

Gestión de energía en comunidades energéticas mediante Blockchain y MPC estocástico y distribuido

Sivianes, Manuel^a, Velarde, Pablo^{b,*}, Zafra-Cabeza, Ascensión^a, Bordons, Carlos^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. 2023. Energy management in energy communities through Blockchain and stochastic and distributed MPC. XLIV Jornadas de Automática 370-375. <https://doi.org/10.17979/spudc.9788497498609.370>

Resumen

Este trabajo presenta una plataforma de gestión de energía distribuida que utiliza un contrato inteligente implementado en una red Blockchain para optimizar el rendimiento de una comunidad energética ante perturbaciones estocásticas, como la variabilidad en la radiación solar y las fluctuaciones en la demanda de energía por parte de los agentes. Estas perturbaciones se modelan mediante distribuciones de probabilidad y se abordan mediante un esquema de control predictivo distribuido basado en restricciones estocásticas. El rendimiento del algoritmo propuesto se evalúa a través de diversas simulaciones.

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

Energy management in energy communities through Blockchain and stochastic and distributed MPC

Abstract

This paper presents a distributed energy management platform that utilizes a smart contract implemented on a Blockchain network to optimize the performance of an energy community in the face of stochastic disturbances, such as variability in solar radiation and fluctuations in energy demand from the agents. These disturbances are modeled using probability distributions and are addressed through a distributed predictive control scheme based on chance-constraints. The performance of the proposed algorithm is evaluated through various simulations.

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

1. Introducción

Las microrredes son beneficiosas para la generación de energía renovable, reducción de costos y emisiones de carbono (García-Torres et al., 2021). Se han desarrollado diversas técnicas de control para abordar la demanda eléctrica y las incertidumbres en las microrredes (Minchala-Avila et al., 2015; Zafra-Cabeza et al., 2020). El Control Predictivo basado en Modelo (MPC) es una estrategia óptima que resuelve un problema de optimización para minimizar una función objetivo sujeta a restricciones (Camacho y Bordons, 2013).

En la gestión de energía, es importante considerar las incertidumbres en la demanda y la generación renovable (Bordons

et al., 2020). El MPC con restricciones estocásticas (Chance-constraints, CC-MPC) ajusta las restricciones según un nivel de riesgo determinado, teniendo en cuenta la distribución de probabilidad de las incertidumbres (Vergara-Dietrich et al., 2019; Márquez et al., 2021).

En comunidades energéticas (CE), donde hay múltiples agentes tomando decisiones, se utiliza el enfoque de MPC Distribuido (DMPC) para evitar la dependencia de un controlador centralizado (Maestre y Negenborn, 2013). El DMPC ofrece modularidad y reduce la carga computacional, pero requiere un intercambio de información entre los controladores locales, lo que plantea desafíos de seguridad y privacidad (Maestre et al.,

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

2021).

La tecnología Blockchain proporciona seguridad y confiabilidad en sistemas distribuidos al permitir transacciones directas entre pares y eliminar intermediarios (Nakamoto, 2008). A través de la tecnología de registro distribuido, se comparten simultáneamente los datos entre los nodos de la red para garantizar su integridad (Nofer et al., 2017). El consenso se logra mediante algoritmos como Prueba de Trabajo, Prueba de Participación o Prueba de Autoridad (Yaga et al., 2019). Los datos se almacenan de forma inmutable en bloques enlazados criptográficamente, lo que dificulta la manipulación por agentes maliciosos (Nofer et al., 2017).

Además, la tecnología Blockchain ofrece la posibilidad de utilizar contratos inteligentes, que permiten a los usuarios programar acciones basadas en reglas inmutables definidas. En el contexto de las microrredes y las CE con agentes distribuidos que participan en algoritmos de optimización distribuida, los contratos inteligentes pueden actuar como coordinadores, eliminando la necesidad de intermediarios externos. Se pueden encontrar en la literatura varios trabajos que usan la tecnología Blockchain para la gestión de energía en el contexto de las microrredes (Mengelkamp et al., 2018; van Leeuwen et al., 2020).

La contribución de este trabajo consiste en ampliar la investigación previa realizada por Sivianes et al. (2022), incorporando un enfoque estocástico para manejar las perturbaciones. En particular, se utiliza un esquema de DMPC para operar una CE compuesta por varios agentes que se ven afectados por la incertidumbre tanto en la generación de energía renovable como en la demanda eléctrica. Todo esto se logra mediante el uso de tecnología Blockchain. Por lo tanto, la novedad de este trabajo radica en la propuesta de un nuevo enfoque basado en controladores distribuidos y estocásticos que abordan la incertidumbre en los sistemas de gestión de energía.

La estructura restante de este artículo es la siguiente. En la Sección 2, se introduce la formulación del problema de la gestión de energía en una CE. La 3 presenta el enfoque de CC-MPC. En la Sección 4 se amplía la formulación del CC-MPC en una arquitectura distribuida, detallando el procedimiento de negociación para las variables acopladas. En la Sección 5, se describe la implementación de la tecnología Blockchain. A continuación, en la Sección 6, se presentan los resultados obtenidos y en la Sección 7, se presentan las conclusiones y las líneas futuras de investigación.

2. Formulación del problema

Una Comunidad Energética (CE) se compone de dos grupos de agentes: los prosumidores, que tienen acceso a recursos energéticos distribuidos como baterías, paneles solares o vehículos eléctricos (VEs), y los consumidores, que necesitan importar energía de fuentes externas para satisfacer su demanda. Una CE se puede representar mediante un grafo completo dirigido $\mathcal{G} = (\mathcal{A}, \mathcal{V})$, donde $\mathcal{A} = 1, \dots, n$ es el conjunto de agentes y $\mathcal{V} \subseteq \mathcal{N} \times \mathcal{N}$ es el conjunto de aristas dirigidas entre cada agente $(i, j) \in \mathcal{A}$. Todos los agentes pueden importar energía de la red eléctrica principal (utility grid, UG), representada como $p_{i,t}^{ug}$, y la energía excedente vendida de vuelta a la UG se representa como $p_{i,t}^{ugb}$ y se recompensa con un costo de κ_t^b [€/kWh].

La importación de $p_{i,t}^{ug}$ incurre en un costo económico unitario de κ_t [€/kWh].

Dentro del modelo se consideran dos fuentes de incertidumbre: la irradiancia horizontal global $\varpi_{i,t}$ [W/m²] y la demanda de carga $p_{i,t}^{ul}$ para cada agente $i \in \mathcal{A}$. Dado que se supone que la CE abarca un área geográfica relativamente pequeña en comparación con la variación de $\varpi_{i,t}$ en función de la posición, se asume que $\varpi_{i,t}$ es la misma para todos los agentes $i \in \mathcal{A}$ en cada instante de tiempo t , es decir, $\varpi_{i,t} \cong \varpi_t$.

Las baterías desempeñan dos funciones principales: el almacenamiento de energía para su uso posterior y la gestión del exceso de energía. La energía almacenada en la batería del agente i se representa como $e_{i,t}^b$ y se calcula y restringe de la siguiente forma:

$$e_{i,t}^b = e_{i,t-1}^b + (\eta_c^b p_{i,t}^{bc} - \frac{p_{i,t}^{bd}}{\eta_d^b} - \sum_{j \neq i}^n \frac{p_{j,t}^{bt}}{\eta_t^b}) \Delta t + (\eta^{pv} a_i \varpi_t) \Delta t - p_{i,t}^{ugb} \Delta t, \quad \forall i, t, \quad (1)$$

$$e_{i,t}^b | l \leq e_{i,t}^b \leq e_{i,t}^b | u, \quad \forall i, t, \quad (2)$$

$$0 \leq p_{i,t}^{bc} \leq p_{i,t}^{bc} | u, \quad \forall i, t, \quad (3)$$

$$0 \leq p_{i,t}^{bd} \leq p_{i,t}^{bd} | u, \quad \forall i, t, \quad (4)$$

$$0 \leq p_{i,j,t}^{bt} \leq p_{i,j,t}^{bt} | u, \quad \forall i, j, t. \quad (5)$$

Los VEs son cargas flexibles controladas mediante la potencia de carga ($p_{i,t}^{ev}$). La energía almacenada en los VEs se denota como $e_{i,t}^{ev}$ y se calcula así:

$$e_{i,t}^{ev} = e_{i,t-1}^{ev} + \eta_c^{ev} p_{i,t}^{ev} \Delta t, \quad \forall i, t, \quad (6)$$

$$e_{i,t}^{ev} | l \leq e_{i,t}^{ev} \leq e_{i,t}^{ev} | u, \quad \forall i, t, \quad (7)$$

$$0 \leq p_{i,t}^{ev} \leq v_{i,t} p_{i,t}^{ev} | u, \quad \forall i, t, \quad (8)$$

Aquí, η_c^{ev} representa la eficiencia de carga de los VEs. El parámetro binario v indica la disponibilidad de carga de los VEs, definido por el horario predefinido $\Upsilon_i = [v_{1,i}, \dots, v_{end,i}]$, que especifica los instantes de tiempo en los que el VE estará en el punto de carga del agente. Para cumplir con la carga diaria de energía requerida e_{dia}^{ev} , se tiene que

$$e_{i,t}^{ev} = e_{i,dia}^{ev}, \quad \forall i \in \mathcal{E}, \quad t = t^{ev}, \quad (9)$$

\mathcal{E} representa el conjunto de agentes equipados con un VE, y t^{ev} es el tiempo límite para que los VEs hayan recibido la carga diaria requerida e_{dia}^{ev} .

La Ecuación (10) representa el balance de potencia para cada agente, donde $p_{i,t}^{ug}$ se obtiene como la diferencia entre la demanda y la energía suministrada:

$$p_{i,t}^{ug} = p_{i,t}^{bc} - p_{i,t}^{bd} - \sum_{j \neq i}^n p_{j,t}^{bt} + p_{i,t}^{ul} + p_{i,t}^{ev} \quad \forall i, t, \quad (10)$$

$$p_{i,t}^{ug} \geq 0, \quad \forall i, t, \quad (11)$$

donde $\sum_{j \neq i}^n p_{j,t}^{bt}$ corresponde a la potencia enviada desde la CE al agente i .

Finalmente, estas ecuaciones se pueden expresar de forma matricial en un sistema discreto lineal e invariante en el tiempo, como:

$$x_{t+1} = A \cdot x_t + B \cdot u_t + D \cdot \omega_t, \quad (12)$$

$$\text{con: } x_t = \begin{bmatrix} \hat{p}_t^{\text{ug}} \\ \hat{e}_t^{\text{ev}} \\ \hat{e}_t^{\text{b}} \end{bmatrix}, \quad u_t = \begin{bmatrix} \hat{p}_t^{\text{bc}} \\ \hat{p}_t^{\text{bd}} \\ \hat{p}_t^{\text{bt}} \\ \hat{p}_t^{\text{ugb}} \\ \hat{p}_t^{\text{ev}} \end{bmatrix}, \quad \omega_t = \begin{bmatrix} \hat{\omega}_t \\ \hat{p}_t^{\text{ul}} \end{bmatrix},$$

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

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

donde x , u y ω denotan los estados, entradas y perturbaciones del sistema, respectivamente; el carácter $\hat{\cdot}$ agrega un estado, entrada o perturbación para todos los agentes; y $\Pi \in \mathbb{R}^{n \times n(n-1)}$ es una matriz de ceros excepto por $(n-1)$ elementos en cada fila.

Para simplificar la formulación, se definen poliedros cerrados \mathcal{X} a partir de las restricciones de estado (2), (7), (11); y \mathcal{U} a partir de las restricciones de entrada (3)-(5), (8) y (9). Las restricciones se pueden escribir de la siguiente manera:

$$x_{t+1} \in \mathcal{X}, \quad (13a)$$

$$u_t \in \mathcal{U}. \quad (13b)$$

La función de coste Φ que se minimiza tiene como objetivo encontrar un equilibrio entre la reducción del coste económico derivado de la compra de p^{ug} , el esfuerzo de control y el seguimiento de referencia de e^{b} , de la siguiente manera:

$$\begin{aligned} \Phi = & \sum_{t=1}^{N_h} (c_t \hat{p}_t^{\text{ug}} + \delta^{\text{b}} (e_t^{\text{b}}|_u - \hat{e}_t^{\text{b}}) + \delta^{\text{ev}} (e_t^{\text{ev}}|_u - \hat{e}_t^{\text{ev}})) \\ & + c_{N_h+1} \hat{p}_{N_h+1}^{\text{ug}} + \delta^{\text{b}} (e_{N_h+1}^{\text{b}}|_u - \hat{e}_{N_h+1}^{\text{b}}) \\ & + \delta^{\text{ev}} (e_{N_h+1}^{\text{ev}}|_u - \hat{e}_{N_h+1}^{\text{ev}}) + \sum_{t=1}^{N_h} u_t^T R u_t, \end{aligned} \quad (14)$$

donde R es una matriz de dimensiones adecuadas que penaliza p^{bc} , p^{bd} y p^{bt} . Del mismo modo, incentiva p^{ugb} con peso $-\gamma c_t$, donde $\gamma < 1$. Es importante destacar que, dado que $\gamma < 1$, los prosumidores siempre intentarán mitigar el déficit de energía de un vecino antes de vender energía a la UG a través de p^{ugb} con un descuento del $100(1-\gamma)$ %.

3. Formulación del MPC Estocástico

En el CC-MPC, las restricciones estocásticas se pueden convertir en determinísticas al asumir un riesgo de violación (δ_x), y la función objetivo nominal se reemplaza por su valor esperado ($\mathbb{E}[\Phi]$).

3.1. Formulación del MPC estándar

La estrategia de un MPC consiste en resolver un problema de optimización en cada instante de tiempo, t , para calcular un conjunto de variables de control a lo largo del horizonte N_h . Solo se aplica la primera componente, u_t , en el tiempo actual, mientras que el resto de elementos se descartan. El problema de optimización se formula como

$$\arg, \min_{u\{t:N_h-1\}} \Phi, \quad (15)$$

sueto a (12)-(13), y se repite en el siguiente paso de tiempo $t+1$.

3.2. Formulación del CC-MPC

Las incertidumbres en la radiación solar y la demanda de energía impactan en la carga de las baterías (e^{b}, t en la Ecuación (1)). $p_{i,t}^{\text{ul}}$ influye indirectamente en $e_{i,t}^{\text{b}}$ al despejar $p_{i,t}^{\text{bc}}$ en la Ecuación (10) e introducirla en (1). Por lo tanto, la Ecuación (2) se convierte en una restricción de probabilidad, estableciendo un nivel de cumplimiento $1 - \delta_x$.

$$\mathbb{P} [e_{i,t}^{\text{b}}|_t \leq e_{i,t}^{\text{b}} \leq e_{i,t}^{\text{b}}|_u] \geq 1 - \delta_x. \quad (16)$$

Aquí, $\mathbb{P}[\cdot]$ es el operador de probabilidad. Las expresiones estocásticas $\eta^{\text{pv}} a_i \varpi_t \Delta t$ y $p_{i,t}^{\text{ul}} \Delta t$ se modelan como distribuciones de probabilidad conocidas. El equivalente determinístico de las restricciones estocásticas se formulan como

$$e_{i,t}^{\text{b}} \geq e_{i,t}^{\text{b}}|_t + \phi_i^{-1} (1 - \delta_x), \quad (17)$$

$$e_{i,t}^{\text{b}} \leq e_{i,t}^{\text{b}}|_u - \phi_i^{-1} (1 - \delta_x), \quad (18)$$

donde ϕ es la función de distribución acumulativa (cdf) que representa la variable aleatoria de cada agente en el horizonte de predicción. La variable estocástica se ha modelado utilizando distribuciones normales con media μ y desviación estándar σ , es decir, $\phi_i = \mathcal{N}(\mu_i, \sigma_i^2)$. Con esto, el problema de optimización que debe resolver el controlador CC-MPC se expresa de la siguiente manera:

$$\arg, \min_{u\{t:t+N_h-1\}} \mathbb{E}[\Phi], \quad (19)$$

sueto a (7), (11), (12), (13b), (17) y (18).

4. CC-MPC Distribuido

Para resolver el CC-MPC de manera distribuida, se utiliza el algoritmo de MPC basado en cooperación factible (FC-MPC) propuesto por Venkat et al. (2005). La idea principal de este enfoque es establecer una función de coste para cada agente $i \in \mathcal{A}$ que mida el desempeño del sistema en su conjunto, como una combinación convexa de las funciones de coste locales Φ_i :

$$\Phi = \sum_{i=1}^n \alpha_i \Phi_i, \quad (20)$$

donde $\alpha_i > 0$ y $\sum_{i=1}^n \alpha_i = 1$. El algoritmo FC-MPC garantiza la factibilidad global del sistema en iteraciones intermedias, lo que significa que incluso si el tiempo de cómputo excede el tiempo requerido para la convergencia, la secuencia de control calculada en la última iteración sigue siendo factible para todo el sistema. La formulación del DMPC se calcula para cada agente $i \in \mathcal{A}$ durante un número de iteraciones p :

$$U_i^* \in \arg(\text{FC-MPC})_i, \quad (21)$$

donde $\text{FC-MPC}_i \triangleq \min_{u_i} \frac{1}{N} \Phi_i$, sueto a

$$x_i(t+1) = A \cdot x_i(t) + B \cdot u_i(t) + D \cdot w(t), \forall t \in \{1, \dots, N_h\} \quad (22)$$

y (13), $\forall t \in \{1, \dots, N_h+1\}$.

La secuencia de control óptima para cada agente i se almacena en U_i^* , y las variables de estado y entradas se denotan

como x_i y u_i . El modelo optimiza solo las variables correspondientes a cada agente, mientras que el resto se mantiene como valores constantes de la iteración anterior.

Los pasos para resolver el algoritmo FC-MPC se muestran en el Algoritmo 1, donde el superíndice p se refiere a la p -ésima iteración. El objetivo es lograr que cada agente calcule un par de secuencias de control y estado $(x_i^p; U_i^p)$ que difieran en menos de un error admisible μ de aquellas calculadas en la iteración anterior. El error entre dos iteraciones consecutivas del agente i se define como ϑ_i^p . Cada agente resuelve (21) considerando la información proporcionada por sus vecinos durante la iteración anterior y obtiene U_i^* . Luego, $x_i^{p,*}$ se obtiene al reemplazar $U_i^{p,*}$ y $U_{j \neq i}^{p,*}$ en (22). Finalmente, $(x_i^p; U_i^p)$ se determina como una combinación lineal de $(x_i^{p-1}, x_i^{p,*}; U_i^{p-1}, U_i^{p,*})$, y se calcula ϑ_i^p . Si $\forall \vartheta_i^p \leq \varkappa$, se alcanza la condición de terminación.

Algorithm 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**

$U_i^{p,*} \in \arg(\text{FC-MPC}_i, \text{Ec. (21)})$

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. (22)

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

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

end for

$p \leftarrow p + 1$

end while

5. Implementación de Blockchain

Una de las principales preocupaciones discutidas en este trabajo es abordar un problema de optimización distribuida sin depender de un coordinador centralizado que tenga un control completo sobre el algoritmo. Un contrato inteligente implementado en Blockchain puede reemplazar a un coordinador centralizado en un problema de optimización distribuida. Ethereum (Buterin et al., 2013), una Blockchain pública y sin permisos, permite la creación de contratos inteligentes Turing completos a través de Solidity¹, que es un lenguaje de programación orientado a objetos de alto nivel diseñado para apuntar a la Máquina Virtual Ethereum². El contrato inteligente funciona como reemplazo del coordinador, realizando el intercambio de información entre agentes, el almacenamiento de datos y el flujo de control del algoritmo distribuido. Cabe destacar que un contrato inteligente es inmutable una vez que se despliega en la plataforma Blockchain. Esto significa que no se pueden realizar cambios en el código o estado del contrato, lo que facilita la auditoría del proceso. A continuación, se describen las herramientas

de software utilizadas para implementar en una plataforma Blockchain. Se utiliza la red de prueba Rinkeby de Ethereum³ para el desarrollo y las pruebas. Se desarrolla una interfaz gráfica de usuario utilizando React⁴ y web3.js, que permite a los agentes interactuar con el contrato inteligente. Web3.js⁵ es un conjunto de bibliotecas que permite a los usuarios conectarse a un nodo Ethereum, y se utiliza Infura⁶, que proporciona el nodo Ethereum. Metamask se utiliza como billetera Ethereum. En la Figura 1 se muestra un diagrama simplificado de la interconexión entre estas herramientas. El Algoritmo 2 incorpora un contrato inteligente en el problema de optimización distribuida. Las principales diferencias con el Algoritmo 1 son que los agentes deben cargar el estado actual y una secuencia de control inicial factible en el contrato inteligente antes de la primera iteración, y durante las iteraciones, los agentes deben interactuar con el contrato inteligente para cargar u_i^p y obtener $u_j^{p,*}$, $\forall j \in \mathcal{A} - i$. El contrato inteligente también evalúa la condición de terminación.




Figura 1: Diagrama simplificado de la interconexión entre las herramientas utilizadas en la implementación de Blockchain.

6. Resultados y discusión

En esta sección se estudia una comunidad energética compuesta por 15 agentes, incluyendo 7 prosumidores y 8 consumidores. Los prosumidores tienen baterías, paneles solares y VEs, mientras que los consumidores solo pueden comprar energía de la UG o a través de intercambios. El coste de compra de energía de la red se basa en los precios del Mercado Eléctrico Ibérico, y el precio de venta de energía de vuelta a la red es el 50% del precio de compra. Las simulaciones cubren un día completo, comenzando a la medianoche en septiembre, con un horizonte de predicción de 24 horas.

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-García 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. Por otro lado, para cada subconjunto, definiendo como $\phi_{i,t,m}^{p,ul} = \mathcal{N}(\mu_i^{\Omega_{m,t}}, \sigma_i^{\Omega_{m,t}})$, $\forall t \in \{1, \dots, 24\}$.

¹<https://docs.soliditylang.org/en/develop/index.html>

²<https://ethereum.org/en/developers/docs/evm/>

³<https://ethereum.org/en/developers/docs/networks/>

⁴<https://es.reactjs.org/>

⁵<https://web3js.readthedocs.io/en/v1.3.4/>

⁶<https://docs.infura.io/infura/>

Los mismos procedimientos se repiten para la radiación solar, donde los datos se obtienen del Sistema de Información Geográfica Fotovoltaica PVGIS⁷, lo que lleva a $\phi_{i,t,m}^{\sigma} = \mathcal{N}(\mu_i^{\Omega_{m,t}}, \sigma_i^{\Omega_{m,t}}) \forall t \in 1, \dots, 24$. Los prosumidores están equipados con una sola batería con una capacidad de energía que varía entre 3.3 y 3.9 kWh, y eficiencias de carga, descarga e intercambio del 94.5 %, 94.5 % y 93 %, respectivamente. Los límites inferior y superior para el nivel de energía de la batería se establecen como $e_i^b|_l=28\%$ y $e_i^b|_u=87\%$ de la capacidad máxima de energía. Para los vehículos eléctricos, la carga diaria de energía está entre 7.25 y 8.35 kWh, con un tiempo de carga de 24 horas. El horario de disponibilidad del vehículo eléctrico se genera de forma aleatoria y el límite superior de potencia para la carga del mismo se establece en 2.5 kW. La eficiencia de carga del vehículo eléctrico es de 0.95.

Se llevaron a cabo simulaciones en tres escenarios de prueba para comparar las estrategias de control propuestas. El primer escenario fue un enfoque aislado donde no se permitieron intercambios de energía entre los agentes. El segundo escenario fue el enfoque de CC-DMPC (CC-MPC Distribuido), donde se habilitaron los intercambios de energía y se estableció un riesgo de violación de restricciones del 5 %. El tercer escenario fue el DMPC estándar, que no consideró la naturaleza estocástica de las perturbaciones. Los resultados de las simulaciones para cada escenario se muestran en las Figuras 2, 3 y 4, respectivamente.

Los resultados se presentan en la Tabla 1, donde se definen tanto los índices económicos como de rendimiento como sigue: C_1 : coste económico de compra de energía a la red eléctrica, C_2 : ganancia por venta de energía a la UG, C_3 : diferencia entre C_1 y C_2 , E_1 : energía intercambiada entre los agentes, E_2 : energía vendida de vuelta a la red eléctrica, E_3 : energía comprada a la red eléctrica, E_4 : energía comprada a la red eléctrica pública por los consumidores, y E_5 : energía comprada a la red eléctrica por los prosumidores.

Tabla 1: Resultados de las simulaciones

Indexes	Tests		
	Aislado CC-MPC	Distribuido CC-DMPC	Estándar DMPC
C_1 [€]	38.59	28.86	27.09
C_2 [€]	11.68	5.25	4.57
C_3 [€]	26.90	23.61	22.52
E_1 [kWh]	0	37.49	40.66
E_2 [kWh]	56.40	24.47	21.15
E_3 [kWh]	113.13	83.80	79.35
E_4 [kWh]	59.37	30.04	27.71
E_5 [kWh]	53.76	53.76	51.64

Teniendo en cuenta los índices económicos y de rendimiento mostrados en la Tabla 1, el valor más alto de C_1 se encuentra en la prueba de CC-MPC aislado, ya que no se permiten intercambios de energía y los prosumidores no pueden ayudar a los consumidores a reducir su consumo p^{ug} .

Los resultados indican que CC-DMPC y DMPC estándar dependen menos de la red eléctrica en comparación con CC-MPC aislado, lo que resulta en una reducción de C_1 . El CC-MPC aislado muestra valores más altos para C_2 y E_2 debido al exceso de generación de energía solar. El DMPC estándar tiene el valor más bajo para C_3 , mientras que CC-DMPC y DMPC estándar reducen la brecha entre $e_i^b|_u$ y $e_i^b|_l$, lo que implica un menor uso de la batería en términos de intercambio de energía, como se refleja en E_1 . Además, mediante E_4 y E_5 , se observa que la demanda de energía de los consumidores es ligeramente mayor que la de los prosumidores en el caso del CC-MPC aislado, pero esta diferencia disminuye considerablemente cuando se permiten los intercambios de energía. Por último, se destaca que E_5 se mantiene constante tanto en las pruebas de CC-MPC aislado como en CC-DMPC debido al exceso de energía generada por la generación solar, lo que permite a los prosumidores obtener un mayor beneficio global en términos de consumo de energía sin incurrir en ninguna pérdida de rendimiento.

Algorithm 2 Algoritmo FC-MPC basado en Blockchain.

Dados $c_i \geq 0, p^{\max} > 0, \varkappa > 0, p \leftarrow 1, \forall \theta_i^1 \gg 1, \phi_i, i \in \mathcal{A}$
while $\theta_i^p > \varkappa$ 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 $p_{ij,t}^b|_u = 0$.
 • 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
 • Ensamble global de las matrices $U^{1,*}$ 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. (22)
 $(x_i^p, u_i^p) = \frac{1}{N}(x_i^{p,*}, u_i^{p,*}) + (1 - \frac{1}{N})(x_i^{p-1}, u_i^{p-1})$
 $\theta_i^p = \|(x_i^p, u_i^p) - (x_i^{p-1}, u_i^{p-1})\|$
 • 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

⁷https://joint-research-centre.ec.europa.eu/pvgis-photovoltaic-geographical-information-system_en




Figura 2: Resultados aplicando CC-MPC aislado.




Figura 3: Resultados aplicando CC-DMPC.




Figura 4: Results aplicando DMPC estándar.

7. Conclusiones y trabajos futuros

Este estudio ha presentado la gestión de energía en una comunidad energética afectada por la incertidumbre tanto en la radiación solar como en la demanda de energía. La naturaleza estocástica de las perturbaciones se ha abordado mediante el uso de un controlador CC-MPC en cada agente del sistema. Además, el esquema DMPC se basa en un contrato inteligente desplegado en Rinkeby y sirve como coordinador global del algoritmo distribuido sin depender de una autoridad central. Los

resultados muestran que los algoritmos CC-MPC y Blockchain, trabajando conjuntamente, son adecuados para llevar a cabo un proceso de negociación entre agentes para satisfacer la demanda de energía a pesar de las incertidumbres. El trabajo futuro se centrará en nuevas formulaciones de comunidades energéticas y esquemas seguros de DMPC para mejorar los resultados obtenidos.

Agradecimientos

Este proyecto ha recibido financiación del proyecto PID2019-104149RB-I00 financiado por MCIN/AEI/10.13039/501100011033.

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., 2013. Model predictive control. Springer science & business media.

Garcia-Torres, F., Zafra-Cabeza, A., Silva, C., Grieu, S., Darure, T., Estanqueiro, A., 2021. Model predictive control for microgrid functionalities: Review and future challenges. *Energies* 14 (5), 1296.

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 dmpe. *Control Engineering Practice* 114, 104879.

Mengelkamp, E., Gärtner, J., Rock, K., Kessler, S., Orsini, L., Weinhardt, C., 2018. Designing microgrid energy markets: A case study: The brooklyn microgrid. *Applied Energy* 210, 870–880.

Mínchala-Avila, L. I., Garza-Castañón, L. E., Vargas-Martínez, A., Zhang, Y., 2015. A review of optimal control techniques applied to the energy management and control of microgrids. *Procedia Computer Science* 52, 780–787.

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.

Nakamoto, S., 2008. Bitcoin: A peer-to-peer electronic cash system. *Decentralized Business Review*, 21260.

Nofer, M., Gomber, P., Hinz, O., Schiereck, D., 2017. Blockchain. *Business & Information Systems Engineering* 59 (3), 183–187.

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., 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.

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.

Yaga, D., Mell, P., Roby, N., Scarfone, K., 2019. Blockchain technology overview. *arXiv preprint arXiv:1906.11078*.

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 Applications and Methods* 41 (1), 94–106.