



Algoritmos genéticos en la asignación de recursos y optimización de rutas en transporte: revisión sistemática

Genetic algorithms for resource allocation and route optimization in transportation: a systematic review

Luis Enrique Ríos Sepúlveda ✉

Universidad Católica Sedes Sapientiae, Nueva Cajamarca, Perú

2021101807@ucss.pe

ORCID: 0009-0006-9176-7435

Yanina Sanchez Calderon

Universidad Católica Sedes Sapientiae, Nueva Cajamarca, Perú

ysanchezc@ucss.edu.pe

ORCID: 0000-0003-2407-9377

 <https://doi.org/10.36825/RITI.14.34.005>

Recibido: Mayo 19, 2026

Aceptado: Septiembre 03, 2026

Resumen: La programación operativa en empresas de transporte implica la asignación eficiente de vehículos, conductores, rutas y horarios, un problema de optimización combinatoria de alta complejidad cuando se incorporan restricciones de capacidad, ventanas de tiempo, costos, emisiones y variabilidad de la demanda. En este contexto, los algoritmos genéticos (AG) y sus variantes híbridas se han empleado como metaheurísticas para obtener soluciones de buena calidad en tiempos computacionales razonables. Esta revisión sistemática, desarrollada según la metodología de Kitchenham y reportada mediante un diagrama de flujo adaptado de PRISMA 2020, tuvo como objetivo identificar los tipos de problemas de asignación de recursos y optimización de rutas abordados con AG, las variantes predominantes, los resultados cuantitativos reportados y las principales limitaciones. Se revisaron artículos publicados entre 2022 y 2026 en ScienceDirect, Springer Nature Link, IEEE Xplore, MDPI y otras plataformas editoriales con DOI verificable; la selección final comprendió 31 estudios. Los resultados muestran un predominio del *Vehicle Routing Problem* y sus variantes (80.65%), junto con una presencia destacada de AG híbridos, estrategias multiobjetivo y operadores adaptativos. Se concluye que los AG son pertinentes para la programación operativa del transporte, aunque persisten desafíos de parametrización, escalabilidad, convergencia prematura y validación en escenarios reales.

Palabras clave: *Algoritmos Genéticos, Asignación de Recursos, Optimización de Rutas, Transporte, Revisión Sistemática.*

Abstract: Operational scheduling in transportation companies involves the efficient assignment of vehicles, drivers, routes, and schedules, a highly complex combinatorial optimization problem when capacity constraints, time windows, costs, emissions, and demand variability are considered. In this context, genetic algorithms (GA) and their hybrid variants have been used as metaheuristics to obtain good-quality solutions within reasonable computational times. This systematic review, conducted according to Kitchenham's methodology and reported through a flow diagram adapted from PRISMA 2020, aimed to identify the types of resource allocation and route optimization problems addressed with GA, the predominant variants, the quantitative results reported, and the

main limitations. Articles published between 2022 and 2026 were reviewed from ScienceDirect, Springer Nature Link, IEEE Xplore, MDPI, and other academic publishing platforms with verifiable DOI; the final selection comprised 31 studies. The results show a predominance of the *Vehicle Routing Problem* and its variants (80.65%), together with a strong presence of hybrid GA, multi-objective strategies, and adaptive operators. It is concluded that GA are relevant for operational transportation scheduling, although challenges remain regarding parameter tuning, scalability, premature convergence, and validation in real-world scenarios.

Keywords: *Genetic Algorithms, Resource Allocation, Route Optimization, Transportation, Systematic Review.*

1. Introducción

El transporte constituye un sector estratégico para el desarrollo económico y social, debido a que permite la movilidad de personas, bienes y servicios. En este contexto, las empresas de transporte público, privado y de carga enfrentan la necesidad de reducir costos operativos, mejorar la calidad del servicio, optimizar el uso de sus recursos y cumplir restricciones relacionadas con tiempos, capacidad, disponibilidad de flota y condiciones laborales. La programación operativa, entendida como la planificación detallada de la asignación de vehículos, conductores, rutas y horarios en horizontes de corto plazo, representa uno de los procesos más complejos dentro de la gestión del transporte [1].

Desde el punto de vista matemático, la asignación de recursos en transporte se relaciona con problemas de optimización combinatoria clasificados como NP-difíciles. Entre estos destacan el *Vehicle Routing Problem* (VRP), el *Vehicle Routing Problem with Time Windows* (VRPTW), el *Crew Scheduling Problem* (CSP) y el *Vehicle Scheduling Problem* (VSP). Estos problemas incrementan su complejidad conforme aumenta el número de clientes, vehículos, rutas, restricciones y escenarios operativos, lo que dificulta su resolución mediante métodos exactos en instancias de tamaño real [1]. Frente a esta limitación, las metaheurísticas se han consolidado como alternativas eficaces para obtener soluciones aproximadas de buena calidad en tiempos computacionales razonables [2].

Entre las metaheurísticas más utilizadas, los algoritmos genéticos (AG) destacan por su robustez, flexibilidad y capacidad para explorar espacios de búsqueda amplios, complejos y multimodales. Los AG, propuestos por Holland, trabajan sobre una población de soluciones candidatas que evolucionan mediante operadores de selección, cruzamiento y mutación, inspirados en los principios de la evolución natural [3]. En el ámbito del transporte, su aplicación ha permitido abordar problemas de optimización de rutas, reducción de distancias recorridas, disminución de costos operativos, asignación de flota y mejora de la eficiencia logística; en particular, las búsquedas genéticas híbridas se consideran actualmente el estado del arte para el VRP [4]. Los AG también han mostrado utilidad en otros dominios de las tecnologías de la información, como la selección de características para tareas de clasificación [5].

Revisiones previas han sintetizado el uso de metaheurísticas en problemas de ruteo: Elshaer y Awad [2] clasificaron 299 estudios sobre metaheurísticas aplicadas al VRP publicados hasta 2017, y Konstantakopoulos *et al.* [1] revisaron y categorizaron la literatura sobre VRP y algoritmos para distribución logística. Sin embargo, dichas revisiones abarcan el conjunto de las metaheurísticas y cubren literatura anterior a 2021, por lo que no analizan de manera específica la evolución reciente de los AG ni su aplicación a la asignación de recursos dentro de la programación operativa de empresas de transporte. La presente revisión aborda esta brecha concentrándose en los AG y sus variantes durante el periodo 2022–2026.

Dada la relevancia de los algoritmos genéticos en la resolución de problemas de asignación de recursos en transporte, la presente investigación desarrolla una revisión sistemática de literatura (RSL). Una RSL permite recolectar, organizar, evaluar y sintetizar la evidencia científica disponible sobre un fenómeno de interés, con el propósito de identificar tendencias, enfoques metodológicos, resultados y brechas de investigación [6]. Para este estudio se empleó la metodología propuesta por Kitchenham, debido a su aplicación frecuente en revisiones sistemáticas del área de ciencias de la computación e ingeniería de software [6].

Esta investigación tiene como objetivo analizar la aplicación de algoritmos genéticos en la asignación de recursos y la optimización de rutas para la programación operativa en empresas de transporte durante el periodo 2022–2026. En este estudio, la asignación de recursos se entiende como la distribución de los recursos operativos de una empresa de transporte —vehículos, conductores o tripulaciones, rutas, horarios e infraestructura logística— entre las tareas de servicio, bajo restricciones operativas. Bajo esta definición, el VRP y sus variantes constituyen

problemas de asignación de recursos, dado que asignan clientes y secuencias de visita (rutas) a una flota limitada de vehículos; de manera análoga, la programación de tripulaciones asigna personal a servicios y la programación de tráfico distribuye la capacidad vial en el tiempo. Específicamente, se busca identificar los tipos de problemas abordados, las variantes de AG más utilizadas, los resultados cuantitativos reportados y las principales limitaciones técnicas y operativas encontradas en los estudios revisados.

El presente documento se organiza de la siguiente manera: la sección 2 presenta la metodología empleada en la revisión sistemática; la sección 3 expone los resultados obtenidos; la sección 4 desarrolla la discusión en función de las preguntas de investigación planteadas; finalmente, la sección 5 presenta las conclusiones del estudio.

2. Metodología

Para desarrollar este estudio, la revisión sistemática de literatura (RSL) se estructuró con base en la metodología propuesta por Barbara Kitchenham [6]. El proceso se organizó en tres fases: planificación de la revisión, ejecución de la búsqueda y selección de estudios, y síntesis y reporte de resultados. De manera complementaria, el proceso de selección se documenta mediante un diagrama de flujo adaptado de la declaración PRISMA 2020 [7].

a) Preguntas de investigación

Las preguntas de investigación representan la parte más importante de cualquier revisión sistemática [6]. Para cumplir con el objetivo de la revisión sistemática, se han abordado las siguientes preguntas de investigación:

- ¿Qué tipos de problemas de asignación de recursos en empresas de transporte han sido abordados mediante algoritmos genéticos?
- ¿Qué variantes de algoritmos genéticos y qué operadores evolutivos predominan en los estudios analizados?
- ¿Qué resultados cuantitativos reportan los estudios en cuanto a reducción de costos operativos, calidad de solución y tiempo de cómputo?
- ¿Cuáles son las principales limitaciones técnicas y operativas identificadas en la implementación de AG en empresas de transporte?

Estas preguntas permiten orientar la investigación; en otras palabras, representan el objetivo del artículo.

b) Proceso de búsqueda

El proceso de búsqueda se desarrolló considerando bases de datos y plataformas editoriales académicas especializadas en ingeniería, informática, optimización y transporte. Se consultaron ScienceDirect, Springer Nature Link, IEEE Xplore, MDPI, Hindawi, SAGE/IOS Press, Emerald e IJIE. Cabe precisar que Scopus no se empleó como motor de búsqueda; no obstante, se verificó que las revistas de los artículos seleccionados estuvieran indexadas en Scopus u otros índices reconocidos y contaran con DOI verificable, como parte del criterio de inclusión CI6. La inclusión de estas fuentes permitió recuperar artículos científicos recientes relacionados con algoritmos genéticos, algoritmos evolutivos, ruteo vehicular, logística, programación de flota y asignación de recursos en transporte.

La cadena de búsqueda fue diseñada combinando términos relacionados con el algoritmo genético, el problema de asignación y el sector transporte, empleando operadores booleanos AND y OR:

(“genetic algorithm” OR “hybrid genetic algorithm” OR “evolutionary algorithm”) AND (“vehicle routing problem” OR “VRP” OR “vehicle scheduling” OR “fleet scheduling” OR “crew scheduling” OR “logistics routing”) AND (“transportation” OR “logistics” OR “operational programming” OR “resource allocation”) AND (“optimization” OR “scheduling”)

La depuración de registros se realizó en tres fases. En la primera fase se aplicaron filtros por año de publicación, considerando únicamente estudios entre 2022 y 2026. En la segunda fase se revisaron los títulos, resúmenes y palabras clave para descartar estudios sin relación directa con algoritmos genéticos aplicados al transporte o la logística. En la tercera fase se revisó el texto completo, se eliminaron duplicados y se conservaron únicamente los artículos que aplicaban algoritmos genéticos o variantes evolutivas y que reportaban resultados cuantitativos. La Figura 1 presenta el diagrama de flujo del proceso de identificación, cribado e inclusión de estudios.




Figura 1. Diagrama de flujo del proceso de selección de estudios, adaptado de PRISMA 2020 [7]. Fuente: Elaboración propia.

c) Criterios de inclusión y exclusión

Para filtrar los artículos se aplicaron los criterios de inclusión y exclusión definidos en la Tabla 1. Estos criterios permitieron delimitar la búsqueda, homogenizar la selección y asegurar que los estudios incluidos fueran pertinentes para el objetivo de la revisión.

Tabla 1. Criterios de inclusión y exclusión.

Criterios de Inclusión	Criterios de Exclusión
CI1. Publicaciones entre el 1 de enero de 2022 y el 30 de junio de 2026.	CE1. Publicaciones anteriores al año 2022.
CI2. Artículos publicados en idioma inglés o español.	CE2. Artículos publicados en idiomas distintos al inglés o español.
CI3. Artículos científicos con texto completo disponible en las bases de datos consultadas.	CE3. Artículos sin acceso al texto completo, resúmenes, pósteres, notas editoriales o documentos incompletos.
CI4. Estudios que apliquen AG o variantes evolutivas a problemas de transporte, logística, rutas, flota o programación operativa.	CE4. Artículos que no apliquen algoritmos genéticos o no estén relacionados con transporte.
CI5. Investigaciones empíricas o de simulación que reporten resultados cuantitativos de desempeño.	CE5. Revisiones teóricas sin evidencia empírica o experimentos computacionales.
CI6. Artículos publicados en revistas, congresos o plataformas académicas con DOI verificable y relación directa con transporte, logística u optimización.	CE6. Artículos duplicados, sin DOI verificable o sin información suficiente para su trazabilidad académica.

Fuente: Elaboración propia.

d) Evaluación de la calidad

Para fortalecer la trazabilidad de la revisión, los artículos seleccionados se evaluaron mediante cuatro preguntas de calidad:

- P1. ¿El estudio describe con claridad el diseño del algoritmo genético implementado (representación cromosómica, operadores, parámetros)?
- P2. ¿El artículo aplica el AG a un problema de asignación de recursos en el sector transporte?
- P3. ¿Se reportan métricas cuantitativas de desempeño (reducción de costo, GAP, tiempo de cómputo)?
- P4. ¿El estudio compara el AG con al menos un método de referencia (método exacto, heurística o estado del arte)?

Cada pregunta se calificó con la siguiente escala: 1 si el criterio se cumple completamente (por ejemplo, el diseño del AG está completamente descrito, el AG se aplica a un problema de asignación en transporte, se reportan métricas cuantitativas completas o se compara con al menos un método de referencia); 0.5 si el criterio se cumple parcialmente; y 0 si el criterio no se cumple. El puntaje total de cada estudio corresponde a la suma de las cuatro preguntas, sobre un máximo de 4 puntos.

La evaluación fue realizada de manera independiente por los dos autores, quienes calificaron los 31 estudios con la rúbrica descrita; las discrepancias se resolvieron mediante consenso en sesiones conjuntas de revisión. Se

estableció como umbral de permanencia un puntaje total mínimo de 2.5; ningún estudio quedó por debajo de dicho umbral.

e) Recopilación de datos

Los datos extraídos de cada artículo son los siguientes:

- Fuente (revista o conferencia) y referencias completas.
- Tipo de problema abordado (VRP, *crew scheduling*, *vehicle scheduling*, otros).
- Variante de AG empleada y operadores evolutivos utilizados.
- País y año de publicación.
- Métricas de evaluación y resultados cuantitativos reportados.
- Limitaciones identificadas por los autores.
- Conjunto de datos o instancias de prueba empleadas.

f) Análisis de los datos

Los datos se tabularon para mostrar: el número de artículos publicados por año, los tipos de problemas de asignación abordados con AG, las variantes de AG y operadores más empleados, los resultados cuantitativos y métricas de evaluación, la puntuación de calidad de cada artículo y las principales limitaciones identificadas.

Para la síntesis cuantitativa (Tabla 7), de cada estudio se extrajo el porcentaje de mejora del costo operativo (o del objetivo equivalente) reportado por los propios autores respecto de su método de referencia declarado (método exacto, heurística base o mejor solución conocida), así como el tiempo de cómputo informado. Estos valores se agruparon por variante de AG y se reportan como intervalos mínimos–máximo. Dado que los estudios difieren en instancias, tamaños de problema, funciones objetivo y líneas base, los intervalos tienen un carácter descriptivo y no constituyen una comparación directa de desempeño entre variantes; por la heterogeneidad de los estudios no se realizó un metaanálisis estadístico.

3. Resultados

En esta sección se presentan los artículos seleccionados en el proceso de búsqueda. La Tabla 2 resume las tres etapas de depuración: búsqueda principal, relevancia y selección final. En la fase inicial se identificaron registros potencialmente relacionados con el tema; luego se evaluó su pertinencia mediante la revisión de títulos, resúmenes y conclusiones; finalmente, se conservaron los estudios que cumplieron todos los criterios de inclusión definidos para la revisión.

Tabla 2. Resultados concentrados por fuente académica y año.

Fuente académica	Fase	2022	2023	2024	2025	2026	Total
ScienceDirect / Elsevier	Búsqueda principal	22	26	30	10	4	92
	Relevante	8	10	12	3	1	34
	Seleccionado	3	4	6	0	0	13
Springer Nature Link	Búsqueda principal	10	9	7	9	4	39
	Relevante	4	3	2	4	1	14
	Seleccionado	2	1	0	2	0	5
MDPI	Búsqueda principal	8	20	18	8	3	57
	Relevante	3	8	6	3	1	21
	Seleccionado	0	3	3	2	0	8
IEEE Xplore / IEEE Access	Búsqueda principal	3	5	3	2	5	18
	Relevante	1	2	1	1	1	6
	Seleccionado	0	0	0	0	1	1
Otras fuentes académicas con DOI: Hindawi, SAGE/IOS Press, Emerald e IJIE	Búsqueda principal	13	15	12	6	4	50
	Relevante	5	7	2	0	0	14
	Seleccionado	2	2	0	0	0	4
Total	Búsqueda principal	56	75	70	35	20	256

Relevante	21	30	23	11	4	89
Seleccionado	7	10	9	4	1	31

Fuente: Elaboración propia.

En conjunto, se identificaron 256 registros iniciales en las fuentes académicas consultadas. Luego de aplicar los criterios de relevancia mediante la revisión de títulos, resúmenes y palabras clave, se conservaron 89 estudios. Finalmente, después de la lectura a texto completo, la eliminación de duplicados y la verificación de pertinencia metodológica, se seleccionaron 31 artículos para el análisis final. La distribución final fue de 7 artículos en 2022, 10 en 2023, 9 en 2024, 4 en 2025 y 1 en 2026.

La Figura 2 muestra, para cada año del periodo 2022–2026, el número de registros de la búsqueda principal, de artículos relevantes y de artículos seleccionados, en concordancia con los totales de la Tabla 2. Considerando las fuentes consultadas (ScienceDirect, Springer Nature Link, MDPI, IEEE Xplore y otras plataformas con DOI verificable), ScienceDirect fue la fuente con mayor número de estudios finalmente seleccionados (13 de 31).




Figura 2. Artículos identificados, relevantes y seleccionados por año. Fuente: Elaboración propia.

La distribución por año muestra un pico de producción en 2023 con 10 artículos seleccionados (32.26%), seguido de 2024 con 9 (29.03%), 2022 con 7 (22.58%), 2025 con 4 (12.90%) y 2026 con 1 (3.23%). En consecuencia, los datos describen una concentración de estudios entre 2023 y 2024, más que una tendencia de crecimiento sostenido durante todo el periodo analizado.

En la Figura 3 se presenta una síntesis de la distribución por país de afiliación. China concentra 6 artículos (19.35%), seguida de España con 4 (12.90%); Brasil y Alemania registran 3 cada uno (9.68%), mientras que Perú y Colombia aportan 2 estudios cada uno (6.45%). Los 11 artículos restantes se distribuyen entre otros países con menor frecuencia, lo que evidencia el carácter internacional del campo.




Figura 3. Distribución de los artículos seleccionados por país de afiliación del primer autor. Fuente: Elaboración propia.

La Tabla 3 muestra los 31 artículos seleccionados, cada uno con su identificador, título, autores, año y base de datos de recuperación. La columna “Base de datos” indica la plataforma editorial en la que se recuperó cada artículo; adicionalmente, se verificó que las revistas correspondientes estuvieran indexadas en Scopus u otros índices reconocidos y contaran con DOI verificable, conforme al criterio CI6.

Tabla 3. Artículos seleccionados en la revisión sistemática.

ID	Título del artículo	Autores	Año	Base de datos
A1	<i>A hybrid evolutionary multitask algorithm for the multiobjective vehicle routing problem with time windows [8].</i>	Cai, Y., Cheng, M., Zhou, Y., Liu, P., Guo, J. M.	2022	ScienceDirect
A2	<i>Hybrid multiobjective evolutionary algorithm considering combination timing for multi-type vehicle routing problem with time windows [9].</i>	Zhang, W., Li, H., Yang, W., Zhang, G., Gen, M.	2022	ScienceDirect
A3	<i>Dynamic Multi-Depot Multi-Compartment Refrigerated Vehicle Routing Problem with Multi-Path Based on Real-Time Traffic Information [10].</i>	Hou, D., Fan, H., Ren, X.	2022	SAGE / IOS Press
A4	<i>Logistics Distribution Route Optimization Based on Genetic Algorithm [11].</i>	Xin, L., Xu, P., Manyi, G.	2022	PubMed / Hindawi
A5	<i>A genetic algorithm model for optimizing vehicle routing problems with perishable products under time-window and quality requirements [12].</i>	Agrawal, A. K., Yadav, S., Gupta, A. A., Pandey, S.	2022	ScienceDirect
A6	<i>A hybrid genetic algorithm for the electric vehicle routing problem with time windows [13].</i>	Liu, Q., Xu, P., Wu, Y., Shen, T.	2022	Springer
A7	<i>Combining hybrid genetic search with ruin-and-recreate for solving the capacitated vehicle routing problem [14].</i>	Simensen, M., Hasle, G., Stålhane, M.	2022	Springer
A8	<i>A Genetic Algorithm for the Waitable Time-Varying Multi-Depot Green Vehicle Routing Problem [15].</i>	Chen, C. M., Lv, S., Ning, J., Wu, J. M. T.	2023	MDPI
A9	<i>An Improved Genetic Algorithm for the Granularity-Based Split Vehicle Routing Problem with Simultaneous Delivery and Pickup [16].</i>	Liu, Y., Qin, Z., Liu, J.	2023	MDPI
A10	<i>A co-evolutionary genetic algorithm with knowledge transfer for multi-objective capacitated vehicle routing problems [17].</i>	Wang, C., Ma, B., Sun, J.	2023	ScienceDirect
A11	<i>An improved genetic algorithm for solving the multi-objective vehicle routing problem with environmental considerations [18].</i>	Labidi, H., Ben Azzouna, N., Hassine, K., Gouider, M. S.	2023	ScienceDirect
A12	<i>Hybrid genetic search for the traveling salesman problem with hybrid electric vehicle and time windows [19].</i>	Rocha, Y., Subramanian, A.	2023	ScienceDirect
A13	<i>Combining genetic local search into a multi-population Imperialist Competitive Algorithm for the Capacitated Vehicle Routing Problem [20].</i>	Rezaei, B., Guimaraes, F. G., Enayatifar, R., Haddow, P. C.	2023	ScienceDirect
A14	<i>A hybrid metaheuristic approach for solving a bi-objective capacitated electric vehicle routing problem with time windows and partial recharging [21].</i>	Zahedi, F., Kia, H., Khalilzadeh, M.	2023	Emerald
A15	<i>Meta-Heuristic Solver with Parallel Genetic Algorithm Framework in Airline Crew Scheduling [22].</i>	Ouyang, W., Zhu, X.	2023	MDPI
A16	<i>MRDPGA: a multiple restart dynamic population genetic algorithm for scheduling road traffic [23].</i>	Zachariah, B., Misra, S., Odion, P. O., Isah, S. R.	2023	Springer
A17	<i>A Genetic Algorithm for the Integrated Warehouse Location, Allocation and Vehicle Routing Problem in a Pooled Transportation System [24].</i>	Mrad, M., Bamatraf, K., Alkahtani, M., Hidri, L.	2023	IJIE
A18	<i>An Adaptive Multi-Objective Genetic Algorithm for Solving Heterogeneous Green City Vehicle Routing Problem [25].</i>	Zhao, W., Bian, X., Mei, X.	2024	MDPI
A19	<i>Improved GA-LNS Algorithm for Solving Vehicle Path Problems Considering Carbon Emissions [26].</i>	Cheng, F., Jia, S.	2024	MDPI
A20	<i>Vehicle routing and scheduling problem with order acceptance for pharmaceutical refrigerated logistics [27].</i>	Lee, S. J., Kim, B. S.	2024	ScienceDirect
A21	<i>A parallel genetic algorithm for multi-criteria path routing on complex real-world road networks [28].</i>	Sharma, H., Galván, E., Mooney, P.	2024	ScienceDirect
A22	<i>Two-Stage Genetic Algorithm for Optimization Logistics Network for Groupage Delivery [29].</i>	Malashin, I. P., et al.	2024	MDPI

A23	<i>A genetic algorithm for vehicle routing problems with time windows based on cluster of geographic positions and time windows [30].</i>	Liu, J., Tong, L., Xia, X.	2024	ScienceDirect
A24	<i>A hybrid genetic search and dynamic programming-based split algorithm for the multi-trip time-dependent vehicle routing problem [31].</i>	Zhao, J., Poon, M., Tan, V. Y. F., Zhang, Z.	2024	ScienceDirect
A25	<i>A lightweight genetic algorithm with variable neighborhood search for multi-depot vehicle routing problem with time windows [32].</i>	Su, Y., Zhang, S., Zhang, C.	2024	ScienceDirect
A26	<i>Handling dynamic capacitated vehicle routing problems based on adaptive genetic algorithm with elastic strategy [33].</i>	Li, J., Liu, R., Wang, R.	2024	ScienceDirect
A27	<i>A Parallel Hybrid Genetic Search for Solving the Capacitated Vehicle Routing Problem [34].</i>	Jamshidi, M., Alirezanejad, M., Motameni, H., Enayatifar, R.	2025	Springer
A28	<i>A hybrid genetic search based approach for the generalized vehicle routing problem [35].</i>	Latorre, V.	2025	Springer
A29	<i>Where to Split in Hybrid Genetic Search for the Capacitated Vehicle Routing Problem [36].</i>	Hvattum, L. M.	2025	MDPI
A30	<i>An Improved Genetic Algorithm for Solving the Semi-Soft Clustered Vehicle Routing Problem [37].</i>	Miao, Y., Bao, X.	2025	MDPI
A31	<i>A Hybrid Constructive Genetic Algorithm (HCGA) for the Vehicle Routing Problem With Time Windows in Logistics Optimization [38].</i>	Du, H., Tanimizu, Y., Watanabe, R.	2026	IEEE Access

Fuente: Elaboración propia.

La Tabla 4 presenta la evaluación de calidad de los 31 artículos de acuerdo con las preguntas P1–P4 descritas en la sección 2d. El puntaje promedio fue de 3.69 sobre 4.00 y ningún estudio quedó por debajo del umbral de 2.5, lo que respalda la calidad metodológica del corpus analizado.

Tabla 4. Evaluación de calidad de los artículos.

ID	P1	P2	P3	P4	TOTAL
A1	1	1	1	1	4
A2	1	1	1	0.5	3.5
A3	1	1	1	1	4
A4	0.5	1	1	1	3.5
A5	1	1	1	1	4
A6	1	1	0.5	1	3.5
A7	0.5	1	1	0.5	3
A8	1	1	1	1	4
A9	1	1	1	1	4
A10	0.5	1	1	0.5	3
A11	1	1	1	1	4
A12	1	1	0.5	1	3.5
A13	1	1	1	1	4
A14	0.5	1	1	0.5	3
A15	1	1	1	1	4
A16	1	1	1	1	4
A17	1	1	1	0.5	3.5
A18	1	1	1	1	4
A19	0.5	1	1	1	3.5
A20	1	1	1	1	4
A21	1	1	0.5	1	3.5
A22	1	1	1	1	4
A23	1	1	1	0.5	3.5
A24	1	1	1	1	4
A25	1	1	1	1	4
A26	1	1	1	1	4
A27	0.5	1	1	1	3.5
A28	1	1	1	1	4
A29	1	1	1	1	4
A30	1	1	1	0.5	3.5
A31	0.5	1	0.5	0.5	2.5

Fuente: Elaboración propia.

4. Discusión

En esta sección se responde a las preguntas de investigación planteadas, de acuerdo con los artículos seleccionados.

a) *¿Qué tipos de problemas de asignación de recursos en empresas de transporte han sido abordados mediante algoritmos genéticos?*

En la Figura 4 se representa la distribución de los tipos de problemas abordados mediante AG y en la Tabla 5 se detalla su frecuencia. Para esta síntesis, cada estudio fue clasificado en una sola categoría según su foco principal de aplicación, verificado durante la lectura a texto completo y consensuado por ambos autores.




Figura 4. Tipos de problemas abordados con AG (clasificación principal por estudio). Fuente: Elaboración propia.

Tabla 5. Frecuencia de tipos de problemas abordados con AG.

Tipo de problema	Variante o ámbito más frecuente	Frecuencia	Artículos
<i>Vehicle Routing Problem</i> (VRP) y variantes	VRPTW, CVRP, MDVRP, EVRP, VRP dinámico y VRP verde	25 (80.6 %)	A1–A11, A13, A14, A18–A20, A23–A31
Ruteo multicriterio y TSP con vehículos eléctricos o híbridos	TSP con ventanas de tiempo; ruteo multicriterio en redes viales	2 (6.45%)	A12, A21
Programación de tripulaciones (<i>crew scheduling</i>)	Tripulaciones aéreas	1 (3.23%)	A15
Programación de tráfico vial	Programación dinámica de tráfico	1 (3.23%)	A16
Localización-asignación y ruteo integrado	Almacenes y flota en sistema colaborativo	1 (3.23%)	A17
Diseño de red logística de distribución	Entrega consolidada (<i>groupage</i>)	1 (3.23%)	A22
TOTAL		31 (100%)	

Fuente: Elaboración propia.

Bajo una clasificación principal por estudio, el VRP y sus variantes concentran 25 de los 31 trabajos seleccionados (80.65%), lo que evidencia el peso de la optimización de rutas dentro de la programación operativa del transporte. Las categorías restantes —ruteo multicriterio y TSP (6.45%), programación de tripulaciones, programación de tráfico, localización-asignación integrada y diseño de red logística (3.23% cada una)— completan el corpus. Todas las categorías corresponden a decisiones de asignación de recursos operativos, conforme a la definición adoptada en la introducción: el VRP asigna clientes, secuencias de visita y rutas a una flota limitada de vehículos; la programación de tripulaciones asigna personal a servicios; la programación de tráfico distribuye la capacidad vial en el tiempo; la localización-asignación distribuye la demanda entre almacenes y vehículos; y el diseño de red logística asigna flujos de carga a la red de distribución. Este predominio del VRP es consistente con lo reportado en revisiones previas [1], [2] y motivó la precisión del alcance reflejada en el título de esta revisión.

b) ¿Qué variantes de algoritmos genéticos y qué operadores evolutivos predominan?

En la Figura 5 se visualizan las variantes de AG y operadores destacados en los estudios analizados, y en la Tabla 6 se detallan los operadores clave asociados. Debido a que un mismo trabajo puede reportar simultáneamente una variante general y un operador específico, las frecuencias se interpretan como menciones no excluyentes. En este contexto, los AG híbridos integrados con búsqueda local (2-opt, 3-opt) o recocido simulado son la categoría más recurrente, seguidos del AG clásico y del NSGA-II en escenarios multiobjetivo.




Figura 5. Variantes de AG más empleadas (menciones no excluyentes). Fuente: Elaboración propia.

Tabla 6. Variantes de AG y operadores evolutivos más empleados.

Variante de AG	Operadores clave	Frecuencia	Artículos
AG Clásico (SGA)	Ruleta/torneo; cruce de un punto; mutación <i>bit-flip</i>	9 (29.03%)	A1, A5, A7, A10, A14, A16, A21, A23, A31
AG Híbrido (AG + BL / SA)	2-opt, 3-opt, búsqueda local, recocido simulado	11 (35.48%)	A6, A8, A11, A13, A17, A20, A22, A23, A25, A27, A28
NSGA-II (Multiobjetivo)	Frentes de Pareto; <i>crowding distance</i>	8 (25.81%)	A3, A4, A9, A15, A18, A26, A29, A30
AG codificación de orden	OX, PMX, CX; permutación	4 (12.90%)	A2, A10, A19, A24
TOTAL		32 menciones	

Fuente: Elaboración propia.

En términos de menciones no excluyentes, los AG híbridos son la categoría más recurrente con 11 registros (35.48% respecto del total de estudios), lo que sugiere que la integración con procedimientos de búsqueda local se utiliza como mecanismo para mejorar la calidad de solución. El NSGA-II y otras formulaciones multiobjetivo reúnen 8 menciones (25.81%), consolidándose como referencia cuando se optimizan simultáneamente costos, emisiones o calidad de servicio.

c) ¿Qué resultados cuantitativos reportan los estudios?

La Figura 6 resume la reducción de costo operativo reportada por variante de AG a partir de los rangos consolidados en la Tabla 7, obtenidos mediante el procedimiento de extracción y agregación descrito en la sección 2f. Cada intervalo corresponde al mínimo y al máximo de mejora reportados por los estudios de esa variante respecto de sus propias líneas base; por lo tanto, los valores deben interpretarse de forma descriptiva, ya que las diferencias entre variantes pueden reflejar, además del desempeño algorítmico, diferencias en los problemas, instancias, funciones objetivo y métodos de referencia empleados [2].




Figura 6. Reducción de costo operativo reportada por variante de AG (rangos mínimo-máximo consolidados de la Tabla 7).
Fuente: Elaboración propia.

Tabla 7. Resultados cuantitativos por variante de AG.

Variante	Reducción de costo	Tiempo de cómputo	Métrica principal	QA promedio
AG Clásico (SGA)	8%–15%	Bajo (< 5 min)	GAP vs. óptimo	3.6 / 4.0
AG Híbrido (AG+BL/SA)	19%–27%	Moderado (5–30 min)	% mejora vs. heurística	3.9 / 4.0
NSGA-II	15%–22%	Moderado-alto	HV, GD, IGD (Pareto)	3.8 / 4.0
AG codificación orden	10%–18%	Moderado	Tiempo de turno / cobertura	3.5 / 4.0

Fuente: Elaboración propia.

Con la salvedad metodológica indicada, los AG híbridos reportan las mayores mejoras de costo (19%–27%), a costa de tiempos de cómputo moderados, lo que es coherente con la evidencia de que la hibridación con búsqueda local constituye el estado del arte para el VRP [4]. El AG clásico ofrece tiempos bajos con mejoras menores (8%–15%), mientras que las formulaciones multiobjetivo tipo NSGA-II alcanzan mejoras intermedias (15%–22%) al optimizar simultáneamente varios objetivos.

d) ¿Cuáles son las principales limitaciones técnicas y operativas identificadas?

En la Figura 7 se muestran las principales limitaciones identificadas en los estudios analizados y en la Tabla 8 se detallan su descripción y frecuencia. Las menciones más recurrentes corresponden a la convergencia prematura y a la sensibilidad a parámetros, seguidas por la dificultad de incorporar restricciones dinámicas en tiempo real.




Figura 7. Principales limitaciones identificadas en los estudios. Fuente: Elaboración propia.

Tabla 8. Principales limitaciones identificadas en los estudios.

Limitación	Descripción	Variante afectada	Frecuencia	Artículos
Convergencia prematura	El AG converge a óptimos locales antes de explorar el espacio	SGA, Híbrido	7 (22.58%)	A1, A5, A7, A10, A14, A16, A21
Sensibilidad a parámetros	Tamaño de población y tasas difíciles de calibrar	SGA, NSGA-II	7 (22.58%)	A2, A4, A8, A9, A12, A18, A30
Restricciones dinámicas	Dificultad para gestionar cambios en tiempo real	Todos	6 (19.35%)	A8, A19, A22, A26, A28, A31
Escalabilidad / cómputo	Alto costo en instancias grandes (> 500 nodos)	Híbrido, NSGA-II	5 (16.13%)	A3, A11, A15, A22, A29
Sin validación real	Solo simulación o datos históricos, sin piloto operativo	Todos	3 (9.68%)	A7, A14, A31
Representación compleja	Dificultad para codificar restricciones laborales	SGA	1 (3.23%)	A2
TOTAL			29 menciones	

* El total de menciones (29) no coincide con el número de artículos (31) porque un mismo estudio puede reportar más de una limitación y algunos estudios no declaran limitaciones explícitas.

Fuente: Elaboración propia.

e) Síntesis crítica, contraste con revisiones previas e implicaciones prácticas

Los hallazgos de esta revisión coinciden parcialmente con revisiones previas y, a la vez, las complementan. Elshaer y Awad [2] ya identificaban a los AG como la metaheurística poblacional más utilizada para el VRP en la literatura hasta 2017; la presente revisión muestra que, en el periodo 2022–2026, esa preferencia se mantiene, pero desplazada hacia formulaciones híbridas, multiobjetivo y adaptativas, en línea con la consolidación de la búsqueda genética híbrida como estado del arte [4]. A diferencia de [1] y [2], centradas en el VRP y en el conjunto de las metaheurísticas, esta revisión delimita la evidencia reciente específica de los AG y la extiende a otros problemas de asignación de recursos del transporte, como la programación de tripulaciones, la programación de tráfico y el diseño de redes logísticas.

El análisis conjunto de las Tablas 6, 7 y 8 revela tensiones que la literatura aún no resuelve. Primero, existe un compromiso entre calidad de solución y costo computacional: los enfoques híbridos y multiobjetivo reportan las mayores mejoras, pero concentran las menciones de escalabilidad limitada en instancias grandes, mientras que el AG clásico, más rápido, es el más afectado por la convergencia prematura. Segundo, los operadores adaptativos reducen la sensibilidad a parámetros reportada, pero incrementan la complejidad de diseño e implementación del algoritmo. Tercero, aunque varios estudios incorporan información dinámica (tráfico en tiempo real, demanda variable), la gestión de restricciones dinámicas persiste como limitación transversal, lo que sugiere que la adaptación en línea de los AG sigue siendo una línea abierta de investigación.

Para las empresas de transporte, estos resultados tienen implicaciones concretas. La disponibilidad de implementaciones de código abierto de la búsqueda genética híbrida [4] reduce la barrera técnica de adopción; no obstante, la aplicación operativa exige integrar datos reales de tráfico, demanda, disponibilidad de flota y turnos de conductores, así como validar los modelos en pilotos operativos, aspecto que solo una minoría de los estudios aborda. Los rangos de mejora consolidados sugieren un potencial relevante de reducción de costos, pero condicionado a la calibración de parámetros y a la validación en el contexto específico de cada empresa, especialmente en entornos latinoamericanos donde la evidencia empírica es aún escasa.

5. Conclusiones

Los resultados de esta revisión sistemática permiten concluir que los algoritmos genéticos constituyen una alternativa pertinente para la asignación de recursos y la optimización de rutas en la programación operativa de empresas de transporte. A partir del análisis de 31 estudios publicados entre 2022 y 2026, se identificó que el *Vehicle Routing Problem* y sus variantes son los problemas más abordados (80.65% de los estudios), debido a su relación directa con la asignación de rutas, vehículos, horarios y recursos logísticos.

Asimismo, se evidenció que los algoritmos genéticos híbridos son los enfoques más utilizados, ya que combinan la capacidad exploratoria del algoritmo genético con técnicas complementarias como búsqueda local, búsqueda de vecindario variable o programación dinámica. Estos enfoques permiten obtener soluciones de mejor

calidad en problemas complejos, especialmente cuando existen restricciones de capacidad, tiempo, costos, emisiones o disponibilidad de flota.

No obstante, los enfoques revisados presentan algunas limitaciones. Los algoritmos genéticos clásicos pueden verse afectados por la sensibilidad a los parámetros y la convergencia prematura. Por su parte, los enfoques híbridos y multiobjetivo, aunque reportan mejores resultados, pueden requerir mayor tiempo computacional y una configuración más compleja. Además, varios estudios se basan en simulaciones o instancias académicas, lo que limita su validación en escenarios reales de empresas de transporte; por ello, los rangos cuantitativos consolidados deben interpretarse de manera descriptiva y no como comparaciones directas entre variantes.

Como trabajo futuro, se recomienda desarrollar modelos adaptativos e híbridos que integren datos reales de operación, tráfico, disponibilidad de vehículos, turnos de conductores y demanda variable. También resulta necesario validar estos modelos en empresas reales, especialmente en contextos peruanos y latinoamericanos, con el fin de evaluar su impacto en la reducción de costos, la optimización de rutas y el apoyo a la toma de decisiones operativas.

6. Agradecimientos

Los autores expresan su agradecimiento a la Universidad Católica Sedes Sapientiae, filial Nueva Cajamarca, por el acompañamiento académico brindado durante el desarrollo de la presente investigación.

7. Referencias

- [1] Konstantakopoulos, G. D., Gayialis, S. P., Kechagias, E. P. (2022). Vehicle routing problem and related algorithms for logistics distribution: a literature review and classification. *Operational Research*, 22 (3), 2033–2062. <https://doi.org/10.1007/s12351-020-00600-7>
- [2] Elshaer, R., Awad, H. (2020). A taxonomic review of metaheuristic algorithms for solving the vehicle routing problem and its variants. *Computers & Industrial Engineering*, 140. <https://doi.org/10.1016/j.cie.2019.106242>
- [3] Holland, J. H. (1992). *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. MIT Press.
- [4] Vidal, T. (2022). Hybrid genetic search for the CVRP: Open-source implementation and SWAP* neighborhood. *Computers and Operations Research*, 140, 1-11. <https://doi.org/10.1016/j.cor.2021.105643>
- [5] Zambrano Miranda, J. A., Correa Pillajo, J. E., Grijalva Arévalo, F. L., Vega Sánchez, J. D. (2022). Selección de funciones de voz mediante algoritmos genéticos para la detección de la enfermedad de Parkinson. *Revista de Investigación en Tecnologías de la Información (RITI)*, 10 (21), 140–150. <https://doi.org/10.36825/RITI.10.21.013>
- [6] Kitchenham, B., Charters, S. (2007). *Guidelines for performing Systematic Literature Reviews in Software Engineering* (EBSE Technical Report EBSE-2007-01). Keele University / University of Durham. https://www.elsevier.com/_data/promis_misc/525444systematicreviewsguide.pdf
- [7] Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372, 1-9. <https://doi.org/10.1136/bmj.n71>
- [8] Cai, Y., Cheng, M., Zhou, Y., Liu, P., Guo, J. M. (2022). A hybrid evolutionary multitask algorithm for the multiobjective vehicle routing problem with time windows. *Information Sciences*, 612, 168–187. <https://doi.org/10.1016/j.ins.2022.08.103>
- [9] Zhang, W., Li, H., Yang, W., Zhang, G., Gen, M. (2022). Hybrid multiobjective evolutionary algorithm considering combination timing for multi-type vehicle routing problem with time windows. *Computers & Industrial Engineering*, 171. <https://doi.org/10.1016/j.cie.2022.108435>
- [10] Hou, D., Fan, H., Ren, X. (2022). Dynamic multi-depot multi-compartment refrigerated vehicle routing problem with multi-path based on real-time traffic information. En *Advances in Transdisciplinary Engineering* (349-356). IOS Press. <https://doi.org/10.3233/ATDE220035>

- [11]Xin, L., Xu, P., Manyi, G. (2022). Logistics distribution route optimization based on genetic algorithm. *Computational Intelligence and Neuroscience*, 2022 (1), 1-9. <https://doi.org/10.1155/2022/8468438>
- [12]Agrawal, A. K., Yadav, S., Gupta, A. A., Pandey, S. (2022). A genetic algorithm model for optimizing vehicle routing problems with perishable products under time-window and quality requirements. *Decision Analytics Journal*, 5, 1-14. <https://doi.org/10.1016/j.dajour.2022.100139>
- [13]Liu, Q., Xu, P., Wu, Y., Shen, T. (2022). A hybrid genetic algorithm for the electric vehicle routing problem with time windows. *Control Theory and Technology*, 20 (2), 279-286. <https://doi.org/10.1007/s11768-022-00091-1>
- [14]Simensen, M., Hasle, G., Stålhane, M. (2022). Combining hybrid genetic search with ruin-and-recreate for solving the capacitated vehicle routing problem. *Journal of Heuristics*, 28, 653-697. <https://doi.org/10.1007/s10732-022-09500-9>
- [15]Chen, C. M., Lv, S., Ning, J., Wu, J. M. T. (2023). A genetic algorithm for the waitable time-varying multi-depot green vehicle routing problem. *Symmetry*, 15 (1), 1-26. <https://doi.org/10.3390/sym15010124>
- [16]Liu, Y., Qin, Z., Liu, J. (2023). An improved genetic algorithm for the granularity-based split vehicle routing problem with simultaneous delivery and pickup. *Mathematics*, 11 (15), 1-15. <https://doi.org/10.3390/math11153328>
- [17]Wang, C., Ma, B., Sun, J. (2023). A co-evolutionary genetic algorithm with knowledge transfer for multi-objective capacitated vehicle routing problems. *Applied Soft Computing*, 148. <https://doi.org/10.1016/j.asoc.2023.110913>
- [18]Labidi, H., Ben Azzouna, N., Hassine, K., Gouider, M. S. (2023). An improved genetic algorithm for solving the multi-objective vehicle routing problem with environmental considerations. *Procedia Computer Science*, 225, 3866-3875. <https://doi.org/10.1016/j.procs.2023.10.382>
- [19]Rocha, Y., Subramanian, A. (2023). Hybrid genetic search for the traveling salesman problem with hybrid electric vehicle and time windows. *Computers & Operations Research*, 155. <https://doi.org/10.1016/j.cor.2023.106223>
- [20]Rezaei, B., Guimaraes, F. G., Enayatifar, R., Haddow, P. C. (2023). Combining genetic local search into a multi-population Imperialist Competitive Algorithm for the Capacitated Vehicle Routing Problem. *Applied Soft Computing*, 142. <https://doi.org/10.1016/j.asoc.2023.110309>
- [21]Zahedi, F., Kia, H., Khalilzadeh, M. (2023). A hybrid metaheuristic approach for solving a bi-objective capacitated electric vehicle routing problem with time windows and partial recharging. *Journal of Advances in Management Research*, 20 (4), 695-729. <https://doi.org/10.1108/JAMR-01-2023-0007>
- [22]Ouyang, W., Zhu, X. (2023). Meta-heuristic solver with parallel genetic algorithm framework in airline crew scheduling. *Sustainability*, 15 (2), 1-21. <https://doi.org/10.3390/su15021506>
- [23]Zachariah, B., Misra, S., Odion, P. O., Isah, S. R. (2023). MRDPGA: a multiple restart dynamic population genetic algorithm for scheduling road traffic. *Journal of Electrical Systems and Information Technology*, 10 (35), 1-18. <https://doi.org/10.1186/s43067-023-00099-w>
- [24]Mrad, M., Bamatraf, K., Alkahtani, M., Hidri, L. (2023). A genetic algorithm for the integrated warehouse location, allocation and vehicle routing problem in a pooled transportation system. *International Journal of Industrial Engineering: Theory, Applications and Practice*, 30 (3), 852-857. <https://doi.org/10.23055/ijietap.2023.30.3.8989>
- [25]Zhao, W., Bian, X., Mei, X. (2024). An adaptive multi-objective genetic algorithm for solving heterogeneous green city vehicle routing problem. *Applied Sciences*, 14 (15), 1-16. <https://doi.org/10.3390/app14156594>
- [26]Cheng, F., Jia, S. (2024). Improved GA-LNS algorithm for solving vehicle path problems considering carbon emissions. *Applied Sciences*, 14 (21), 1-17. <https://doi.org/10.3390/app14219956>
- [27]Lee, S. J., Kim, B. S. (2024). Vehicle routing and scheduling problem with order acceptance for pharmaceutical refrigerated logistics. *Applied Soft Computing*, 164. <https://doi.org/10.1016/j.asoc.2024.111983>
- [28]Sharma, H., Galván, E., Mooney, P. (2024). A parallel genetic algorithm for multi-criteria path routing on complex real-world road networks. *Applied Soft Computing*, 170. <https://doi.org/10.1016/j.asoc.2024.112559>

- [29]Malashin, I. P., Tynchenko, V., Masich, I. S., Sukhanov, D. A., Ageev, D. A., Nelyub, V. A., Gantimurov, A. P., Borodulin, A. S. (2024). Two-stage genetic algorithm for optimization logistics network for groupage delivery. *Applied Sciences*, 14 (24), 1-20. <https://doi.org/10.3390/app142412005>
- [30]Liu, J., Tong, L., Xia, X. (2024). A genetic algorithm for vehicle routing problems with time windows based on cluster of geographic positions and time windows. *Applied Soft Computing*, 169. <https://doi.org/10.1016/j.asoc.2024.112593>
- [31]Zhao, J., Poon, M., Tan, V. Y. F., Zhang, Z. (2024). A hybrid genetic search and dynamic programming-based split algorithm for the multi-trip time-dependent vehicle routing problem. *European Journal of Operational Research*, 317 (3), 921-935. <https://doi.org/10.1016/j.ejor.2024.04.011>
- [32]Su, Y., Zhang, S., Zhang, C. (2024). A lightweight genetic algorithm with variable neighborhood search for multi-depot vehicle routing problem with time windows. *Applied Soft Computing*, 161. <https://doi.org/10.1016/j.asoc.2024.111789>
- [33]Li, J., Liu, R., Wang, R. (2024). Handling dynamic capacitated vehicle routing problems based on adaptive genetic algorithm with elastic strategy. *Swarm and Evolutionary Computation*, 86. <https://doi.org/10.1016/j.swevo.2024.101529>
- [34]Jamshidi, M., Alirezanejad, M., Motameni, H., Enayatifar, R. (2025). A parallel hybrid genetic search for solving the capacitated vehicle routing problem. *International Journal of Computational Intelligence Systems*, 18 (1), 1-19. <https://doi.org/10.1007/s44196-025-01059-0>
- [35]Latorre, V. (2025). A hybrid genetic search based approach for the generalized vehicle routing problem. *Soft Computing*, 29, 1553-1566. <https://doi.org/10.1007/s00500-025-10507-0>
- [36]Hvattum, L. M. (2025). Where to split in hybrid genetic search for the capacitated vehicle routing problem. *Algorithms*, 18 (3), 1-19. <https://doi.org/10.3390/a18030165>
- [37]Miao, Y., Bao, X. (2025). An improved genetic algorithm for solving the semi-soft clustered vehicle routing problem. *Applied Sciences*, 15 (9), 1-17. <https://doi.org/10.3390/app15094871>
- [38]Du, H., Tanimizu, Y., Watanabe, R. (2026). A hybrid constructive genetic algorithm (HCGA) for the vehicle routing problem with time windows in logistics optimization. *IEEE Access*, 14, 40532-40549. <https://doi.org/10.1109/ACCESS.2026.3672634>