indicadores no se contabiliza ninguna penalización por incumplimiento de restricciones y el controlador CC-DMPC presenta restricciones extras que el controlador determinista no. Observando el KPI₄, que considera las penalizaciones asociadas al incumplimiento de restricciones probabilísticas, se evidencia una disminución en los resultados en la mayoría de las configuraciones, excepto en aquellas donde las perturbaciones siguen exactamente la predicción esperada. Esta discrepancia se explica por la naturaleza más restrictiva del controlador CC-DMPC en comparación con el determinista. En situaciones donde las perturbaciones coinciden con las expectativas, el controlador CC-DMPC se ve limitado en su rango de operación de variables controlables, resultando en un rendimiento inferior.

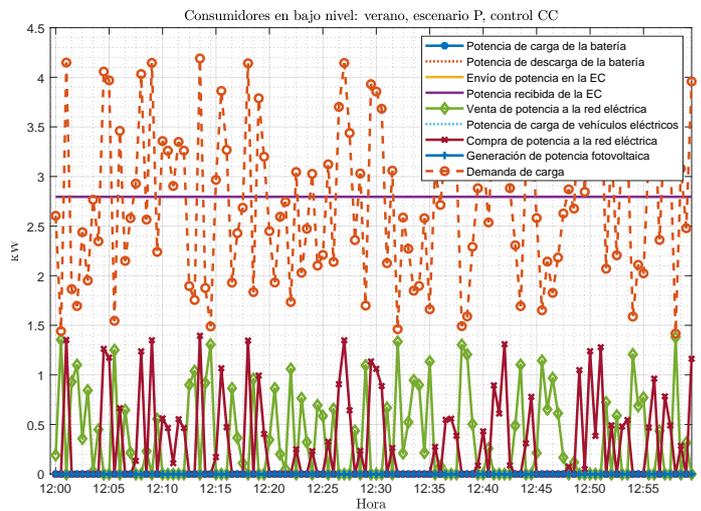


Figura 8: Resultados de los consumidores, simulación P_V^{CC} a las 12 del mediodía.

Sin embargo, cuando las perturbaciones exhiben su naturaleza estocástica, se observa que el controlador CC-DMPC logra cumplir con las restricciones probabilísticas sin incurrir en costos adicionales, lo que conduce a un mejor control de la CE. Este aspecto resalta la capacidad del controlador CC-DMPC para adaptarse a la incertidumbre asociada con las perturbaciones y garantizar el cumplimiento de las restricciones establecidas, lo que se traduce en un rendimiento más eficaz de la CE en escenarios menos predecibles.

En relación con los indicadores de potencia, en el KPI₅, se observan volúmenes ligeramente menores de energía intercambiada en la CE en las configuraciones con el controlador CC-DMPC. Este fenómeno se atribuye a una estrategia de control más conservadora implementada por el controlador CC-DMPC. Los KPI₆ y KPI₇ revelan volúmenes más altos de energía vendida y comprada de la red externa, respectivamente, en los escenarios de control CC-DMPC en comparación con los deterministas. Esta tendencia se mantiene constante para cada estación y escenario de perturbación.

Por último, los KPI₈ y KPI₉ detallan el volumen de compra de energía de la red externa por parte de los consumidores y los prosumidores, respectivamente. En cada estación, se observan comportamientos opuestos: durante el verano, los consu-

midores experimentan un mayor consumo de energía de la red externa, mientras que en invierno, los prosumidores muestran una mayor demanda. Esta variación estacional se explica por la insuficiente generación solar en invierno, lo que lleva a los prosumidores a anticipar la compra de energía cuando es más económica, actuando como almacenes de energía para suministrarla a los consumidores en momentos de mayor demanda y precios. En contraste, en verano, la generación solar abundante permite a los prosumidores satisfacer sus necesidades y las de sus vecinos durante las horas pico del día, limitando así la compra de energía de la RE a las horas fuera de esa franja.

6. Conclusiones y trabajos futuros

Este trabajo ha presentado un marco de optimización distribuida para comunidades energéticas bajo incertidumbres, utilizando *blockchain* y contratos inteligentes para su implementación. El esquema de control se presentó según una arquitectura jerárquica con dos capas, la capa superior y la capa inferior, utilizando enfoques de MPC diferentes en ambos niveles.

En la capa superior, se empleó un MPC estocástico para abordar las incertidumbres dentro de los sistemas de energía de manera distribuida. Específicamente, se utilizó el enfoque CC-DMPC para integrar restricciones probabilísticas para cada agente. Para resolver el problema de optimización distribuida sin depender de un coordinador central, se presentó un enfoque alternativo mediante la introducción de un contrato inteligente implementado en una red *blockchain*. La capa inferior es responsable de rastrear las referencias derivadas del consenso desde la capa superior. Cabe destacar que el controlador de la capa inferior opera en una escala de tiempo más corta, lo que le permite adaptarse a posibles discrepancias entre las previsiones y las perturbaciones en tiempo real. La función principal de la capa inferior es garantizar el cumplimiento de las transacciones energéticas acordadas en el algoritmo CC-DMPC al tiempo que se minimizan los costos operativos del agente y se cumplen con las restricciones. Varias simulaciones validan la efectividad de la propuesta jerárquica.

Las líneas futuras tienen como objetivo permitir intercambios eficientes entre agentes de la CE al reducir el intercambio de información privada y los costos económicos, por un lado, y maximizar el autoconsumo de la comunidad energética, por otro.

Agradecimientos

La publicación es parte del proyecto PID2022-142069OB-I00, financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE.

Referencias

Bordons, C., Garcia-Torres, F., Ridao, M. A., 2020. Model predictive control of microgrids. Springer.
Buterin, V., et al., 2013. Ethereum white paper. GitHub repository 1, 22–23.

Camacho, E. F., Bordons, C., 2007. Model Predictive Control, second edition Edition. Springer-Verlag, London, England.
European Union Science Hub, June 2, 2022. https://joint-research-centre.ec.europa.eu/pvgis-photovoltaic-geographical-information-system_en.
Grosso, J., Ocampo-Martínez, C., Puig, V., Joseph, B., 2014. Chance-constrained model predictive control for drinking water networks. *Journal of Process Control* 24 (5), 504–516.
Gui, E. M., Diesendorf, M., MacGill, I., 2017. Distributed energy infrastructure paradigm: Community microgrids in a new institutional economics context. *Renewable and Sustainable Energy Reviews* 72, 1355–1365.
Inês, C., Guilherme, P. L., Esther, M.-G., Swantje, G., Stephen, H., Lars, H., 2020. Regulatory challenges and opportunities for collective renewable energy prosumers in the eu. *Energy Policy* 138, 111212.
Maciejowski, J., 2002. Predictive control with constraints. Prentice Hall, Essex, England.
Maestre, J. M., Negenborn, R. R., 2013. Distributed MPC Made Easy. *Intelligent Systems, Control and Automation: Science and Engineering*. Springer-Verlag, Vol. 69, New York, USA.
Maestre, J. M., Velarde, P., Ishii, H., Negenborn, R. R., 2021. Scenario-based defense mechanism against vulnerabilities in lagrange-based dmppc. *Control Engineering Practice* 114, 104879.
Márquez, J., Zafra-Cabeza, A., Bordons, C., Ridao, M. A., 2021. A fault detection and reconfiguration approach for MPC-based energy management in an experimental microgrid. *Control Engineering Practice* 107, 104695.
Olivares, D. E., Lara, J. D., Cañizares, C. A., Kazerani, M., 2015. Stochastic-predictive energy management system for isolated microgrids. *IEEE Transactions on Smart Grid* 6 (6), 2681–2693.
O'Malley, M., Kroposki, B., Hannegan, B., Madsen, H., Andersson, M., D'haeseleer, W., McGranaghan, M. F., Dent, C., Strbac, G., Baskaran, S., et al., 2016. Energy systems integration. defining and describing the value proposition. Tech. rep., National Renewable Energy Lab.(NREL), Golden, CO (United States).
Palacios-García, E., Moreno-Munoz, A., Santiago, I., Flores-Arias, J., Bellido-Outeirino, F., Moreno-García, I., 2018. A stochastic modelling and simulation approach to heating and cooling electricity consumption in the residential sector. *Energy* 144, 1080–1091.
Sivianes, M., Maestre, J. M., Zafra-Cabeza, A., Bordons, C., 2023a. Blockchain for energy trading in energy communities using stochastic and distributed model predictive control. *IEEE Transactions on Control Systems Technology* 31 (5), 2132–2145.
Sivianes, M., Velarde, P., Zafra-Cabeza, A., Maestre, J. M., Bordons, C., 2023b. Uncertainty management in peer-to-peer energy trading based on blockchain and distributed model predictive control. *IFAC-PapersOnLine* 56 (2), 7102–7107.
Sivianes, M., Zafra-Cabeza, A., Bordons, C., 2022. Blockchain-based peer to peer energy trading using distributed model predictive control. In: *Proceedings of the 2022 European Control Conference (ECC)*. IEEE, London, United Kingdom, pp. 1832–1837.
van Leeuwen, G., AlSkaif, T., Gibescu, M., van Sark, W., 2020. An integrated blockchain-based energy management platform with bilateral trading for microgrid communities. *Applied Energy* 263, 114613.
Velarde, P., Valverde, L., Maestre, J. M., Ocampo-Martínez, C., Bordons, C., 2017. On the comparison of stochastic model predictive control strategies applied to a hydrogen-based microgrid. *Journal of Power Sources* 343, 161–173.
Velarde, P., Zafra-Cabeza, A., Márquez, J. J., Maestre, J. M., Bordons, C., 2024. Stochastic MPC-based reconfiguration approaches for microgrids. *IEEE Transactions on Control Systems Technology*. 32 (3), 891–904.
Venkat, A. N., Rawlings, J. B., Wright, S. J., 2005. Stability and optimality of distributed model predictive control. In: *Proceedings of the 44th IEEE Conference on Decision and Control*. Seville, Spain, pp. 6680–6685.
Vergara-Dietrich, J. D., Morato, M. M., Mendes, P. R., Cani, A. A., Normey-Rico, J. E., Bordons, C., 2019. Advanced chance-constrained predictive control for the efficient energy management of renewable power systems. *Journal of Process Control* 74, 120–132.
Zafra-Cabeza, A., Velarde, P., Maestre, J. M., 2020. Multicriteria optimal operation of a microgrid considering risk analysis, renewable resources and model predictive control. *Optimal Control Application Methods* 41 (1), 94–106.