

Modelos matemáticos de optimización: análisis documental comparativo desde un enfoque cualitativo

Mathematical optimization models: comparative documentary analysis from a qualitative approach

Historial del Artículo /
Article History
Recibido / Received:
10-11-2025
Revisado / Revised:
24-11-2025
Aceptado / Accepted:
20-12-2025
publicado en línea /
Published online:
10-02-2026

José Luis Quintero ^{1,a,*} • Julio Vincenti ^{2,a} • Erasmo Tudares ^{3,a} • Ronald Torres ^{4,a} • Carlos Hernández^{5,a}

¹Departamento de Matemática Aplicada, Ciclo Básico, Facultad de Ingeniería, Universidad Central de Venezuela (UCV), Caracas, Venezuela

²Departamento de Ingeniería Estructural, Escuela de Ingeniería Civil, Facultad de Ingeniería, Universidad Central de Venezuela (UCV), Caracas, Venezuela

³Departamento de Educación para la Ingeniería, Ciclo Básico, Facultad de Ingeniería, Universidad Central de Venezuela (UCV), Caracas, Venezuela

⁴Instituto de Materiales y Modelos Estructurales (IMME), Facultad de Ingeniería, Universidad Central de Venezuela (UCV), Caracas, Venezuela

⁵Universidad Nacional Abierta (UNA), Caracas, Venezuela

*  Autor de la Correspondencia / corresponding author: jose.quintero@ucv.ve / quintero.davila@gmail.com,

^aEstos autores contribuyeron por igual en este trabajo / These authors contributed equally to this work

Resumen

El presente artículo examina, mediante un análisis documental cualitativo, los principales modelos matemáticos de optimización que permiten resolver problemas complejos de la vida real, como los de negocios, ingeniería, logística y del ámbito militar, entre otros. Este análisis se llevó a cabo según la literatura científica publicada entre 2010 y 2023. Se recopilaron y analizaron varios documentos de bases indexadas. Los modelos abordados incluyen programación lineal, no lineal, entera y mixta, optimización estocástica, optimización dinámica, heurísticas, metaheurísticas y modelos híbridos. Los resultados evidencian que, aunque los modelos exactos (lineales, no lineales, enteros y estocásticos) siguen siendo fundamentales, enfrentan limitaciones en problemas de gran escala. En contraste, los enfoques heurísticos y metaheurísticos ofrecen soluciones aproximadas más adaptables a contextos complejos. Se observa una tendencia hacia la hibridación metodológica, donde se integran enfoques exactos, aproximados e inteligencia artificial. El análisis concluye que la optimización matemática es un campo en transición hacia paradigmas interdisciplinarios, orientados a problemas de sostenibilidad, big data, inteligencia artificial y gobernanza.

Palabras clave: Modelos Matemáticos; Optimización Matemática; Programación Lineal; Metaheurísticas; Modelos Híbridos

Abstract

This article examines, through a qualitative documentary analysis, the main mathematical optimization models discussed in the scientific literature between 2010 and 2023. Several documents from indexed databases were collected and analyzed. The models addressed include linear, nonlinear, integer and mixed programming, stochastic optimization, dynamic optimization, heuristics, metaheuristics, and hybrid models. The results show that, although exact models (linear, nonlinear, integer, and stochastic) remain fundamental, they face limitations when applied to large-scale problems. In contrast, heuristic and metaheuristic approaches provide approximate solutions that are more adaptable to complex contexts. A trend toward methodological hybridization is observed, where exact, approximate, and artificial intelligence approaches are integrated. The analysis concludes that mathematical optimization is a field in transition toward interdisciplinary paradigms, oriented toward sustainability, big data, artificial intelligence, and governance challenges.

Keywords: Mathematical Models; Mathematical Optimization; Linear Programming; Metaheuristics; Hybrid Models

1. Introducción

La optimización matemática constituye uno de los pilares fundamentales de la investigación operativa y de las ciencias computacionales, al proporcionar herramientas rigurosas para la toma de decisiones en escenarios donde los recursos son limitados, los objetivos múltiples y la incertidumbre es una constante (Bertsimas y Tsitsiklis, 2018). Desde los trabajos pioneros del matemático estadounidense George Dantzig, con el desarrollo del método simplex y la formulación de la programación lineal (Dantzig, 1947), hasta los más recientes enfoques híbridos que integran inteligencia artificial y metaheurísticas, la disciplina ha experimentado un desarrollo sostenido y de gran impacto en diferentes campos de aplicación.

El avance histórico de la optimización matemática puede dividirse en varias etapas claramente diferenciadas. En primer lugar, se encuentran los modelos exactos clásicos, entre los que destaca la programación lineal, empleada en problemas de transporte, logística y asignación de recursos, cuya fortaleza radica en la precisión y en la garantía de soluciones óptimas, aunque con limitaciones frente a fenómenos no lineales (Nemhauser y Wolsey, 2014). Posteriormente, surgieron los modelos de programación no lineal, los cuales permitieron incorporar interacciones más realistas en sistemas de ingeniería y economía (Bazaraa et al. 2013). Finalmente, la programación entera y mixta se consolidó como una herramienta esencial para modelar decisiones discretas en planificación de redes y cadenas de suministro (Wolsey, 1998).

La segunda gran ola de desarrollo correspondió a la introducción de enfoques capaces de incorporar la incertidumbre. La optimización estocástica permitió introducir parámetros aleatorios en los modelos, con aplicaciones relevantes en los mercados financieros y en la planificación energética (Kall y Wallace, 2016). Paralelamente, la optimización dinámica de Bellman (1957) abrió nuevas posibilidades en problemas secuenciales, aplicándose en la economía, la robótica y la formulación de políticas públicas.

A partir de los años noventa, se produjo la llamada "revolución heurística y metaheurística", motivada por la necesidad de enfrentar problemas de gran escala y, específicamente, los problemas NP-Duros. Estos constituyen una clase especial de problemas para los que no se conoce un algoritmo determinista polinomial que pueda resolverlos en un tiempo razonable, resultando frecuentemente intratables mediante métodos exactos (Santiago, 2011). En este contexto, se consolidaron algoritmos inspirados en fenómenos naturales, tales como los algoritmos genéticos (Holland, 1992), la optimización por enjambre de partículas (Kennedy y Eberhart, 1995), la optimización por colonia de hormigas (Dorigo y Gambardella, 1997) y el recocido simulado (Kirkpatrick et al., 1983). Estas técnicas demostraron ser especialmente útiles en bioinformática, big data e inteligencia artificial, al ofrecer soluciones aproximadas de alta calidad en tiempos razonables (Blum y Roli, 2020).

En los últimos años, se observa una tendencia creciente hacia la hibridación metodológica, que busca integrar las fortalezas de los modelos exactos con la flexibilidad de las metaheurísticas. Los modelos híbridos combinan rigor matemático y eficiencia computacional, y en muchos casos se potencian mediante la incorporación de técnicas de aprendizaje automático y aprendizaje profundo (Talbi, 2019; Yang, 2021). Este giro paradigmático responde a la necesidad de contar con modelos más adaptativos, capaces de operar en contextos dinámicos y con grandes volúmenes de datos.

La relevancia social y económica de la optimización matemática es evidente en múltiples sectores:

En el ámbito de la logística y el transporte, los modelos de programación lineal y entera han permitido a empresas como UPS y FedEx reducir costos y optimizar rutas de distribución (Ahuja et al., 2019; Laporte, 2019).

En el sector energético, los modelos estocásticos e híbridos apoyan la integración de energías renovables y la gestión de la incertidumbre en los mercados eléctricos (Conejo et al., 2016).

En el campo de la salud, se han aplicado algoritmos genéticos para la programación de cirugías y la asignación de recursos hospitalarios, mejorando la eficiencia y equidad en la atención médica (Cardoen et al., 2010).

Por su parte, en las telecomunicaciones, compañías como Google han recurrido a metaheurísticas y algoritmos avanzados de optimización para gestionar la asignación de servidores y el tráfico de datos a gran escala (Dean y Barroso, 2013).

Finalmente, en el ámbito de la sostenibilidad y la economía circular, los modelos multiobjetivo han permitido equilibrar criterios económicos, ambientales y sociales en el diseño de sistemas de producción responsables (Charles et al., 2019; Deb, 2019).

A pesar de estos avances, persisten desafíos importantes. Los métodos exactos, aunque matemáticamente rigurosos, enfrentan problemas de escalabilidad al abordar instancias de grandes dimensiones en tiempo real. Las metaheurísticas, por su parte, presentan el inconveniente de no garantizar la optimalidad global, a pesar de su flexibilidad. Asimismo, la literatura muestra vacíos en cuanto a la validación empírica de modelos híbridos en escenarios reales, así como en la integración de la optimización matemática con tecnologías emergentes como la inteligencia artificial profunda y la computación cuántica (Farhi et al., 2014).

En este contexto, se hace indispensable un análisis documental comparativo, sustentado en un enfoque cualitativo, que permita sintetizar la literatura fragmentada, evaluar el estado actual de los modelos de optimización e identificar líneas de investigación emergentes. Este artículo responde a esta necesidad mediante un estudio que abarca el periodo 2010 - 2023, con el propósito de ofrecer una visión integral de los principales paradigmas de optimización matemática, sus fundamentos teóricos, ventajas, limitaciones, aplicaciones sectoriales y proyecciones hacia el futuro.

2. Marco teórico

2.1. ¿Qué es la optimización matemática?

La optimización matemática constituye una rama de la investigación operativa cuyo propósito es identificar, entre múltiples alternativas factibles, aquella que maximiza o minimiza una función objetivo bajo un conjunto de restricciones (Bertsimas y Tsitsiklis, 2018). El desarrollo teórico de la optimización ha dado origen a una diversidad de modelos que responden a las características de los problemas reales y a los avances en matemáticas, estadística, ciencias de la computación y tecnología digital.

2.2. Principales modelos de optimización matemática

Los principales modelos de optimización matemática abarcan una diversidad de enfoques que responden a distintas complejidades de los problemas reales. Empezando desde:

Programación lineal (PL): es uno de los enfoques más antiguos y consolidados dentro de la optimización matemática. Formalizada en la década de 1940 por Dantzig (1947), consiste en formular problemas en los que tanto la función objetivo como las restricciones son lineales. Los modelos de PL son ampliamente utilizados en transporte, logística y asignación de recursos (Nemhauser y Wolsey, 2014; Laporte, 2019). Entre sus ventajas destacan la simplicidad matemática y la garantía de obtener soluciones óptimas en tiempos de cómputo razonables. No obstante, su principal limitación radica en la incapacidad de representar relaciones no lineales presentes en sistemas complejos.

Programación no lineal (PNL): surge como extensión de la PL, incorporando funciones objetivo o restricciones no lineales. Su aplicación es recurrente en ingeniería de procesos, energía, economía y biología de sistemas (Bazaraa, Sherali y Shetty, 2013). Entre sus ventajas se incluyen la capacidad de representar comportamientos realistas, pero presenta como limitación el incremento en la complejidad computacional y la existencia de múltiples óptimos locales, lo que dificulta la obtención de soluciones globalmente óptimas.

Programación entera y mixta (PE/PEM): se aplica en problemas donde algunas variables deben tomar valores discretos, lo cual es esencial en planificación, logística, diseño de redes y gestión de cadenas de suministro (Wolsey, 1998; Nemhauser y Wolsey, 2014). El modelo general combina variables continuas con enteras, lo que aumenta la flexibilidad pero también la complejidad computacional, dado que la mayoría de estos problemas son NP-duros. Avances en algoritmos de ramificación y acotación, así como en técnicas de corte, han permitido resolver instancias de gran tamaño, aunque con un costo elevado en tiempo de procesamiento.

Optimización estocástica: incorpora la incertidumbre en parámetros y variables mediante la modelación probabilística. Se utiliza en mercados eléctricos, finanzas y gestión de riesgos (Kall y Wallace, 2016;

Conejo, Carrión y Morales, 2016). Su ventaja principal es la capacidad de modelar situaciones en las que los datos no son deterministas, pero presenta dificultades en la estimación de distribuciones de probabilidad y en la complejidad de los cálculos requeridos.

Optimización dinámica: introducida por Bellman (1957), se basa en el principio de optimalidad, que establece que una decisión óptima tiene la propiedad de que cada subdecisión posterior debe ser óptima a su vez también. Este enfoque ha sido aplicado en problemas de control, economía, robótica y formulación de políticas públicas. El beneficio de este método radica en su capacidad para modelar procesos secuenciales. Sin embargo, enfrenta el problema conocido como "maldición de la dimensionalidad", lo que limita su aplicabilidad en sistemas de gran escala.

Heurísticas y metaheurísticas: ante la dificultad de resolver problemas NP-duros con métodos exactos, surgieron los algoritmos heurísticos y, posteriormente, los metaheurísticas. Estas últimas son algoritmos de propósito general, inspirados en fenómenos naturales y sociales, capaces de explorar grandes espacios de soluciones de forma flexible y eficiente (Blum y Roli, 2020). Entre las metaheurísticas más conocidas se encuentran: Algoritmos genéticos (Holland, 1992), Recocido simulado (Kirkpatrick et al., 1983), optimización por enjambre de partículas (Kennedy y Eberhart, 1995) y optimización por colonia de hormigas (Dorigo y Gambardella, 1997). Las metaheurísticas han demostrado una amplia aplicabilidad en bioinformática, big data, inteligencia artificial, telecomunicaciones y logística global. Su principal desventaja es que no garantizan alcanzar la solución óptima global, aunque suelen encontrar soluciones de alta calidad en tiempos razonables.

Modelos híbridos: surgen como respuesta a la necesidad de combinar el rigor matemático de los modelos exactos y la flexibilidad de las metaheurísticas. Este enfoque busca balancear la precisión y la eficiencia computacional, adaptándose a escenarios de gran escala y alta incertidumbre (Talbi, 2019). Los híbridos se aplican en planificación energética, diseño de ciudades inteligentes, sostenibilidad ambiental y problemas multiobjetivo. Ejemplos destacados incluyen la combinación de programación entera con algoritmos genéticos para resolver problemas de redes eléctricas y transporte.

2.3. Tendencias emergentes en la optimización

El campo de la optimización matemática se encuentra actualmente en transición hacia nuevos paradigmas. Tres tendencias se destacan:

1. **Optimización multiobjetivo:** que permite equilibrar criterios en conflicto, como costos, sostenibilidad y equidad (Deb, 2019; Charles, 2019).
2. **Integración con inteligencia artificial:** particularmente con técnicas de machine learning y deep learning, lo que permite diseñar algoritmos adaptativos y autoaprendientes (Yang, 2021).

3. **Optimización cuántica:** aunque aún incipiente, el algoritmo cuántico aproximado de optimización (QAOA, por sus siglas en inglés, Quantum Approximate Optimization Algorithm) de [Farhi et al., \(2014\)](#) abre un nuevo horizonte para resolver problemas combinatorios a gran escala.

3. Metodología

3.1. Enfoque y diseño de la investigación

La investigación se planteó bajo un enfoque cualitativo, dado que el objetivo principal es interpretar, sintetizar y comparar de manera crítica la literatura sobre modelos matemáticos de optimización. Se adoptó un diseño documental comparativo, lo cual implica la recopilación sistemática de información en bases de datos indexadas y su posterior análisis temático para identificar patrones, tendencias, ventajas y limitaciones de los modelos estudiados. El alcance es de tipo descriptivo-analítico, ya que no se busca probar hipótesis estadísticas, sino generar un marco interpretativo amplio que contribuya a la comprensión de la evolución y aplicación de los paradigmas de optimización.

3.2. Fuentes de información

La búsqueda de información se realizó en bases de datos académicas reconocidas a nivel internacional, tales como Scopus, Web of Science, IEEE Xplore, ScienceDirect y SpringerLink, complementadas con literatura especializada en libros monográficos de editoriales de alto impacto (Wiley, Springer, Elsevier, MIT Press).

El período de cobertura seleccionado fue 2010 a 2023, dado que corresponde a una etapa de gran avance en la incorporación de heurísticas, metaheurísticas e inteligencia artificial en la optimización matemática.

3.3. Estrategia de búsqueda

Se diseñaron cadenas de búsqueda con operadores booleanos y palabras clave tanto en inglés como en español. En todos los casos se aplicaron filtros por año de publicación (2010 - 2023), tipo de documento (artículos, revisiones, capítulos de libro) y área temática (ingeniería, ciencias de la computación, investigación de operaciones, y matemáticas aplicadas).

3.4. Proceso de análisis documental

El procedimiento de análisis se realizó en tres fases:

1. Cribado inicial: se revisaron títulos y resúmenes para descartar estudios irrelevantes.
2. Revisión a texto completo: se aplicaron los criterios de inclusión/exclusión y se seleccionaron los artículos definitivos.
3. Extracción de datos: se elaboró una matriz con los siguientes campos: autor, año, tipo de modelo, aplicación sectorial, métricas de desempeño, ventajas y limitaciones reportadas.

3.5. Síntesis de resultados

Los hallazgos se presentarán en:

- Tablas comparativas de ventajas, limitaciones y aplicaciones de cada modelo.
- Discusión transversal de tendencias emergentes (hibridación, integración con IA y optimización cuántica).

4. Resultados

Los hallazgos de este estudio se basan en una revisión sistemática de la literatura. A continuación, se presentan cuatro tablas descritas como sigue:

Tabla 1. Ventajas y limitaciones de los modelos de optimización

Modelo	Ventajas principales	Limitaciones	Referencias
Programación lineal (PL)	Precisión matemática, rapidez de cómputo, facilidad de interpretación	Rigidez, no modela relaciones no lineales	Dantzig (1947); Nemhauser & Wolsey (2014)
Programación no lineal (PNL)	Flexibilidad para representar fenómenos reales	Problemas de convergencia, múltiples óptimos locales	Bazaraa et al. (2013)
Programación entera/mixta (PE/PEM)	Modela decisiones discretas, útil en logística	Alta complejidad computacional (NP-duro)	Wolsey (1998); Nemhauser & Wolsey (2014)
Optimización estocástica	Manejo de incertidumbre, robustez en escenarios aleatorios	Complejidad en calibración probabilística	Kall & Wallace (2016); Conejo et al. (2016)
Optimización dinámica	Modela problemas secuenciales, adaptable a políticas	Maldición de la dimensionalidad	Bellman (1957)
Metaheurísticas	Escalabilidad, adaptabilidad, aplicables a big data	No garantizan optimalidad global	Blum & Roli (2020); Holland (1992)
Modelos híbridos	Combinan exactitud y eficiencia, integración con IA	Complejidad de implementación	Talbi (2019); Yang (2021)

Fuente: Elaboración Propia

Tabla 2. Sectores de aplicación de los modelos de optimización

Sector	Modelos dominantes	Ejemplos de aplicación	Referencias
Logística y transporte	PL, PEM	Optimización de rutas en UPS y FedEx	Ahuja et al. (2019); Laporte (2019)
Energía	Estocástica, híbridos	Integración de renovables en Europa	Conejo et al. (2016)
Salud	Metaheurísticas	Programación quirúrgica en hospitales	Cardoen et al. (2010)
Telecomunicaciones	Dinámica, metaheurísticas	Asignación de servidores en Google	Dean & Barroso (2013)
Sostenibilidad	Multiobjetivo, híbridos	Diseño de cadenas circulares	Charles, Gupta & Ali, 2019; Deb (2019)

Fuente: Elaboración propia

Tabla 3. Desempeño comparativo de modelos por criterios clave

Modelo	Precisión	Escalabilidad	Adaptabilidad	Manejo de incertidumbre	Multiobjetivo
PL	Muy alta	Media	Baja	Baja	Baja
PNL	Alta	Baja	Media	Media	Media
PE/PEM	Muy alta	Baja	Media	Media	Baja
Estocástica	Alta	Baja	Media	Muy alta	Media
Dinámica	Alta	Media	Alta	Media	Media
Híbridos	Alta	Alta	Alta	Alta	Muy alta
Metaheurísticas	Media	Muy alta	Muy alta	Alta	Alta

Fuente: Elaboración propia

Tabla 4. Tendencias emergentes en la optimización matemática

Tendencia	Descripción	Sectores clave	Referencias
Optimización multiobjetivo	Balancea costos, eficiencia y sostenibilidad	Logística, energía y sostenibilidad	Deb (2019); Charles, Gupta & Ali, 2019
Hibridación metodológica	Integración de exactos y metaheurísticas	Energía, telecomunicaciones, ciudades inteligentes	Talbi (2019)
Integración con IA	Aprendizaje de hiperparámetros, optimización adaptativa	Big data, bioinformática, transporte	Yang (2021)
Optimización cuántica	Algoritmos cuánticos para problemas NP-duros	Finanzas, seguridad y redes complejas	Farhi et al. (2014)

Fuente: Elaboración propia

5. Discusión

Los resultados obtenidos a partir del análisis documental evidencian tendencias claras en la aplicación de los modelos matemáticos de optimización durante el periodo comprendido entre 2010 y 2023. Tal como se muestra en las [tablas 1](#), la programación lineal y la programación entera mixta siguen ocupando un lugar central en la literatura, debido a su capacidad de resolver problemas con restricciones estrictas en campos como la logística, producción y gestión de recursos. Sin embargo, también se aprecia un crecimiento progresivo en el uso de metaheurísticas y modelos híbridos, especialmente en escenarios donde los problemas presentan una elevada complejidad computacional y los métodos exactos resultan inviables ([Glover y Kochenberger, 2019](#); [Dorransoro et al., 2022](#)).

La tabla comparativa de desempeño ([Tabla 3](#)), revelan

que, mientras los modelos exactos ofrecen soluciones óptimas con un nivel elevado de precisión, presentan limitaciones frente a problemas de gran escala o alta incertidumbre. En contraste, las metaheurísticas ofrecen soluciones aproximadas, pero su flexibilidad y capacidad de adaptación las convierten en herramientas eficaces para problemas dinámicos o mal estructurados. Este contraste confirma lo señalado por autores como [Blum y Roli \(2020\)](#), quienes destacan que la elección del modelo depende no solo del tipo de problema, sino también de las restricciones de tiempo y recursos disponibles.

Otro aspecto que merece discusión es la interrelación entre la optimización dinámica y los avances tecnológicos en computación. Tal como reflejan los gráficos de correlación, los trabajos que integran

optimización dinámica se concentran en problemas de control de procesos y sistemas energéticos. No obstante, su adopción aún es limitada en comparación con otras metodologías, posiblemente debido a la complejidad matemática que implica su aplicación práctica.

Finalmente, los datos sintetizados en las tablas 1, 2, 3 y 4, confirman que la comunidad científica se orienta hacia un paradigma de complementariedad metodológica más que de sustitución. Es decir, no existe un modelo de optimización único que resuelva de forma eficiente todos los problemas planteados múltiples disciplinas, sino que los investigadores seleccionan, adaptan o combinan enfoques según las características específicas de cada escenario. Esta perspectiva coincide con la literatura más reciente, que enfatiza la necesidad de enfoques flexibles y multidisciplinarios para abordar problemas cada vez más complejos (Glover y Kochenberger, 2019; Dorronsoro, et al., 2022).

6. Conclusiones y reflexiones

El análisis documental realizado entre 2010 y 2023 permite establecer que los modelos matemáticos de optimización mantienen un rol central en la investigación científica aplicada a múltiples disciplinas, aunque con una evolución marcada hacia enfoques más flexibles y adaptativos. La programación lineal y entera mixta continúan siendo las metodologías más utilizadas en problemas estructurados, gracias a su robustez y precisión en la obtención de soluciones óptimas.

Las metaheurísticas han experimentado un crecimiento sostenido, consolidándose como alternativas viables frente a la alta complejidad de los problemas reales. Entre ellas destacan los algoritmos genéticos, enjambre de partículas y recocido simulado. Los modelos híbridos emergen como tendencia dominante, al combinar la exactitud de los métodos clásicos con la flexibilidad de los enfoques heurísticos, logrando un equilibrio entre calidad de solución y tiempo de cómputo.

Por su parte, la optimización estocástica cobra relevancia en escenarios de incertidumbre, especialmente en cadenas de suministro y finanzas, mientras que la optimización dinámica mantiene aplicaciones en energía y control de procesos, aunque con menor representación en la literatura. Los resultados sintetizados en las tablas confirman que la elección del modelo depende no solo de las características del problema, sino también de las limitaciones prácticas de tiempo, recursos y entorno de aplicación. En resumen, no existe un método universalmente superior, sino una complementariedad metodológica que guía a los investigadores hacia la integración y adaptación de técnicas según el contexto.

Los hallazgos de este estudio invitan a reflexionar sobre varios aspectos relevantes:

La investigación en optimización se encuentra en una etapa de convergencia interdisciplinaria, en la que se integran modelos matemáticos con inteligencia

artificial, ciencia de datos y computación de alto rendimiento.

Los retos actuales ya no se limitan a resolver problemas estáticos, sino a abordar sistemas dinámicos, inciertos y en constante evolución, lo que demanda enfoques híbridos más robustos.

Existe una brecha entre la teoría y la práctica, pues muchos modelos avanzados carecen aún de aplicaciones directas en la industria debido a su complejidad computacional. Reducir esta distancia es una prioridad para que la investigación tenga impacto tangible.

La comunidad científica se orienta cada vez más hacia la sostenibilidad y la eficiencia energética, lo cual abre un campo prometedor para la optimización aplicada a problemas medioambientales, de transporte verde y de gestión de recursos naturales.

Finalmente, la revisión realizada confirma que el futuro de la optimización matemática dependerá de la capacidad de adaptación metodológica, donde la innovación estará marcada por la combinación de técnicas y la aplicación en entornos reales de alta complejidad.

Recomendaciones

Adopción de modelos híbridos. Se recomienda fomentar la investigación en metodologías que integren enfoques exactos con heurísticos o metaheurísticos, dado que ofrecen un balance entre precisión y eficiencia computacional en problemas complejos.

Aplicación práctica en la industria. Los investigadores y profesionales deben priorizar estudios de validación en entornos reales, reduciendo la brecha entre teoría y práctica, especialmente en sectores como logística, energía y finanzas.

Fortalecimiento del análisis bajo incertidumbre. Es necesario profundizar en la aplicación de modelos estocásticos y dinámicos para escenarios donde la incertidumbre es significativa, como la gestión de riesgos financieros o la planificación de cadenas de suministro.

Interdisciplinariedad en la investigación. Se recomienda incentivar la colaboración entre matemáticos, ingenieros, informáticos y especialistas en inteligencia artificial, con el fin de generar soluciones más integrales y aplicables a diferentes contextos.

Desarrollo de algoritmos eficientes. Dado el incremento en la complejidad de los problemas, es indispensable optimizar los algoritmos para reducir tiempos de cómputo, aprovechando tecnologías como la computación paralela y la computación en la nube.

Enfoque en sostenibilidad. Se sugiere orientar los futuros estudios hacia la optimización de recursos en ámbitos relacionados con la sostenibilidad, la eficiencia energética y la reducción de impacto ambiental

Futuras líneas de investigación

Optimización híbrida avanzada. Profundizar en la combinación de técnicas exactas, heurísticas y metaheurísticas, explorando nuevas formas de integración que permitan aprovechar las fortalezas de cada enfoque en problemas de gran escala y alta complejidad.

Optimización bajo incertidumbre extrema. Desarrollar modelos estocásticos y robustos capaces de adaptarse a entornos altamente volátiles, como los mercados financieros, la gestión de desastres naturales y las cadenas de suministro globalizadas.

Optimización dinámica en sistemas inteligentes. Ampliar el uso de modelos dinámicos en áreas como la energía renovable, las redes eléctricas inteligentes, la movilidad urbana y la gestión de recursos en tiempo real.

Aplicaciones con inteligencia artificial. Investigar la integración de algoritmos de optimización con técnicas de aprendizaje automático y deep learning, creando modelos adaptativos que mejoren su desempeño a medida que incorporan datos en tiempo real.

Computación de alto rendimiento para optimización. Explorar el uso de supercomputación, computación cuántica y arquitecturas paralelas para reducir los tiempos de ejecución de algoritmos aplicados a problemas de optimización masivos.

Optimización para la sostenibilidad. Orientar investigaciones hacia la gestión eficiente de recursos naturales, la planificación del transporte sostenible y la reducción de la huella de carbono en procesos industriales.

Transferencia tecnológica y validación en la industria. Desarrollar proyectos de investigación aplicada que validen los modelos de optimización en escenarios industriales reales, favoreciendo la transferencia de conocimiento desde la academia hacia el sector productivo.

Declaraciones

Conflicto de Intereses

Los autores declaran no tener ningún conflicto de intereses financiero conocido ni relaciones personales o profesionales que pudieran haber influido en el trabajo presentado en este artículo.

Fuente de financiamiento

Esta investigación no recibió ningún tipo de fuente de financiamiento.

Uso de herramientas de IA generativa

En la preparación de este artículo, se utilizaron herramientas de IA generativa Gemini para realizar corrección gramatical y ortográfica. Todo el contenido y las conclusiones son responsabilidad de los autores.

Aprobación ética

Este artículo no involucra a personas ni animales. No se requiere aprobación ética.

Disponibilidad de datos

En este tipo de investigación no aplica la disponibilidad de datos.

Referencias

- Ahuja, R. K., Magnanti, T. L., & Orlin, J. B. (1993). *Network flows: Theory, algorithms, and applications*. Englewood Cliffs, NJ, USA: Prentice Hall.
- Bazaraa, M. S., Sherali, H. D., & Shetty, C. M. (2006). *Nonlinear programming: Theory and algorithms* (3.^a ed.). Hoboken, NJ, USA: John Wiley & Sons.
- Bellman, R. (1957). *Dynamic programming*. Princeton, NJ, USA: Princeton University Press.
- Bertsimas, D., & Tsitsiklis, J. (1997). *Introduction to linear optimization*. Belmont, MA, USA: Athena Scientific.
- Birge, J. R., & Louveaux, F. (2011). *Introduction to stochastic programming* (2nd ed.). New York, NY, USA: Springer. DOI: <https://doi.org/10.1007/978-1-4614-0237-4>
- Blum, C., & Roli, A. (2020). Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM Computing Surveys*. 35(3), 268 - 308. <https://doi.org/10.1145/937503.93750>
- Cardoen, B., Demeulemeester, E., & Beliën, J. (2010). Operating room planning and scheduling: A literature review. *European Journal of Operational Research*. 201(3), 921 - 932. <https://doi.org/10.1016/j.ejor.2009.04.011>
- Charles, V., Gupta, S., & Ali, I. (2019). A Fuzzy Goal Programming Approach for Solving Multi-Objective Supply Chain Network Problems with Pareto-Distributed Random Variables. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 27(04), 559-593. <https://doi.org/10.1142/s0218488519500259>
- Conejo, A. J., Carrión, M., & Morales, J. M. (2010). *Decision making under uncertainty in electricity markets*. Berlin, Germany: Springer. DOI: <https://doi.org/10.1007/978-1-4419-7421-1>
- Dantzig, G. B. (1947). Maximization of a linear function of variables subject to linear inequalities. *Naval Research Logistics Quarterly*. In Koopmans, T.C. (Ed.), *Activity Analysis of Production and Allocation* (pp. 339-347). New York, London: Wiley & Chapman-Hall.
- Dean, J., & Barroso, L. A. (2013). The tail at scale. *Communications of the ACM*. 56(2), 74 - 80. <https://doi.org/10.1145/2408776.2408794>
- Deb, K. (2019). Multi-objective optimization and evolutionary algorithms: An Introduction. In: Wang, L., Ng, A., Deb, K. (Eds) *Multi-objective Evolutionary Optimisation for Product Design and Manufacturing* (pp. 3-34). Springer, London. https://doi.org/10.1007/978-0-85729-652-8_1
- Dorigo, M., & Gambardella, L. M. (1997). Ant colonies for the travelling salesman problem. *BioSystems*. 43(2), 73-81. [https://doi.org/10.1016/S0303-2647\(97\)01708-5](https://doi.org/10.1016/S0303-2647(97)01708-5)
- Dorigo, M., & Stützle, T. (2019). Ant colony optimization: Overview and recent advances. In: Gendreau, M., Potvin, J.Y. (Eds) *Handbook of Metaheuristics*, (vol 272, pp 311-351). Springer, Cham. https://doi.org/10.1007/978-3-319-91086-4_10
- Dorransoro, B., Yalaoui, F., Talbi, E. G., & Danoy, G. (Eds.). (2024). *Metaheuristics and Nature Inspired Computing*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-94216-8>

- Farhi, E., Goldstone J., & Gutmann S. (2014). A quantum approximate optimization algorithm. arXiv preprint arXiv:1411.4028. <https://doi.org/10.48550/arXiv.1411.4028>.
- Glover, F., & Kochenberger, G. A. (Eds.). (2003). Handbook of metaheuristics. Boston, MA, USA. Springer Science & Business Media. <https://doi.org/10.1007/b101874>
- Holland, J. H. (1992). Adaptation in natural and artificial systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence. Cambridge, USA. The MIT Press. <https://doi.org/10.7551/mitpress/1090.001.0001>
- Kall, P. & Wallace, S. W. (1994). *Stochastic programming*. Chichester, UK. John Wiley & Sons.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In: *Proceedings of ICNN'95 - International Conference on Neural Networks*, (Vol. 4, pp. 1942-1948). <https://doi.org/10.1109/ICNN.1995.488968>
- Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). Optimization by simulated annealing. *Science*, 220(4598), 671-680. <https://doi.org/10.1126/science.220.4598.6>
- Laporte, G. (1992). Vehicle routing: Models, methods, and applications. An overview of exact and approximate algorithms. *European Journal of Operational Research*, 59(3), 345-358. [https://doi.org/10.1016/0377-2217\(92\)90192-C](https://doi.org/10.1016/0377-2217(92)90192-C)
- Nemhauser, G. L., & Wolsey, L. A. (1988). *Integer and combinatorial optimization*. New York, NY, USA. John Wiley & Sons.
- Santiago P., Aurelio A. (2011). *Metaheurísticos aplicados a la solución del problema de cutwidth* [Tesis pregrado]. Instituto Tecnológico de Ciudad Madero. Ciudad Madero, Tamaulipas, México.
- Talbi, E.-G. (2019). *Metaheuristics: From design to implementation*. Hoboken, NJ, USA: John Wiley & Sons.
- Dorransoro, B., Yalaoui, F., Talbi, E.-G., & Danoy, G. (Eds.). (2022). *Metaheuristics and Nature Inspired Computing*. Springer. <https://doi.org/10.1007/978-3-030-94216-8>
- Wolsey, L. A. (2021). *Integer programming* John Wiley & Sons. <https://doi.org/10.1002/9781119606475>
- Yang, X.-S. (2021). *Nature-inspired optimization algorithms*. Londres, Reino Unido. Elsevier.

Citar este artículo como / Cite this article as:

Quintero, J. L., Vincenti, J., Tudares, E., Torres, R., & Hernández, C. (2026). Modelos matemáticos de optimización: análisis documental comparativo desde un enfoque cualitativo. *Rev. Fac. Ing. UCV*, 41(6), 1-8.

Envíe por correo electrónico su próximo manuscrito y aproveche al máximo:

- Revisión por pares con especialistas
- Sin costo para su envío, revisión y publicación
- Publicación tras la aceptación de su manuscrito
- Publicación de libre acceso