

Economic Dispatch of Power Flow Considering the Uncertainties of Renewable Energy Sources Using the GSA Optimization Algorithm

Paulo C. Mendoza¹; Juan C. Quispe²
^{1,2}Universidad Tecnológica del Perú, Perú,
U19220255@utp.edu.pe, C21675@utp.edu.pe

Abstract– The increase in the share of renewable energy sources, driven by CO₂ emission reduction targets, lower generation costs, and energy policies, has introduced a significant level of uncertainty into the operation of electrical systems. This variability generates discrepancies between scheduled generation and dispatched generation, increasing the need for backup systems to ensure the security and stability of supply, which makes the operation of the electrical system vulnerable. This paper develops a cost optimization model for economic dispatch based on the gravitational search algorithm (GSA), which considers the uncertainty associated with a renewable generation source using Monte Carlo simulation. Thirty scenarios are generated over a 24-hour horizon, from which the minimum, average, and maximum costs per hour are obtained. A performance comparison of each algorithm is also carried out with the particle swarm optimization (PSO) method, widely used in the literature. The performance comparison shows that both methods produce high-quality solutions; however, the GSA obtains lower costs in most scenarios and presents less dispersion of results, demonstrating greater robustness and stability in the face of renewable uncertainty.

Keywords– Economic dispatch, power system, uncertainty, Particle Swarm Optimization (PSO), Gravitational Search Algorithm (GSA).

Despacho Económico de Flujo de Potencia Considerando las Incertidumbres de Fuentes de Energías Renovables Mediante el Algoritmo de Optimización GSA

Paulo C. Mendoza¹ ; Juan C. Quispe² 
^{1,2}Universidad Tecnológica del Perú, Perú,
U19220255@utp.edu.pe, C21675@utp.edu.pe

Resumen— El incremento en la participación de fuentes de energía renovable, impulsado por los objetivos de reducción de emisiones de CO₂, la disminución de costos de generación y las políticas energéticas, ha introducido un nivel significativo de incertidumbre en la operación de los sistemas eléctricos. Esta variabilidad genera discrepancias entre la generación programada y la generación despachada, incrementando la necesidad de sistemas de respaldo para garantizar la seguridad y estabilidad del suministro, lo cual hace vulnerable la operación del sistema eléctrico. En este trabajo se desarrolla un modelo de optimización de costos del despacho económico basado en el Algoritmo de Búsqueda Gravitacional (GSA) donde considera la incertidumbre asociada a una fuente de generación renovable mediante simulación de Monte Carlo. Se generan 30 escenarios en un horizonte de 24 horas, a partir de los cuales se obtienen los costos mínimo, medio y máximo por hora. Asimismo, se realiza una comparación de desempeño de cada algoritmo con el método de Optimización por Enjambre de Partículas (PSO), ampliamente utilizado en la literatura. La comparación de desempeño muestra que ambos métodos producen soluciones de alta calidad; sin embargo, el GSA obtiene menores costos en la mayoría de los escenarios y presenta menor dispersión de resultados, evidenciando mayor robustez y estabilidad frente a la incertidumbre renovable.

Palabras clave— Economic dispatch, power system, uncertainty, Particle Swarm Optimization (PSO), Gravitational Search Algorithm (GSA).

I. INTRODUCCIÓN

La transición energética está cobrando mayor relevancia, impulsada por la necesidad de reducir el uso de combustibles fósiles y los costos de generación eléctrica. En este contexto, las fuentes renovables como la solar y eólica se están incorporando en gran escala a los sistemas eléctricos con el fin de disminuir la dependencia de centrales térmicas [1]. Sin embargo, la dependencia de condiciones meteorológicas variables que afectan directamente la potencia generada ocasiona un alto grado de incertidumbre [2], lo que afecta considerablemente la formulación y resolución del despacho económico de carga [3], por discrepancias entre la energía programada y la realmente inyectada al sistema, asociado a una mayor complejidad en la coordinación operativa [4].

En el despacho económico de carga, un aspecto relevante es el costo de operación de las centrales térmicas. Las unidades de generación se representan con costos operativos cuya función es cuadrática, lo que implica la necesidad de una adecuada optimización para minimizar los costos totales del sistema. Las centrales térmicas, por lo general, son consideradas como fuentes confiables y estables de generación, ya que, al operar con combustibles, están disponibles de manera constante para satisfacer la demanda energética, especialmente en condiciones donde otras fuentes pueden ser intermitentes [5], [6].

En la literatura científica se han propuesto diversos enfoques para resolver el problema de despacho económico de carga con integración de energías renovables. Entre ellos, destaca el Algoritmo Evolutivo Novedoso (NEA), el cual ha demostrado eficiencia en problemas de optimización robusta y de gran escala bajo incertidumbre [7]. Asimismo, el Algoritmo de Optimización de Ballenas (WOA) ofrece un enfoque robusto y eficiente para resolver problemas con restricciones de emisiones [8]. Adicionalmente, el Algoritmo de Evolución Diferencial Mejorado basado en información de descenso por gradiente (DE-GD) presenta una alta capacidad para manejar restricciones operativas complejas en sistemas hidrotérmicos y eólicos [9]. De manera similar, la Evolución Diferencial mejorada con Programación Cuadrática Secuencial (SQP) se posiciona como una alternativa prometedora para el despacho económico dinámico bajo incertidumbre en la generación eólica [10]. Finalmente, el Método de Optimización de Doble Capa Acelerado mediante Redes Neuronales Profundas ha mostrado un desempeño superior frente a métodos tradicionales y metaheurísticos como Optimización por Enjambre de Partículas (PSO) y Optimización del Lobo Gris GWO [11]. En general, estos trabajos se han enfocado principalmente en la integración de energía eólica, reportando mejoras significativas en la reducción de costos operativos bajo distintos escenarios de optimización.

En contraste, algunos estudios han abordado la integración de generación solar e hidroeléctrica. Por ejemplo, en [2] se consideran unidades hidroeléctricas, solares y eólicas en un enfoque de despacho multiobjetivo. En [12], se emplea la Optimización por Búsqueda de Núcleo (KSO), incorporando

generación solar y eólica. Asimismo, en [13] se utiliza el Algoritmo de Mercado de Intercambio Modificado (MEMA) para analizar tres escenarios: generación solar, generación eólica y un caso combinado de ambas fuentes renovables.

A pesar de los avances recientes, la mayoría de los estudios se ha concentrado en la integración de generación eólica, mientras que la combinación simultánea de fuentes hidroeléctricas, eólicas y solares fueron evaluados en menor medida. Además, gran parte de las investigaciones revisadas se enfoca en la minimización de costos y reducción de emisiones, pero sin contemplar un horizonte de 24 horas evaluado hora a hora, aspecto clave para representar adecuadamente la variabilidad de las energías renovables. Por otro lado, el uso del Algoritmo de Búsqueda Gravitacional (GSA) como algoritmo de optimización es recientemente incorporado en este tipo de aplicaciones y ha mostrado adecuados resultados [14][15].

En ese sentido, se propone un modelo de optimización basado en dicho algoritmo para un sistema eléctrico mixto compuesto por unidades hidroeléctricas, eólicas y solares. Las centrales térmicas son tratadas como variables de decisión en la minimización de costos, mientras que la generación solar se representa con incertidumbre a través de métodos aleatorios. La propuesta busca evaluar el desempeño del GSA en un horizonte de 24 horas, mediante 30 simulaciones que permitan analizar los costos mínimos, máximos y promedio del sistema eléctrico.

La ausencia de un modelo de optimización adaptado a estos escenarios conllevaría un aumento en los costos de inversión asociados a las centrales solares, debido a la necesidad de incorporar fuentes de respaldo que compensen la variabilidad de la generación. Esta situación, a su vez, restringiría la participación de las energías renovables en la matriz eléctrica.

II. METODOLOGÍA

A. Desarrollo del modelo del despacho económico

El Despacho Económico de Carga (DEC) es una función fundamental en la operación de sistemas eléctricos, cuyo objetivo principal es asignar la generación entre las unidades disponibles de tal manera que se satisfaga la demanda total con el menor costo posible, respetando las restricciones técnicas de cada generador. El proceso para determinar la solución óptima del despacho económico se muestra en la Figura 1.

El problema consiste en minimizar la función de costo total de generación, que usualmente se modela como la suma de los costos individuales de cada planta generadora.

Función objetivo

La función de costo se modela como una función cuadrática [3].

$$C_i(P_i) = a_i + b_i P_i + c_i P_i^2 \quad (1)$$

Donde a_i, b_i, c_i son coeficientes del costo del combustible para generar cierta potencia que será suministrada a la red




Fig. 1 Diagrama de flujo desarrollo del modelo de optimización del flujo de potencia

Restricciones

Límites de la capacidad de generación: Cada generador debe operar dentro de sus límites mínimos y máximos de potencia [7].

$$P_i^{min} \leq P_i \leq P_i^{max} \quad (2)$$

Donde P_i^{min} es la potencia mínima de generación, P_i^{max} es la potencia máxima de generación y P_i es la potencia de operación.

El despacho económico es crucial para garantizar la operación eficiente del sistema eléctrico, minimizando costos y asegurando un suministro confiable. En ese sentido, cuando se integran fuentes renovables, que introducen incertidumbre resalta la importancia de contar con métodos más robustos que puedan optimizar el despacho económico de carga considerando dicha incertidumbre.

B. Representación de la incertidumbre

Para el tratamiento de la incertidumbre en la generación fotovoltaica se emplean dos enfoques de modelamiento complementarios. Por un lado, se utiliza un enfoque paramétrico basado en la desviación estándar, donde la generación fotovoltaica es representada como una variable aleatoria alrededor de un valor esperado, permitiendo modelar perturbaciones de forma simplificada.

Por otro lado, se incorpora un enfoque basado en datos históricos utilizando simulación de Monte Carlo. A diferencia de los modelos paramétricos tradicionales, en este caso se emplean perfiles reales de generación solar, lo que permite una representación más fiel de la variabilidad.

Los datos fueron obtenidos de registros históricos de una central fotovoltaica disponibles en la plataforma oficial del COES, correspondientes a un periodo de 31 días consecutivos. Cada perfil representa la curva horaria de generación solar a lo largo de un día completo (24 horas), preservando la correlación temporal intradiaria.

Durante la simulación de Monte Carlo, en cada escenario k se selecciona aleatoriamente un perfil diario completo de la base de datos, de modo que la generación fotovoltaica queda definida como:

$$G_{k,t}^{PV} = G_{d,t}^{PV} \quad (3)$$

donde $d \in \{1,2,\dots,31\}$ representa el índice del día seleccionado aleatoriamente, y t corresponde a la hora del día.

Este enfoque permite capturar de manera más realista la variabilidad de la generación solar, incluyendo efectos meteorológicos y patrones temporales, evitando suposiciones simplificadas sobre la distribución de la incertidumbre.

C. Algoritmo de búsqueda gravitacional (GSA)

En este algoritmo GSA, contamos con dos tipos de búsquedas que son la exploración y explotación que se van dando según la gravedad de cada partícula, al iniciar con el algoritmo contamos con gravedad alta lo que aumenta la velocidad y por ende restamos en la fase exploración, mientras tanto, a medida que se va aumentando las iteraciones o cuando este en la etapa final entramos a la fase de explotación ya que la gravedad baja y su velocidad disminuye [16].

Esta ecuación (4) permite que la fuerza gravitacional disminuya con el tiempo, favoreciendo la exploración al inicio y la explotación al final del proceso.

$$G(t) = G_0 e^{-\alpha \frac{t}{t_{max}}} \quad (4)$$

Donde $G(t)$ representa la constante gravitacional en la iteración t , G_0 es el valor inicial de la constante gravitacional, α es un factor de decaimiento que controla la tasa de reducción, t_{max} es el número total de iteraciones; la cual disminuye exponencialmente con el tiempo para equilibrar la exploración y la explotación del espacio de búsqueda.

Las partículas con mejor desempeño (menor costo) obtienen mayor masa, lo que les permite atraer más fuertemente a las

demás partículas [16], esto se expresa mediante las ecuaciones (5) y (6).

$$m_i(t) = \frac{f_{max}(t) - f_i(t)}{f_{max}(t) - f_{min}(t)} \quad (5)$$

$$M_i(t) = \frac{m_i(t)}{\sum_{j=1}^N m_j(t)} \quad (6)$$

Donde los valores $f_i(t)$, $f_{max}(t)$ y $f_{min}(t)$ denotan respectivamente el valor de la función objetivo del agente i , así como los valores máximo y mínimo del conjunto de soluciones en la población, utilizados para calcular la masa relativa de cada agente. La variable $M_i(t)$ representa la masa normalizada del agente i , la cual determina su capacidad de atracción sobre los demás agentes.

La fuerza gravitacional entre partículas viene determinada por la siguiente ecuación:

$$F_{ij}^d(t) = G(t) \frac{M_i(t) M_j(t)}{R_{ij}(t) + \varepsilon} [x_j^d(t) - x_i^d(t)] \quad (7)$$

Donde $F_{ij}^d(t)$ indica la fuerza ejercida por el agente j sobre el agente i en la dimensión d , mientras que $R_{ij}(t)$ es la distancia euclidiana entre ambos agentes, y ε es una constante pequeña introducida para evitar divisiones por cero, $x_j^d(t)$ y $x_i^d(t)$ son las posiciones en la dimensión d . Cada agente experimenta una atracción hacia los demás agentes proporcional a su masa y distancia.

La fuerza total es la suma ponderada aleatoriamente de las fuerzas ejercidas por los demás agentes [16].

$$F_i^d(t) = \sum_{j=1, j \neq i}^N rand_j(t) F_{ij}^d(t) \quad (8)$$

Donde $rand_j \in [0,1]$ es un número aleatorio que introduce variabilidad en el proceso.

La aceleración de la partícula está dada por:

$$a_i^d(t) = \frac{F_i^d(t)}{M_i(t)} \quad (9)$$

Donde $a_i^d(t)$ representa la aceleración de la partícula i en la dimensión d . Una mayor fuerza o menor masa genera una aceleración más alta, lo que impulsa el movimiento de la partícula en el espacio de búsqueda como se muestra en la ecuación (10).

$$v_i^d(t+1) = rand_i v_i^d(t) + a_i^d(t) \quad (10)$$

Donde $v_i^d(t)$ es la velocidad de la partícula i en la dimensión d , $rand_i \in [0,1]$ es un factor aleatorio. Este paso incorpora memoria del movimiento anterior y la nueva aceleración calculada mediante la ecuación (11).

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (11)$$

Donde $x_i^d(t)$ es la posición actual de la partícula y $x_i^d(t+1)$

su posición actualizada. Las posiciones representan nuevas soluciones candidatas, por lo que este paso actualiza la población de agentes en el espacio de búsqueda.

Como parámetros fue considerando una población de 30 agentes, donde cada agente representa un vector candidato de potencias de generación térmica dentro de sus límites operativos. El proceso de optimización se ejecutó durante un máximo de 30 iteraciones. La constante gravitacional inicial G_0 de 4 y el coeficiente de decaimiento α fue de 1.5 se emplearon para regular la intensidad de atracción entre agentes a lo largo del proceso iterativo, permitiendo un comportamiento de exploración global en las primeras etapas y de explotación local en las etapas finales. El proceso de método se muestra en la figura 2.




Fig. 2 Diagrama de flujo de proceso del GSA

D. Balance de la demanda

Para el balance de la demanda se considera la siguiente ecuación:

$$\sum_{i \in T} P_{i,t} + \sum_{j \in H} P_{j,t} + \sum_{k \in R} G_{k,t}^{PV} = D_t \quad (12)$$

Donde D_t representa la demanda eléctrica en la hora t , H el conjunto de unidades hidroeléctricas, T las unidades térmicas y R las unidades fotovoltaicas. Asimismo, $G_{k,t}^{PV}$ denota la generación real de la unidad fotovoltaica k en el intervalo t , considerando la incertidumbre asociada a la variabilidad solar.

E. Descripción del caso de estudio

El presente artículo utiliza como sistema de referencia el modelo IEEE de 14 barras, el cual cuenta con cinco unidades generadoras. En esta configuración se consideran tres unidades térmicas, una hidroeléctrica y una fotovoltaica, cuya incertidumbre es modelada mediante un enfoque basado en desviación estándar.

El objetivo es evaluar el impacto de incorporar la incertidumbre en la generación fotovoltaica dentro del problema de optimización.




Fig. 3 Diagrama unifilar del sistema eléctrico para el caso de estudio

La Tabla 1 resume los parámetros de las unidades generadoras, considerando la potencia de cada unidad térmica, los coeficientes de la función de costo cuadrática y los límites operativos mínimo y máximo.

TABLA I
PARÁMETROS DE LAS UNIDADES TÉRMICAS CASO 1

Parámetro	Unidad 1	Unidad 2	Unidad 3
Potencia	400 kW	300 kW	200 kW
a	600	300	250
b	5.3	5.5	5.8
c	0.004	0.006	0.009
P min	100 kW	80 kW	50 kW
P max	400 kW	300 kW	200 kW

La unidad hidroeléctrica tendrá como potencia nominal 100 kW, y se considera que generan todo el tiempo la misma potencia. En cambio, en la central Solar se tendrá una potencia de 280 kW con una desviación estándar del 25%, no pudiendo superar la potencia máxima.

La Tabla II presenta los parámetros utilizados en el sistema de prueba basado en el estándar IEEE 30 barras. En esta configuración se incorpora un generador adicional, lo que

incrementa la dimensionalidad del problema de optimización a cuatro variables de decisión.

TABLA II
PARÁMETROS DE LAS UNIDADES TÉRMICAS CASO 2

Parámetro	Unidad 1	Unidad 2	Unidad 3	Unidad 4
Potencia	400 kW	300 kW	200 kW	150 kW
a	600	300	250	200
b	5.3	5.5	5.8	5.7
c	0.004	0.006	0.009	0.007
P min	100 kW	80 kW	50 kW	50 kW
P max	400 kW	300 kW	200 kW	150 kW

Las potencias asociadas a la central hidroeléctrica y a la generación fotovoltaica se mantienen; sin embargo, la incertidumbre de esta última es modelada mediante un enfoque basado en datos históricos y perfiles con correlación temporal, en lugar de un esquema paramétrico simplificado.

F. Ejecución del modelo de optimización

Para la demanda a optimizar se toma como modelo un sistema eléctrico típico de Latinoamérica, escalando los valores ya que el sistema de prueba será más pequeño en comparación solo se mantiene la forma. Los valores de la demanda se muestran en la Tabla II y son expresados en kW.

TABLA III
PARÁMETROS DE DEMANDA EN HORIZONTE DE 24H EN (kW)

1 h	2 h	3 h	4 h	5 h	6 h
787	772	757	759	750	741
7 h	8 h	9 h	10 h	11 h	12 h
719	738	768	781	804	808
13 h	14 h	15 h	16 h	17 h	18 h
814	811	791	802	793	795
19 h	20 h	21 h	22 h	23 h	24 h
857	876	870	843	806	773

Además, en la Figura 4 se muestra el comportamiento del perfil de demanda.




Fig. 4 Perfil de la demanda típico

Para la ejecución de la incertidumbre en el algoritmo se usaron parámetros de desviación estándar del 25%, 24 horas y los escenarios que fueron 30. En [7] la desviación máxima de la producción es 30% de la producción esperada. La característica de la generación fue tomada de la página pública del COES.




Fig. 5 Perfil de generación solar incluyendo la incertidumbre

La figura 6 incluye de la incertidumbre en el algoritmo se incluyeron datos sobre 31 días del mes de marzo del 2026 de la página oficial del COES que representa todos los perfiles que puede tomar el algoritmo para optimizar el despacho de carga.




Fig. 6 Perfil de generación solar incluyendo la incertidumbre

G. Evaluación del modelo del despacho económico

Para evaluar el desempeño del despacho económico implementado con GSA, se realizó una comparación con PSO clásico sobre 30 escenarios generados, considerando la incertidumbre en la demanda y la generación renovable, siendo este algoritmo el más utilizado en la literatura para las comparaciones por su buena convergencia a la hora de optimizar el despacho económico.

Se utilizó la librería pyswarm de Python dando como parámetros de tamaño de enjambre de 30 y el máximo de iteraciones a realizar serán de 30 que son las mismas que se ejecutaron en el algoritmo GSA.

III. RESULTADOS

Luego de la ejecución del modelo, se procedió a la ejecución del algoritmo propuesto, se obtuvieron los resultados luego de 30 iteraciones por parte del algoritmo GSA, así mismo, fueron aplicados a 30 distintos escenarios con incertidumbre. Obtenido un cuadro de resultados de la potencia optimizada por el algoritmo hora a hora.

La Figura 6 muestra los valores mínimo, máximo y promedio del costo total de operación del sistema eléctrico obtenidos bajo distintos escenarios de incertidumbre en la generación solar. La dispersión observada entre los valores extremos refleja el impacto directo de la variabilidad solar sobre el costo del sistema, mientras que el valor promedio representa el comportamiento esperado de la operación bajo condiciones inciertas.




Fig. 7 Costo horario del sistema

La Figura 7 muestra la potencia generada promedio por cada unidad térmica a lo largo de un horizonte de 24 horas. Se observa la contribución horaria de cada unidad al abastecimiento de la demanda, evidenciando la asignación óptima de carga en función de sus características operativas y costos de generación.




Fig. 8 Generación promedio de unidades térmicas

Así mismo, en la figura 8 se visualiza la participación de las centrales térmicas y las renovables según la hora, se puede observar que las renovables tienen mayor participación a horas del mediodía.




Fig. 9 Comparación renovables vs térmicas

Luego de la ejecución del algoritmo PSO para la comparación con el GSA se obtuvieron los siguientes resultados por día generados ya promediados bajo los 30 escenarios.

TABLA IV
COMPARACIÓN DE RESULTADOS DE OPTIMIZACIÓN PSO VS GSA

Costo (\$)	PSO	GSA
Demanda mínima	\$121704.9	\$121723.9
Demanda medio	\$124668.4	\$124321.8
Demanda máxima	\$128768.9	\$128094.9

Según la Tabla III, se presenta la comparación del desempeño de los algoritmos PSO y GSA a partir de 30 escenarios de incertidumbre evaluados. Los valores reportados corresponden a los costos mínimo, medio y máximo obtenidos sobre el conjunto de escenarios simulados. En el costo mínimo, ambos métodos muestran un comportamiento muy similar, con \$121704.9 para PSO y \$121723.9 para GSA, lo que indica un desempeño al PSO ligeramente menor. Para el costo medio, el algoritmo GSA obtiene un menor valor \$124321.8 frente a PSO \$124668.4, evidenciando una ligera ventaja en el rendimiento promedio del GSA. De forma consistente, en el costo máximo GSA también presenta un resultado inferior \$128094.9 respecto a PSO \$128768.9, lo que sugiere un mejor comportamiento relativo en los escenarios más exigentes dentro del conjunto analizado. En conjunto, los resultados muestran que GSA mantiene una calidad de solución similar y en algunos casos incluso mejor, esto bajo incertidumbre.

Como complemento a la evaluación del desempeño del algoritmo propuesto basado en GSA, se analizó el desempeño computacional y se comparó con el algoritmo de referencia PSO. El consumo de memoria RAM de los algoritmos evaluados muestra una diferencia moderada. El PSO registra un uso aproximado de 7.9 MB, mientras que el GSA alcanza 10.84 MB de RAM, lo que refleja el mayor requerimiento de memoria asociado a la gestión de agentes, fuerzas gravitacionales y variables intermedias propias del algoritmo propuesto.

Del análisis de los resultados obtenidos sobre los 30 escenarios de incertidumbre evaluados se observa que el desempeño de ambos algoritmos es cercano en términos generales. No obstante, el

método basado en GSA alcanza menores costos en los valores estadísticos medio y máximo del conjunto de escenarios, mientras que PSO presenta una ligera ventaja en el costo mínimo en la demanda máxima. Aunque las diferencias no son de gran magnitud, se aprecia una tendencia favorable a GSA en los casos de mayor costo dentro de la distribución de resultados, lo que indica un mejor comportamiento relativo bajo condiciones más exigentes del sistema. Por su parte, PSO mantiene un rendimiento competitivo en los escenarios más favorables. En conjunto, los resultados sugieren que GSA ofrece una respuesta más robusta frente a la variabilidad introducida por la incertidumbre, manteniendo una calidad de solución comparable en el total de escenarios analizados.

La Tabla V muestra los resultados del caso determinístico de 24 horas, donde todos los parámetros son fijos y la generación solar se representa mediante un único perfil horario. Estos resultados sirven como línea base para comparar el impacto de incorporar incertidumbre en la generación fotovoltaica.

TABLA V
COMPARACIÓN DE TIEMPO DE EJECUCIÓN PSO VS GSA

Resultado	PSO	GSA
Tiempo	4.28 s	5.60 s
Costo	\$122601.5	\$122473.1

Los resultados obtenidos muestran que ambos algoritmos alcanzan soluciones de costo similares, aunque con diferencias en desempeño computacional. El algoritmo PSO registró un tiempo de ejecución de 4.2 s con un costo total de \$122601.50, mientras que GSA obtuvo un costo menor de \$122473.10, pero con un tiempo de cómputo mayor de 5.6 s. Esto indica que PSO presenta una convergencia más rápida, mientras que GSA logra una solución económicamente más favorable en el escenario determinístico evaluado.

Asimismo, se realizó la optimización del despacho económico de carga en una red de prueba basada en el modelo IEEE de 30 barras, incorporando un generador adicional. Los parámetros de este generador se presentan en la Tabla III correspondiente. Se empleó la misma demanda y perfiles solares con correlación temporal. Los resultados obtenidos, tras 20 ejecuciones independientes se muestran en la Table VI.

TABLA VI
COMPARACIÓN MEDIAS Y DESVIACIÓN ESTÁNDAR PSO VS GSA

Resultado	PSO	GSA
Media	\$126736.26	\$126506.5
Desviación	\$47.28	\$60.86

A fin de evaluar la significancia estadística de estas diferencias, se aplicó la prueba no paramétrica de Wilcoxon para muestras relacionadas, obteniéndose un estadístico $W = 0$ y un $p\text{-value} = 0.000002$. Dado que el $p\text{-value}$ es menor al nivel de significancia establecido ($\alpha = 0.05$), se rechaza la hipótesis nula, concluyéndose que existen diferencias estadísticamente significativas entre ambos

algoritmos. En este contexto, el algoritmo GSA demuestra un mejor desempeño al presentar consistentemente menores costos en comparación con PSO.

IV. DISCUSIÓN DE RESULTADOS

En los experimentos basados en un modelamiento paramétrico de la incertidumbre, se utilizó una semilla aleatoria fija para inicializar el generador de números aleatorios del algoritmo metaheurístico. Esto asegura que cada ejecución emplee la misma secuencia de valores aleatorios, permitiendo la reproducibilidad de los resultados y una comparación directa entre algoritmos bajo condiciones controladas. Sin embargo, esta configuración limita la variabilidad entre ejecuciones, por lo que no permite evaluar completamente la robustez del método frente a la naturaleza estocástica del problema. Por otro lado, en los experimentos que emplean escenarios de incertidumbre basados en datos históricos con correlación temporal, la semilla aleatoria fija se utilizó únicamente para la generación de los escenarios mediante simulación de Monte Carlo, mientras que el algoritmo metaheurístico se ejecutó con inicialización aleatoria en cada corrida. De esta manera, todos los algoritmos son evaluados bajo las mismas condiciones de incertidumbre, garantizando comparabilidad en los datos de entrada. Al mismo tiempo, se conserva la variabilidad inherente del proceso de optimización, permitiendo analizar la robustez y consistencia de los métodos a lo largo de múltiples ejecuciones independientes. Este enfoque logra un balance entre reproducibilidad del entorno y una evaluación realista del desempeño de los algoritmos.

Los resultados muestran que GSA obtiene costos inferiores en la gran mayoría de las ejecuciones evaluadas, reflejando un comportamiento más estable frente a la aleatoriedad inherente del proceso de optimización. Asimismo, aunque PSO presenta un valor ligeramente inferior en el costo máximo, esta diferencia corresponde a un caso puntual y no representa la tendencia general observada. En contraste, GSA mantiene menores costos promedio y una variabilidad controlada a lo largo de las ejecuciones, lo que indica una convergencia más consistente hacia soluciones de alta calidad. En conjunto, estos resultados confirman que GSA presenta un desempeño más robusto y confiable frente a la naturaleza estocástica del problema, mientras que PSO, si bien es competitivo, muestra una mayor dispersión en sus resultados.

En contraste, el algoritmo GSA presenta un mayor costo computacional, asociado al cálculo iterativo de fuerzas gravitacionales y a la interacción global entre las partículas. Sin embargo, esta mayor complejidad le permite explorar de forma más efectiva el espacio de búsqueda, lo que se traduce en menores costos operativos y una mayor estabilidad de las soluciones, particularmente durante horas de alta demanda o elevada variabilidad en la generación solar. En consecuencia, PSO resulta adecuado para evaluaciones rápidas en escenarios base, mientras que GSA ofrece ventajas cuando se busca mayor robustez y minimización de costo bajo condiciones inciertas.

Por otro lado, el análisis evidenció la alta facilidad de incorporar la incertidumbre en el algoritmo de optimización del GSA mostrando mayor capacidad de adaptación ante la

variabilidad del recurso solar, por lo tanto, ofrece una mayor robustez y estabilidad en las soluciones obtenidas, mostrando una mejor capacidad de adaptación ante cambios en la demanda y en la disponibilidad de recursos energéticos, lo que lo posiciona como una opción más adecuada para aplicaciones prácticas donde la confiabilidad del despacho y la calidad de la solución son prioritarias.

V. CONCLUSIONES

En este trabajo se analizó la aplicación del GSA al problema de despacho económico en sistemas eléctricos de potencia, considerando múltiples escenarios que representan la variabilidad e incertidumbre inherentes a la operación del sistema. El desempeño de este algoritmo fue evaluado y contextualizado mediante su comparación con PSO, ampliamente utilizado como algoritmo de referencia en la literatura. Desde un enfoque estadístico, los resultados obtenidos en los 30 escenarios de incertidumbre muestran que el algoritmo GSA no solo logra menores costos promedio, sino que además presenta una menor dispersión respecto a PSO, lo que indica un comportamiento más estable y consistente ante variaciones en la generación renovable. Esta menor variabilidad sugiere una convergencia más uniforme hacia soluciones de buena calidad, manteniendo simultáneamente una adecuada capacidad de exploración del espacio de búsqueda, aspecto clave en problemas de despacho económico con múltiples óptimos locales.

El análisis escenario a escenario evidencia que GSA obtiene el menor costo operativo en la amplia mayoría de los casos evaluados (superior a dos tercios de los 30 escenarios), mientras que PSO solo resulta mejor en un número reducido de escenarios puntuales. Esta tendencia confirma la ventaja comparativa de GSA bajo condiciones de incertidumbre, al ofrecer soluciones sistemáticamente más económicas. Por lo tanto, los resultados validan al GSA como una alternativa adaptable a la incertidumbre y eficiente para el despacho económico estocástico, y respaldan su potencial para futuras extensiones mediante esquemas adaptativos o estrategias híbridas orientadas a reforzar aún más su desempeño. Desde una perspectiva aplicada, estos resultados tienen implicancias directas en el contexto de los mercados eléctricos, particularmente en problemas de despacho económico y operación óptima bajo incertidumbre. La incorporación de métodos de optimización robustos, como GSA, permite reducir costos operativos de manera consistente, lo cual es clave en entornos donde pequeñas mejoras en el costo marginal pueden traducirse en beneficios económicos significativos a gran escala.

REFERENCIAS

- [1] V. M. Garrido-Arevalo, W. Gil-Gonzalez, O. D. Montoya, L. F. Grisales-Norena, and J. C. Hernandez, "Optimal Dispatch of DERs and Battery-Based ESS in Distribution Grids While Considering Reactive Power Capabilities and Uncertainties: A Second-Order Cone Programming Formulation," *IEEE Access*, vol. 12, pp. 48497–48510, 2024, doi: 10.1109/ACCESS.2024.3382940.
- [2] A. Ali *et al.*, "Multi-objective multiperiod stable environmental economic power dispatch considering probabilistic wind and solar PV generation," *IET Renew. Power Gener.*, vol. 18, no. 16, pp. 3903–3922, Dec. 2024, doi: 10.1049/RPG2.13077;ISSUE:ISSUE:DOI.
- [3] Z. Zhang, H. Zhang, Y. Tian, C. Li, and D. Yue, "Cooperative constrained multi-objective dual-population evolutionary algorithm for optimal dispatching of wind-power integrated power system," *Swarm Evol. Comput.*, vol. 87, p. 101525, Jun. 2024, doi: 10.1016/J.SWEVO.2024.101525.
- [4] C. Jena, J. M. Guerrero, A. Abusorrah, Y. Al-Turki, and B. Khan, "Multi-Objective Generation Scheduling of Hydro-Thermal System Incorporating Energy Storage With Demand Side Management Considering Renewable Energy Uncertainties," *IEEE Access*, vol. 10, pp. 52343–52357, 2022, doi: 10.1109/ACCESS.2022.3172500.
- [5] E. E. Hassan, H. I. M. Noor, M. R. Bin Hashim, M. F. Sulaima, and N. Bahaman, "Optimal economic environmental power dispatch by using artificial bee colony algorithm," *IAES Int. J. Artif. Intell.*, vol. 13, no. 2, pp. 1469–1478, Jun. 2024, doi: 10.11591/ijai.v13.i2.pp1469-1478.
- [6] Y. Gao *et al.*, "Economic Dispatch Optimization Strategies and Problem Formulation: A Comprehensive Review," *Energies* 2024, Vol. 17, Page 550, vol. 17, no. 3, p. 550, Jan. 2024, doi: 10.3390/EN17030550.
- [7] Q. Niu, L. Wang, and L. Yu, "A novel evolutionary algorithm for solving large-scale dynamic economic dispatch problem integrated with wind power," *ACM Int. Conf. Proceeding Ser.*, pp. 149–155, Jul. 2022, doi: 10.1145/3556677.3556699;TOPIC:TOPIC:CONFERENCE-COLLECTIONS.
- [8] S. R. Kar, D. P. Dash, and S. K. Sanyal, "Application of whale optimization algorithm for environmental constrained economic dispatch of fixed head hydro-wind-thermal power system," *Int. J. Eng. Adv. Technol.*, vol. 9, no. 1, pp. 5608–5616, Oct. 2019, doi: 10.35940/IJEAT.A2261.109119.
- [9] G. Liu, J. Zhou, X. Xiao, L. Mo, Y. Yuqi, and L. Chengwei, "Dynamic Economic Dispatch in Thermal-Wind-Small Hydropower Generation System," *MATEC Web Conf.*, vol. 246, p. 01085, Dec. 2018, doi: 10.1051/MATECONF/201824601085.
- [10] H. Zhang, D. Yue, and X. Xie, "Robust Optimization for Dynamic Economic Dispatch under Wind Power Uncertainty with Different Levels of Uncertainty Budget," *IEEE Access*, vol. 4, pp. 7633–7644, 2016, doi: 10.1109/ACCESS.2016.2621338.
- [11] L. Yin and W. Ding, "Deep neural network accelerated-group African vulture optimization algorithm for unit commitment considering uncertain wind power," *Appl. Soft Comput.*, vol. 162, p. 111845, Sep. 2024, doi: 10.1016/J.ASOC.2024.111845.
- [12] R. Dong, L. Sun, Z. Cai, A. A. Heidari, L. Liu, and H. Chen, "An advanced kernel search optimization for dynamic economic emission dispatch with new energy sources," *Int. J. Electr. Power Energy Syst.*, vol. 160, p. 110085, Sep. 2024, doi: 10.1016/J.IJEPES.2024.110085.
- [13] H. Nourianfar and H. Abdi, "Solving power systems optimization problems in the presence of renewable energy sources using modified exchange market algorithm," *Sustain. Energy, Grids Networks*, vol. 26, p. 100449, Jun. 2021, doi: 10.1016/J.SEGAN.2021.100449.
- [14] W. Li, "An Improved Gravitational Search Algorithm for Optimization Problems," *Proc. 31st Chinese Control Decis. Conf. CCDC 2019*, pp. 2605–2608, Jun. 2019, doi: 10.1109/CCDC.2019.8833403.
- [15] S. Rajakumari, K. Hc, S. Ahmad, R. R. Sharma, S. Sudha, and T. Ramesh, "Energy-Efficient Transmission in Wireless Networks Using Resnet with Gravitational Search Algorithm," *2024 2nd Int. Conf. Disruptive Technol. ICDT 2024*, pp. 1162–1167, 2024, doi: 10.1109/ICDT61202.2024.10489688.
- [16] A. J. P. Barbosa, E. M. Moreira, C. H. V. Moraes, and O. A. S. Carpinteiro, "A heuristic to determine the initial gravitational constant of the GSA," Apr. 2022, Accessed: Jan. 31, 2026. [Online]. Available: <https://arxiv.org/pdf/2205.06770>.