

MPC con modelos neuroborrosos para la gestión energética en una planta de fabricación

Gómez, J.^{a,*}, Chicaiza, W. D.^a, Escaño, J. M.^a, Bordons, C.^{a,b}

^aDepartamento de Ingeniería de Sistemas y Control Automático, Universidad de Sevilla, España

^bENGREEN - Laboratorio de Ingeniería para la Sostenibilidad Energética y Medioambiental, Universidad de Sevilla, España

To cite this article: Gómez, J., Chicaiza, W. D., Escaño, J. M., Bordons, C.. 2023. MPC with fuzzy modelling for energy management in a manufacturing plant. XLIV Jornadas de Automática, 156-161. <https://doi.org/10.17979/spudc.9788497498609.156>

Resumen

Se propone un Control Predictivo Basado en Modelo (MPC) para maximizar el uso de energías renovables en un proceso de fabricación. La estrategia se ha aplicado en un sistema de fabricación que cuenta con varias máquinas, recursos de generación renovable, un generador combinado de calor y electricidad (CHP) para la producción de energía, y un banco de baterías para el almacenamiento de energía. El trabajo pretende maximizar el uso de fuentes de energía renovables en este proceso, teniendo en cuenta también el precio del mercado eléctrico, para reducir el coste. El uso de modelos neuroborrosos para la predicción de la energía producida por los generadores renovables permite una predicción dinámica, utilizando valores de entrada obtenidos a partir de variables típicas de predicción (velocidad del viento, irradiancia global, etc.).

Palabras clave: Sistemas de apoyo a la toma de decisiones, Algoritmos evolutivos en control e identificación, Sistemas difusos y neuronales relevantes para el control y la identificación, Control predictivo basado en modelos y en optimización, Funcionamiento y planificación del almacenamiento de energía

MPC with fuzzy modelling for energy management in a manufacturing plant

Abstract

A Model Predictive Control (MPC) is proposed to maximise the use of renewable energy in a manufacturing process. The strategy has been applied in a manufacturing system with several machines, renewable generation resources, a combined heat and power (CHP) generator for energy production, and a battery bank for energy storage. The work aims to maximise the use of renewable energy sources in this process, also taking into account the electricity market price, to reduce the cost. The use of neuroborros models for the prediction of the energy produced by renewable generators allows a dynamic prediction, using input values obtained from typical prediction variables (wind speed, global irradiance, etc.).

Keywords: Decision support systems, Evolutionary algorithms in control and identification, Fuzzy and neural systems relevant to control and identification, Model predictive and optimization-based control, Energy storage operation and planning

1. Introducción

El Control Predictivo Basado en Modelo (MPC, por sus siglas en inglés: Model Predictive Control) es bien conoci-

do en la industria (Camacho and Bordons, 2007). Existen buenos resultados de MPC en gestión energética de edificios (Roshany-Yamchi et al., 2017) y microrredes (Bordons

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

et al., 2020), pero no se han realizado trabajos relevantes para la gestión energética completa en procesos de fabricación (Gómez et al., 2023).

Este trabajo propone un MPC para maximizar el uso de energía renovable en una fábrica real con varias máquinas, recursos de generación renovable, un generador combinado de calor y electricidad, y un banco de baterías para el almacenamiento de energía. En esta estrategia se tienen en cuenta las predicciones del precio del mercado eléctrico, los costes del gas y los modelos predictivos de generación de energía renovable. El resultado del MPC dará la secuencia de operaciones de fabricación, así como el funcionamiento de las baterías y la cogeneración.

El resto del artículo se organiza como sigue. En la sección 2 se plantea el problema de optimización a resolver. La sección 3 explica y desarrolla modelos neuroborrosos de producción de energía renovable. La estrategia MPC se presenta en la sección 4. La sección 5 muestra los resultados de la evaluación y el artículo finaliza con una sección de conclusiones y trabajo futuro.

2. Problema de optimización

El objetivo principal es maximizar el uso de energías renovables. Para conseguirlo, se propone minimizar el coste energético diario (C^{day}). El proceso a controlar forma parte de una planta de fabricación real: un conjunto de M máquinas de Control Numérico Computarizado (CNC), que son las únicas cargas manipulables; y un perfil de consumo fijo para el resto de cargas de la fábrica (RC, Remaining Consumption, en inglés). En el lado de la generación, un aerogenerador (WT, en inglés Wind turbine) y un conjunto de paneles fotovoltaicos (PV, en inglés Photovoltaic), son las dos únicas fuentes de energía renovables (RES, Renewable Energy Sources, en inglés); junto con un generador combinado de calor y electricidad (CHP, Combined Heat and Power, en inglés) y una conexión al proveedor de electricidad (MP, Market Provider, en inglés). Por último, se ha incluido un banco de baterías (B). La fábrica puede considerarse una microrred (Bordons et al., 2020). En la figura 1 puede verse un esquema de la microrred.

Las variables de decisión pueden manipularse para modificar el comportamiento de los activos de la central (generadores y cargas). Dado que las RES deben maximizarse, no tendrán variables de decisión porque se utilizarán siempre que estén disponibles. La estrategia de optimización seleccionada de las variables de decisión (n_{obj}^k) se resume en tres tipos de variables:

- n_{CNC}^k representa cuántas máquinas están en funcionamiento en el momento k .
- n_{CHP}^k representa si la unidad CHP está encendida o apagada en el momento k .
- n_B^k muestra de manera unitaria cuánta energía se va a cargar/descargar de la batería en el instante k .




Figura 1: Esquema de la microrred

Con esta estrategia se desacoplan dos optimizaciones: el número de máquinas necesarias en cada instante para cumplir el número de piezas necesarias (DPT) y, en concreto, qué máquinas encender en cada instante. Esta segunda optimización, dado que el consumo implementado para los CNCs es idéntico para todos ellos, se ha resuelto encendiendo primero los CNCs con menor índice i . Los límites de cada variable de decisión se pueden ver en la Tabla 1. Las restricciones asociadas a las variables de decisión se resumen en (1).

| Símbolo | Tipo | Límites inferior & superior | |
|-------------|--------|-----------------------------|---------|
| n_{CNC}^k | Entero | 0 | $M = 7$ |
| n_{CHP}^k | Entero | 0 | 1 |
| n_B^k | Real | -1 | 1 |

$$\text{Model Constraints} \equiv \left[\begin{array}{l} TPU \geq DPT \\ SOC^k \geq SOC_{min} \end{array} \right] \quad (1)$$

Siendo, cada una de las restricciones de (1):

1. El estado de carga de las baterías en cualquier instante (SOC^k) debe ser mayor que el mínimo seleccionado (SOC^{min}) para aumentar la vida útil de la batería.
2. El número total de piezas producidas (TPU) debe ser igual o superior al número de piezas necesarias (DPT).

El tiempo de muestreo elegido (Δt) es de 0,5 horas y el horizonte de optimización (OH) es igual a un día. Esto implica que la optimización se ejecutará cada 30 min y que hay 48 k instantes ($OH = 48 \text{ muestras}$) a lo largo del OH . El coste energético diario (C^{day}) del proceso se obtiene a partir del balance energético del sistema, dando como resultado (2).

$$\begin{aligned} C^{day} &= \sum_{k=1}^{OH} C_{MP}^k + C_{CHP}^k = \\ &= \sum_{k=1}^{OH} E_{MP}^k \cdot Pr_{MP}^k + E_{CHP}^k \cdot \eta_{CHP}^{-1} \cdot Pr_{gas}^k \end{aligned} \quad (2)$$

Siendo $C_{MP/CHP}^k$ el coste de la energía comprada / producida por MP / CHP, $E_{MP/CHP}^k$ la energía comprada / producida por MP / CHP, $Pr_{MP/gas}^k$ el precio de la electricidad / del gas comprado y η_{CHP} la eficiencia eléctrica de la CHP. Todo es relativo al instante k . A continuación se explican todos los subsistemas que componen el sistema.

Cada CNC se ha modelado como una máquina encendida/apagada, integrando la potencia media en reposo ($P_{CNC}^{apagada,media}$) o en funcionamiento ($P_{CNC}^{encendida,media}$) durante un periodo; como se ve en (3).

$$E_{CNC}^k = \Delta t \cdot \begin{cases} P_{CNC}^{on,mean} & \text{si } n_{CNC}^k = 1 \\ P_{CNC}^{off,mean} & \text{en otros casos} \end{cases} \quad (3)$$

Los parámetros necesarios para configurar el modelo de producción CNC se pueden ver en la Tabla 2. El DPT se refiere a los M CNCs manipulados, no al total de la fábrica real.

Tabla 2: Parámetros del modelo de las CNCs

| Parámetro | Símbolo | Valor | Unidad |
|-------------------------------|---------|-------|----------|
| Objetivo diario de producción | DPT | 378 | piezas |
| Tiempo de producción | PT | 15 | minutos |
| Número de CNCs manipulables | M | 7 | máquinas |

Se ha incluido un modelo lineal para la carga y descarga de la batería. El modelo implementado se describe en ((4), (5), (6)). Los parámetros del modelo se pueden encontrar en la Tabla 3.

$$E_B^{aux,k} = n_B^k \cdot P_B^{max} \cdot \Delta t \quad (4)$$

$$E_B^k = \begin{cases} \text{si } n_B^k \geq 0 & \begin{cases} E_B^{aux,k} \cdot \eta_d & \text{si } SOC^k \geq E_B^{aux,k} \\ SOC^k \cdot \eta_d & \text{en otros casos} \end{cases} \\ \text{si } n_B^k < 0 & \begin{cases} \frac{E_B^{aux,k}}{\eta_c} & \text{si } SOC^k - E_B^{aux,k} \leq SOC_{max} \\ \frac{SOC^k - SOC_{max}}{\eta_c} & \text{en otros casos} \end{cases} \end{cases} \quad (5)$$

$$SOC^{k+1} = SOC^k - \begin{cases} \frac{E_B^k}{\eta_d} & \text{si } n_B^k \geq 0 \\ E_B^k \cdot \eta_c & \text{si } n_B^k < 0 \end{cases} \quad (6)$$

Tabla 3: Parámetros del modelo de las baterías

| Parámetro | Símbolo | Valor | Unidad |
|-------------------------------|-------------|-------|--------|
| Capacidad de la batería | SOC_{max} | 2 | MWh |
| Estado mínimo de carga | SOC_{min} | 0,6 | MWh |
| Estado inicial de carga | SOC^1 | 0,6 | MWh |
| Máximo intercambio de energía | P_B^{max} | 2 | MW |
| Rendimiento de la carga | η_c | 0,95 | - |
| Rendimiento de la descarga | η_d | 0,95 | - |

El modelo CHP implementado con una operación de encendido/apagado puede verse en (7, 8). Los datos necesarios para el modelo son el precio del gas a lo largo del día (Pr_{gas}^k), el rendimiento de la cogeneración y el porcentaje de energía eléctrica producida por MWh de gas (ambos contenidos en η_{CHP} , de la ficha técnica de la cogeneración); y la potencia nominal de la cogeneración (P_{CHP}^{max}). Estos parámetros se encuentran en la tabla 4.

$$E_{CHP}^k = n_{CHP}^k \cdot P_{CHP}^{max} \cdot \Delta t \quad (7)$$

$$C_{CHP}^k = E_{CHP}^k \cdot \eta_{CHP} \cdot Pr_{gas}^k \quad (8)$$

Tabla 4: Parámetros del modelo del CHP

| Parámetro | Símbolo | Valor | Unidad |
|--------------------------------|-----------------|-------|--------|
| Potencia nominal | P_{CHP}^{max} | 435 | kW |
| Índice de eficiencia eléctrica | η_{CHP} | 39,9 | % |

La energía total generada por las RES (E_{RES}^k) se suma en (9). El Consumo Remanente (E_{RC}^k) es el resultado de restar la demanda global menos el consumo del Comportamiento Base (se explicará más adelante) de los M CNC manipulables (el propietario de la fábrica proporciona estos datos). $E_{MP}^{aux,k}$ representa la demanda insatisfecha, calculada en (10). Como la electricidad no puede venderse en el mercado en el sistema real, está saturada en (11). El proveedor de electricidad, sujeto al mercado eléctrico, satisfará la demanda cuando todas las demás fuentes de energía no lo hagan, con un coste asociado, según (12). El precio de la electricidad se obtiene de una base de datos del proveedor del sistema real.

$$E_{RES}^k = E_{WT}^k + E_{PV}^k \quad (9)$$

$$E_{MP}^{aux,k} = -(E_{CHP}^k + E_B^k + E_{RES}^k) + E_{RC}^k + \sum_{i=1}^M E_{CNC_i}^k \quad (10)$$

$$E_{MP}^k = \begin{cases} 0 & \text{si } E_{MP}^{aux,k} < 0 \\ E_{MP}^{aux,k} & \text{en otros casos} \end{cases} \quad (11)$$

$$C_{MP}^k = E_{MP}^k \cdot Pr_{MP}^k \quad (12)$$

3. Modelos neuroborrosos de las Energías Renovables

Dado que las variables meteorológicas que pueden predecirse en el horizonte son escasas (velocidad del viento e irradiancia global) y que la generación de energía renovable responde a un modelo no lineal complejo, que incluye varias variables como entrada, se ha decidido utilizar un sistema de inferencia borrosa basada en red adaptativa (Adaptive Neuro Fuzzy Inference System, ANFIS) para predecir la generación de energía renovable. La modelización difusa ha demostrado ser una técnica eficaz para modelizar y controlar sistemas no lineales, expresando con éxito el modelo no lineal original.

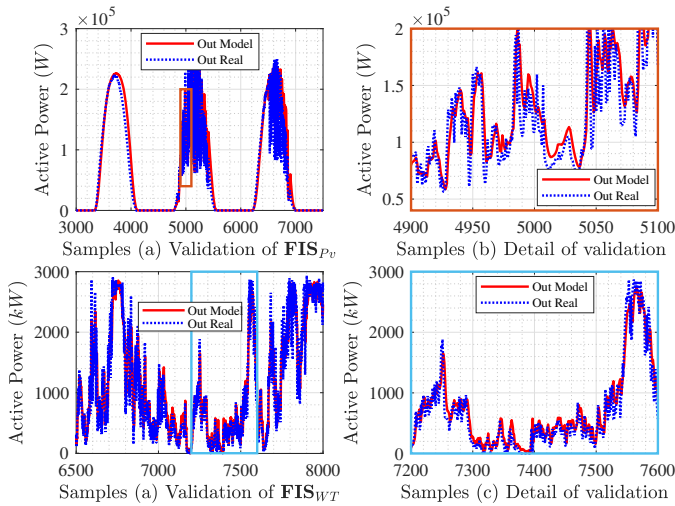


Figura 2: Resultados de la validación

Para predecir el próximo valor de potencia activa del aerogenerador, sólo se utilizan la velocidad del viento y la potencia activa actual. Para la modelización fotovoltaica, sólo se utilizan la irradiancia global directa y la potencia activa. Tras el preprocesamiento de los datos (eliminación de valores atípicos, interpolación y normalización), los conjuntos de datos se organizan en conjuntos de entrenamiento y validación para evitar el sobreajuste mediante validación cruzada. Tras el procedimiento de entrenamiento, se obtienen dos sistemas de inferencia borrosa (Fuzzy Inference System, FIS) (eólico y fotovoltaico) con una estructura descrita en (Chicaiza et al., 2022). Ambos modelos neuroborrosos tienen dos reglas. Para una descripción detallada del proceso de modelado ANFIS con las proyecciones de los datos mediante PCA, consulte (Machado et al., 2023).

Tabla 5: Índice de validación de los modelos de predicción neuroborrosos

| Error índices | FIS _{PV} modelo | FIS _{WT} modelo |
|---------------|--------------------------|--------------------------|
| \bar{E} | 7,424 [kW] | 28,42 [kW] |
| RMSE | 24,587 [kW] | 267,89 [kW] |
| R^2 | 0,91 | 0,91 |

El proceso de validación compara la salida prevista FIS_s con el conjunto de datos de validación correspondiente a cada RES. La figura 2 muestra que FIS_{PV} y FIS_{WT} son capaces de predecir el valor real de la potencia activa en ambas RES, y estas evaluaciones consideran datos durante el día y la noche. Los índices de error obtenidos de ambos modelos se muestran en la Tabla 5.

4. Control Predictivo Basado en Modelo

Para diseñar un MPC son necesarios tres componentes importantes: un optimizador, un modelo predictivo y la realimentación del sistema real. La arquitectura del MPC implementado puede verse en la Figura 3.

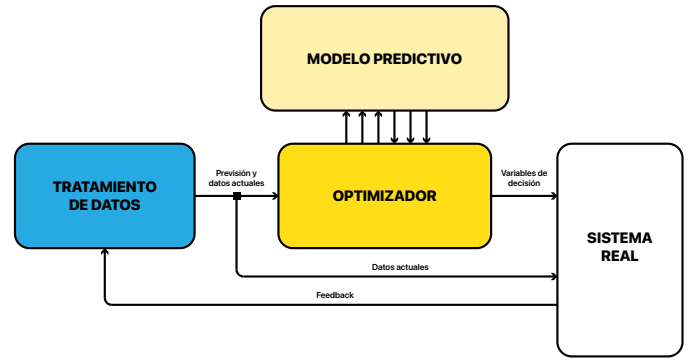


Figura 3: Arquitectura MPC

El problema de optimización, en este caso, se compone de variables enteras y reales, es decir, es de tipo mixto. Uno de los mejores algoritmos (Gen and Lin, 2012) para resolver este problema es el Algoritmo Genético (AG). Los valores de los parámetros más relevantes del AG se han seleccionado empíricamente, obteniendo los valores mostrados en la Tabla 6. La función de mutación obtiene el conjunto de individuos aleatorios que intentan evitar que el AG vaya a un mínimo local. Se han utilizado dos funciones de mutación diferentes:

1. Mutación de Potencia (PM) (Deep et al., 2009): más preciso, pero requiere una mayor carga computacional en problemas mixtos.
2. Mutación uniforme (UM) (Michalewicz, 1996): menos preciso pero menos carga computacional.

La mejor combinación para problemas de tipo mixto es utilizar la función UM para aproximar el mínimo deseado y después utilizar PM, a partir del punto final anterior, para mejorarlo.

Tabla 6: Parámetros seleccionados del algoritmo genético

| Parámetro | Valor |
|------------------------|---------------------------|
| Tamaño de la Población | 500 |
| Recuento de Élite | 75 |
| Función de Cruce | <i>crossoverlaplace</i> |
| Fracción de Cruce | 0,8 |
| Función de Selección | <i>selectionstochunif</i> |

En el bloque Proceso de datos se llevan a cabo las siguientes tareas: obtención de los datos de entrada reales para los modelos, creación de datos de previsión y realimentación de las salidas del modelo.

Todos los datos reales ($Data_{actual}$) para los modelos (precio, velocidad del viento, irradiancia, etc.) se han obtenido de bases de datos. Para imitar un escenario realista, el MPC utiliza datos de previsión. Estos datos se crean a partir de datos reales, introduciendo una incertidumbre creciente en el tiempo.

En la figura 4, la velocidad real del viento se muestra en naranja y el valor creado con incertidumbre en azul.




Figura 4: Ejemplo de creación de datos de previsión

En cada instante k , el intervalo de 24 horas (48 muestras) de los datos previstos se vuelve a calcular a partir de los datos reales. De este modo, la información en el instante k es la misma que la de los datos reales.

5. Resultados

Para comparar las mejoras obtenidas con el controlador, se ha obtenido una secuencia de variables de decisión (Comportamiento Base) a partir del análisis del comportamiento seguido por los trabajadores del sistema real en un día normal.

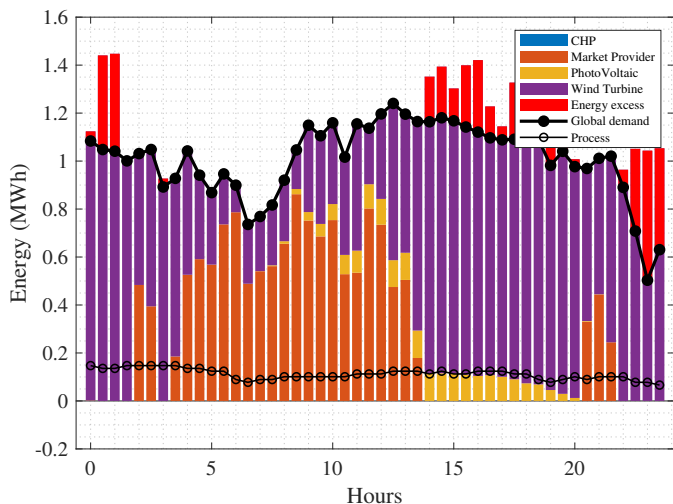


Figura 5: Consumo de energía del Comportamiento Base el día de la simulación

Gráficamente, la secuencia puede verse en la Figura 5. Los segmentos negros representan la demanda total y los puntos negros la demanda manipulada (M CNCs). En cada instante, el balance energético de cada intervalo de tiempo se cumple con un exceso de energía en algún intervalo de tiempo producido por el aerogenerador (este exceso, al no poder ser almacenado, se desecha saturando el aerogenerador). La energía consumida por las CNC

M es aproximadamente del 15%, respecto al consumo del resto de elementos del sistema real, lo que implica que el margen para tocar la demanda se reduce. Además, ese día, la potencia generada por la cogeneración fue nula, sin tener en cuenta la ventaja de la diferencia de precios entre el mercado y el gas a lo largo del tiempo.

A través de esta secuencia, se producen 378 piezas. Esto será el valor DPT para el MPC (ver Tabla 2). El MPC se ha simulado durante un día completo. Los precios del gas y la electricidad para ese día se muestran en la Figura 6.

La figura 7 muestra el comportamiento del sistema con el MPC. Como puede verse, el MPC hace que la producción de piezas se acumule al principio del día, ya que el coste de la energía es mucho menor (véase la Figura 6). También aprovecha la diferencia de precios entre la cogeneración y la MP, introduciendo la cogeneración cuando es más barata. A su vez, las baterías se utilizan para almacenar energía cuando es más barata y luego se utilizan cuando aumenta el precio de la electricidad (tanto CHP como MP). Esto explica por qué la cogeneración carga las baterías al final del día, ya que el precio de la electricidad y el gas a primera hora de la mañana del día siguiente al simulado es más caro que a última hora de la mañana del día simulado, como puede verse en la Figura 6.




Figura 6: Precios del gas y de la electricidad de ambos días

El SOC de las baterías para ese día puede verse en la Figura 8. Como puede verse, el MPC, aunque mantiene la restricción mínima de SOC permitida para prolongar la vida útil de las baterías, aprovecha al máximo la capacidad de las baterías.

Para comparar el coste del sistema sin controlar y el sistema con el MPC, se ha realizado la optimización del día siguiente sobre los datos reales (con la intención de introducir en los resultados los beneficios del horizonte deslizante, anticipando el comportamiento del día siguiente) obteniendo los resultados de la Tabla 7.

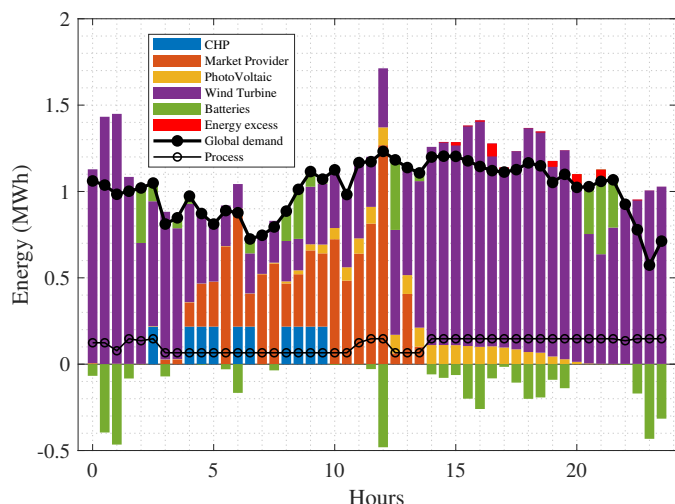


Figura 7: Consumo de energía con el MPC el día de la simulación

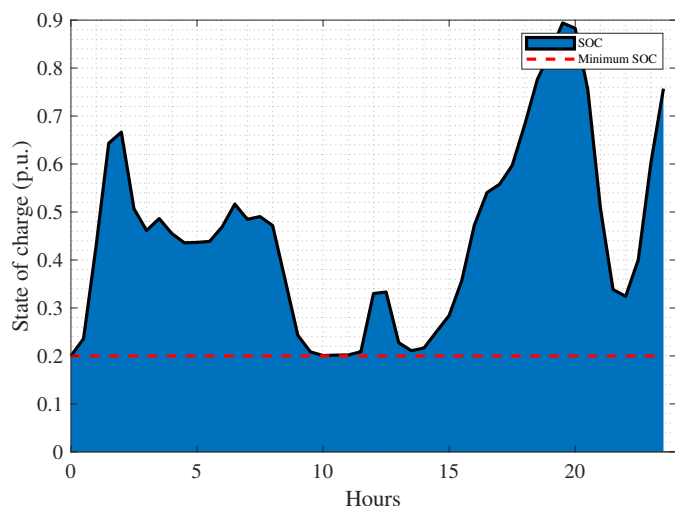


Figura 8: SOC de las baterías con el MPC el día de la simulación

Tabla 7: Comparación de costes

| Día | Comportamiento base | MPC |
|--------------|---------------------|--------|
| Primero | 5026 € | 3816 € |
| Segundo | 3309 € | 2196 € |
| Coste total | 8335 € | 6012 € |
| Ahorro total | - | 2323 € |

6. Conclusión

Este artículo presenta un controlador basado en MPC para maximizar el uso de energías renovables, al tiempo que se reduce el coste energético, para un sistema real de producción de piezas. El controlador está diseñado para optimizar el coste de producción de piezas, teniendo en cuenta los costes de producción de las piezas, los costes energéticos y los costes de mantenimiento de los elementos del sistema. El controlador se ha validado con datos reales de un sistema de producción de piezas, lo que ha permitido ahorrar un 27,87% por día de producción.

Para mejorar el presente trabajo, se están llevando a cabo las siguientes investigaciones:

1. La inclusión, en la función objetivo, de un modelo de todos los costes relacionados con las baterías.
2. La adición de incertidumbres en el controlador para mejorar la robustez.

Agradecimientos

Los autores agradecen a la Comisión Europea la financiación de este trabajo en el marco del proyecto DENiM. Este proyecto ha recibido financiación del programa de investigación e innovación Horizonte 2020 de la Unión Europea en virtud del acuerdo de subvención nº 958339. También agradecen al proyecto PID2019-104149RB-I00 financiado por MCIN/AEI/10.13039/501100011033.

The authors want to thank the European Commission for funding this work under Project DENiM. This project has received funding from the European Union's Horizon 2020 research and innovation programme under grant agreement no. 958339. Also by Grant PID2019-104149RB-I00 funded by MCIN/AEI/10.13039/501100011033.

Referencias

- Bordons, C., Garcia-Torres, F., Ridao, M., 2020. Model Predictive Control of Microgrids. *Advances in industrial control*. Springer.
- Camacho, E. F., Bordons, C., 2007. *Model Predictive control*. Advanced Textbooks in Control and Signal Processing. Springer London, London.
DOI: 10.1007/978-0-85729-398-5-1
- Chicaiza, W. D., Ortiz-Machado, D., Gallego, A. J., Escaño, J. M., Bordons, C., de Andrade, G. A., Normey-Rico, J. E., 2022. Neuro-fuzzy digital twin of a high temperature generator. *IFAC-PapersOnLine* 55 (9), 466–471, 11th IFAC Symposium on Control of Power and Energy Systems CPES 2022.
DOI: <https://doi.org/10.1016/j.ifacol.2022.07.081>
- Deep, K., Singh, K. P., Kansal, M., Mohan, C., 2009. A real coded genetic algorithm for solving integer and mixed integer optimization problems. *Applied Mathematics and Computation* 212 (2), 505–518.
DOI: <https://doi.org/10.1016/j.amc.2009.02.044>
- Gen, M., Lin, L., 12 2012. Multiobjective genetic algorithm for scheduling problems in manufacturing systems. *Industrial Engineering and Management Systems* 11, 310–330.
DOI: 10.7232/iems.2012.11.4.310
- Gómez, J., Chicaiza, W. D., Escaño, J. M., Bordons, C., 2023. A renewable energy optimisation approach with production planning for a real industrial process: An application of genetic algorithms. *Renewable Energy* 215, 118933.
URL: <https://www.sciencedirect.com/science/article/pii/S096014812300839X>
DOI: <https://doi.org/10.1016/j.renene.2023.118933>
- Machado, D. O., Chicaiza, W. D., Escaño, J. M., Gallego, A. J., de Andrade, G. A., Normey-Rico, J. E., Bordons, C., Camacho, E. F., 2023. Digital twin of a fresnel solar collector for solar cooling. *Applied Energy* 339, 120944.
URL: <https://www.sciencedirect.com/science/article/pii/S0306261923003082>
DOI: <https://doi.org/10.1016/j.apenergy.2023.120944>
- Michalewicz, Z., 1996. *Genetic Algorithms + Data Structures = Evolution Programs*. Springer Berlin Heidelberg, Berlin, Heidelberg.
DOI: <https://doi.org/10.1007/978-3-662-03315-9>
- Roshany-Yamchi, S., Witheepanich, K., Escaño, J. M., McGibney, A., Rea, S., 2017. Selective distributed model predictive control for comfort satisfaction in multi-zone buildings. In: *2017 21st International Conference on System Theory, Control and Computing (ICSTCC)*. pp. 648–653.
DOI: 10.1109/ICSTCC.2017.8107109