

Jornadas de Automática

Planificación energética estocástica de microrredes con MPC mediante análisis probabilístico multiescenario: Gestión de incertidumbre

Girona-García, V.^{a,*}, González-Reina, A.E.^b, Sánchez-Sánchez-de-Puerta, A.^a, Vázquez, F.^a, Jiménez-Hornero, J.E.^a, García-Torres, F.^a

^a Departamento de Ingeniería Eléctrica y Automática, Universidad de Córdoba, Córdoba, España.

^b Escuela Politécnica Superior del Ejército, Ministerio de Defensa de España, Madrid, España.

To cite this article: Girona-García, V., González-Reina, A.E., Sánchez-Sánchez-de-Puerta, A., Vázquez, F., Jiménez-Hornero, J.E., García-Torres, F. 2026. Stochastic Energy Planning of Microgrids with MPC via Multi-Scenario Probabilistic Analysis with: Uncertainty Management. Jornadas de Automática, 47. <https://doi.org/10.17979/ja-cea.2026.47.13635>

Resumen

En este trabajo se presenta y valida un procedimiento para gestionar la incertidumbre inherente a la generación de energía renovable en microrredes equipadas con sistemas de almacenamiento de energía. El método propuesto integra un esquema de Control Predictivo Basado en Modelo Estocástico Multiescenario (MS-SMPC) con restricciones probabilísticas. Esta metodología mejora la planificación de las microrredes bajo incertidumbre e incrementa la flexibilidad. El problema de optimización se formula y resuelve como un conjunto de subproblemas de Programación Cuadrática Mixta Entera (MIQP), considerando que se ha de mantener el mismo intercambio energético con la red en todos los escenarios considerados. Debemos destacar que no sólo se consideran criterios económicos, sino también de mejora en la operatividad del sistema. Los resultados muestran que el procedimiento fortalece significativamente la fiabilidad y flexibilidad de la microrred bajo incertidumbre.

Palabras clave: Control predictivo, Sistemas complejos, Sistemas de energía, Redes inteligentes, Operación y control óptimos de sistemas eléctricos de potencia.

Stochastic Energy Planning of Microgrids with MPC via Multi-Scenario Probabilistic Analysis with: Uncertainty Management

Abstract

This work presents and validates a procedure for managing the uncertainty inherent in renewable energy generation within microgrids equipped with energy storage systems. The proposed method integrates a Multi-Scenario Stochastic Model Predictive Control (MS-SMPC) scheme with probabilistic constraints. This methodology enhances microgrid planning under uncertainty and increases operational flexibility. The optimization problem is formulated and solved as a set of Mixed-Integer Quadratic Programming (MIQP) subproblems, ensuring that a consistent energy exchange with the main grid is maintained across all considered scenarios. Notably, the approach addresses not only economic criteria but also improvements in system operability. The results show that this procedure enhances the reliability and flexibility of the microgrid under uncertain conditions.

Keywords: Predictive control, Complex systems, Energy systems, Smart grids, Optimal operation and control of power systems

1. Introducción

Los mercados eléctricos requieren la conciliación entre oferta y demanda, imponiendo un comportamiento determinista, sujeto a penalización, de los diferentes

participantes involucrados. Entre estos se encuentran las microrredes, que son sistemas eléctricos locales constituidos, fundamentalmente, por cargas y fuentes de generación. En el caso de que estas últimas sean de origen renovable, presentan importantes limitaciones de fiabilidad y gestionabilidad, al ser dependientes de la meteorología. Sin embargo, gracias a los

avances en electrónica de potencia, control automático y, especialmente, a la integración de sistemas de almacenamiento de energía (ESS), se ha mejorado notablemente su rendimiento, al aportar mayor flexibilidad y capacidad de gestión de la incertidumbre. Además de las baterías, los sistemas de almacenamiento basados en hidrógeno se están incorporando en soluciones híbridas, aumentando la capacidad energética y la densidad de potencia. Al tratarse de sistemas multivariables, la optimización de la operación de microrredes que integran todos estos elementos es compleja, especialmente al considerar múltiples restricciones junto con los aspectos mencionados [1]-[3].

1.1 Revisión bibliográfica

La gestión de la incertidumbre en microrredes eléctricas es un área de creciente interés, donde diversos trabajos analizan técnicas de optimización que incluyen revisiones de métodos de gestión óptima [3] así como evaluaciones económicas de la distribución de ingresos [4]. Asimismo, se han propuesto enfoques basados en programación robusta, análisis de sensibilidad multivariable y optimización *chance constraint* para evaluar el impacto de la incertidumbre de las energías renovables en la operación de microrredes [5]–[7].

Desde el punto de vista de la planificación, en [8] el problema se divide en inversiones y operación mediante descomposición de Benders, mientras que el trabajo presentado en [9] propone un modelo de planificación para microrredes híbridas AC/DC en modo isla considerando incertidumbres de carga y generación. Para gestionar múltiples incertidumbres operativas, en [10] se plantea un modelo de optimización robusta mixta de dos etapas y tres niveles. La gestión de la estocasticidad en microrredes se analiza en [11]–[13], incluyendo enfoques multiobjetivo para la operación en isla, el estudio de la incertidumbre en la demanda aplicada al compromiso de unidades y métodos de optimización *chance constraint* que consideran la variabilidad de la generación renovable y las cargas.

Otra alternativa, dado su potencial de aplicación en este campo, es el Control Predictivo basado en Modelo (MPC), cuya capacidad para resolver problemas complejos se demuestra en diversos trabajos, donde su formulación como Control Predictivo Estocástico (SMPC) permite una gestión eficiente de la incertidumbre en microrredes [14]–[17]. Estos enfoques incluyen estrategias de programación estocástica en dos etapas, sistemas de control jerárquicos y esquemas cooperativos en escenarios de multimicrorredes. Finalmente, en [18] se propone un procedimiento basado en MS-MPC (Multi-Scenario MPC) para optimizar la operación de una microrred con baterías, incorporando la demanda, la generación solar y los procesos de carga y descarga de vehículos eléctricos.

1.2 Contribuciones principales

Aunque las técnicas SMPC han mostrado buenos resultados en la optimización de microrredes bajo incertidumbre, sigue siendo un reto obtener un intercambio energético determinista y factible con la red principal a partir de previsiones probabilísticas. Este trabajo propone una metodología que aborda la incertidumbre asociada a la

generación renovable, superando las limitaciones de los enfoques deterministas y generando un perfil de intercambio energético común y realizable para todos los escenarios considerados. El algoritmo propuesto minimiza la esperanza matemática de las funciones de coste y evita pérdidas económicas y penalizaciones por desviaciones en tiempo real. Esta metodología amplía el enfoque desarrollado en [19] a un número arbitrario de escenarios probabilísticos, trabajando sobre una microrred tipo como la mostrada en la Fig. 1, que incluye generación fotovoltaica y eólica, cargas internas y sistemas de almacenamiento basados en baterías e hidrógeno, coordinados mediante un Sistema de Gestión Energética (EMS) basado en MS-SMPC




Figura 1: Microrred bajo estudio

2. Diseño de un controlador MS-MPC para planificar de generación energía en microrredes considerando incertidumbre.

El diseño del EMS propuesto considera los aspectos que se describen a continuación:

- 1 *Coste operativo de los componentes de la microrred.*
- 2 *Integración probabilística de la incertidumbre en la predicción energética.*
- 3 *Intercambio de energía determinista con la red.*

La estructura del EMS propuesto se muestra en la Fig. 2.




Figura 2: Diagrama de bloques del EMS

La descripción de los bloques de la figura se realiza en las secciones siguientes.

2.1. Enfoques estocásticos de MPC basados en escenarios probabilísticos con restricciones deterministas.

La aplicación de técnicas SMPC al problema de gestión óptima de microrredes [14]–[21] con intercambio determinista con la red principal se puede resolver usando el marco MLD (Mixed Logic Dynamic) [19], que puede formularse genéricamente como el problema de minimizar una función de coste (1), cuyo valor depende de una serie de variables

continuas $\mathbf{u} \in \mathbb{R}^{N_u}$, de variables lógicas $\delta \in \mathbb{N}^{N_\delta}$ y de un conjunto de perturbaciones $\mathbf{d} \in \mathbb{R}^{N_d}$, sujetas a un conjunto de restricciones indicadas en (2)-(4). La función objetivo que tratamos de optimizar se estructura para integrar los costes asociados a la gestión de energía de una microrred que dispone de capacidad de almacenamiento híbrido como se observa en la fig.1

$$\min_{\mathbf{u}, \delta} J(\mathbf{u}(t), \delta(t), \mathbf{d}(t), \mathbf{x}(t), \mathbf{z}(t)) \quad (1)$$

$$\mathbf{x}(t+1) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}_u\mathbf{u}(t) + \mathbf{B}_\delta\delta(t) + \mathbf{B}_z\mathbf{z} + \mathbf{B}_d\mathbf{d}(t) \quad (2)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}_u\mathbf{u}(t) + \mathbf{D}_\delta\delta(t) + \mathbf{D}_z\mathbf{z}(t) + \mathbf{D}_d\mathbf{d}(t) \quad (3)$$

$$\mathbf{E}_\delta\delta(t) + \mathbf{E}_z\mathbf{z}(t) \leq \mathbf{F}\mathbf{x}(t) + \mathbf{E}_u\mathbf{u}(t) + \mathbf{E}_d\mathbf{d}(t) \quad (4)$$

Las restricciones (2)-(4) son las ecuaciones de estado del modelo de la planta necesarias para implementar el controlador MPC, siendo $\mathbf{x} \in \mathbb{R}^{N_x}$ las variables de estado, $\mathbf{y} \in \mathbb{R}^{N_y}$ las salidas y $\mathbf{z} \in \mathbb{R}^{N_z}$ las variables definidas como productos mixtos de variables lógicas y continuas [19]. Las matrices A, B, C, D E y F expresan las relaciones entre las variables que componen el modelo de la planta.

Las formulaciones deterministas de controladores basados en MPC asumen un valor fijo para las perturbaciones; sin embargo, para integrar la incertidumbre, en este trabajo se adopta y desarrolla una formulación estocástica del controlador MPC, analizando posibles escenarios que se darán con cierta probabilidad conocida. Cada uno de estos problemas de optimización se resuelve de forma independiente, y posteriormente se integran para lograr una solución que abarca todo el espectro de incertidumbre imponiendo que el intercambio de potencia con la red principal (P_{grid}) debe ser el mismo en todos los escenarios [s] contemplados. Para ello, se busca minimizar la esperanza matemática de las funciones de coste para cada escenario (5).

$$\min \Psi = \mathbb{E}(J(\mathbf{u}^{[s]}, \delta^{[s]}, \mathbf{d}^{[s]})) \quad (5)$$

Las variables aleatorias $\mathbf{d}^{[s]}$ se describen mediante una distribución probabilística $\mathbb{P}(\mathbf{d}^{[s]})$ y la función de coste (5) puede reescribirse de forma determinista usando una formulación multiescenario (6), siendo N_s el número de escenarios. Cada escenario se define por $\mathbf{d}^{[s]}$ y su probabilidad $\mathbb{P}(\mathbf{d}^{[s]})$. Todas las variables de la planta dependerán del escenario considerado, por lo que las restricciones (2)-(4) también deben expresarse en función del escenario, como se indica en las ecuaciones (7)-(9).

$$\min \Psi = \frac{1}{N_s} \sum_{s=1}^{N_s} (J(\mathbf{u}^{[s]}(t), \delta^{[s]}(t), \mathbf{d}^{[s]}(t)) \mathbb{P}(\mathbf{d}^{[s]}(t))) \quad (6)$$

$$\mathbf{x}^{[s]}(t+1) = \mathbf{A}\mathbf{x}^{[s]}(t) + \mathbf{B}_u\mathbf{u}^{[s]}(t) + \mathbf{B}_\delta\delta^{[s]}(t) + \mathbf{B}_z\mathbf{z}^{[s]}(t) + \mathbf{B}_d\mathbf{d}^{[s]}(t) \quad (7)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}^{[s]}(t) + \mathbf{D}_u\mathbf{u}^{[s]}(t) + \mathbf{D}_\delta\delta^{[s]}(t) + \mathbf{D}_z\mathbf{z}^{[s]}(t) + \mathbf{D}_d\mathbf{d}^{[s]}(t) \quad (8)$$

$$\mathbf{E}_\delta\delta^{[s]}(t) + \mathbf{E}_z\mathbf{z}^{[s]}(t) \leq \mathbf{F}\mathbf{x}^{[s]}(t) + \mathbf{E}_u\mathbf{u}^{[s]}(t) + \mathbf{E}_d\mathbf{d}^{[s]}(t) \quad (9)$$

2.2. Módulo de predicción

El algoritmo de predicción se basa en la metodología desarrollada en [1], integrando en su primera parte las perturbaciones $\mathbf{d}$, consideradas para cada escenario como

$\mathbf{d}^{[s]}(t) = [P_{un}^{[s]}(t)]$, siendo $P_{un}^{[s]}(t)$ la potencia de incertidumbre que afecta a la precisión de las predicciones. $P_{rem}^{[s]}(t)$ es la potencia restante en la microrred (diferencia entre potencia generada y consumida), $P_{pv}^{[s]}(t)$ la generación fotovoltaica, $P_{wt}^{[s]}(t)$ la generación eólica y $P_{load}^{[s]}(t)$ la carga, quedando el balance energético según (10):

$$[P_{pv}^{[s]}(t) + P_{wt}^{[s]}(t) - P_{load}^{[s]}(t) + P_{un}^{[s]}(t)] = [P_{rem}^{[s]}(t)] \quad (10)$$

Se consideran dos escenarios, pesimista [-] y optimista [+], ambos con el mismo error $P_{un}^{[s]}$ en la predicción, pero con distinto signo, obteniendo perfiles $P_{rem}^{[+,-]}(t)$ según la Fig. 3.




Figura 3: Predicción de generación con dos escenarios

La segunda parte del módulo de predicción dispone de una estimación de los precios de compra/venta de la energía en el mercado eléctrico para el día bajo análisis, de cara a la optimización de la gestión de compra/venta con la red.

2.3. Modelo de la planta

El vector de variables de entrada continuas $\mathbf{u}^{[s]}$ (11) comprende $P_{ch}^{[s]}$, $P_{dis}^{[s]}$, $P_{elz}^{[s]}$ y $P_{fc}^{[s]}$, que son las potencias de consigna proporcionadas por el controlador de microrred a los controladores de bajo nivel para los procesos de carga o descarga de las baterías, el electrolizador y la pila de combustible, respectivamente. $P_{pur}^{[s]}$ y $P_{sale}^{[s]}$ representan la potencia de compra y venta con la red, respectivamente.

$$\mathbf{u}^{[s]} = [P_{dis}^{[s]}, P_{ch}^{[s]}, P_{elz}^{[s]}, P_{fc}^{[s]}, P_{pur}^{[s]}, P_{sale}^{[s]}]^T \quad (11)$$

Las variables lógicas $\delta^{[s]}$ se definen en (12)

$$\delta^{[s]} = [\delta_{elz}^{[s]}, \delta_{fc}^{[s]}, \sigma_{elz}^{[s]}, \sigma_{fc}^{[s]}, \chi_{elz}^{[s]}, \chi_{fc}^{[s]}]^T \quad (12)$$

Donde los estados de encendido/apagado del electrolizador y de la pila de combustible están representadas por $\delta_{elz}^{[s]}$ y $\delta_{fc}^{[s]}$, respectivamente, mientras que $\sigma_{elz}^{[s]}$ y $\sigma_{fc}^{[s]}$ están vinculados a los procesos de arranque de esos equipos, y $\chi_{elz}^{[s]}$ y $\chi_{fc}^{[s]}$ se introducen para modelar el estado de degradación por fluctuaciones de potencia en procesos de arranque y transitorios.

Las variables producto mixto se definen según (13).

$$\mathbf{z}^{[s]} = [\mathbf{z}_{elz}^{[s]}, \mathbf{z}_{fc}^{[s]}, \mathbf{v}_{elz}^{[s]}, \mathbf{v}_{fc}^{[s]}]^T \quad (13)$$

$z_{elz}^{[s]}$ and $z_{fc}^{[s]}$ son el producto mixto de las variables de control continuas y lógicas del electrolizador y la pila de combustible, respectivamente. $\vartheta_{elz}^{[s]}$ y $\vartheta_{fc}^{[s]}$ son las variaciones de potencia del electrolizador y la pila de combustible cuando están activos, excepto en los intervalos de tiempo en que están encendidos o apagados. Por su parte, las variables de estado de la microrred están definidas por el nivel de batería $SOC^{[s]}$ y el almacenamiento de hidrógeno en el tanque $LOH^{[s]}$ (14).

$$x^{[s]} = [SOC^{[s]}, LOH^{[s]}]^T \quad (14)$$

La salida del modelo se corresponde con la potencia intercambiada con la red, $P_{grid}^{[s]}$ (15).

$$y^{[s]} = [P_{grid}^{[s]}]^T \quad (15)$$

La expresión (7) se puede particularizar usando (16) y (17), donde C_{bat} es la capacidad de la batería y los coeficientes, η_{ch} y η_{dis} representan las eficiencias en cuanto a los procesos de carga y descarga de las baterías. Finalmente, η_{fc} y η_{elz} son las eficiencias en los procesos de conversión realizados por el electrolizador y la pila de combustible, mientras que T_s es el periodo de muestreo.

$$SOC^{[s]}(t+1) = SOC^{[s]}(t) + T_s \left(\frac{P_{ch}^{[s]}(t) \cdot \eta_{ch}}{C_{bat}} - \frac{P_{dis}^{[s]}(t) / \eta_{dis}}{C_{bat}} \right) \quad (16)$$

$$LOH^{[s]}(t+1) = LOH^{[s]}(t) + T_s z_{elz}^{[s]}(t) \cdot \eta_{elz} - \frac{z_{fc}^{[s]}(t)}{\eta_{fc}} \quad (17)$$

La restricción (8) corresponde a la diferencia entre la potencia comprada y vendida con la red (18), obteniendo el balance energético para cada escenario indicado en (19).

$$P_{grid}^{[s]}(t) = P_{pur}^{[s]}(t) - P_{sale}^{[s]}(t) \quad (18)$$

$$P_{grid}^{[s]}(t) + P_{dis}^{[s]}(t) - P_{ch}^{[s]}(t) + z_{elz}^{[s]}(t) - z_{fc}^{[s]}(t) + P_{rem}^{[s]}(t) = 0 \quad (19)$$

Asimismo, la expresión (9) puede particularizarse transformando las relaciones lógicas entre las variables u , δ y z , siguiendo el procedimiento definido en [24].

2.4. Controlador MS-MPC

- *Análisis estadístico*

En este trabajo se abordan un mayor número de escenarios, tal y como se muestra en la Fig. 4.




Figura 4: Predicción de generación con varios escenarios

Cada escenario está sujeto a un nivel de incertidumbre determinado por un valor $P_{un}^{[s]}$. En la Fig. 5, para un escenario con $P_{un}^{[1]} = 1000 W$ y asumiendo una distribución normal, se representa la probabilidad del error de la predicción en torno a dicho valor $\mathbb{P}(1000 - \beta \leq P_{un}^{[1]} \leq 1000 + \beta)$, siendo β un valor de un rango determinado para obtener un valor de probabilidad de nuestra variable aleatoria dado que en funciones de densidades la probabilidad de un punto es cero.




Figura 5: Probabilidad en un escenario optimista

- *Controlador*

Se propone un método innovador para resolver el problema estocástico de múltiples escenarios, capaz de encontrar el intercambio energético óptimo de forma determinista entre la microrred y la red principal, descomponiendo el problema en dos pasos.

Paso 1: Incertidumbre fija

Dada la distribución probabilística para aproximar la incertidumbre de la generación renovable, se definen varios casos en función del error en la predicción energética $P_{un}^{[s]}$. Para facilitar el análisis, se considera que la incertidumbre no depende del tiempo y de que tiene asociada una distribución simétrica. Por lo tanto, cada caso tiene asociados dos escenarios que comparten valor absoluto de $P_{un}^{[s]}$ pero con distinto signo, $P_{un}^{[s,+]} = +P_{un}^{[s]}$ y $P_{un}^{[s,-]} = -P_{un}^{[s]}$. Los diferentes escenarios considerados se muestran en la Tabla 1.

Tabla 1. Casos analizados

Id Caso	Caso	Escenarios
$P_{un}^{[0]}$	$P_{un}^{[0]} = 0 W$	$P_{un}^{[0]}$
$P_{un}^{[1]}$	$P_{un}^{[1]} = 1000 W$	$P_{un}^{[1,+]}, P_{un}^{[1,-]}$
$P_{un}^{[2]}$	$P_{un}^{[2]} = 2000 W$	$P_{un}^{[2,+]}, P_{un}^{[2,-]}$
$P_{un}^{[3]}$	$P_{un}^{[3]} = 3000 W$	$P_{un}^{[3,+]}, P_{un}^{[3,-]}$
$P_{un}^{[4]}$	$P_{un}^{[4]} = 4000 W$	$P_{un}^{[4,+]}, P_{un}^{[4,-]}$
$P_{un}^{[5]}$	$P_{un}^{[4]} = 5000 W$	$P_{un}^{[5,+]}, P_{un}^{[5,-]}$

Este primer paso evalúa el mejor intercambio energético con la red principal para cada caso según [16]. El problema de optimización tiene como función de coste (20), sujeto a las restricciones (8)-(9) y (21), que garantiza un intercambio de energía determinista con la red en cada caso.

$$\begin{aligned}
J^{[s]} = & \sum_{s=+, -} \sum_{k=SH_0}^{k=SH} (-\Gamma_{sale}^{DM}(t_k) P_{sale}^{[s]}(t_k) + \Gamma_{pur}^{DM}(t_k) P_{pur}^{[s]}(t_k)) \\
& \text{Intercambio con la red coste/beneficio} \\
& + \frac{CC_{bat}}{2 \cdot Cycles_{bat}} \cdot \sum_{\alpha=ch, dis} (P_{bat, \alpha}^{[s]}(t_k)) \\
& \text{Coste ciclos batería ESS} \\
& + \sum_{\alpha=ch, dis} (Cost_{degr, \alpha} \cdot (P_{bat, \alpha}^{[s]}(t_k))^2) \\
& \text{Coste Degradación Batería ESS} \\
& + \sum_{\alpha=elz, fc} \left(\frac{CC_{\alpha}}{Hours_{\alpha}} + Cost_{o\&m, \alpha} \right) \delta_{\alpha}^{[s]}(t_k) \\
& \text{ESS de Hidrógeno coste horas de uso} \\
& + Cost_{startup, \alpha} \delta_{\alpha}^{[s]}(t_k) + Cost_{degr, \alpha} \cdot (\delta_{\alpha}^{[s]}(t_k))^2 \cdot T_s \\
& \text{Degradación ESS de Hidrógeno} \\
& + \omega_{SOC} \cdot (SOC^{[s]}(t_{SH}) - SOC^{ref})^2 \\
& \text{Incertidumbres futuras} \\
& + \omega_{LOH} \cdot (LOH^{[s]}(t_{SH}) - LOH^{ref})^2 \\
& \text{Incertidumbres futuras}
\end{aligned} \quad (20)$$

$$P_{grid}^{[s, +]}(t) = P_{grid}^{[s, -]}(t) = P_{grid}^{[s]}(t) \quad \forall s \quad (21)$$

Este método se aplica a un cierto número de casos, N_{prob} (pares de escenarios con el mismo P_{un} , pero signos diferentes). Para cada valor de P_{un} se obtiene un perfil de potencia de intercambio con la red $P_{grid}^{[s]}(t)$.

Paso 2: Evaluación de los escenarios en función del intercambio de energía con la red

Para ello se requiere modificar la función de coste introduciendo una restricción suave (22), donde w_{req} es un factor de ponderación, que permite evaluar el comportamiento de la microrred en función de los perfiles de intercambio con la red obtenidos en el Paso 1.

$$J^{[1] \rightarrow [2]} = J^{[1]} + w_{req} \left(P_{grid}^{[1]}(t) - P_{grid, Paso1}^{[2]}(t) \right)^2 \quad (22)$$

El procedimiento evalúa el primer término de (22), que considera el caso 1, intentando seguir el perfil obtenido para el caso 2 en el paso 1. En la Tabla 2 se resumen los resultados obtenidos en el Paso 2 para todos los casos considerados.

Tabla 2. Valores de la función de coste Paso 2

Función de coste	Intercambio de perfiles de potencia				
	[0]	[1]	[2]	...	[N]
Caso 0	$J^{[0] \rightarrow [0]}$	$J^{[0] \rightarrow [1]}$	$J^{[0] \rightarrow [2]}$	...	$J^{[0] \rightarrow [N]}$
Caso 1	$J^{[1] \rightarrow [0]}$	$J^{[1] \rightarrow [1]}$	$J^{[1] \rightarrow [2]}$	...	$J^{[1] \rightarrow [N]}$
Caso 2	$J^{[2] \rightarrow [0]}$	$J^{[2] \rightarrow [1]}$	$J^{[2] \rightarrow [2]}$	...	$J^{[2] \rightarrow [N]}$
...	...	...	...	...	...
Caso N	$J^{[N] \rightarrow [0]}$	$J^{[N] \rightarrow [1]}$	$J^{[N] \rightarrow [2]}$	...	$J^{[N] \rightarrow [N]}$

Las columnas son los perfiles de intercambio obtenidos en el Paso 1 y las filas son los casos bajo estudio. Se recomienda aplicar primero al caso más crítico, es decir, aquél con mayor valor de P_{un} (y menor probabilidad), para comprobar que la microrred dispone de flexibilidad suficiente para cumplir con el perfil del Paso 1. Si no cumple, se tomará el $P_{grid}^{[s]}(t)$ obtenido como el perfil de intercambio de energía más cercano al obtenido en el Paso 1 (llamándolo $P_{grid, Paso1}^{[2], factible}(t)$). En este caso, la expresión (22) quedaría como (23).

$$J^{[1] \rightarrow [2]} = J^{[1]} + w_{req} \left(P_{grid}^{[1]}(t) - P_{grid, Paso1}^{[2], factible}(t) \right)^2 \quad (23)$$

Una vez obtenidos los valores de la Tabla 2 y teniendo en cuenta (6), la esperanza de la función de coste para el caso [1] se calcula según (24).

$$\Psi^{[1]} = \frac{1}{2N_{prob}} \sum_{s=0}^{N_{prob}} J^{[s] \rightarrow [1]} \cdot Pr_s \quad (24)$$

Donde Pr_s es la probabilidad de cada caso, (Pr_0 corresponde a $P_{un} = 0$). De este modo, se obtiene la esperanza matemática para cada caso $\Psi = [\Psi^{[0]}, \Psi^{[1]}, \dots, \Psi^{[N_{prob]}]}$, siendo el óptimo aquél que tenga la mínima ($\Psi^{[s_{opt}]}$).

3. Resultados

Se presentan los resultados en simulación para una microrred cuyos datos figuran en la Tabla 3, usando MATLAB y la biblioteca Tomlab (CPLEX® como algoritmo de optimización). El tiempo de procesamiento de datos para completar el cálculo fue de 8347,8976 segundos y se llevó a cabo con un PC que disponía de Intel Core i7-9750H 2,6GHz y 16GB de Memoria RAM.

Tabla 3. Datos de la microrred considerada

Energía Renewable Fotovoltaica: 40 kW _p ; Eólica 15 kW
ESS Hidrogeno Electrolizador 10 kW; Tanque 56 Nm ³ ; Célula de combustible 10kW
$Cost_{degr, elz} = 0,0577 \frac{\text{€}}{\text{Wh}}$, Horas = 10000 h, $LOH_{max} = 35 \text{ Nm}^3$; $LOH_{min} = 5 \text{ Nm}^3$
$\zeta = 0,23 \frac{\text{Nm}^3}{\text{kWh}}$, $CC = 8,22 \text{ €/kW}$, $Cost_{O\&M, elz} = 0,002 \frac{\text{€}}{\text{h}}$, $Cost_{startup, elz} = 0,123 \text{ €}$
$Cost_{degr, fc} = 0,0018 \frac{\text{€}}{\text{Wh}}$, Horas = 10000 h.
$\zeta = 1,320 \frac{\text{kWh}}{\text{Nm}^3}$, $CC = 30 \text{ €/kW}$, $Cost_{O\&M, fc} = 0,001 \frac{\text{€}}{\text{h}}$, $Cost_{startup, fc} = 0,01 \text{ €}$, $\omega_{LOH} = 1$
ESS Baterías: 60 kW, 336 kWh
$\eta_{ch} = 0,90$, $\eta_{dis} = 0,95$, $CC = 125 \text{ €/kWh}$, Ciclos = 3000; $\omega_{SOC} = 10$, $Cost_{degr, dis} = 10^{-9} \text{ €/W}^2 \text{h}$, $Cost_{degr, ch} = 10^{-9} \text{ €/W}^2 \text{h}$, $SOC_{max} = 1$; $SOC_{min} = 0,25$

Para describir la incertidumbre en generación se empleó una distribución gaussiana, siendo los casos bajo análisis $P_{un} = 0 \text{ W}$, 1000 W, 2000 W, 3000 W, 4000 W y 5000 W (Fig. 8), resultando $N_{prob} = 6$.




Figura 8: Casos planteados

La probabilidad de cada caso (Fig. 9) se calcula según (25) (particularizado para el caso 1):

$$Pr_1 = \mathbb{P}(1000 - \beta \leq P_{un}^{[1]} \leq 1000 + \beta) + \mathbb{P}(-1000 - \beta \leq P_{un}^{[1]} \leq -1000 + \beta) \quad (25)$$

Tabla 5. Valores de esperanza matemática para cada perfil de intercambio paso 2

0→0	0.082	0→1	0,061	0→2	0,059	0→3	0,185	0→4	0,091	0→5	0,089
1→0	0.158	1→1	0,118	1→2	0,114	1→3	0,355	1→4	0,162	1→5	0,169
2→0	0.136	2→1	0,103	2→2	0,102	2→3	0,309	2→4	0,143	2→5	0,147
3→0	0.11	3→1	0,087	3→2	0,081	3→3	0,246	3→4	0,112	3→5	0,114
4→0	0.08	4→1	0,062	4→2	0,061	4→3	0,182	4→4	0,091	4→5	0,084
5→0	0.053	5→1	0,041	5→2	0,041	5→3	0,121	5→4	0,065	5→5	0,058
$\Psi \rightarrow [0]$	0.619	$\Psi \rightarrow [1]$	0,474	$\Psi \rightarrow [2]$	0,458	$\Psi \rightarrow [3]$	1,401	$\Psi \rightarrow [4]$	0,656	$\Psi \rightarrow [5]$	0,664




Figura 9: Probabilidad para el caso 1

El resto de los valores de Pr_s se obtienen de igual forma.

Tabla 4. Valor óptimo función de coste Paso 2

Caso	Intercambio de perfiles de potencia					
	[0]	[1]	[2]	[3]	[4]	[5]
$P_{un} = 0$	13.65	10.22	9.95	30.93	14.47	14.91
$P_{un} = 1000$	13.77	10.36	9.97	31.03	14.28	14.82
$P_{un} = 2000$	13.59	10.21	10.05	30.97	14.18	14.78
$P_{un} = 3000$	13.76	10.33	10.18	30.86	14.39	14.38
$P_{un} = 4000$	13.96	10.90	10.58	30.82	14.76	14.46
$P_{un} = 5000$	13.75	10.77	10.57	31.37	15.23	15.06

Con los datos de la Tabla 4 y la probabilidad de cada caso, en la Tabla 5 se muestra la esperanza matemática para cada uno de ellos. El valor más bajo de la esperanza Ψ se obtiene para $P_{un} = 2000 W$, de modo que $\Psi^{s_{opt}} = \Psi \rightarrow [2]$ es la solución óptima para la función de coste garantizando un intercambio determinista con la red.

4. Conclusiones

En este trabajo se aborda el problema de la gestión de la incertidumbre de la generación renovable en microrredes que disponen de almacenamiento híbrido de energía. Para ello se propone una metodología de control avanzado basada en SMPC para obtener el intercambio óptimo de energía con la red principal, considerando diferentes escenarios de incertidumbre y su distribución de probabilidad. Los resultados muestran que, a pesar de la complejidad, este enfoque permite mejorar la flexibilidad y resiliencia de las microrredes, garantizando la continuidad del servicio.

Agradecimientos

Este trabajo ha sido realizado como parte del desarrollo del proyecto PID2024-159933OB-I00, financiado por el MICIU/AEI/10.13039/501100011033/ ERDF, EU y el proyecto AD-GRHID, financiado por el CDTI en el Programa Misiones CDTI 2022 (Exp. MIG-20221009) (2022–2025).

Referencias

- [1] P. Pinson, C. Chevallier, and G. N. Kariniotakis, "Trading wind generation from short-term probabilistic forecasts of wind power," *IEEE Transactions on Power Systems*, vol. 22, no. 3, pp. 1148–1156, 2007.
- [2] H. Holttinen, "Optimal electricity market for wind power," *Energy Policy*, vol. 33, no. 16, pp. 2052–2063, 2005.
- [3] F. Garcia-Torres and C. Bordons "Optimal economical schedule of Hydrogen-Based microgrids with Hybrid Storage using Model Predictive Control," *IEEE Trans. Ind. Electron*, vol. 62, no. 8, pp. 5195–5207, 2015.
- [4] Y. Yang, Y. Ji, G. Geng, Q. Jiang, "Probabilistic revenue analysis of microgrid considering source-load and forecast uncertainties" *IEEE Access*, 10, 2469–2479, 2022.
- [5] Y. Huang, L. Wang, W. Guo, Q. Kang, Q. Wu, "Chance constraint optimization in a home energy management system" *IEEE Trans. Smart Grid*, 9 (1), 252–260, 2018.
- [6] P. Zhao, H. Wu, C. Gu, I. Hernando, "Optimal home energy management under hybrid photovoltaic-storage uncertainty: a distributionally robust chance-constraint approach" *IET Renew. Power Gener.* 13, 1911–1919, 2019.
- [7] H. Wang, Z. Yan, M. Shahidehpour, X. Xu and Q. Zhou, "Quantitative evaluations of uncertainties in multivariate operation of microgrids," *IEEE Trans. Smart Grid*, vol. 11, no. 4, pp. 2892–2903, 2020.
- [8] A. Khodaei, S. Bahramirad and M. Shahidehpour, "Microgrid planning under uncertainty," *IEEE Trans. Pow. Syst.*, vol. 30, no. 5, 2417–2425, 2015.
- [9] H. Qiu, H. Long, W. Gu and G. Pan, "Recourse-Cost constrained robust optimization for microgrid dispatch with correlated uncertainties," *IEEE Trans. Ind. Electr.*, vol. 68, no. 3, pp. 2266–2278, 2020.
- [10] H. Qiu, W. Gu, Y. Xu, W. Yu, G. Pan and P. Liu, "Tri-level mixed integer optimization for two stage microgrid dispatch with uncertainties," *IEEE Trans. Pow. Syst.*, vol. 35, no. 5, pp. 3636–3647, 2020.
- [11] H. Farzin, M. Fotuhi-Firuzabad and M. Moeini-Aghaie, "A stochastic multi-objective framework for optimal scheduling of energy storage systems in microgrids," *IEEE Trans. Smart Grid*, vol. 8, no. 1, pp. 117–127, 2017.
- [12] L. Alvarado-Barrios, Á. R. del Nozal, J. B. Valerino, I. García Vera and J. L. Martínez-Ramos, "Stochastic unit commitment in microgrids: Influence of the load forecasting error and the availability of energy storage," *Renew. Energy*, vol. 146, pp. 2060–2069, 2020.
- [13] Y. Zhang, S. Shen and J. L. Mathieu, "Distributionally robust chance constraint optimal power flow with uncertain renewables and uncertain reserves provided by load," *IEEE Trans. Power Syst.*, 32(2), 1378–1388, 2017.
- [14] C. Bordons, F. Garcia-Torres and M.A. Ridao, *Model Predictive Control of Microgrids*, Cham, Switzerland: Springer, 2020.
- [15] A. Parisio, E. Rikos and L. Glielmo, "Stochastic model predictive control for economic/environmental operation management of microgrids: An experimental case of study," *J. Proc. Control*, 43, pp. 24–37, 2016.
- [16] S.R. Cominesi, M. Farina, L. Giulioni, B. Picasso and R. Scattolini, "A two-layer stochastic model predictive control scheme for microgrids," *IEEE Trans. Control Syst. Tech.*, vol. 26, no. 1, pp. 1–13, 2017.
- [17] N. Bazmohammadi, A. Tahsiri, A. Anvari-Moghaddam and J. M. Guerrero, "Stochastic predictive control of multi-microgrid systems," *IEEE Trans. Ind. App.*, vol. 55, no. 5, pp.5311–5319, 2019.
- [18] P. Velarde, L. Valverde, J. Maestre, C. M. Ocampo-Martinez and C. Bordons, "On the comparison of stochastic model predictive control strategies applied to a hydrogen-based microgrid," *J. Pow. Sources*, 343, 161–173, 2017.
- [19] C. Lu, X. Zhang, X. Wang, Y. Han, "Mathematical expectation modeling of Wide-Area Controlled power systems with stochastic time delay," *IEEE Trans. Smart Grid*, vol. 6, no. 3, pp. 1511–1519, 2015.
- [20] M.I. Saleem, S. Saha, U. Izhar, L. Ang, "A stochastic MPC-Based energy management system for integrating solar PV, Battery storage and EV charging in residential complexes", *Energy & buildings* 325, 2024.
- [21] F. García-Torres, C. Bordons, J. Tobajas, R. Real-Calvo, I. Santiago and S. Greu, "Stochastic optimization of microgrids with hybrid energy storage systems for grid flexibility services considering energy forecast uncertainties" *IEEE Trans. Power Syst.*, vol. 36, no. 6, pp. 5537–5547, 2