TecnoLógicas

Aplicación de un enfoque basado en dinámicas poblacionales para la gestión energética en microrredes interconectadas

Application of a Population Dynamics-Based Approach for Energy Management in Interconnected Microgrids

Sara Melo[1]; Germán Obando[1]; Andrés Pantoja[1]

[1]Universidad de Nariño, Pasto - Colombia

Correspondencia: sgmelo@udenar.edu.co

Recibido: 08 Septiembre 2025 **Aceptado:** 28 Septiembre 2026 **Disponible:** 09 Octubre 2026

Cómo citar / How to cite
S. Melo, G. Obando, and A. Pantoja, "Aplicación de un enfoque basado en dinámicas poblacionales para la gestión energética en microrredes interconectadas," *TecnoLógicas*, vol. 29, no. 67, e3641, 2026.
https://doi.org/10.22430/22565337.3641

CC BY NC SA

Resumen

Las dinámicas poblacionales proporcionan un modelo robusto para asignar recursos entre agentes de manera distribuida. Esta investigación tuvo como objetivo desarrollar y evaluar un algoritmo jerárquico basado en replicadores dinámicos (RD) para resolver el despacho óptimo de potencia activa en microrredes interconectadas. La metodología empleada consistió en formular una arquitectura con dos niveles acoplados: en el nivel inferior, cada microrred distribuye localmente la carga asignada entre sus unidades generadoras usando RD; en el nivel superior, un replicador adicional redistribuye la demanda total entre las microrredes con base en información agregada del nivel local. Cada microrred calcula y transmite variables agregadas, mientras que el nivel superior calcula y comunica una función de desempeño (o *fitness*) promedio global, preservando la privacidad de los datos. El algoritmo se evaluó en dos casos de estudio con múltiples microrredes, considerando variaciones en la demanda. La validación incluyó comparaciones con *quadprog,* como referencia de optimización centralizada estándar, y con un algoritmo de optimización por enjambre de partículas (PSO, por sus siglas en inglés). En los escenarios evaluados, la brecha relativa máxima de costo respecto de *quadprog* fue 1.90×10^{-9}. En todas las pruebas, el error de balance entre generación y carga alcanzado por RD fue menor que 3.33×10^{-12} y no se presentaron violaciones de los límites operativos. Los resultados mostraron que el método produjo soluciones consistentes con la referencia centralizada. Finalmente, se concluye que, dentro de los casos estudiados, la arquitectura jerárquica propuesta permite resolver el despacho sin centralizar datos individuales de las unidades generadoras, limitando el intercambio a variables agregadas por microrred.

Palabras clave

Despacho económico, dinámicas poblacionales, microrredes interconectadas, replicadores dinámicos, teoría de juegos evolutivos.

Abstract

Population dynamics provide a model for allocating resources among multiple agents in a distributed manner. This research aimed to develop and evaluate a hierarchical algorithm based on replicator dynamics (RD) to solve the problem of optimal active power dispatch in interconnected microgrids. The employed methodology consisted of formulating an architecture with two coupled levels: at the lower hierarchical level, each microgrid locally distributes its own assigned load among its generating units using RD; at the upper level, an additional replicator model redistributes the total demand among the microgrids based on aggregated information received directly from the local level. Within this structured framework, each microgrid calculates and transmits aggregated variables, while the upper level calculates and communicates a global average performance (or *fitness*) function, thereby preserving data privacy. The algorithm was evaluated in two case studies with multiple microgrids, considering demand variations. The validation included comparisons with *quadprog*, which acts as a standard centralized optimization reference, and with a particle swarm optimization (PSO) algorithm. In the evaluated scenarios, the maximum relative cost gap observed with respect to *quadprog* was 1.90×10^{-9}. Furthermore, in all experimental tests, the generation-load balance error achieved by RD was strictly less than 3.33×10^{-12}, and no operational limit violations occurred. The results obtained showed that the method produced solutions that were fully aligned with the centralized reference. Finally, it is concluded that the proposed hierarchical architecture allows optimal dispatch to be solved in interconnected microgrids without centralizing individual data from the generating units, effectively limiting exchange to aggregated variables per microgrid.

Keywords

Economic dispatch, population dynamics, interconnected microgrids, replicator dynamics, evolutionary game theory.

1. INTRODUCCIÓN

El despacho óptimo de potencia activa en microrredes interconectadas (PDPMI) requiere coordinar múltiples fuentes de generación para satisfacer la demanda y minimizar el costo total de operación. Esta coordinación resulta compleja porque las decisiones internas de cada microrred deben articularse con la distribución de potencia entre las diferentes áreas del sistema, preservando los límites operativos y la autonomía de los participantes [1]. Los métodos centralizados pueden resolver este problema cuando se dispone de información completa. Sin embargo, requieren concentrar los parámetros técnicos y económicos de todas las unidades generadoras en un único coordinador. Por esta razón, los enfoques descentralizados y distribuidos han cobrado relevancia, pues permiten reducir el intercambio de información, preservar la autonomía de las áreas y mejorar la resiliencia del sistema [2].

En la literatura se han propuesto diferentes metodologías para resolver problemas de despacho en sistemas multiárea con microrredes interconectadas. Los enfoques descentralizados buscan conservar la autonomía de las áreas y reducir algunas de las limitaciones asociadas con la coordinación centralizada [3]. También se han utilizado técnicas de descomposición, como el método de Benders, y metaheurísticas basadas en colonias de hormigas, optimización evolutiva y enjambres de partículas [4], [5]. De manera complementaria, se han desarrollado modelos robustos para considerar la incertidumbre asociada con la variabilidad de la generación renovable y la demanda [6].

Otros trabajos combinan métodos de consenso y estrategias de co-optimización para mejorar la flexibilidad del despacho en sistemas interconectados [7], [8]. Asimismo, se han utilizado métodos distribuidos basados en ADMM y consenso para coordinar el despacho entre agentes y áreas [9]. Dentro de las metaheurísticas, se han propuesto algoritmos multiobjetivo, como el Multi-Objective Squirrel Search Algorithm (MOSSA), para minimizar simultáneamente los costos de generación y las emisiones contaminantes [10]. Además, la incorporación de vehículos eléctricos y sistemas de almacenamiento se considera una alternativa para aumentar la flexibilidad operativa y reducir el efecto de la incertidumbre sobre el despacho [11], [12].

Dado que el PDPMI es fundamentalmente un problema de asignación de recursos (demanda distribuida entre las unidades generadoras del sistema), las dinámicas poblacionales constituyen una alternativa para coordinar agentes que compiten por un recurso limitado. Estos modelos, inspirados en la teoría de juegos evolutivos, describen cómo las decisiones de una población

cambian de acuerdo con el desempeño relativo de las estrategias disponibles [13]. En los replicadores dinámicos, las estrategias con un desempeño superior al promedio aumentan su participación, mientras que aquellas con un desempeño inferior la reducen; este comportamiento se ha utilizado recientemente en problemas de control, optimización y asignación dinámica de recursos [14].

Las dinámicas poblacionales también se han utilizado para modelar la cooperación en sistemas multi-agente. En [15] se propone un modelo que combina incentivos institucionales y mecanismos de reciprocidad para promover comportamientos cooperativos. En un sistema energético, una interpretación relacionada consiste en considerar a las unidades generadoras como agentes que ajustan sus decisiones de acuerdo con su desempeño económico y con las condiciones de operación del sistema.

En el campo de la gestión energética, se han presentado aplicaciones directas de replicadores dinámicos y ecuaciones distribuidas para resolver problemas de despacho económico en microrredes [16], [17], [18], [19]. En estos enfoques, las unidades generadoras se representan como estrategias y la demanda asignada a cada unidad corresponde a la proporción de la población que utiliza dicha estrategia. Al definir la función de desempeño o fitness a partir del costo marginal, la dinámica redistribuye la demanda hasta alcanzar una condición de equilibrio compatible con la solución del problema de optimización. Estas formulaciones permiten realizar la asignación de recursos utilizando información local y pueden preservar las restricciones operativas a partir de condiciones iniciales factibles [19].

Más recientemente, el aprendizaje por refuerzo multi-agente se ha empleado para coordinar múltiples microrredes. Entre las aplicaciones del aprendizaje por refuerzo se encuentra una arquitectura jerárquica para sistemas multienergía [20], un esquema federado para el despacho cooperativo [21] y un método seguro para la operación descentralizada de redes activas con múltiples microrredes [22]. Estas metodologías están principalmente orientadas a problemas con decisiones secuenciales, incertidumbre y entrenamiento basado en datos. El enfoque considerado en este artículo tiene un alcance diferente: partiendo de un problema convexo conocido, se obtiene un método completamente interpretable puesto que su evolución se basa en equilibrar los costos marginales de las unidades generadoras.

A pesar de los avances descritos, la aplicación de replicadores dinámicos se ha concentrado principalmente en microrredes aisladas o en problemas de una sola área. En estos casos, la generación y la demanda se coordinan dentro de un único sistema. En una estructura de microrredes interconectadas, en cambio, es necesario resolver dos problemas relacionados: distribuir la demanda total entre las microrredes y, simultáneamente, distribuir la demanda asignada a cada microrred entre sus unidades generadoras. Esta coordinación debe realizarse sin concentrar en un único punto toda la información técnica y económica de las unidades.

La organización jerárquica constituye una alternativa natural para abordar este problema. En el nivel local, cada microrred puede determinar la distribución de carga entre sus unidades generadoras. En el nivel superior, la demanda global puede distribuirse entre las microrredes utilizando información agregada sobre sus condiciones de operación. Sin embargo, la integración de ambos niveles mediante dinámicas poblacionales requiere garantizar la consistencia entre las asignaciones locales y globales, y verificar la optimalidad y factibilidad de las soluciones obtenidas.

En este contexto, el objetivo de este trabajo fue desarrollar y evaluar un algoritmo jerárquico basado en replicadores dinámicos para resolver el despacho óptimo de potencia activa en microrredes interconectadas. La propuesta utilizó dos niveles acoplados. En el nivel inferior, cada microrred distribuye localmente la carga asignada entre sus unidades generadoras. En el nivel superior, un replicador adicional redistribuye la demanda total entre las microrredes con base en información agregada proveniente del nivel local.

Las contribuciones del trabajo fueron las siguientes. Primero, se formuló un flujo jerárquico de información en el que cada microrred calcula y transmite variables agregadas, mientras que el nivel superior calcula y comunica una fitness promedio global. Segundo, se estableció una implementación que satisface el balance de potencia y los límites operativos a partir de

una condición inicial factible. Tercero, el algoritmo se comparó con una referencia centralizada estándar, quadprog, y con un método de optimización por enjambre de partículas (PSO). Además, se analizó su comportamiento frente a diferentes condiciones iniciales, niveles de demanda, y cambios escalonados de carga. La formulación del replicador dinámico y la selección de la fitness se basaron en desarrollos previos; la contribución del presente trabajo se concentró en la organización jerárquica del proceso de coordinación y en su evaluación para microrredes interconectadas.

El resto del artículo está organizado de la siguiente manera. La Sección 2 presenta la formulación matemática del PDPMI, el modelo de replicador dinámico, la arquitectura jerárquica y el procedimiento de implementación numérica. La Sección 3 describe los casos de estudio, presenta los resultados y compara el algoritmo con los métodos de referencia. También se analizan la sensibilidad del método, su respuesta ante cambios escalonados de demanda y sus principales limitaciones. Finalmente, la Sección 4 presenta las conclusiones y las posibles líneas de trabajo futuro.

2. METODOLOGÍA

2.1 Planteamiento del problema

El costo de generación de un sistema con M microrredes se define en (1):

$$F = \sum_{m\in\mathcal{M}} \sum_{j\in\mathcal{J}^m} \left(A_{mj}P_{mj}^2 + B_{mj}P_{mj}\right), \tag{1}$$

donde J^m es el total de unidades generadoras (UG) de la MG m; P_{mj} es la potencia activa generada por la UG j en el área m, y la expresión $A_{mj}P_{mj}^2 + B_{mj}P_{mj}$ modela el costo de generación en el que incurre dicha UG, siendo A_{mj} y B_{mj} coeficientes de la función de costo [9].

El PDPMI tiene como objetivo minimizar la función de costo dada en (1) sujeto a las restricciones (2), (3), (4), (5):

$$\sum_{j\in\mathcal{J}^m} P_{mj} = n_m\,, \tag{2}$$

$$\sum_{m\in\mathcal{M}} \sum_{j\in\mathcal{J}^m} P_{mj} = n\,, \tag{3}$$

$$P_{min_{mj}} \le P_{mj} \le P_{max_{mj}}, \qquad \forall\, m \in M, \qquad \forall\, j \in J^m, \tag{4}$$

$$\textstyle\sum_{j\in\mathcal{J}^m} P_{min_{mj}} = n_{min_m} \le n_m \le \sum_{j\in\mathcal{J}^m} P_{max_{mj}} = n_{max_m}\,,\ \forall\, m \in M,\ \forall\, j \in J^m, \tag{5}$$

donde n_m y n representan la carga local del área m y la carga total que las M áreas deben abastecer, respectivamente; $P_{min_{mj}}$ y $P_{max_{mj}}$ representan las potencias mínimas y máximas que la UG j del área m puede generar; mientras que n_{min_m}y n_{max_m}son las cargas mínimas y máximas que se pueden abastecer en el área m.

Las restricciones dadas en (2) y (3) están asociadas con el balance de potencia, es decir, toda la potencia producida por el sistema se utiliza para abastecer la carga. Además, las restricciones dadas en (4) y (5) representan los límites de generación por UG y los límites de abastecimiento de carga por MG.

2.2 Solución mediante replicadores dinámicos (RD)

El RD es un modelo matemático inspirado en la teoría de juegos evolutivos que describe cómo las proporciones de individuos en una población cambian con el tiempo en función de su desempeño relativo o *fitness*. En este contexto, cada individuo elige una estrategia y la *fitness* mide qué tan favorable es el entorno actual para esa estrategia. El RD simula un proceso de selección natural donde las estrategias con una mejor *fitness* tienen una mayor probabilidad de ser replicadas en la población [19].

Para introducir el modelo matemático se considera una población de jugadores que es lo suficientemente grande, donde cada jugador tiene a su disposición un conjunto de estrategias $S = \{1, \dots, N\}$. La cantidad de individuos jugando la estrategia i está representada por $x_i(t) \geq 0$, y $x^T = [x_1, x_2, \dots, x_N]$ es el vector de estado de la población, que modela la distribución de los individuos entre las estrategias disponibles.

La ecuación de RD utilizada en este trabajo se basa en la formulación del modelo RD clásico. Sin embargo, con el fin de incorporar las restricciones del sistema (descritas en las ecuaciones (2)-(5)) se adapta la metodología propuesta en [19], donde se limita la cantidad de individuos que puede elegir cada estrategia. Es decir, la variable x_i está acotada por un límite superior, $\bar{x}_{ub_i}$, y uno inferior, $\bar{x}_{lb_i}$. De esta manera, el modelo propuesto se expresa como (6):

$$\dot{x}_i(t) = \hat{x_i}(t)\left(f_i - \hat{f}\right), \quad \forall\, i \in S, \tag{6}$$

donde f_i representa la *fitness* asociada a la estrategia i; $\hat{x_i}$ se define como (7):

$$\hat{x_i} = \left(x_i(t) - \bar{x}_{lb_i}\right)\left(\bar{x}_{ub_i} - x_i(t)\right), \quad \forall\, i \in S, \tag{7}$$

y $\hat{f}$ (cantidad llamada *fitness* promedio) está dada por (8):

$$\hat{f} = \frac{1}{\sum_{j \in S} \hat{x_j}} \sum_{j \in S} \hat{x_j}(t) f_j \,. \tag{8}$$

La *fitness* desempeña un papel crucial en el modelo del RD. De acuerdo con (6), las estrategias con *fitness* más alta que la promedio aumentan su proporción en la población, mientras que aquellas con menor *fitness* disminuyen. Se puede demostrar que este efecto conduce al sistema a un estado de equilibrio en el cual todas las estrategias cuya población no ha alcanzado su límite superior o inferior presentan el mismo nivel de *fitness*. De esta forma se logra una asignación óptima de los recursos disponibles (una demostración formal de esta propiedad puede encontrarse en [19]).

Teniendo en cuenta este contexto, el objetivo es ajustar continuamente las estrategias de los jugadores (por ejemplo, la potencia asignada a diferentes generadores si hablamos de despacho) para minimizar una función objetivo global, que se puede representar por una función potencial H. La idea general, es que las estrategias se ajusten en la dirección de mayor decrecimiento de H , es decir, actuando como un sistema de descenso de gradiente. Por tal razón, la *fitness* asociada a cada estrategia debe ser proporcional al cambio de la función objetivo cuando se modifica esa estrategia.

De hecho, según [19], si seleccionamos las funciones de *fitness* de la forma (9):

$$f_i = -\frac{\partial H}{\partial x_i} \quad \forall\, i \in S, \tag{9}$$

se garantiza que el sistema se mueva hacia un equilibrio en el cual la función $H(x)$ se minimiza.

Una propiedad clave del RD es la siguiente:

Teorema 1 - invarianza del simplex [19]: *Sea P el tamaño inicial de la población, tal que* $\sum_{i\in S} x_i(0) = P$. El simplex acotado que se muestra en (10) es invariante bajo el RD dado en (6).

$$\Delta = \left\{ y \in \mathbb{R}^N : \bar{x}_{lb} \leq y_i \leq \bar{x}_{ub} \, , \sum_{i\in S} y_i = P \right\}, \tag{10}$$

donde y_i es la *i-ésima* posición del vector *y*. Esto es, *x(t)*$\in \Delta$ para todo $t \geq 0$.

Observe que esta propiedad asegura que las restricciones del modelo poblacional planteado se respeten de forma natural durante la evolución del RD, siempre y cuando se parta de condiciones iniciales válidas.

2.3 Formulación jerárquica

Para resolver el PDPMI se propone una arquitectura jerárquica basada en dos niveles de RD. Esta estructura permite dividir el problema en subniveles coordinados: uno que actúa localmente dentro de cada MG y otro que distribuye la carga global entre las diferentes MG.

2.3.1 RD de nivel 1 (intra-microrred)

En el primer nivel jerárquico, se emplea un RD por cada MG, que se encarga de resolver el problema de despacho de potencia de forma local (RD intra-microrred). En este contexto, cada ecuación de los replicadores distribuye internamente la porción de carga asignada a su MG correspondiente (como se detalla en la Sección 2.3.2, esta asignación se hace en el nivel jerárquico superior) entre las UG de dicha MG. Por lo tanto, las estrategias de los RD se asocian con las UG disponibles. Además, como la cantidad de potencia asignada a cada UG busca minimizar el costo total de generación dado en (1), es conveniente, de acuerdo con la Ecuación (9), que las *fitness* del modelo de los RD se definan como el negativo del costo marginal de generación. De esta forma, los RD permiten que las potencias se redistribuyan continuamente hasta alcanzar un equilibrio donde todos los generadores operan con un costo marginal idéntico, minimizando así el costo total. Las columnas 1 y 2 de la Tabla 1 formalizan la analogía planteada, estableciendo la relación entre cada una de las variables que intervienen en la ecuación de los replicadores dada en (6)-(9) y las variables del problema de despacho intra-microrred.

Tabla 1. Variables usadas en el modelo RD de nivel 1 (intra-microrred) y nivel 2 (intra-microrred)
Fuente: elaboración propia.

Variable en el modelo de RD	Variable en el problema de despacho intra-microrred	Variable en el problema de despacho intra-microrred
Estrategias: $\boldsymbol{S}$	Conjunto de UG de la MG m: J^m	Conjunto total de áreas: M
Población que elige la estrategia i: $\boldsymbol{x_i(t)}$	Potencia activa generada por la UG j en el área m: P_{mj}	Carga por abastecer en el área m: n_m
Mínima población que puede elegir la estrategia i: $\bar{\boldsymbol{x}}_{\boldsymbol{lb_i}}$	Potencia límite mínima que la UG j del área m puede generar: $P_{min_{mj}}$	Carga límite mínima que el área m puede abastecer: n_{min_m}
Máxima población que puede elegir la estrategia i: $\bar{\boldsymbol{x}}_{\boldsymbol{ub_i}}$	Potencia límite máxima que la UG j del área m puede generar: $P_{max_{mj}}$	Carga límite máxima que el área m puede abastecer: n_{max_m}
Fitness de la población que ha elegido la estrategia i: $\boldsymbol{f_i(x)}$	Negativo de los costos marginales asociados a la producción de potencia en la UG j en el área m: $-\frac{\partial F}{\partial P_{mj}} = -2(A_{mj}P_{mj}) - B_{mj}$	*Fitness* promedio de los RD correspondientes a la MG m: $-\frac{1}{\sum_{j\in S}\hat{x_j}} \sum_{j\in S} \hat{x_j}(t) \frac{\partial F}{\partial P_{mj}}$.
Tamaño población: $\boldsymbol{P}$	Carga del área m: n_m	Carga total por abastecer: n

Es importante señalar que una propiedad clave del modelo de los RD es que preserva el *simplex* (formulado en la Ecuación (10)) en el tiempo (Teorema 1). Note que, de acuerdo con la analogía planteada en la Tabla 1, esta propiedad implica que, partiendo de condiciones iniciales apropiadas, la solución dada por los RD respeta las restricciones del problema de despacho intra-microrred. Esto es, las restricciones (2) y (4) del PDPMI.

En resumen, el primer nivel jerárquico permite que cada MG resuelva su problema de optimización local con base en la carga asignada. Los resultados de esta etapa proporcionan los despachos de potencia por UG y permiten calcular la *fitness* promedio de cada MG, la cual será utilizada por el nivel jerárquico superior.

2.3.2 RD de nivel 2 (intra-microrred)

En el segundo nivel de la arquitectura jerárquica, se propone un único modelo de RD que actúa sobre el conjunto de MG. Este RD tiene como objetivo distribuir la demanda total del sistema entre las diferentes MG, considerando sus condiciones operativas actuales y su eficiencia relativa.

La dinámica de este nivel se basa en la información agregada proveniente de cada MG, en particular los valores del costo marginal promedio de generar energía en cada una de ellas. A partir de esta información, el modelo de RD ajusta progresivamente la asignación de carga entre las microrredes, favoreciendo a aquellas con condiciones más favorables, en términos de costos o disponibilidad de generación. Las columnas 1 y 3 de la Tabla 1 contienen la representación e interpretación de las variables usadas para implementar el RD del nivel 2. Además, en este nivel jerárquico, la asignación de variables dadas en la Tabla 1 y la propiedad descrita en el Teorema 1 garantizan que el RD satisfaga las restricciones del problema intra-microrred (restricciones (3) y (5) del PDPMI).

El esquema propuesto permite que la redistribución de la carga entre MG se realice de manera coordinada, mientras que cada MG continúa ajustando internamente su estrategia de despacho en el nivel inferior. Como se describe en la siguiente sección, la interacción iterativa entre ambos niveles guía al sistema hacia un equilibrio en el que se optimiza globalmente el despacho de potencia activa.

Gracias a la estructura jerárquica del modelo, el proceso evoluciona respetando las restricciones técnicas del sistema en cada nivel, y permitiendo que tanto las estrategias de generación como las asignaciones de carga converjan simultáneamente hacia la solución óptima, tal y como se muestra en la sección de resultados.

2.4 Formulación jerárquica

A continuación, se describe el funcionamiento del algoritmo jerárquico, cuyo proceso iterativo lleva a la solución del PDPMI dado en (1)-(5). El algoritmo se compone de las siguientes etapas principales:

Inicialización: Se definen los parámetros del sistema, incluyendo el número de MG, UG, demanda total, costos de generación, límites operativos de cada generador, iteraciones y tiempo de ejecución de las ecuaciones diferenciales correspondientes a los RD. Se establecen las condiciones iniciales para las variables de generación de potencia y para la asignación de carga por MG. Las condiciones iniciales deben satisfacer las restricciones dadas en (2)-(5) en cada caso.

Iteración:

i) Implementación del RD del nivel 1: En cada iteración, se implementa el RD para solucionar el problema de despacho de potencia al interior de cada MG tal como se describe en la subsección 2.3.1.

ii) Cálculo de fitness promedio por MG: A partir de las soluciones encontradas en el paso (i) se calcula la *fitness* promedio de cada MG usando (8).

iii) Implementación del RD de nivel 2: El algoritmo de nivel jerárquico superior ajusta la carga de cada MG mediante la implementación del RD como se describe en la subsección 2.3.2.

iv) Actualización de estrategias de carga: A partir de las soluciones halladas en el paso (iii), se actualizan las cargas que las MG deben suplir para la siguiente iteración. Este proceso se repite hasta alcanzar el número de iteraciones propuestas al inicio. A medida que el algoritmo avanza, la distribución de potencia se ajusta, y las *fitness* promedio de cada MG tienden a igualarse, lo que indica que se alcanza progresivamente la solución óptima.

Resultados: Al finalizar el proceso, el algoritmo obtiene el despacho óptimo de potencia para cada UG, lo que garantiza que la demanda total sea satisfecha al menor costo posible.

La Figura 1 ilustra las etapas del algoritmo descrito anteriormente.

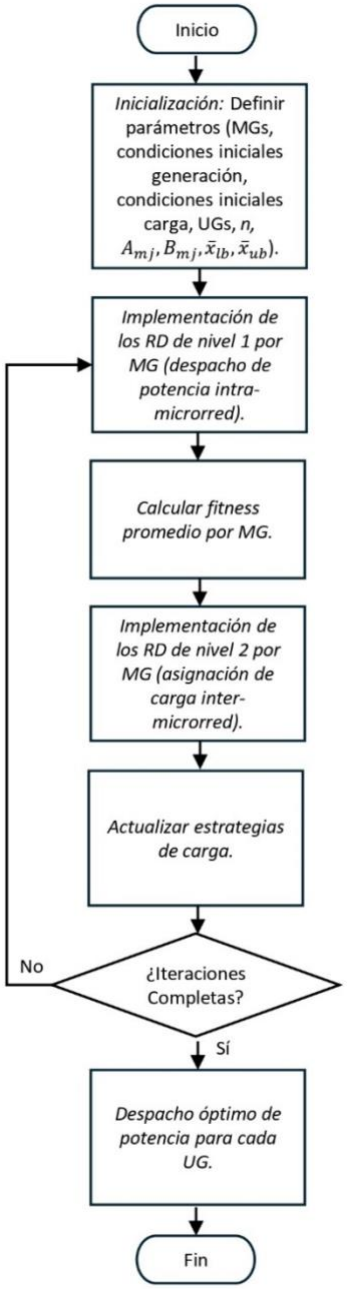


Figura 1. Diagrama de flujo que ilustra las etapas del algoritmo propuesto
Fuente: elaboración propia.

2.5 Implementación numérica y evaluación

2.5.1 Procedimiento de solución

Observe que en el algoritmo descrito en la Figura 1, en cada iteración se debe encontrar la solución de dos modelos de RD, uno por nivel jerárquico. Esto implica la solución de un conjunto de ecuaciones diferenciales. Dicha solución se ejecuta usando métodos numéricos. Específicamente, el procedimiento se describe a continuación.

Se inicia con una condición estrictamente factible. Para generarla se obtiene un vector aleatorio dentro de una caja reducida en 10^{-4} del intervalo de cada UG y se proyecta, en distancia euclidiana, sobre el conjunto definido por el balance y los límites. Se usa el generador twister con semillas fijas. En cada evaluación del campo vectorial, las MG calculan las variables correspondientes, el nivel superior calcula $\bar{f}$ y las UG actualizan sus potencias mediante (6).

Las ecuaciones diferenciales se resolvieron con ode45. Se usaron RelTol = 1e-8, AbsTol = 1e-10 y MaxStep = 1. La integración se realizó en bloques de 100 unidades de tiempo. En las pruebas se fijó un horizonte máximo de 6000 unidades.

El residuo de gradiente proyectado se define como (11):

$$r_{PG} = \left\| P - \Pi_{\Omega}\left(P - \nabla F(P)\right) \right\|_{\infty}, \tag{11}$$

donde Π_{Ω} es la proyección sobre el conjunto factible Ω dado por las restricciones (2)-(5). El algoritmo se considera convergente cuando el residuo es menor o igual que 1e-6 y la norma infinita de la derivada es menor o igual que 1e-8 durante tres bloques consecutivos. También se registran la brecha relativa de costo, el error de balance y la violación máxima de límites.

2.5.2 Métodos de comparación

El optimizador *quadprog* se usó como referencia porque (1)-(5) definen un problema cuadrático convexo. Se empleó el algoritmo interior-point-convex, tolerancias de optimalidad y restricciones de 10^{-10}, tolerancia de paso de 10^{-12} y un máximo de 1000 iteraciones. Se realizó una ejecución de calentamiento y se reportó la mediana de 30 repeticiones.

El PSO se implementó sin penalizaciones. Cada partícula se proyectó después de cada actualización sobre el conjunto factible. Se usaron 60 partículas, 400 iteraciones máximas, inercia decreciente de 0.9 a 0.4, coeficientes cognitivo y social de 1.7, y 20 ejecuciones con semillas distintas. El criterio de estancamiento fue de 40 iteraciones con una tolerancia relativa de 10^{-10}.

2.5.3 Configuración computacional y complejidad

Las pruebas se ejecutaron en MATLAB R2024b en un computador con procesador Intel Core i7-8700K y 32 GB de RAM. Los tiempos se midieron con tic y toc. Para el RD se reportó la mediana de cinco ejecuciones con la misma condición inicial. Para PSO se reportaron la mediana, el mejor y el peor resultado de 20 ejecuciones.

Sea N el número total de UG y M el número de MG. Una evaluación del campo vectorial requiere $O(N+M)$ operaciones y $O(N+M)$ memoria. Esta estimación no incluye el número adaptativo de evaluaciones de ode45. En PSO, el costo por iteración es $O(SN)$, donde S es el número de partículas.

3. RESULTADOS Y DISCUSIÓN

3.1 Categorización de escenarios de estudio

Para demostrar la efectividad y aplicabilidad en la solución del PDPMI del algoritmo anteriormente propuesto, se definen dos tipos de escenarios de prueba. El Caso I corresponde a un escenario conformado por cuatro microrredes con límites de generación pequeños, donde se evalúa la capacidad del algoritmo para responder a condiciones en las que algunas UG llegan a sus límites de operación y la carga debe redistribuirse entre diferentes MG. El Caso II es un escenario compuesto por siete microrredes, donde el sistema se ve forzado a operar bajo un número elevado de restricciones activas. Este escenario es propicio para analizar el comportamiento del algoritmo al gestionar un sistema que es llevado a trabajar cerca de sus límites técnicos.

La selección de estos casos de estudio permite además analizar el desempeño del algoritmo en diferentes condiciones operativas, incluyendo variaciones en la demanda, la disponibilidad de recursos energéticos y las características de los generadores distribuidos.

3.2 Casos de estudio

El Caso I presenta un sistema de $M = 4$ microrredes interconectadas (MGIs), donde es necesario suplir una demanda total de $n = 4$ kW. La Tabla 2 muestra los parámetros de las UG disponibles por MG. Los parámetros $P_{min_{mj}}$ y $P_{max_{mj}}$ vienen dados en kW, mientras que A_{mj} en \$/kW^2 y B_{mj} en \$/kW. El algoritmo trabaja con un total de 500 iteraciones.

Tabla 2. Parámetros por generador del caso de estudio I. Fuente: elaboración propia.

Generador g_{mj}	$P_{min_{mj}}$	$P_{max_{mj}}$	A_{mj}	B_{mj}
g_{11}	0.1	0.7	0.8407	0.2435
g_{12}	0.1	0.4	0.2543	0.9293
g_{13}	0	0.5	0.8143	0.3500
g_{21}	0.2	0.8	0.1966	0.6160
g_{22}	0	0.5	0.2511	0.4733
g_{31}	0.2	0.8	0.6377	0.2891
g_{32}	0	0.5	0.9577	0.6718
g_{33}	0.2	0.7	0.2407	0.6951
g_{34}	0.3	0.8	0.6761	0.0680
g_{41}	0.2	0.8	0.2548	0.7805
g_{42}	0	0.5	0.2240	0.6753
g_{43}	0.2	0.7	0.6678	0.0067
g_{43}	0.3	0.8	0.8444	0.6022
g_{43}	0.1	0.6	0.3445	0.3868

El Caso II incluye un sistema de $M = 7$ MGIs, donde es necesario suplir una demanda total de $n = 12$ kW. Para este escenario, los parámetros de las UG se muestran en la Tabla 3. Puede notarse que los parámetros de las UG de las cuatro primeras MG coinciden con los presentados en el caso de estudio I (Tabla 2). Además, el número de iteraciones elegido fue nuevamente 500.

Tabla 3. Parámetros por generador del caso de estudio II. Fuente: elaboración propia.

Generador g_{mj}	$P_{min_{mj}}$	$P_{max_{mj}}$	A_{mj}	B_{mj}
g_{11}	0.1	0.7	0.8407	0.2435
g_{12}	0.1	0.4	0.2543	0.9293
g_{13}	0	0.5	0.8143	0.3500
g_{21}	0.2	0.8	0.1966	0.6160
g_{22}	0	0.5	0.2511	0.4733
g_{31}	0.2	0.8	0.6377	0.2891
g_{32}	0	0.5	0.9577	0.6718
g_{33}	0.2	0.7	0.2407	0.6951
g_{34}	0.3	0.8	0.6761	0.0680
g_{41}	0.2	0.8	0.2548	0.7805
g_{42}	0	0.5	0.2240	0.6753
g_{43}	0.2	0.7	0.6678	0.0067
g_{44}	0.3	0.8	0.8444	0.6022
g_{45}	0.1	0.6	0.3445	0.3868
g_{51}	0.1	0.7	0.7965	0.5260
g_{52}	0.1	0.5	0.2318	0.4893
g_{53}	0	0.5	0.6570	0.4063
g_{61}	0.1	0.8	0.8567	0.8273
g_{62}	0.1	0.5	0.3575	0.0067
g_{71}	0.1	0.7	0.0961	0.1230
g_{72}	0.1	0.8	0.3314	0.0213
g_{73}	0	0.6	0.6798	0.1458
g_{74}	0.2	0.5	0.3896	0.4733

3.3 Resultados estáticos

La Tabla 4 compara el RD con *quadprog*. En ambos casos, la brecha relativa de costo fue inferior a 2×10^{-9}. El error de balance fue inferior a 7.5×10^{-13} y no se observaron violaciones de los límites. Las diferencias máximas entre las potencias obtenidas por RD y *quadprog()* fueron 5.27×10^{-7} kW en el Caso I y 5.66×10^{-7} kW en el Caso II.

Tabla 4. Resultados estáticos del RD y *quadprog.* Fuente: elaboración propia.

Caso	Costo *quadprog*	Costo RD	Brecha relativa	r_{PG}	Error de balance	Tiempo RD (s)	Tiempo *quadprog* (s)
1	2.001165978	2.001165982	1.90e-09	4.94e-07	7.02e-14	0.446	0.0017
2	6.120399331	6.120399333	3.09e-10	5.84e-07	7.48e-13	0.738	0.0019

Para el Caso I, la Figura 2 muestra la evolución de las *fitness* promedio y las cargas por MG del sistema, representadas por las líneas sólidas. Las líneas punteadas corresponden a la solución óptima del problema, obtenida usando el método convencional.

Las Figuras 3-6 presentan la evolución (en escala logarítmica) de las *fitness* y la potencia generada por UG en cada MG, representadas por líneas sólidas. Las líneas punteadas, como en el caso anterior, representan la solución óptima obtenida usando *quadprog*.

Para el Caso II, la Figura 7 muestra la evolución de las *fitness* promedio y las cargas por MG del sistema, representadas por la línea sólida. La línea punteada, nuevamente, es la solución óptima del problema, obtenida usando *quadprog*.

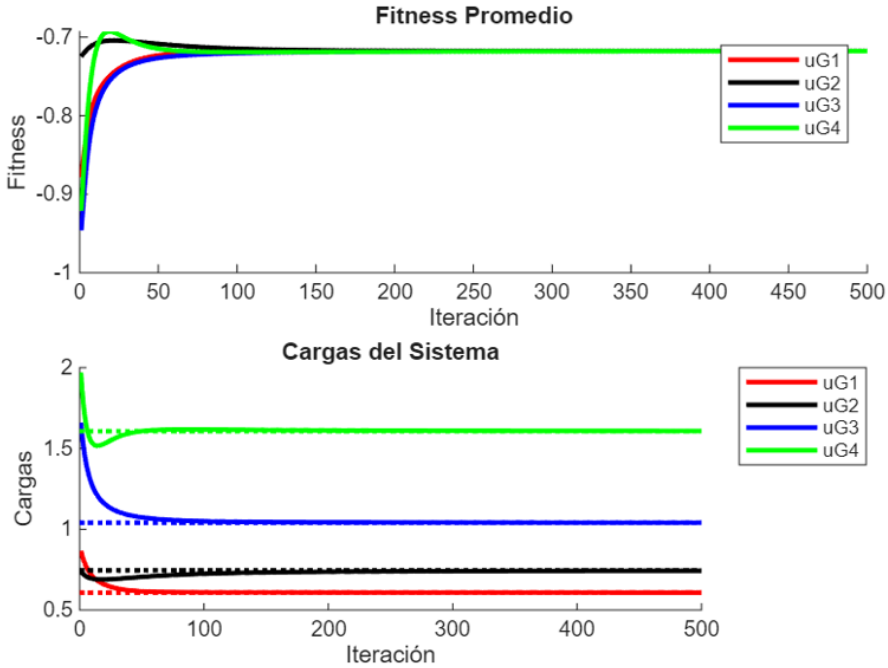


Figura 2. Evolución de las *fitness* promedio y cargas de cada MG del sistema del caso de estudio I
Fuente: elaboración propia.

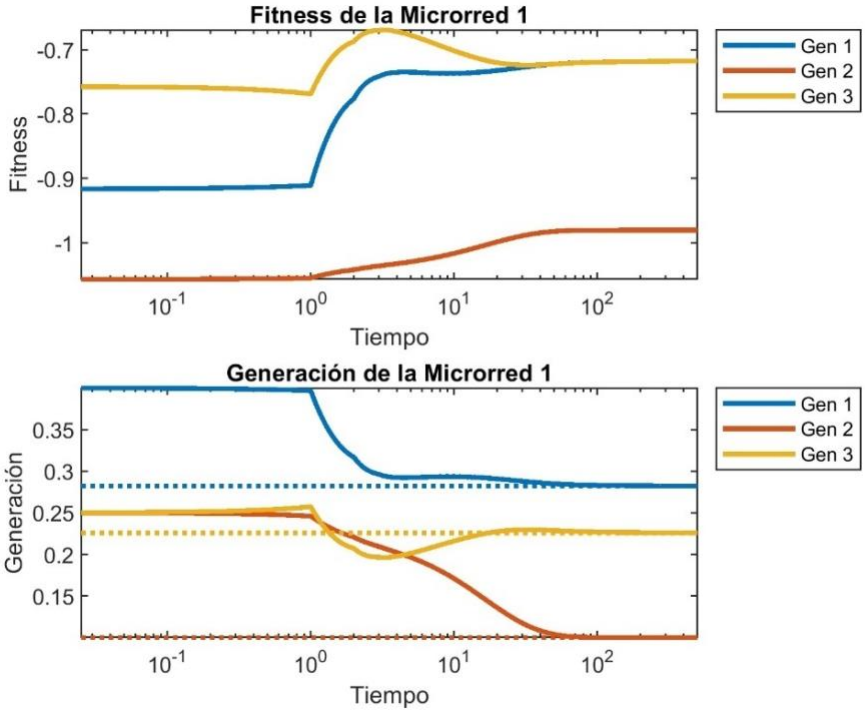


Figura 3. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 1
Fuente: elaboración propia.

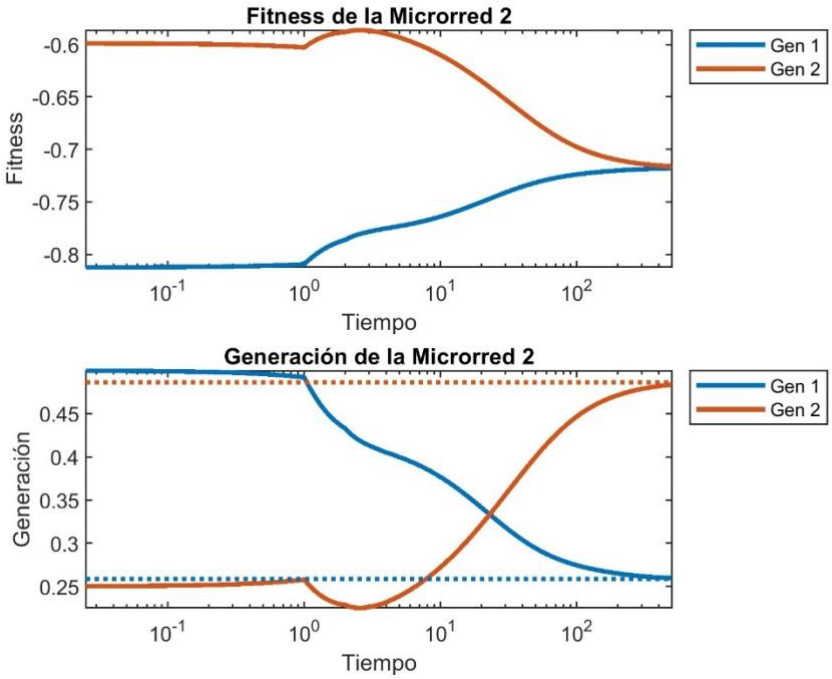


Figura 4. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 2
Fuente: elaboración propia.

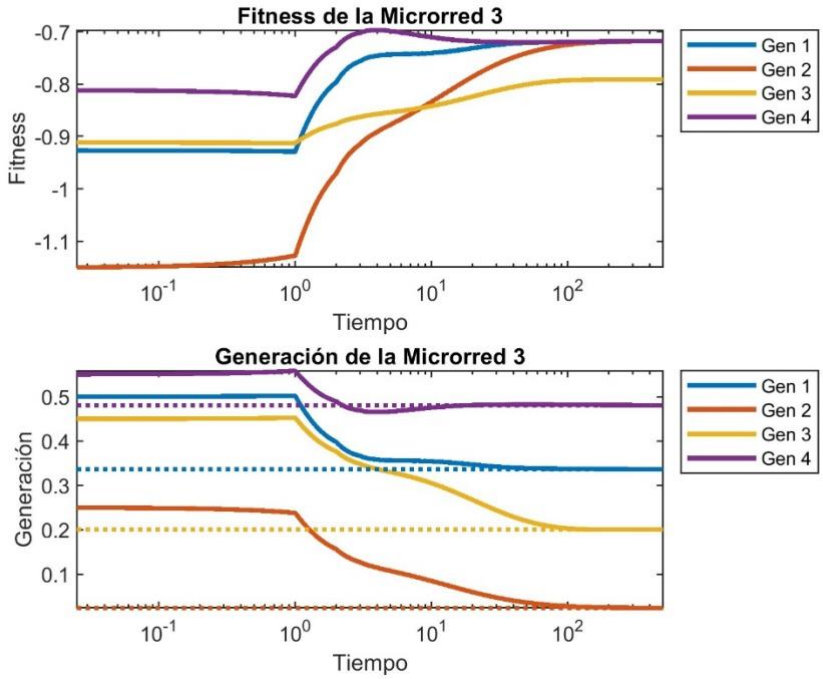


Figura 5. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 3
Fuente: elaboración propia.

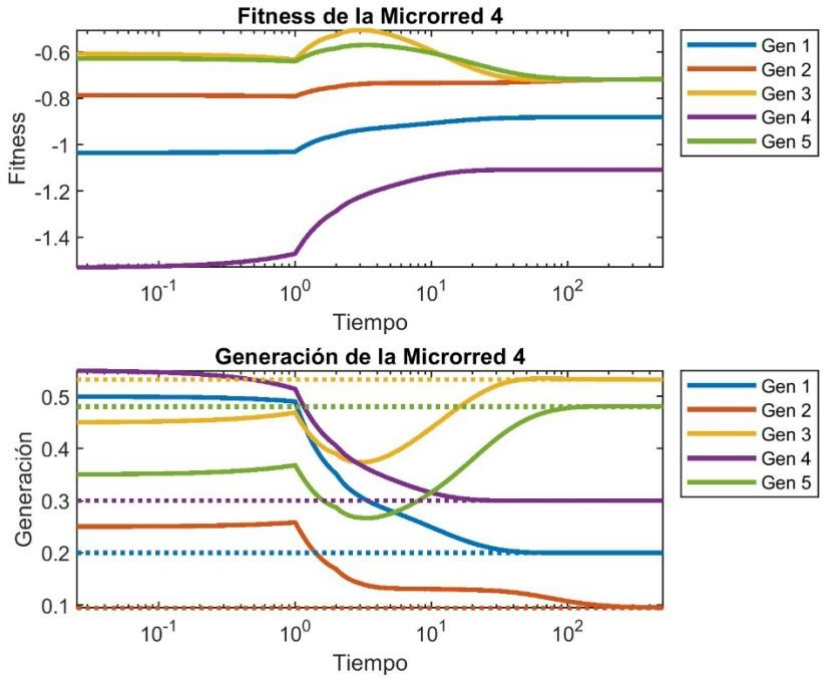


Figura 6. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 4
Fuente: elaboración propia.

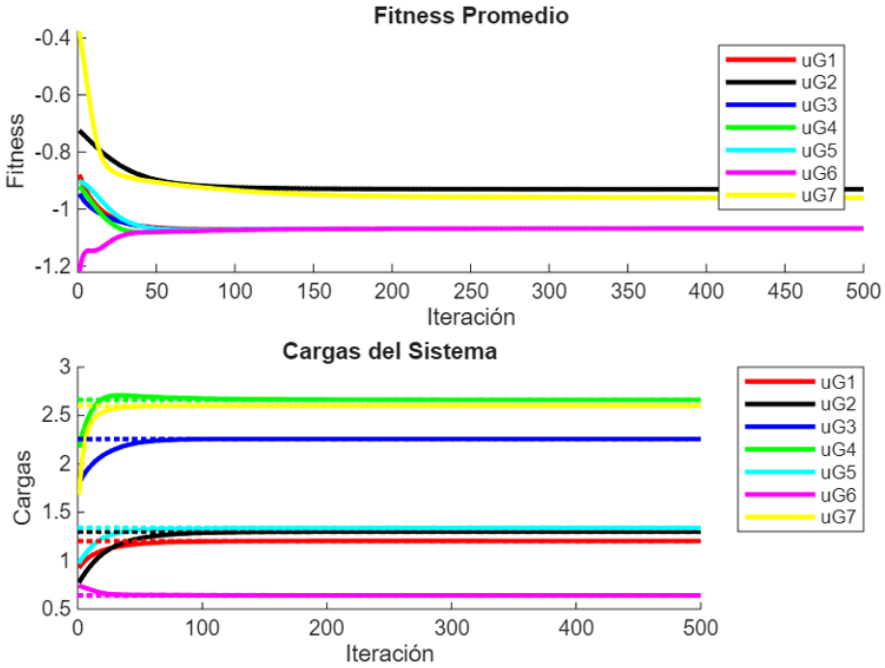


Figura 7. Evolución de las *fitness* promedio y cargas de cada MG del sistema del caso de estudio II
Fuente: elaboración propia.

Las Figuras 8-14 muestran, en línea sólida, la evolución (logarítmica) de las *fitness* y potencia generada por unidad generadora en cada MG. Además, la línea punteada muestra la solución óptima obtenida usando el método convencional *quadprog*.

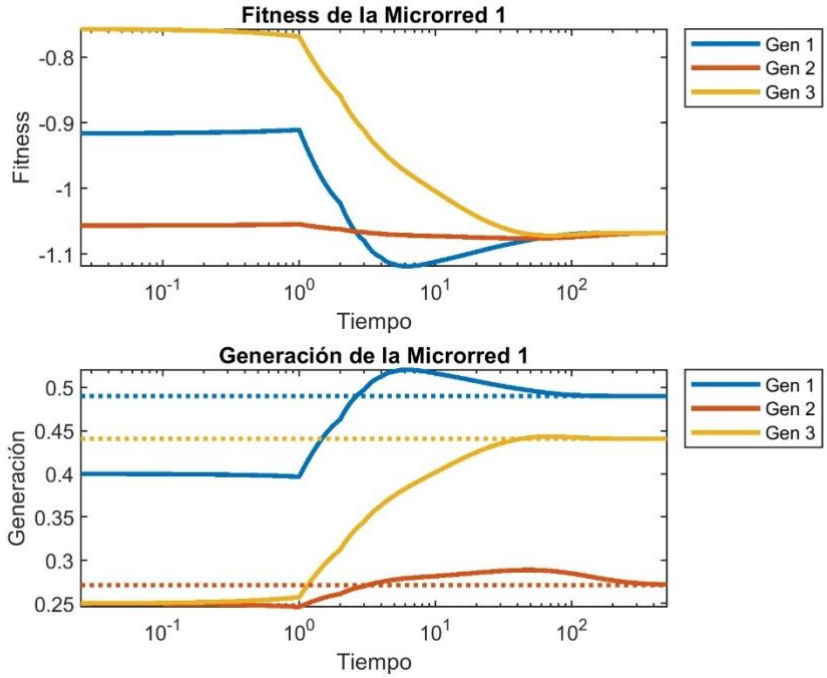


Figura 8. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 1
Fuente: elaboración propia.

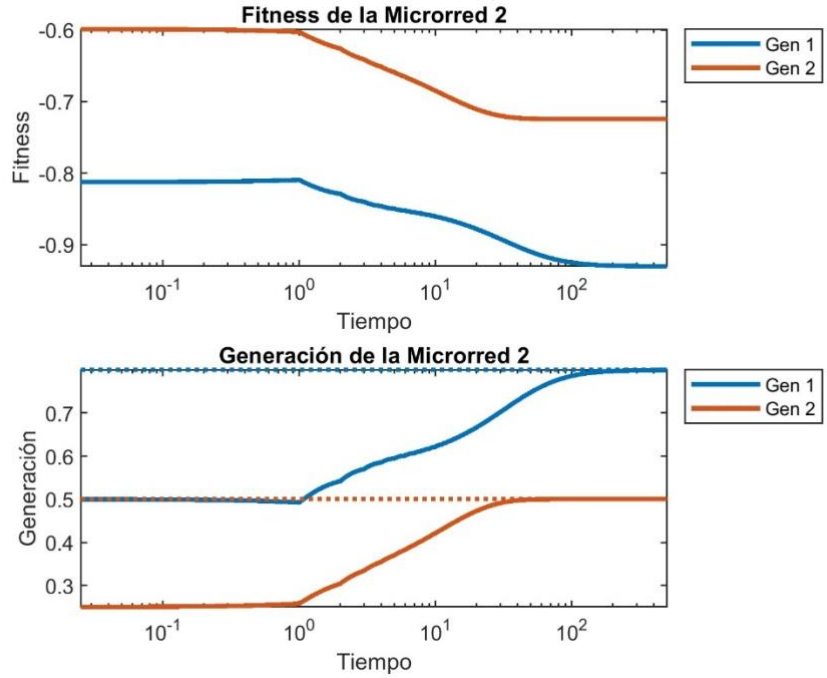


Figura 9. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 2
Fuente: elaboración propia.

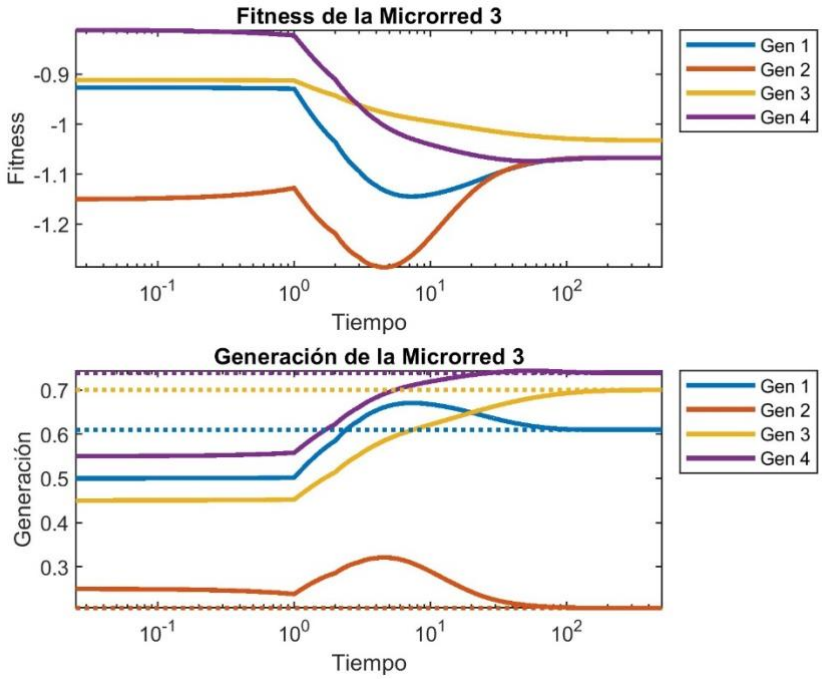


Figura 10. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 3
Fuente: elaboración propia.

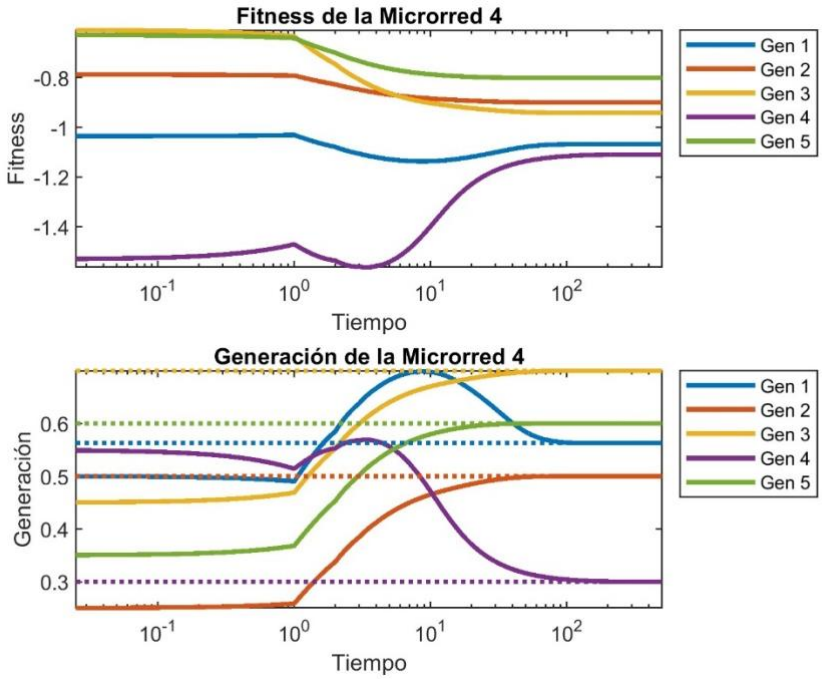


Figura 11. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 4
Fuente: elaboración propia.

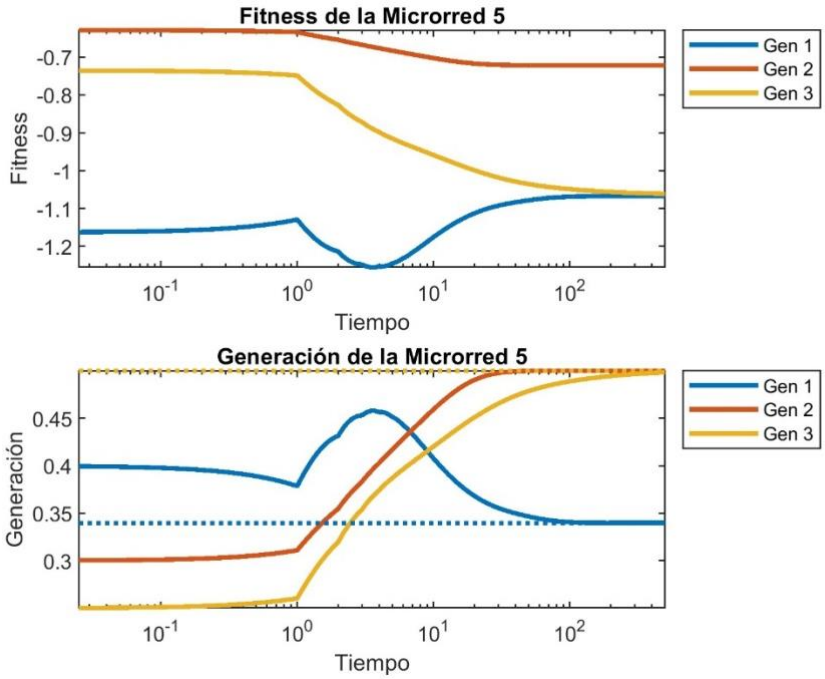


Figura 12. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 5
Fuente: elaboración propia.

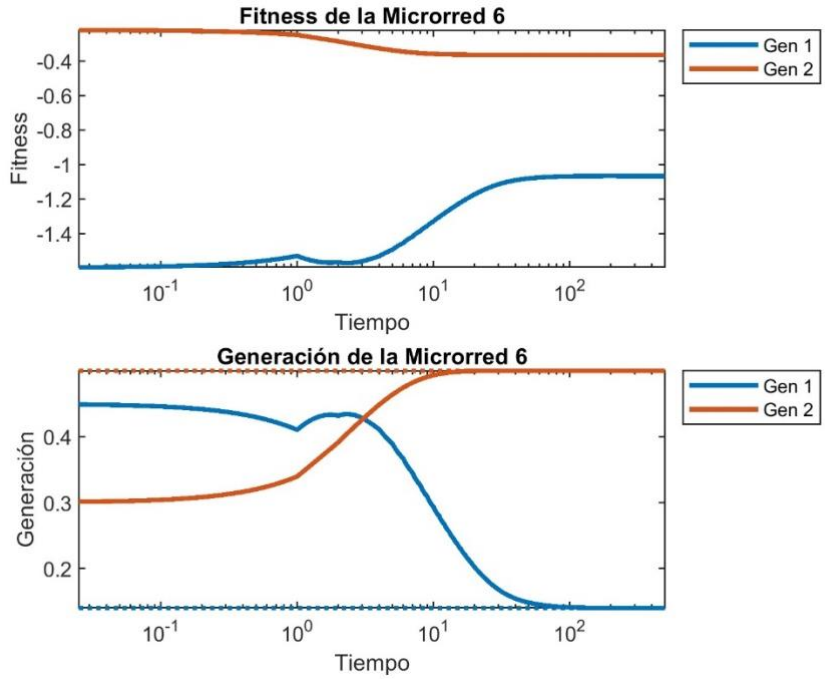


Figura 13. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 6
Fuente: elaboración propia.

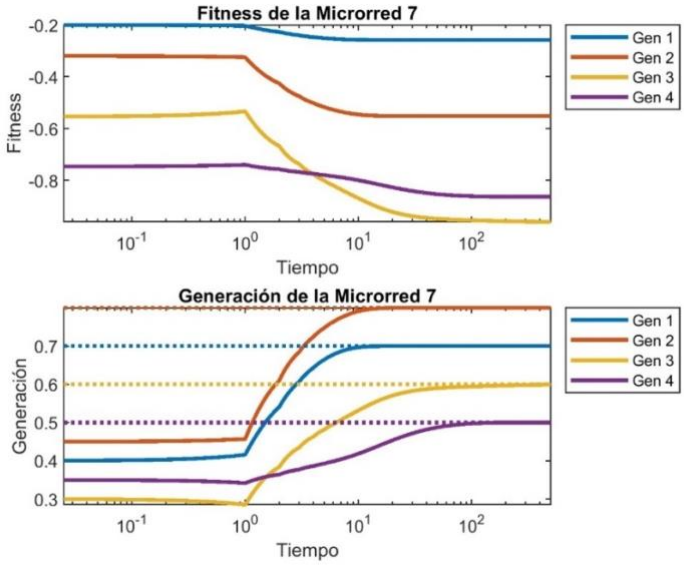


Figura 14. Evolución de las *fitness* y potencia generada por unidad generadora en la MG 7
Fuente: elaboración propia.

Los resultados obtenidos demuestran que el algoritmo basado en dinámicas poblacionales es capaz de resolver el PDPMI, alcanzando una solución óptima equivalente a *quadprog*. En ambos casos de estudio, las Figuras 2 y 7 detallan cómo el algoritmo converge hacia la solución óptima a medida que avanzan las iteraciones. Esto se observa con mayor claridad en los costos marginales (*fitness* promedio) asociados a la producción de energía, que consiguen igualarse en cada MG. La igualación de costos marginales en las unidades no saturadas es consistente con las condiciones de optimalidad del despacho económico.

En el caso de los resultados de las Figuras 3-6 y Figuras 8-14, que muestran la evolución de los costos marginales y de la potencia generada, es posible observar un comportamiento similar: la solución alcanzada también coincide con la obtenida usando el método convencional. En el caso de las *fitness* por UG, se muestra que los costos marginales en cada MG se igualan, excepto en algunos casos donde la UG ha alcanzado su límite superior o inferior. Sin embargo, este comportamiento es consistente con las condiciones de optimalidad de Karush-Kuhn-Tucker para el PDPMI. Además, la cercanía a *quadprog* aporta evidencia numérica de la convergencia a la solución óptima en los casos evaluados.

El desempeño del algoritmo en los diferentes escenarios sugiere que se puede aplicar a diferentes condiciones operativas de las MG. En particular, la prueba escalonada muestra que el algoritmo puede recalcular, sin necesidad de ajustes externos, el despacho ante cambios de demanda dentro del modelo evaluado.

Además, la arquitectura empleada evita centralizar los datos individuales de cada UG, aunque requiere un coordinador superior para procesar variables agregadas. Este hecho le otorga ventajas en términos de eficiencia de comunicaciones. Sin embargo, la misma jerarquización puede afectar la velocidad de convergencia en sistemas de gran escala. En este sentido, futuras investigaciones podrían enfocarse en desarrollar estrategias híbridas que combinen enfoques centralizados y descentralizados para mejorar el tiempo de respuesta sin comprometer la autonomía del sistema.

Con respecto a la elección de los casos de estudio, se podrían considerar futuros trabajos que exploren escenarios más complejos con mayor variación o restricciones operativas: por ejemplo, en MG donde no se deba suplir una demanda global, sino una demanda local (por MG).

3.4 Comparación con PSO

La Tabla 5 resume las 20 ejecuciones de PSO. En el Caso I, las 20 ejecuciones tuvieron brechas inferiores a 10^{-6}. En el Caso II, 18 de 20 alcanzaron ese umbral; las dos restantes presentaron brechas de 3.29×10^{-4} y 5.45×10^{-3}. El RD fue determinista para una condición inicial dada y alcanzó una brecha inferior a 2×10^{-9} en ambos casos. PSO tuvo un menor tiempo mediano que el RD en esta implementación, pero mostró variabilidad entre ejecuciones y requirió parámetros de calibración (Figura 15).

Tabla 5. Resultados de 20 ejecuciones de PSO. Fuente: elaboración propia.

Caso	Costo mediano	Mejor costo	Peor costo	Brecha mediana	Brecha máxima	Tiempo mediano (s)	Brecha ≤ 10^{-6}
1	2.001165978	2.001165978	2.001165978	2.62e-12	1.05e-11	0.166	20/20
2	6.120399331	6.120399331	6.153762075	9.48e-12	5.45e-03	0.199	18/20

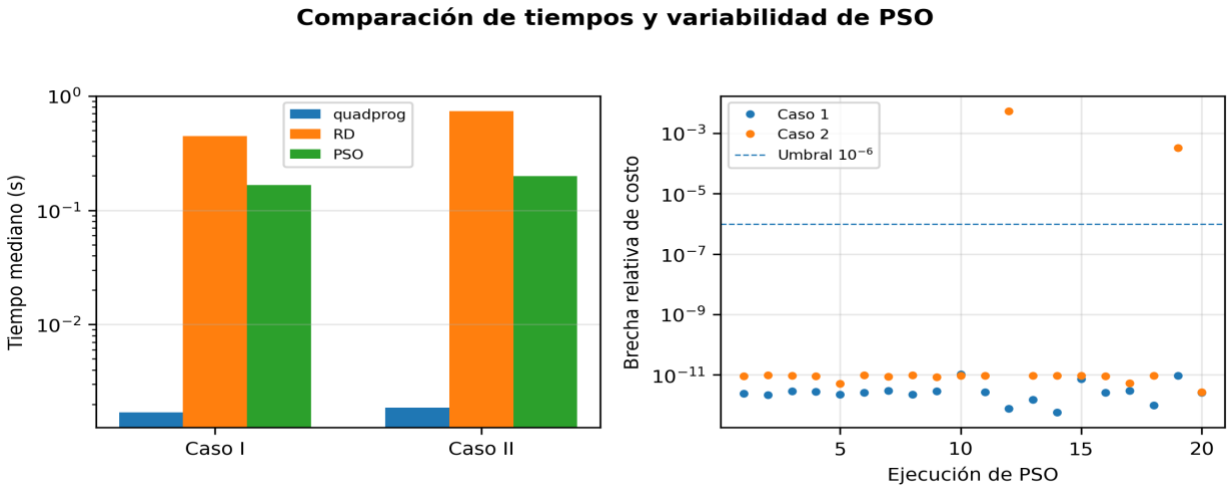


Figura 15. Comparación de tiempos medianos y variabilidad de PSO. Fuente: elaboración propia.

La comparación no demuestra superioridad general de un método. *quadprog* es la opción más eficiente para la formulación centralizada convexa. PSO puede obtener soluciones cercanas, pero su precisión depende de la ejecución. El RD ofrece una trayectoria continua y una interpretación mediante costos marginales, a cambio de un mayor tiempo de integración.

3.5 Análisis de sensibilidad

La sensibilidad se evaluó en el Caso II. Las 20 condiciones iniciales factibles convergieron; la brecha relativa máxima fue 3.53×10^{-10}. Los cinco niveles de demanda, entre 9.6 kW y 14.4 kW, convergieron con brecha máxima de 2.90×10^{-10}. Las tres configuraciones de ode45 produjeron brechas cercanas a 3.28×10^{-10}; el tiempo aumentó de 0.552 s a 1.847 s al pasar de la configuración menos estricta a la más estricta. Estos resultados indican que, dentro del rango evaluado, la solución no depende de una inicialización o tolerancia particular (Tabla 6 y Figura 16).

Tabla 6. Síntesis de las pruebas de sensibilidad y demanda dinámica. Fuente: elaboración propia.

Prueba	Número de ejecuciones	Brecha máxima	r_{PG} máximo	Error de balance máximo	Violación de límites	Convergencia
Condiciones iniciales	20	3.53e-10	6.67e-07	1.05e-12	0	20/20
Nivel de demanda	5	2.90e-10	7.46e-07	1.33e-12	0	5/5
Configuración de ode45	3	3.28e-10	6.20e-07	1.82e-12	0	3/3
Demanda escalonada	4 segmentos	6.55e-10	9.05e-07	3.33e-12	0	4/4

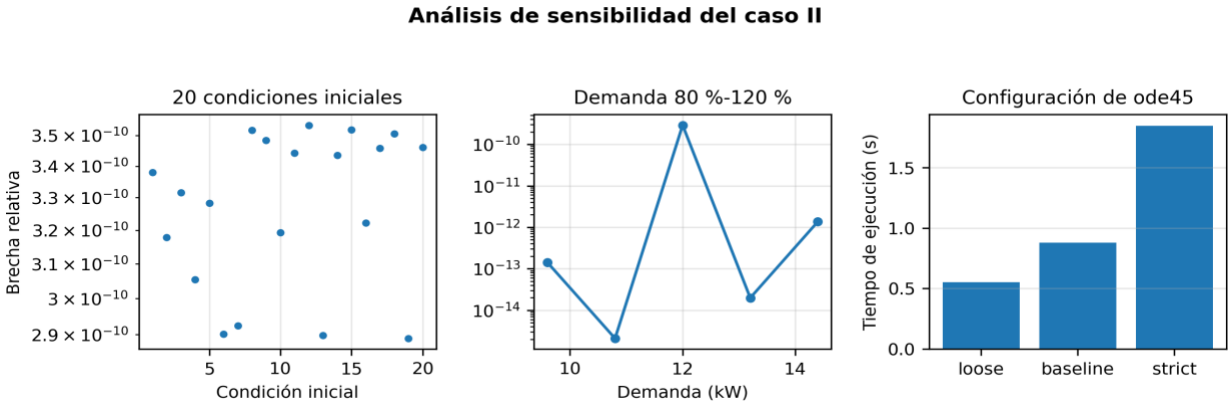


Figura 16. Sensibilidad a condiciones iniciales, demanda y configuración de ode45
Fuente: elaboración propia.

3.6 Demanda escalonada

La demanda del Caso II se cambió de forma escalonada mediante los factores 0.85, 1.00, 0.92 y 1.08. En cada cambio, la solución anterior se proyectó sobre el nuevo conjunto factible y se usó como condición inicial. Los cuatro segmentos cumplieron los criterios de convergencia. La brecha relativa máxima fue 6.55×10^{-10}, el residuo proyectado máximo fue 9.05×10^{-7} y no se presentaron violaciones de los límites (Tabla 7 y Figura 17).

Tabla 7. Resultados de la prueba de demanda escalonada. Fuente: elaboración propia.

Segmento	Factor	Demanda (kW)	Brecha relativa	r_{PG}	Error de balance	Tiempo de ejecución (s)
1	0.85	10.20	6.55e-10	4.48e-07	3.62e-13	0.804
2	1.00	12.00	3.38e-10	6.38e-07	9.68e-13	1.003
3	0.92	11.04	1.82e-13	9.05e-07	3.33e-12	4.055
4	1.08	12.96	1.00e-12	8.12e-10	7.46e-14	0.127

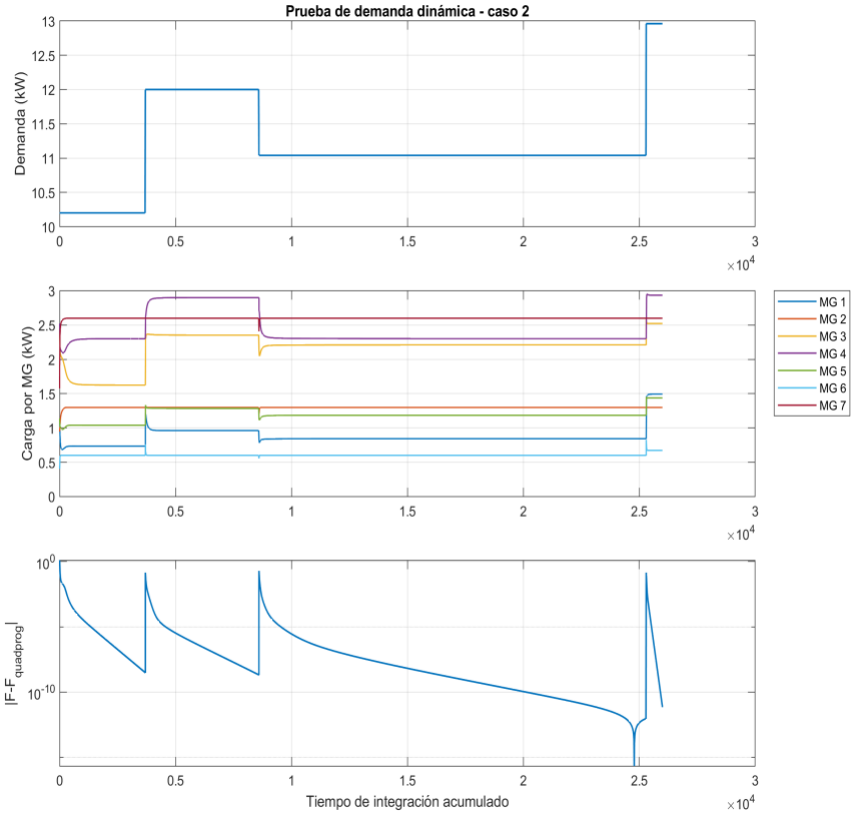


Figura 17. Evolución del despacho ante cambios escalonados de demanda. Fuente: elaboración propia.

La prueba muestra la readaptación del despacho ante cambios deterministas de carga. No representa incertidumbre estocástica, dinámica eléctrica, pérdidas ni retardos de comunicación. Por tanto, permite responder de forma limitada al comentario sobre condiciones dinámicas, pero no sustituye una validación en un sistema eléctrico detallado.

3.7 Limitaciones del algoritmo

El algoritmo presenta algunas limitaciones. En términos de costo computacional, la implementación del método mostró un mayor consumo de recursos en comparación con *quadprog y PSO*. El incremento en el tiempo de procesamiento podría ser un inconveniente en aplicaciones en tiempo real.

Otra limitación potencial es la necesidad del algoritmo de ser inicializado en puntos de operación que satisfagan las restricciones del problema. En futuras investigaciones, sería útil explorar métodos de inicialización factible, proyección o dinámicas que recuperen factibilidad desde condiciones no factibles.

3.8 Valor agregado de la investigación

El valor agregado de este trabajo radica en la aplicación de dinámicas poblacionales al PDPMI, un campo donde la mayoría de los estudios se han centrado en microrredes aisladas o configuraciones radiales. A diferencia de los enfoques convencionales basados en optimización centralizada, el algoritmo propuesto permite resolver el PDPMI de forma potencialmente descentralizada y adaptativa, reduciendo la necesidad de información global del sistema y mejorando la privacidad de datos. Asimismo, el modelo no requiere parámetros de ajuste propios de métodos metaheurísticos, lo que simplifica su implementación práctica.

3.9 Implicaciones prácticas

Desde el punto de vista práctico, el algoritmo puede ser implementado en entornos que involucren microrredes interconectadas que sigan la estructura de los casos de estudio (con una demanda global), especialmente en regiones con limitaciones de infraestructura de comunicación debido a su arquitectura jerárquica que reduce el volumen de información compartida. Su capacidad de operar con información local y de redistribuir la carga en situaciones donde las unidades alcanzan sus límites operativos lo convierte en una solución atractiva para operadores de redes distribuidas. Además, su potencial para ser extendido a microrredes aisladas abre la posibilidad de gestionar comunidades energéticas rurales o sistemas insulares con mayor eficiencia. No obstante, su mayor costo computacional en comparación con *quadprog* sugiere que se requiere optimización adicional del código y análisis de desempeño en plataformas de hardware específicas para garantizar su aplicabilidad en tiempo real.

3.10 Contraste con otros estudios

En contraste con enfoques revisados en la literatura, como los métodos metaheurísticos basados en PSO, differential evolution o MOSSA [10], [11], el algoritmo propuesto presenta la ventaja de no depender de parámetros de ajuste complejos, lo que reduce la sensibilidad a la calibración inicial. A diferencia de modelos híbridos de co-optimización con técnicas de consenso [2], [4], este trabajo se centra en la simplicidad de los replicadores dinámicos como mecanismo de coordinación, lo cual facilita su interpretación y análisis matemático. Asimismo, frente a modelos basados en teoría de juegos y aprendizaje automático [7], el presente enfoque resalta por su carácter biológicamente inspirado y su potencial de implementación distribuida. En síntesis, aunque otros estudios han mostrado eficacia en términos de costo económico y manejo de incertidumbre, el presente trabajo aporta una alternativa jerárquica basada en RD que combina rigor teórico con aplicabilidad práctica en MGI.

4. CONCLUSIONES

Se presentó un algoritmo jerárquico basado en replicadores dinámicos para el despacho económico de microrredes interconectadas. La implementación usa variables agregadas por MG y una fitness promedio global. El algoritmo alcanzó una solución equivalente a la de quadprog y no se observaron violaciones de límites.

La comparación mostró que quadprog fue el método más rápido en el entorno centralizado evaluado. PSO tuvo tiempos medianos menores que el RD, pero presentó variabilidad en el caso de mayor tamaño. El RD produjo resultados consistentes en 20 condiciones iniciales, cinco niveles de demanda, tres configuraciones del integrador y cuatro cambios escalonados de carga.

Los resultados no demuestran robustez o escalabilidad general. El modelo no incluye la red eléctrica ni incertidumbre y requiere una condición inicial factible. El trabajo futuro debe incorporar flujo de potencia, pérdidas, almacenamiento, generación renovable, retardos y fallos de comunicación. También se debe evaluar una implementación paralela o distribuida en plataformas de control.

5. AGRADECIMIENTO Y FINANCIACIÓN

Este trabajo ha sido respaldado por el proyecto BPIN 2021000100499 financiado por el Fondo de Ciencia, Tecnología e Innovación del SGR y Minciencias, Colombia.

6. REFERENCIAS

[1] J. A. Rodriguez-Gil *et al*., "Energy management system in networked microgrids: an overview," *Energy Syst*., vol. 17, pp. 315-346, Feb. 2026. https://doi.org/10.1007/s12667-024-00676-6

[2] M. Azimi *et al*., "Optimal and distributed energy management in interconnected energy hubs," *Appl. Energy*, vol. 365, p. 123282, Jul. 2024. https://doi.org/10.1016/j.apenergy.2024.123282

[3] A. Bagheri, and S. Jadid, "A robust distributed market-clearing model for multi-area power systems," *Int. J. Electr. Power Energy Syst*., vol. 124, p. 106275, Jan. 2021. https://doi.org/10.1016/j.ijepes.2020.106275

[4] K. Dong *et al*., "A co-optimization method and mechanism for day-ahead energy market and reserve market considering VPP participation," in *Proc. 3rd Power System and Green Energy Conference (PSGEC),* Shanghai, China, 2023, pp. 836-841. https://doi.org/10.1109/PSGEC58411.2023.10255924

[5] J. Guo *et al*., "Bi-level economic dispatch strategy for virtual power plants based on electric vehicles aggregation," *Electr. Power Syst. Res*., vol. 225, p. 109783, Dec. 2023. https://doi.org/10.1016/j.epsr.2023.109783

[6] A. Bala Kunya *et al*., "Review of economic dispatch in multi-area power system: State-of-the-art and future prospective," *Electr. Power Syst. Res.*, vol. 217, p. 109089, Apr. 2023. https://doi.org/10.1016/j.epsr.2022.109089

[7] R. Li *et al*., "Nash-Q learning-based collaborative dispatch strategy for interconnected power systems," *Glob. Energy Interconnect.*, vol. 3, no. 3, pp. 227-236, Jun. 2020. https://doi.org/10.1016/j.gloei.2020.07.004

[8] A. Meng *et al*., "Solving high-dimensional multi-area economic dispatch problem by decoupled distributed crisscross optimization algorithm with population cross generation strategy," *Energy*, vol. 258, p. 124836, Nov. 2022. https://doi.org/10.1016/j.energy.2022.124836

[9] A. Rajaei *et al*., "Decentralized transactive energy management of multi-microgrid distribution systems based on ADMM," *Int. J. Electr. Power Energy Syst.*, vol. 132, p. 107126, Nov. 2021. https://doi.org/10.1016/j.ijepes.2021.107126

[10] V. P. Sakthivel *et al*., "Multi-objective squirrel search algorithm for multi-area economic environmental dispatch with multiple fuels and valve point effects," *IEEE Access*, vol. 9, pp. 3988-4007, Dec. 2021. https://doi.org/10.1109/ACCESS.2020.3046257

[11] Y. Sharifian, and H. Abdi, "Multi-area economic dispatch problem: Methods, uncertainties, and future directions," *Renew. Sustain. Energy Rev.*, vol. 191, p. 114093, Mar. 2024. https://doi.org/10.1016/j.rser.2023.114093

[12] J. Wang *et al*., "Incentive mechanism for clearing energy and reserve markets in multi-area power systems," *IEEE Trans. Sustain. Energy*, vol. 11, no. 4, pp. 2470-2482, Oct. 2020. https://doi.org/10.1109/TSTE.2019.2961780

[13] T. Graham *et al*., "Where Do Mistakes Lead? A Survey of Games with Incompetent Players," *Dyn. Games Appl.*, vol. 13, pp. 231-264, Mar. 2023. https://doi.org/10.1007/s13235-022-00425-3

[14] Z. Momeni, and A. Bagchi, "Multi-objective control optimization of isolated bridge using replicator controller and NSGA-II," *Heliyon*, vol. 9, no. 9, p. e19381, Sep. 2023. https://doi.org/10.1016/j.heliyon.2023.e19381

[15] I. S. Lim, and V. Capraro, "A synergy of institutional incentives and networked structures in evolutionary game dynamics of multiagent systems," *IEEE Trans. Circuits Syst. II: Express Briefs*, vol. 69, no. 6, pp. 2777-2781, Jun. 2022. https://doi.org/10.1109/TCSII.2021.3133711

[16] E. Benavides *et al*., "Integrating distributed optimization algorithms into blockchain for P2P energy trading," *Energy Inform.*, vol. 9, p. 37, Feb. 2026. https://doi.org/10.1186/s42162-026-00644-7

[17] X. Shen *et al*., "Dynamic evolution game strategy of government, power grid, and users in electricity market demand-side management," *Mathematics*, vol. 12, no. 20, p. 3249, Oct. 2024. https://doi.org/10.3390/math12203249

[18] E. Baron-Prada, and E. Mojica-Nava, "A population games transactive control for distributed energy resources," *Int. J. Electr. Power Energy Syst.*, vol. 130, p. 106874, Sep. 2021. https://doi.org/10.1016/j.ijepes.2021.106874

[19] G. Obando, and A. Pantoja, "A Robust Population Dynamics Model With Carrying Capacity Constraints for Centrally Coordinated Distributed Optimization," *IEEE Access*, vol. 13, pp. 100861-100874, Jun. 2025. https://doi.org/10.1109/ACCESS.2025.3578157

[20] X. Xu *et al*., "Collaborative optimization of multi-energy multi-microgrid system: A hierarchical trust-region multi-agent reinforcement learning approach," *Appl. Energy*, vol. 375, p. 123923, Dec. 2024. https://doi.org/10.1016/j.apenergy.2024.123923

[21] T. Yang *et al.*, "Cooperative optimal dispatch of multi-microgrids for low carbon economy based on personalized federated reinforcement learning," *Appl. Energy*, vol. 378, p. 124641, Jan. 2025. https://doi.org/10.1016/j.apenergy.2024.124641

[22] T. Ye *et al.*, "Safe multi-agent deep reinforcement learning for decentralized low-carbon operation in active distribution networks and multi-microgrids," *Appl. Energy*, vol. 387, p. 125609, Jun. 2025. https://doi.org/10.1016/j.apenergy.2025.125609

CONFLICTO DE INTERÉS

Los autores declaran que no existe ningún conflicto de intereses.

CONTRIBUCIÓN DE AUTORÍA

Sara Melo: revisión de la literatura, redacción del manuscrito y la ejecución de las simulaciones.

Andrés Pantoja: revisión y edición de todo el contenido del artículo, conceptualización y supervisión del desarrollo metodológico del trabajo.

Germán Obando: revisión y edición de todo el contenido del artículo, conceptualización y supervisión del desarrollo metodológico del trabajo.

DECLARACIÓN IA

En la elaboración del presente artículo, se utilizaron herramientas de Inteligencia Artificial únicamente con el propósito de apoyar el proceso de escritura, especialmente en tareas relacionadas con la corrección ortográfica, gramatical y de estilo. Dichas herramientas fueron empleadas bajo la supervisión de los autores, quienes revisaron exhaustivamente los contenidos generados o sugeridos.