

Uso de algoritmo genético para gestionar la demanda energética en microrredes mediante descomposición poligonal

Topa, Alex Omar^a, Cruz, Nicolás C.^b, Álvarez, José Domingo^{a,*}, Torres, José Luis^c

^aDepartment of Computer Engineering, Automation and Robotics, CIESOL—ceiA3, Ctra. Sacramento s/n, La Cañada de San Urbano, University of Almería, 04120 Almería, Spain; atg511@inlumine.ual.es and jhervas@ual.es

^bDepartment of Computer Architecture and Technology, University of Granada. Journalist Daniel Saucedo Street, 18014 Granada, Spain; ncalvocruz@ugr.es

^cDepartment of Engineering, CIESOL—ceiA3, Ctra. Sacramento s/n, La Cañada de San Urbano, University of Almería, 04120 Almería, Spain; jltmoreno@ual.es

To cite this article: Topa, A.O., Cruz, N.C., Álvarez, J.D., Torres, J.L. 2023. Using of genetic algorithm to manage energy demand in microgrids through polygonal decomposition. XLIV Jornadas de Automática, 495-500. <https://doi.org/10.17979/spudc.9788497498609.495>

Resumen

Este trabajo propone una metodología atractiva para la gestión energética orientada al lado de la demanda en la operación de microrredes. Esta metodología replica aspectos del rompecabezas chino Tangram, ya que los perfiles tanto de producción como de demanda de energía se construyen a través de polígonos y operan con geometría computacional. Por lo tanto, se desarrolla un problema de optimización, que a través de los perfiles de demanda de energía de n dispositivos (piezas) se intenta cubrir la totalidad, o la máxima área posible, de un perfil de producción de energía (forma). Así, el problema de optimización se resuelve con un algoritmo genético que calcula las posiciones óptimas de los polígonos de demanda para cubrir, es decir consumir, la máxima área del polígono equivalente a la producción de energía. Dado que la energía proviene de fuentes renovables de una microrred, este método permite reducir la dependencia del consumo de energía de la red pública y, por lo tanto, la factura de la energía eléctrica.

Palabras clave: Sistemas de potencia, Microrred, Optimización, Algoritmos genéticos, Sistemas de gestión de energía

Using a genetic algorithm for energy demand management in microgrids through polygonal decomposition

Abstract

This work proposes an attractive methodology for demand-side energy management in the operation of microgrids. This method replicates some aspects of the Chinese Tangram puzzle, as production and demand profiles are represented by polygonal shapes to handle through computational geometry. It defines an optimization problem in which the demand profiles (pieces) of n devices must be arranged to cover a production profile (shape) as well as possible. The optimization problem is addressed with a genetic algorithm that calculates the optimal positions of the demand polygons to consume the maximum energy production. Since the energy comes from renewable sources in a microgrid, this method allows reducing the dependence on the public energy grid and the electricity bills.

Keywords: Power systems, Microgrid, Optimization, Genetic algorithms, Energy management system

1. Introducción

La red eléctrica actualmente en uso lleva más de 50 años en activo, *i. e.*, se está quedando obsoleta. Por lo tanto, se pretende modernizar para entregar eficientemente suministros de electricidad sostenibles, económicos y seguros (Gelazanskas and Ga-

mage, 2014). En la Unión Europea (UE), los edificios representan el 40 % del consumo total de energía. Por esta razón, se han propuesto diferentes estrategias y tecnologías para mejorar la sostenibilidad energética en edificaciones (Al Dakheel et al., 2020; Serale et al., 2018). Gran parte del consumo energético

*Autor para correspondencia: jhervas@ual.es

co en edificios bioclimáticos inteligentes se realiza a través de microrredes (MRs). Éstas gestionan las cargas locales, fuentes de energía renovables (FER), fuentes de energía fósil (FEF), y están equipadas con sistemas de almacenamiento de energía (SAE) (Topa et al., 2023; Maślak and Orłowski, 2022). De esta forma, una MR se define como una red de energía que puede ser autosuficiente o formar parte de un sistema global de generación de energía, y que garantiza un flujo de energía bidireccional e información cliente/proveedor (Sarker et al., 2021; Topa Gavilema et al., 2023). Por lo tanto, es indispensable un sistema de gestión de energía (SGE) que garantice, tanto la energía demandada como la comercialización de energía.

En los últimos años, la gestión del lado de la demanda (GLD) ha ganado terreno dentro de las estrategias de gestión de la energía. La GLD se puede definir como un conjunto de acciones de gestión del consumo. Incluye la planificación, implementación y monitoreo de actividades previamente definidas, afectando los patrones de utilización de energía de los consumidores (Sarker et al., 2021). De esta forma, el objetivo de la GLD es modelar la demanda de energía en función del perfil de producción de energía. Esta estrategia pretende manipular las demandas de energía a través de desplazamientos programados, considerando aspectos como: i) disponibilidad de energía, ii) tarifa eléctrica y iii) restricciones físicas del sistema energético (Lizana et al., 2018; Tang et al., 2019). Por lo tanto, la GLD permitirá a minimizar los costos de energía y operación, minimizar las emisiones de CO₂ y maximizar el consumo de energía de las FER mientras se gestiona de forma eficiente y responsable la carga.

Los SGE basados en la GLD utilizan diversos enfoques de optimización. Uno de estos enfoques son los algoritmos genéticos (AG), ampliamente utilizados en un gran número de aplicaciones. Por esta razón, los autores de (Sharda et al., 2021; Behera and Dev Choudhury, 2023; Eisenmann et al., 2022; Sardar et al., 2023) proponen metodologías basadas en AG que obtienen excelentes resultados, reduciendo los costes de energía y maximizando el consumo de energético a través de las FER, siendo muy atractivo trasladar las demandas energéticas a horarios de menor consumo. La complejidad de los problemas resultantes hace que apostar por métodos como los AGs sea necesario Sardar et al. (2023). Los AGs están inspirados en la teoría Darwiniana de la evolución, y la simulan como estrategia para resolver problemas de optimización. Un AG realiza una búsqueda global en la que cada solución es considerada como un individuo sujeto a procesos biológicos como: reproducción sexual, mutación y selección natural. Según los individuos evolucionan, las posibles soluciones mejoran, mientras que otras soluciones son desechadas. Se cumple así el principio de evolución natural según el cual la solución óptima vendrá dada por el individuo más fuerte (Konak et al., 2006; Chung and shik Shin, 2020).

Este artículo se centra en la resolución de casos reales de un SGE basado en la GLD. La metodología fue desarrollada y validada en (Topa et al., 2023). Se inspira en la resolución de un rompecabezas chino Tangram, que utiliza una serie de figuras geométricas (piezas) para replicar a una forma previamente definida como se muestra la Figura 1.

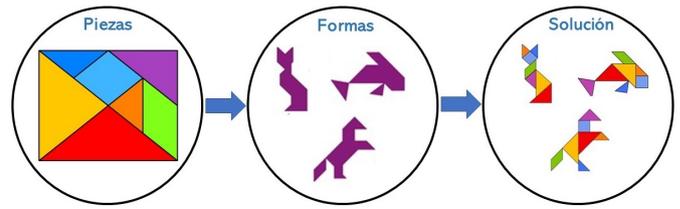


Figura 1: Representación del rompecabezas Tangram.

En este contexto, las demandas de energía se desplazan a lo largo del tiempo con el objetivo de minimizar los costos de energía y maximizar el consumo de FER. Por otro lado, los perfiles de producción y demanda de energía son representados mediante polígonos. Este último es dividido en sub-polígonos de demanda energética de cada una de las cargas. Se usa entonces un AG para encontrar la ubicación óptima de cada uno de ellos dentro del polígono de producción de FER. De esta forma, se obtiene un aprovechamiento óptimo de las FER mientras que se reduce la dependencia de las FEF. Además, esta metodología logra una simplificación conceptual del problema de optimización a través de geometría poligonal, i.e., los desplazamientos óptimos de los polígonos de las demandas dentro del polígono de producción cubren de forma total o parcial la energía total demandada. Para validar la versatilidad de esta metodología se han propuesto diferentes casos utilizando datos reales de un edificio bioclimático del centro de investigación de la energía solar CIESOL ubicado en la Universidad de Almería.

El resto del artículo se ha estructurado de la siguiente manera: la Sección 2 presenta la metodología propuesta para la gestión de la energía del lado de la demanda de MR. Después, la Sección 3 describe los resultados obtenidos de los casos reales propuestos. Por último, la Sección 4 presenta las conclusiones de este trabajo.

2. Metodología

Tal como se describió en la sección anterior, esta metodología se centra en reducir el costo de la energía y el impacto ambiental generado por las FEF mediante la gestión óptima de la demanda de energía. En esta sección se describe el SGE propuesto. Se parte de la representación poligonal de los datos de producción y demanda de energía. Ésta última se dividirá en varios polígonos de energía. Se define entonces un problema de optimización en este contexto. Finalmente, se presenta una descripción general del AG usado para resolver el problema. En cualquier caso, para más detalles se recomienda al lector consultar (Topa et al., 2023).

2.1. Descripción del problema

El principio de funcionamiento de esta metodología está inspirada en un rompecabezas chino llamado Tangram. Dicho juego consiste en construir una forma deseada, utilizando una serie de piezas conformadas por figuras geométricas, para lograr una solución (ver, Figura 1). Con esta introducción, la representación de cada una de las demandas de energía se puede expresar a través de polígonos bidimensionales. Éstos tienen como abscisa el tiempo en horas y como ordenada la potencia

eléctrica en kW. Así, la energía total producida como demanda expresada en kWh es el área total de los polígonos correspondientes. De esta forma, la Figura 2 muestra la metodología propuesta a través de un entorno de simulación sencillo. A la izquierda de la figura tenemos las entradas de la metodología, definida por los polígonos de producción y demanda de energía, respectivamente. Por otro lado, en el centro tenemos el desplazamiento de las demandas de energía dentro de la producción energética. Finalmente, a la derecha se ve la optimización de la demanda energética.

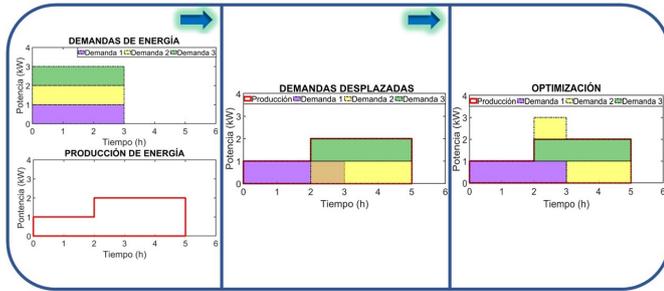


Figura 2: Ejemplo sencillo de aplicación de la metodología.

Esta simulación tiene 8 kWh de producción mientras la suma de las demandas asciende a 9 kWh. Es decir, la producción es menor que la demanda. Por lo tanto, las demandas son desplazadas hacia el polígono de producción de energía, ubicándose de tal forma que la demanda total de energía es optimizada. Por otro lado, el algoritmo acota las demandas dentro de los valores de tiempo que limita el polígono de producción, i.e., las demandas se desplazarán únicamente dentro del polígono de producción. Por esta razón, las intersecciones entre demandas son comunes. Eléctricamente es incorrecto intersecar demandas, pues se trata de un valor energético que se desprecia (ver, Figura 2). Por este motivo, se hace un preprocesamiento en cada instante de evaluación de las configuraciones candidatas.

2.2. Representación del problema

Presentada la metodología del SGE basado en la GLD, el objetivo puede abordarse como un problema de optimización. Éste busca replicar (minimizar la diferencia) el polígono asociado a la producción energética mediante la composición de los polígonos que representan la demanda de energía de los distintos dispositivos, como si fuera el juego Tangram. Así, la posición de cada uno de los polígonos viene asignada por las soluciones candidatas del proceso de optimización, definidas por E_k^x y E_k^y , que representan el tiempo (h) en el eje de las abscisas y la potencia eléctrica (kW) en el eje de las ordenadas, respectivamente. Para evaluar cada solución candidata, primero es necesario construir el polígono de demanda de energía total E_T , a partir de n cargas/dispositivos, representados por cada polígono demandante de energía E_k , como se muestra en (1). Esta codificación se realiza a través de la unión lógica \cup y funciones de MATLAB.

$$E_T = \bigcup_{k=1}^n \text{translate}(E_k, (E_k^x, E_k^y)) \quad (1)$$

Una vez los polígonos E_k son desplazados inicialmente a su punto de referencia previamente establecido a través la función

“translate”, se obtiene E_T . Así, en segundo lugar, la evaluación de las soluciones candidatas se realiza minimizando la función F_{GLD} (ver (2)), que calcula el área de la diferencia entre E_T y el polígono de producción P_T a través de la función “subtract”. El área de esta diferencia poligonal se calcula con la función “area”.

$$F_{GLD}(E_T) = \text{area}(\text{subtract}(P_T, E_T)) \quad (2)$$

La definición general de este problema de optimización se puede formular en (3), donde el objetivo es encontrar la posición óptima de cada polígono de demanda de tal forma que, cuanto más se acerca a 0 el valor de F_{GLD} , mejor es la replicación. Las restricciones requieren que cada polígono de demanda permanezca en la región de interés. Es decir, limitan las coordenadas (E_k^x, E_k^y) respecto a los puntos de referencia $[E_{k,min}^x, E_{k,max}^x]$ y $[E_{k,min}^y, E_{k,max}^y]$

$$\begin{cases} \text{mín} & F_{GLD}(E_T) \\ E_1^x, E_1^y, \dots, E_n^x, E_n^y \\ \text{s.t.} & E_{k,min}^x \leq E_k^x \leq E_{k,max}^x \quad \forall i \in \{1, \dots, n\} \\ & E_{k,min}^y \leq E_k^y \leq E_{k,max}^y \quad \forall i \in \{1, \dots, n\} \end{cases} \quad (3)$$

2.3. Optimizador

Los algoritmos de optimización metaheurísticos inspirados en la naturaleza son una herramienta muy potente, ya que permiten obtener soluciones aceptables cuando una resolución exacta no es viable (Cruz et al., 2022). Entre ellos, los algoritmos evolutivos utilizan una población de soluciones candidatas que interactúan entre sí bajo un entorno simulado de aleatoriedad y evolución biológica (Boussaïd et al., 2013). Los AG posiblemente representan su exponente más visible por su gran rendimiento, simplicidad y adaptabilidad (Cruz et al., 2019).

La herramienta de optimización utilizada en este trabajo es el GA del Global Optimization Toolbox de MATLAB (Mathworks, 2023), en su estructura predeterminada. De acuerdo con su documentación oficial, el AG empieza inicializando una población de soluciones candidatas, i.e., crea aleatoriamente un número de vectores solución dentro de los límites de las condiciones iniciales. Éstos se evalúan de acuerdo con la función objetivo (3). Después del proceso de inicialización, el AG ejecuta su bucle principal con el objetivo de crear nuevos individuos para que evolucionen y así producir mejores soluciones candidatas tras varias iteraciones. Dicho bucle consta de los siguientes operadores genéticos: Selección, Generación de descendencia y Reemplazo.

El operador de selección inicia cada bucle evolutivo. Éste elige varios individuos de la población para que sean los padres de una nueva generación de soluciones candidatas Zhang et al. (2022). La generación de descendientes crea los nuevos individuos que formarán la población de la siguiente iteración. Consiste en selección de élite, cruce y mutación. La selección de élite toma directamente a los mejores individuos para la siguiente población. El cruce utiliza a los padres previamente escogidos para crear nuevas soluciones que combinen parte de sus cualidades y que, además, pueden sufrir modificaciones (mutaciones) según una cierta probabilidad. El reemplazo cierra cada iteración haciendo que estos nuevos individuos formen la población del siguiente ciclo (Cruz et al., 2019).

2.4. Particularidades

Llegados a este punto es importante destacar varios detalles antes de concluir esta sección. En primer lugar, la representación poligonal del problema tratado es general e independiente del optimizador usado. De hecho, se trata de la principal aportación del trabajo. Por tanto, y aunque se apueste por el mencionado AG, se podría utilizar cualquier otro optimizador de propósito general.

En segundo lugar, el AG, como la gran mayoría de metaheurísticas bio-inspiradas, es de naturaleza estocástica. Ésto significa que la calidad de sus soluciones puede variar entre ejecuciones para un mismo problema. Sin embargo, dejando al método operar hasta que toda su población de soluciones converge, y siendo ésta suficientemente grande, es improbable que haya divergencias significativas entre ejecuciones. Además, dado que los métodos acaban con bastante margen de tiempo, siempre cabe la posibilidad de probar varios lanzamientos y quedarse con la mejor solución de todos ellos.

En tercer y último lugar, y como se anticipa, se han omitido los detalles tanto del tratamiento del problema como una composición de polígonos como del propio AG. Por tanto, se recomienda al lector interesado consultar (Topa et al., 2023) para más información.

3. Análisis de resultados

A fin de evaluar la estrategia de GLD se han propuesto dos escenarios de simulación. Éstos han contado con datos reales de consumo y producción de energía de un edificio bioclimático ubicado en el centro de investigación CIESOL de la Universidad de Almería. Esta metodología ha sido implementada en MATLAB utilizando un conjunto de funciones útiles para la operación de polígonos (polyshape) y el AG integrado en el paquete “Global Optimization Toolbox”(Mathworks, 2023). El objetivo principal es consumir la mayor cantidad de energía posible del perfil de producción, es decir, intentar cubrir la totalidad del perfil de producción ubicando los polígonos de demanda. Así, los parámetros de control utilizados en esta metodología se muestran en Tabla 1.

3.1. Primer caso

Para este caso se dispone de un perfil de producción construido con datos de una planta fotovoltaica instalada en el edificio CIESOL. El polígono de producción se ha construido a partir de dichos datos con un tiempo de muestreo de 1h, como se muestra en el gráfico inferior de la Figura 3. Éste corresponde a un día soleado de verano, con una ligera disminución a medio día solar debido a la presencia de sombras. Su valor energético total aproximado es de 22kWh, mientras que la energía total de la demanda es cercana a 23kWh. Después de definir los perfiles iniciales, el polígono de demanda se divide en cuatro demandas de energía diferentes. Ésto se muestra en el gráfico superior de la Figura 3, donde cada polígono representa el consumo de energía de los diferentes dispositivos que operan en una de las oficinas del CIESOL.

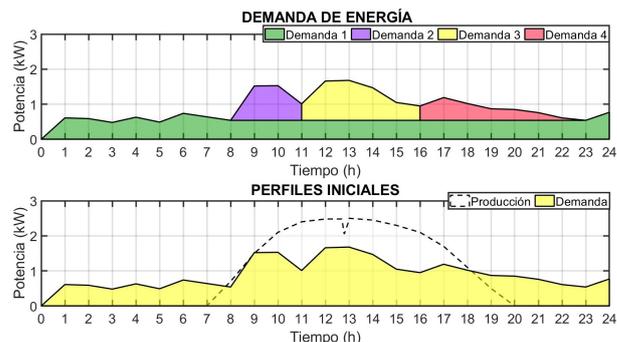


Figura 3: Situación inicial. Primer caso.

Los resultados de nuestra metodología se presentan en la Figura 4. En ella puede verse cómo logra gestionar correctamente la demanda energética de la oficina. Dicho de otra forma, los perfiles de demanda son desplazados hacia el perfil de producción de energía correspondiente a la producción energética fotovoltaica. Por otro lado, una vez que el algoritmo obtuvo las posiciones óptimas de cada una de las demandas, se genera un polígono total de consumo de energía. Éste se representa con una línea entrecortada roja, como se ve en el gráfico superior de la Figura 4. Por lo tanto, se mejora el aprovechamiento de las FER, mientras que al mismo tiempo se reduce el consumo de FEF. Además, el exceso de energía que se muestra en el gráfico inferior de la Figura 4 puede ser aprovechado por un SAE.

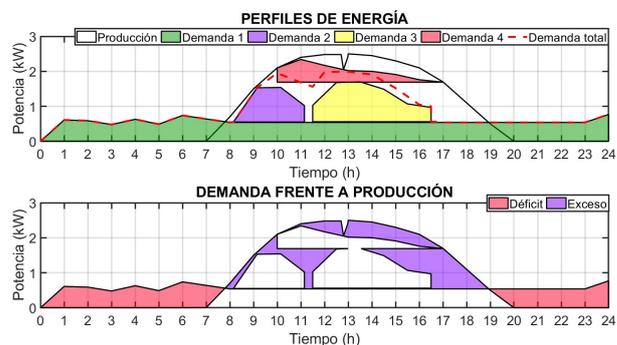


Figura 4: Resultados del optimizador. Primer caso.

3.2. Segundo caso

El segundo caso responde al perfil de producción conformado por mediciones de una planta fotovoltaica y un sistema de almacenamiento de energía por batería. El polígono de producción de ambas fuentes de energía se ha construido a partir de la recolección de datos muestreados a 1h, (ver Figura 5). Se corresponde con un día soleado de verano, junto a la respuesta a la demanda de una batería. El valor energético total aproximado del perfil de producción es 40kWh, mientras que la energía total demandada asciende a 32kWh. Además, el polígono de demanda se divide en cuatro demandas diferentes de energía, como se muestra en el gráfico superior de la Figura 5. Como en el caso anterior, estos polígonos representan el consumo de energía de los dispositivos que operan en la oficina del CIESOL.

Tabla 1: Parámetros para simulación del AG.

Caso	Población	Tolerancia	Parámetros de optimización	Tiempo máximo	Generaciones
1	200	0.005	4	10000	36
2	200	0.005	4	10000	36

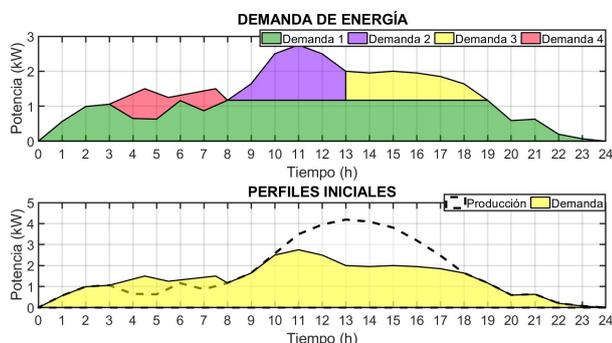


Figura 5: Situación inicial. Segundo caso.

La Figura 6 muestra los resultados de nuestra metodología para gestionar la demanda energética de la oficina. De esta forma, los perfiles de demanda son desplazados dentro del perfil de producción para cubrir la mayor demanda posible. A través de estos desplazamientos, el optimizador obtiene las posiciones óptimas de cada uno de los polígonos de demanda, generando así un polígono global de consumo energético. Este último está representado por una línea entrecortada roja, como se observa en el gráfico superior de la Figura 6. Como se puede apreciar, nuestra metodología maximiza el consumo de las FER mientras que al mismo tiempo reduce el consumo de las FEF. Igualmente, como en el caso previos el exceso de energía puede ser vertido directamente a la carga de la batería.

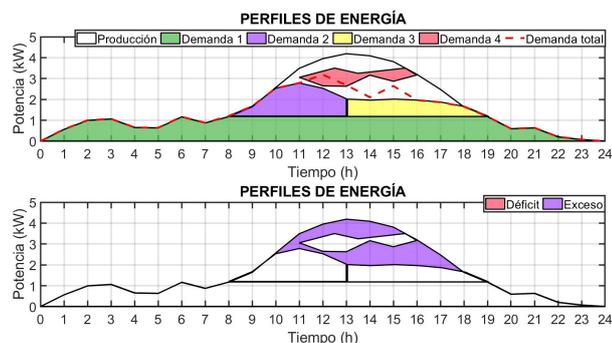


Figura 6: Resultados del optimizador. Segundo caso.

4. Conclusiones

Se ha propuesto una estrategia de gestión energética en el lado de la demanda para la operación de microrredes. Esta se basa en representar los perfiles de producción y demanda mediante polígonos. La idea es ubicar los distintos polígonos de demanda para cubrir el máximo posible de la de producción, lo que se modela como un problema de optimización. Para abordar dicho problema se apuesta por un algoritmo genético.

La metodología propuesta se ha implementado en MATLAB y se ha probado en simulación con datos reales de producción y consumo de energía. La metodología demuestra

una gestión exitosa de la demanda de energía trabajando con polígonos. El algoritmo genético es capaz de adaptarse correctamente al contexto que se le muestra. Desplaza los perfiles de demanda y compone distintas soluciones. Tras acabar su ejecución consigue ubicar las demandas de forma que se ajustan al perfil de producción. Por lo tanto, las demandas se posicionan de tal forma que se maximiza el consumo de la producción de energía, se reduce la dependencia de las FEF, la factura de energía e, indirectamente, las emisiones de CO_2 .

Como trabajos futuros se va a extender la formulación del problema de optimización para soportar restricciones específicas. Concretamente, se pueden encontrar situaciones en los que algunos perfiles de demanda sean fijos y no puedan moverse con total libertad.

Agradecimientos

Este trabajo ha sido financiado por el COMMIT4.0EB, España (ref. PID2021-126889OB-I00) financiado por MCIN/AEI/10.13039/501100 011033 y por “ERDF A way of make Europe”. N.C. Cruz cuenta con el apoyo de la Consejería de Transformación Económica, Industria, Conocimiento y Universidades de la Junta de Andalucía, España (PAIDI 2021: POST-DOC_21_00124)

Referencias

- Al Dakheel, J., Del Pero, C., Aste, N., Leonforte, F., 2020. Smart buildings features and key performance indicators: A review. *Sustainable Cities and Society* 61, 102328. DOI: <https://doi.org/10.1016/j.scs.2020.102328>
- Behera, S., Dev Choudhury, N. B., 2023. Adaptive optimal energy management in multi-distributed energy resources by using improved slime mould algorithm with considering demand side management. *e-Prime - Advances in Electrical Engineering, Electronics and Energy* 3, 100108. DOI: <https://doi.org/10.1016/j.prime.2023.100108>
- Boussaïd, I., Lepagnot, J., Siarry, P., 2013. A survey on optimization metaheuristics. *Information Sciences* 237, 82–117, prediction, Control and Diagnosis using Advanced Neural Computations. DOI: <https://doi.org/10.1016/j.ins.2013.02.041>
- Chung, H., shik Shin, K., 6 2020. Genetic algorithm-optimized multi-channel convolutional neural network for stock market prediction. *Neural Computing and Applications* 32, 7897–7914. DOI: 10.1007/S00521-019-04236-3/TABLES/7
- Cruz, N., Redondo, J. L., Ortigosa, E., Ortigosa, P., 2022. On the design of a new stochastic meta-heuristic for derivative-free optimization. *Computational Science and Its Applications—ICCSA 2022 Workshops: Malaga, Spain, July 4–7, 2022, Proceedings, Part II*, 188–200. DOI: https://doi.org/10.1007/978-3-031-10562-3_14
- Cruz, N. C., Salhi, S., Redondo, J. L., Álvarez, J. D., Berenguel, M., Ortigosa, P. M., 3 2019. Design of a parallel genetic algorithm for continuous and pattern-free heliostat field optimization. *Journal of Supercomputing* 75, 1268–1283. DOI: 10.1007/S11227-018-2404-8/FIGURES/6
- Eisenmann, A., Streubel, T., Rudion, K., 2022. Power quality mitigation via smart demand-side management based on a genetic algorithm. *Energies* 15 (4). DOI: 10.3390/en15041492

- Gelazanskas, L., Gamage, K. A., 2014. Demand side management in smart grid: A review and proposals for future direction. *Sustainable Cities and Society* 11, 22–30.
DOI: <https://doi.org/10.1016/j.scs.2013.11.001>
- Konak, A., Coit, D. W., Smith, A. E., 2006. Multi-objective optimization using genetic algorithms: A tutorial. *Reliability Engineering & System Safety* 91 (9), 992–1007, special Issue - Genetic Algorithms and Reliability.
DOI: <https://doi.org/10.1016/j.ress.2005.11.018>
- Lizana, J., Friedrich, D., Renaldi, R., Chacartegui, R., 2018. Energy flexible building through smart demand-side management and latent heat storage. *Applied Energy* 230, 471–485.
DOI: <https://doi.org/10.1016/j.apenergy.2018.08.065>
- Mathworks, 2023. Global Optimization Toolbox - MATLAB. <https://es.mathworks.com/products/global-optimization.html>, Accessed on: 30 May 2023.
- Maślak, G., Orłowski, P., 2022. Microgrid operation optimization using hybrid system modeling and switched model predictive control. *Energies* 15 (3).
DOI: 10.3390/en15030833
- Sardar, A., Khan, S. U., Hassan, M. A., Qureshi, I. M., 2023. A demand side management scheme for optimal power scheduling of industrial loads. *Energy Systems* 14 (2), 335–356.
DOI: <https://doi.org/10.1007/s12667-022-00510-x>
- Sarker, E., Halder, P., Seyedmahmoudian, M., Jamei, E., Horan, B., Mekhilef, S., Stojcevski, A., 1 2021. Progress on the demand side management in smart grid and optimization approaches. *International Journal of Energy Research* 45, 36–64.
DOI: 10.1002/ER.5631
- Serale, G., Fiorentini, M., Capozzoli, A., Bernardini, D., Bemporad, A., 2018. Model predictive control (mpc) for enhancing building and hvac system energy efficiency: Problem formulation, applications and opportunities. *Energies* 11 (3).
DOI: 10.3390/en11030631
- Sharda, S., Singh, M., Sharma, K., 2021. Demand side management through load shifting in iot based hems: Overview, challenges and opportunities. *Sustainable Cities and Society* 65, 102517.
DOI: <https://doi.org/10.1016/j.scs.2020.102517>
- Tang, R., Wang, S., Li, H., 2019. Game theory based interactive demand side management responding to dynamic pricing in price-based demand response of smart grids. *Applied Energy* 250, 118–130.
DOI: <https://doi.org/10.1016/j.apenergy.2019.04.177>
- Topa, A., Cruz, N., Álvarez, J., Torres, J., 2023. On the optimal demand-side management in microgrids through polygonal composition. *Sustainable Energy, Grids and Networks* 34, 101066.
DOI: <https://doi.org/10.1016/j.segan.2023.101066>
- Topa Gavilema, A. O., Gil, J. D., Álvarez Hervás, J. D., Torres Moreno, J. L., García, M. P., 2023. Modeling and energy management of a microgrid based on predictive control strategies. *Solar* 3 (1), 62–73.
DOI: 10.3390/solar3010005
- Zhang, X., Fan, X., Yu, S., Shan, A., Fan, S., Xiao, Y., Dang, F., 2022. Intersection signal timing optimization: A multi-objective evolutionary algorithm. *Sustainability* 14 (3).
DOI: 10.3390/su14031506