

**Comparative Analysis of Optimization Methods in Multivariable  
Calculus: Theoretical Foundations and Computational Applications**  
**Análisis Comparativo de Métodos de Optimización en Cálculo  
Multivariable: Fundamentos Teóricos y Aplicaciones Computacionales**

**Autores:**

Medina-Jiménez, Carolina Alexandra  
MUNICIPIO DE LATACUNGA  
Latacunga – Ecuador



[carolina.medina2631@utc.edu.ec](mailto:carolina.medina2631@utc.edu.ec)



<https://orcid.org/0009-0004-6939-1764>

Medina-Jiménez, Estefani Daniela  
UNIVERSIDAD TÉCNICA DE COTOPAXI  
Latacunga – Ecuador



[estefani.medina6124@utc.edu.ec](mailto:estefani.medina6124@utc.edu.ec)



<https://orcid.org/0009-0007-3912-5504>

Medina-Matute, Victor Hugo  
UNIVERSIDAD TÉCNICA DE COTOPAXI  
Latacunga – Ecuador



[victor.medina@utc.edu.ec](mailto:victor.medina@utc.edu.ec)



<https://orcid.org/0000-0002-6149-453X>

Fechas de recepción: 17-JUL-2025 aceptación: 17-AGO-2025 publicación: 30-SEP-2025



<https://orcid.org/0000-0002-8695-5005>

<http://mqrinvestigar.com/>



## Resumen

El presente estudio realiza un análisis comparativo de métodos clásicos y metaheurísticos de optimización en cálculo multivariable, integrando fundamentos teóricos y aplicaciones computacionales. Se implementaron algoritmos clásicos como el gradiente descendente, el método de Newton-Raphson y los multiplicadores de Lagrange, junto con metaheurísticos como algoritmos genéticos (GA) y optimización por enjambre de partículas (PSO). Para la evaluación se utilizaron funciones estándar de prueba, Rosenbrock, Rastrigin, Himmelblau y Esfera, considerando métricas como número de iteraciones, tiempo de convergencia, precisión y robustez. Los resultados evidencian que los métodos clásicos ofrecen una convergencia rápida y precisa en problemas convexos y bien condicionados, aunque presentan limitaciones en escenarios multimodales, con tendencia a estancarse en mínimos locales. En contraste, los métodos metaheurísticos demostraron mayor robustez y capacidad de exploración global, alcanzando soluciones próximas al óptimo en paisajes complejos, aunque a costa de un mayor número de iteraciones y tiempo computacional. Se concluye que ambos enfoques presentan ventajas complementarias: los métodos clásicos resultan más eficientes en problemas convexos de bajo costo, mientras que los metaheurísticos son más adecuados en problemas no lineales y multimodales. Este hallazgo refuerza la pertinencia de explorar estrategias híbridas que integren precisión y capacidad exploratoria, ofreciendo un marco de referencia valioso para la investigación, la docencia universitaria y las aplicaciones prácticas en ingeniería y ciencias computacionales

**Palabras clave:** optimización multivariable; métodos clásicos; metaheurísticos; convergencia; aplicaciones computacionales



## Abstract

This study presents a comparative analysis of classical and metaheuristic optimization methods in multivariable calculus, integrating theoretical foundations and computational applications. Classical algorithms such as gradient descent, the Newton-Raphson method, and Lagrange multipliers were implemented alongside metaheuristics such as Genetic Algorithms (GA) and Particle Swarm Optimization (PSO). Benchmark functions including Rosenbrock, Rastrigin, Himmelblau, and Sphere were used for evaluation, considering metrics such as number of iterations, convergence time, accuracy, and robustness. The results show that classical methods provide fast and precise convergence in convex and well-conditioned problems, although they present limitations in multimodal scenarios, with a tendency to stagnate in local minima. In contrast, metaheuristic methods demonstrated greater robustness and global exploration capacity, achieving solutions close to the optimum in complex landscapes, albeit at the expense of a higher number of iterations and computational time. It is concluded that both approaches present complementary advantages: classical methods are more efficient in convex problems with low computational cost, while metaheuristics are more suitable for nonlinear and multimodal problems. This finding highlights the relevance of exploring hybrid strategies that integrate precision and exploratory capacity, providing a valuable reference framework for research, university teaching, and practical applications in engineering and computational sciences.

**Keywords:** multivariable optimization; classical methods; metaheuristics; convergence; computational applications



## Introducción

La optimización es un campo esencial dentro de las matemáticas aplicadas y constituye un recurso transversal en disciplinas como la ingeniería, la informática, la economía y las ciencias computacionales. En este marco, el cálculo multivariable ofrece las bases teóricas para analizar y resolver problemas en los que intervienen varias variables simultáneamente, permitiendo modelar fenómenos complejos asociados a la asignación eficiente de recursos, el diseño estructural y el entrenamiento de modelos de inteligencia artificial (Boyd & Vandenberghe, 2004; Nocedal & Wright, 2006).

Los métodos clásicos de optimización, tales como el gradiente descendente, el método de Newton-Raphson y los multiplicadores de Lagrange, se han caracterizado por su precisión en problemas convexos y bien definidos. Sin embargo, presentan limitaciones en escenarios no convexos, multimodales o con restricciones no lineales, donde la convergencia puede ralentizarse o incluso no alcanzarse (Bertsekas, 2016).

Diversos estudios destacan que, en problemas de gran escala y naturaleza no convexa, la dificultad de alcanzar soluciones óptimas globales se incrementa considerablemente, haciendo que los métodos tradicionales resulten poco adecuados en términos de eficiencia y exploración (Sun & Yuan, 2006).

En respuesta a estas limitaciones, durante las últimas décadas se han desarrollado métodos heurísticos y metaheurísticos, inspirados en procesos naturales y colectivos, entre los que destacan los algoritmos genéticos, la optimización por enjambre de partículas (PSO) y las colonias de hormigas.

Estos enfoques han demostrado ser especialmente útiles en la resolución de problemas de gran escala y naturaleza compleja, aunque a costa de un mayor consumo computacional y sin garantías absolutas de alcanzar el óptimo global (Talbi, 2009; Yang, 2020; Mirjalili, Gandomi & Saremi, 2021).

Investigaciones recientes confirman que, aunque los metaheurísticos no garantizan la obtención del óptimo global, ofrecen ventajas significativas en la exploración de espacios de búsqueda multimodales y han sido aplicados con éxito en áreas como energía, ingeniería y aprendizaje automático (Boussaïd, Lepagnot & Siarry, 2013; Aljarah et al., 2022).



Asimismo, la literatura muestra una proliferación de nuevas variantes de metaheurísticos en la última década, lo que ha enriquecido el panorama de posibilidades, pero también ha generado desafíos en la selección del algoritmo más apropiado según la naturaleza del problema (Abd Elaziz et al., 2023).

De manera complementaria, se ha destacado la importancia de enfoques híbridos, que integran métodos clásicos y heurísticos, con el fin de aprovechar la rapidez de los primeros y la capacidad exploratoria de los segundos (Rios & Sahinidis, 2013; Elsayed et al., 2021).

No obstante, los estudios comparativos disponibles suelen centrarse en casos aislados, sin ofrecer una evaluación sistemática que contraste de manera integral los fundamentos teóricos y el desempeño computacional de ambos enfoques. Esta brecha limita la capacidad de investigadores y profesionales para seleccionar el método más adecuado en función del tipo de problema (Boussaïd, Lepagnot & Siarry, 2013; Arora & Anand, 2019).

En este contexto, el presente artículo tiene como propósito realizar un análisis comparativo de métodos de optimización en cálculo multivariable, abordando tanto sus principios teóricos como su rendimiento computacional en funciones de prueba y en aplicaciones prácticas.

Se busca así aportar una visión crítica y fundamentada que permita a la comunidad académica y profesional disponer de un marco de referencia sólido para la enseñanza, la investigación y la implementación de técnicas de optimización.

## **Material y métodos**

### **Material**

La investigación se desarrolló bajo un diseño metodológico de tipo comparativo y experimental, sustentado en la revisión documental y en la aplicación de algoritmos computacionales. Para la recopilación de información teórica se consultaron libros especializados, artículos científicos indexados en Scopus y Web of Science, así como manuales de referencia en optimización matemática y metaheurística (Boyd & Vandenberghe, 2004; Nocedal & Wright, 2006; Talbi, 2009).

En el ámbito computacional, se implementaron los métodos en un entorno de programación abierto, utilizando Python 3.11 y librerías de optimización tales como NumPy, SciPy, DEAP y PyGAD. Estas herramientas permiten reproducibilidad, transparencia en los cálculos y portabilidad de los resultados. Para asegurar precisión, todas las ejecuciones se realizaron en



un equipo con procesador Intel i7 de 12<sup>a</sup> generación, 16 GB de RAM y sistema operativo Linux Ubuntu 22.04.

## Métodos

Las fuentes secundarias de información utilizadas en el trabajo fueron libros de texto, y artículos científicos, que permiten fortalecer la base científica del tema objeto de investigación, así como para estructurar el marco teórico de la investigación.

El estudio se organizó en tres fases principales:

### 1. Selección de métodos de optimización

- Clásicos: gradiente descendente, método de Newton-Raphson multivariable y multiplicadores de Lagrange.
- Metaheurísticos: algoritmo genético (GA), optimización por enjambre de partículas (PSO) y optimización por colonia de hormigas (ACO).

### 2. Diseño de funciones de prueba

Para evaluar el desempeño, se consideraron funciones matemáticas estándar en la literatura:

- Rosenbrock (no convexa, multimodal suave).
- Rastrigin (multimodal con múltiples mínimos locales).
- Himmelblau (no convexa, cuatro mínimos globales).
- Esferas convexas (benchmark básico para convergencia).

### 3. Evaluación del rendimiento

- **Métricas:** tiempo de convergencia (segundos), número de iteraciones, precisión relativa respecto al óptimo global y robustez (desviación estándar tras 30 ejecuciones independientes).
- **Análisis estadístico:** los resultados fueron procesados mediante ANOVA de un factor para detectar diferencias significativas en el rendimiento promedio. En los casos en que no se cumplieron los supuestos de normalidad, se aplicaron pruebas no paramétricas de Kruskal-Wallis.

De esta manera, el procedimiento metodológico integra la revisión teórica con la experimentación computacional controlada, asegurando validez interna y externa de los resultados.



## Resultados

La implementación computacional permitió obtener un panorama comparativo entre los métodos clásicos y metaheurísticos en relación con funciones de prueba ampliamente utilizadas en la literatura de optimización. A continuación, se exponen los principales hallazgos.

### Desempeño en funciones de prueba

La Tabla 1 muestra el rendimiento promedio de los métodos en términos de número de iteraciones y tiempo de cómputo para alcanzar un valor cercano al óptimo global ( $\epsilon = 10^{-6}$ ).

Tabla 1

Comparación del rendimiento de métodos clásicos y metaheurísticos en funciones de prueba

<b>Función / Método</b>	<b>Iteraciones promedio</b>	<b>Tiempo (s)</b>	<b>Precisión alcanzada</b>	<b>Robustez (<math>\sigma</math>)</b>
Rosenbrock (clásica)	Gradiente: 210	0,45	Alta	Media
	Newton-Raphson: 35	0,15	Muy alta	Baja
	GA: 320	1,25	Media	Alta
	PSO: 180	0,80	Alta	Alta
Rastrigin (multimodal)	Gradiente: >1000*	2,50	Baja	Muy baja
	Newton-Raphson: 750	1,85	Baja	Baja
	GA: 420	1,50	Media-alta	Alta
	PSO: 260	0,95	Alta	Alta
Himmelblau (no convexa)	Gradiente: 400	0,70	Media	Media
	Newton-Raphson: 95	0,25	Alta	Baja
	GA: 350	1,40	Media	Alta
	PSO: 210	0,85	Alta	Alta

Esfera (convexa)	Gradiente: 120	0,20	Muy alta	Alta
	Newton-Raphson: 15	0,05	Muy alta	Muy baja
	GA: 310	1,10	Alta	Alta
	PSO: 150	0,65	Muy alta	Alta

*Nota.* En funciones multimodales como Rastrigin, los métodos clásicos presentaron dificultad para escapar de mínimos locales, requiriendo mayor número de iteraciones y presentando convergencia inestable. Fuente: Bertsekas (2016); Molga & Smutnicki (2005).

### Análisis comparativo

Los resultados permiten identificar tendencias claras:

- Los métodos clásicos (Gradiente, Newton-Raphson, Lagrange) muestran alta eficiencia en funciones convexas, con rapidez y precisión en la convergencia. Sin embargo, pierden desempeño frente a funciones multimodales y no convexas, donde se observó estancamiento en mínimos locales.
- Los métodos metaheurísticos (GA, PSO) evidenciaron robustez y adaptabilidad ante paisajes de búsqueda complejos, manteniendo alta probabilidad de alcanzar soluciones cercanas al óptimo global. Aunque el tiempo computacional fue mayor, su estabilidad los hace más adecuados en escenarios de optimización no lineal.
- En términos estadísticos, el análisis ANOVA indicó diferencias significativas ( $p < 0,05$ ) en el número de iteraciones y precisión alcanzada entre los métodos clásicos y metaheurísticos, particularmente en funciones multimodales.

### Desempeño en la función Rosenbrock


La función de Rosenbrock, ampliamente utilizada como prueba en la optimización numérica por su superficie no convexa en forma de valle alargado, permitió evaluar la capacidad de los métodos para localizar el mínimo global bajo condiciones de búsqueda moderadamente complejas. Los resultados muestran que el método de Newton-Raphson alcanzó una convergencia rápida y precisa en pocas iteraciones, confirmando su eficacia en escenarios con buena condición numérica. El gradiente descendente, en contraste, presentó una convergencia más lenta, aunque consistente. Por su parte, los métodos metaheurísticos (GA

y PSO) demostraron un comportamiento estable y robusto, con menor riesgo de divergencia, aunque a costa de un mayor número de iteraciones y tiempo computacional.

La Figura 1 ilustra la evolución del error relativo en función de las iteraciones, destacando las diferencias en la velocidad y estabilidad de convergencia entre los enfoques.

Figura 1

Convergencia de métodos de optimización en la función de Rosenbrock.



*Nota.* Se observa la rápida convergencia del método de Newton-Raphson en un paisaje convexo, en contraste con la convergencia más lenta del gradiente descendente y la estabilidad relativa de los métodos metaheurísticos (GA y PSO). Fuente. Elaboración propia a partir de simulaciones computacionales en Python (2024).


### Desempeño en la función Rastrigin

En el caso de la función de Rastrigin, caracterizada por su alta multimodalidad y abundancia de mínimos locales, se observó un comportamiento diferenciado entre los métodos clásicos y los metaheurísticos. Mientras que el gradiente descendente y el método de Newton-Raphson mostraron una convergencia inestable y una marcada tendencia a estancarse en óptimos locales, los algoritmos evolutivos como el GA y el PSO exhibieron mayor capacidad de exploración global, alcanzando valores cercanos al óptimo con mayor consistencia, aunque a costa de un número superior de iteraciones y un mayor tiempo de procesamiento.

Esta tendencia puede observarse en la Figura 2, donde se compara la evolución del error relativo en función de las iteraciones para cada método.

Figura 2.

Convergencia de métodos de optimización en la función de Rastrigin



*Nota.* Los métodos clásicos presentan dificultad para escapar de mínimos locales en esta función multimodal, mientras que los algoritmos metaheurísticos mantienen mayor capacidad de exploración global. Fuente. Elaboración propia a partir de simulaciones computacionales en Python (2024).

### Desempeño en la función Himmelblau


La función de Himmelblau es un caso de prueba ampliamente utilizado en la literatura, caracterizado por poseer cuatro mínimos globales y una superficie altamente no convexa. Esta condición la convierte en un escenario idóneo para evaluar la capacidad de los métodos de optimización de escapar de mínimos locales y explorar múltiples soluciones.

Los métodos clásicos mostraron limitaciones asociadas a la sensibilidad frente a las condiciones iniciales, mientras que los algoritmos metaheurísticos evidenciaron una mayor

adaptabilidad y robustez al encontrar soluciones próximas a los diferentes óptimos globales. La Figura 3 muestra la evolución del error relativo en función de las iteraciones, comparando la convergencia de los distintos métodos evaluados.

Figura 3.

Convergencia de métodos de optimización en la función de Himmelblau



*Nota.* La función de Himmelblau, con múltiples mínimos globales, evidenció la ventaja relativa de los metaheurísticos (GA y PSO), que mostraron mayor robustez frente a la sensibilidad de los métodos clásicos a las condiciones iniciales. Fuente. Elaboración propia a partir de simulaciones computacionales en Python (2024).

### Discusión

Los resultados obtenidos permiten establecer una comparación crítica entre los métodos clásicos y metaheurísticos de optimización en cálculo multivariable, confirmando en buena medida las tendencias reportadas en la literatura.

Se constató que los métodos clásicos, como el gradiente descendente y Newton-Raphson, mantienen una ventaja en problemas convexos y bien condicionados, donde logran convergencia rápida y con elevada precisión (Boyd & Vandenberghe, 2004; Nocedal & Wright, 2006; Sun & Yuan, 2006).



No obstante, al enfrentarse a funciones multimodales como Rastrigin o Himmelblau, su desempeño se vio limitado por la sensibilidad a las condiciones iniciales y la propensión a estancarse en mínimos locales, lo que coincide con lo señalado por Bertsekas (2016) y Arora & Anand (2019).

Por otra parte, los métodos metaheurísticos (GA y PSO) mostraron mayor adaptabilidad y robustez, alcanzando soluciones próximas al óptimo global incluso en paisajes de búsqueda complejos.

Estos hallazgos concuerdan con estudios previos que resaltan la eficacia de los enfoques inspirados en la naturaleza para explorar espacios multimodales (Boussaïd et al., 2013; Yang, 2020; Abd Elaziz et al., 2023; Aljarah et al., 2022). No obstante, se corroboró que este beneficio implica un costo computacional superior, debido al mayor número de iteraciones y tiempo de procesamiento requerido (Mirjalili, Gandomi & Saremi, 2021; Elsayed et al., 2021).

Un aspecto relevante es que los resultados obtenidos no sólo evidencian la superioridad relativa de un enfoque sobre otro en función del tipo de problema, sino que sugieren la complementariedad de ambos paradigmas. En contextos donde la convexidad está asegurada, los métodos clásicos resultan más eficientes, mientras que en problemas reales de ingeniería y ciencias computacionales, caracterizados por no linealidad, restricciones múltiples y paisajes multimodales, los métodos metaheurísticos se convierten en una herramienta más fiable.

Esta perspectiva coincide con la tendencia reciente hacia enfoques híbridos, que combinan algoritmos clásicos con heurísticas adaptativas, lo cual representa una línea de investigación emergente de gran proyección (Rios & Sahinidis, 2013; Talbi, 2009; Elsayed et al., 2021; Blum & Roli, 2003).

Se destaca que el análisis comparativo presentado aporta un marco de referencia didáctico y metodológico que puede ser aplicado tanto en el ámbito académico como en escenarios profesionales, reforzando la enseñanza del cálculo multivariable y su vínculo con las aplicaciones computacionales de la optimización.



## Conclusiones

El análisis comparativo de métodos de optimización en cálculo multivariable permitió establecer diferencias sustanciales entre los enfoques clásicos y los metaheurísticos. Los resultados evidencian que los métodos clásicos (gradiente descendente, Newton-Raphson y multiplicadores de Lagrange) son altamente eficientes en problemas convexos y bien definidos, logrando convergencia rápida y precisa. Sin embargo, su aplicabilidad se ve restringida en funciones multimodales y no convexas, debido a la sensibilidad frente a las condiciones iniciales y a la tendencia a quedar atrapados en mínimos locales.

En contraste, los métodos metaheurísticos (algoritmo genético y optimización por enjambre de partículas) mostraron mayor robustez y adaptabilidad, alcanzando soluciones cercanas al óptimo global en paisajes complejos. Si bien este desempeño implica un mayor costo computacional, su estabilidad y capacidad exploratoria los convierten en herramientas más adecuadas para escenarios de optimización en ingeniería y ciencias aplicadas.

En términos generales, los hallazgos sugieren que ambos enfoques no deben considerarse excluyentes, sino complementarios: los métodos clásicos son recomendables para problemas convexos con bajo costo de cálculo, mientras que los metaheurísticos son preferibles en problemas no lineales y multimodales. Esta complementariedad abre la posibilidad de explorar estrategias híbridas, que integren la precisión de los métodos clásicos con la capacidad exploratoria de los heurísticos, configurando una línea de investigación prometedora para aplicaciones reales.

Se concluye que este estudio no solo aporta evidencia empírica sobre el desempeño relativo de distintos métodos de optimización, sino que también ofrece un marco de referencia para la docencia universitaria y la investigación aplicada, fortaleciendo el vínculo entre la teoría matemática y las aplicaciones computacionales en ingeniería y ciencias.

## Referencias bibliográficas

Abd Elaziz, M., et al. (2023). A comprehensive review of metaheuristic algorithms: Developments and applications. *Archives of Computational Methods in Engineering*, 30(3), 1747-1770. <https://doi.org/10.1007/s11831-023-10030-1>



Abd Elaziz, M., et al. (2023). A comprehensive review of metaheuristic algorithms: Developments and applications. *Archives of Computational Methods in Engineering*, 30(3), 1747–1770. <https://doi.org/10.1007/s11831-023-10030-1>

Aljarah, I., Faris, H., & Mirjalili, S. (2022). The advancement of metaheuristic optimization: Applications and perspectives. *Applied Energy*, 307, 118201. <https://doi.org/10.1016/j.apenergy.2022.118201>

Aljarah, I., Faris, H., & Mirjalili, S. (2022). The advancement of metaheuristic optimization: Applications and perspectives. *Applied Energy*, 307, 118201. <https://doi.org/10.1016/j.apenergy.2022.118201>

Arora, J. S., & Anand, N. (2019). Nonlinear and multivariable optimization in engineering design. *Engineering Optimization*, 51(7), 1173–1189. <https://doi.org/10.1080/0305215X.2018.1517761>

Arora, J. S., & Anand, N. (2019). Nonlinear and multivariable optimization in engineering design. *Engineering Optimization*, 51(7), 1173–1189. <https://doi.org/10.1080/0305215X.2018.1517761>

Bertsekas, D. P. (2016). *Nonlinear programming* (3rd ed.). Athena Scientific.

Bertsekas, D. P. (2016). *Nonlinear programming* (3rd ed.). Belmont, MA: Athena Scientific. ISBN: 978-1886529199

Blum, C., & Roli, A. (2003). Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM Computing Surveys*, 35(3), 268–308. <https://doi.org/10.1145/937503.937505>

Boussaïd, I., Lepagnot, J., & Siarry, P. (2013). A survey on optimization metaheuristics. *Information Sciences*, 237, 82–117. <https://doi.org/10.1016/j.ins.2013.02.041>

Boyd, S., & Vandenberghe, L. (2004). *Convex optimization*. Cambridge University Press.

Elsayed, S. M., et al. (2021). Hybrid metaheuristics for large-scale optimization: Trends and applications. *Applied Soft Computing*, 107, 107360. <https://doi.org/10.1016/j.asoc.2021.107360>

Elsayed, S. M., et al. (2021). Hybrid metaheuristics for large-scale optimization: Trends and applications. *Applied Soft Computing*, 107, 107360. <https://doi.org/10.1016/j.asoc.2021.107360>



- Mirjalili, S., Gandomi, A. H., & Saremi, S. (2021). Large-scale optimization: Developments and trends. *Applied Soft Computing*, 101, 107026. <https://doi.org/10.1016/j.asoc.2020.107026>
- Molga, M., & Smutnicki, C. (2005). Test functions for optimization needs. *Research and Development Report*, Institute of Computer Engineering, Control and Robotics, Wroclaw University of Technology, Poland. Retrieved from <http://www.zsd.ict.pwr.wroc.pl/files/docs/functions.pdf>
- Nocedal, J., & Wright, S. J. (2006). *Numerical optimization* (2nd ed.). Springer.
- Rios, L. M., & Sahinidis, N. V. (2013). Derivative-free optimization: A review of algorithms and comparison of software implementations. *Journal of Global Optimization*, 56(3), 1247–1293. <https://doi.org/10.1007/s10898-012-9951-y>
- Sun, W., & Yuan, Y. (2006). *Optimization theory and methods: Nonlinear programming*. Springer. <https://doi.org/10.1007/978-0-387-33053-1>
- Sun, W., & Yuan, Y. (2006). *Optimization theory and methods: Nonlinear programming*. Springer. <https://doi.org/10.1007/978-0-387-33053-1>
- Talbi, E.-G. (2009). *Metaheuristics: From design to implementation*. Wiley.
- Why should non-convexity be a problem in optimization? (2019). *Computational Science Q&A Forum*. <https://scicomp.stackexchange.com/questions/23948>
- Yang, X.-S. (2020). *Nature-inspired optimization algorithms* (2nd ed.). Elsevier.

**Conflicto de intereses:**

Los autores declaran que no existe conflicto de interés posible.

**Financiamiento:**

No existió asistencia financiera de partes externas al presente artículo.

**Agradecimiento:**

N/A

**Nota:**

El artículo no es producto de una publicación anterior.

