

Comparación de algoritmos genéticos, colonia de abejas y colonia de hormigas para la optimización multiobjetivo de redes logísticas

Comparison of genetic algorithms, artificial bee colony, and ant colony optimization for multi-objective optimization of logistics networks

Ángel Alexis Manobanda Suárez¹

Universidad Estatal del Sur de Manabí, Jipijapa, Ecuador
angel.manobanda@unesum.edu.ec
<https://orcid.org/0009-0004-9993-5304>

Balmes Amílcar Arriola Mejía²

Santa Ana, El Salvador
balmes@gmail.com
<https://orcid.org/0009-0002-2828-6082>

Cómo citar:

Manobanda Suárez, Ángel A., & Arriola Mejía, B. A. (2026). Comparación de algoritmos genéticos, colonia de abejas y colonia de hormigas para la optimización multiobjetivo de redes logísticas. *Saber Estratégico Internacional*, 4(3), 1390–1404. <https://doi.org/10.70577/s.e.v4i3.131>

RESUMEN

La optimización de redes logísticas es un problema complejo debido a la necesidad de reducir tiempos de entrega, costos operativos y riesgos de retraso en entornos dinámicos. El objetivo del estudio fue comparar el desempeño del Algoritmo Genético, la Colonia Artificial de Abejas y la Colonia de Hormigas en la optimización multiobjetivo de una red logística. Se aplicó un enfoque cuantitativo, comparativo y aplicado, mediante experimentación computacional sobre una muestra censal de 1.000 registros correspondientes a 10 camiones, utilizando regresión logística para estimar la probabilidad de retraso y tres funciones objetivo: tiempo, costo y riesgo. Los resultados evidenciaron que el Algoritmo Genético generó 17 soluciones no dominadas y redujo el objetivo agregado en 33,9% frente a una asignación aleatoria. En las soluciones balanceadas, ABC alcanzó 5.765,38 horas, USD 13.992,64 y riesgo de 34,84, mientras que ACO obtuvo 4.202,34 horas, USD 10.486,61 y riesgo de 34,94, mejorando frente al GA en 50,92 % en tiempo, 49,26% en costo y 7,17% en riesgo. Se concluyó que ACO presentó el mejor desempeño global bajo las condiciones evaluadas.

Palabras clave: Algoritmos evolutivos, colonia de abejas, colonia de hormigas, logística, optimización multiobjetivo.

ABSTRACT

Logistics network optimization is a complex problem due to the need to reduce delivery times, operating costs, and delay risks in dynamic environments. The study aimed to compare the performance of the Genetic Algorithm (GA), Artificial Bee Colony (ABC), and Ant Colony Optimization (ACO) in the multi-objective optimization of a logistics network. A quantitative, comparative, and applied approach was used, involving computational experimentation on a census sample of 1,000 records corresponding to 10 trucks; logistic regression was employed to estimate the probability of delay, alongside three objective functions: time, cost, and risk. The results showed that the Genetic Algorithm generated 17 non-dominated solutions and reduced the aggregate objective by 33.9% compared to random allocation. Regarding balanced solutions, ABC achieved 5,765.38 hours, USD 13,992.64, and a risk level of 34.84, whereas ACO obtained 4,202.34 hours, USD 10,486.61, and a risk level of 34.94—outperforming GA by 50.92% in time, 49.26% in cost, and 7.17% in risk. It was concluded that ACO demonstrated the best overall performance under the conditions evaluated.

Keywords: Evolutionary algorithms, bee colony, ant colony, logistics, multi-objective optimization.

INTRODUCCIÓN

Según el Banco Mundial (2023), el desempeño logístico es un componente estratégico para la competitividad de las economías, debido a que integra aspectos como infraestructura, calidad de los servicios logísticos, seguimiento de mercancías, aduanas y puntualidad de los envíos; en su Índice de Desempeño Logístico de 2023 fueron evaluados 139 países y se estimó que, considerando las rutas comerciales internacionales, transcurren en promedio 44 días desde que un contenedor ingresa al puerto del país exportador hasta que abandona el puerto de destino. En este contexto, la optimización de redes logísticas se ha convertido en un problema de creciente complejidad debido a que las organizaciones deben reducir simultáneamente tiempos de entrega, costos operativos y riesgos asociados a retrasos. En el caso ecuatoriano, de acuerdo con el Banco Central del Ecuador (2024), el sector de transporte y almacenamiento registró un crecimiento anual de 4,8% durante 2023, mientras que la economía nacional creció 2,4%, evidenciando la importancia que tienen las actividades de movilidad y distribución dentro de la dinámica productiva del país.

En concordancia con Labidi et al. (2023), los problemas modernos de ruteo requieren considerar simultáneamente criterios económicos, operativos y ambientales, razón por la cual los algoritmos genéticos constituyen una alternativa para explorar espacios de soluciones complejos; los autores desarrollaron un algoritmo genético híbrido aplicado a un problema dinámico de ruteo de vehículos con ventanas de tiempo y flota heterogénea, concluyendo que la combinación de estrategias evolutivas permite obtener soluciones de elevada calidad dentro de tiempos computacionales razonables.

Así mismo, Djebbar y Boudia (2022) compararon el algoritmo de Colonia Artificial de Abejas con un algoritmo genético para resolver el problema de ruteo de vehículos mediante 14 instancias que comprendieron entre 50 y 200 clientes, encontrando que la estrategia basada en abejas alcanzó soluciones competitivas y menores tiempos computacionales en determinadas instancias. En otra perspectiva, Gu et al. (2022) aplicaron el algoritmo de Colonia Artificial de Abejas al problema de ruteo de vehículos con múltiples depósitos y reportaron ventajas de hasta 70% frente a un algoritmo voraz y alrededor de 3% respecto a un algoritmo genético, lo cual respalda la utilidad de la inteligencia de enjambre para resolver problemas logísticos con estructuras combinatorias complejas.

Por su parte, Su et al. (2021) desarrollaron una variante responsiva del algoritmo de Colonia de Hormigas para problemas dinámicos de ruteo vehicular a gran escala, incorporando mecanismos de diversidad de feromonas que favorecen la adaptación ante nuevas solicitudes de clientes; su evaluación sobre 12 instancias mostró capacidad para generar rutas de calidad y responder a cambios dinámicos de la red logística. Complementariamente, Thammano y Rungwachira (2021) integraron un sistema modificado de hormigas con técnicas de barrido y *path relinking* para el problema de ruteo capacitado, obteniendo resultados competitivos frente a métodos del estado del arte e incluso mejorando una solución previamente conocida en una de las instancias evaluadas.

A partir de la problemática expuesta, la investigación plantea la siguiente pregunta: ¿qué diferencias de desempeño presentan los algoritmos genéticos, el algoritmo de Colonia Artificial de Abejas y el algoritmo de Colonia de Hormigas en la optimización multiobjetivo de una red logística considerando simultáneamente el tiempo de entrega, el costo operativo y la probabilidad de retraso? En correspondencia con esta interrogante, el objetivo del estudio es comparar el desempeño del Algoritmo

<https://doi.org/10.70577/s.e.v4i3.131>

Genético, el algoritmo de Colonia Artificial de Abejas y el algoritmo de Colonia de Hormigas en la optimización multiobjetivo de una red logística, mediante la evaluación de soluciones orientadas a minimizar el tiempo de entrega, el costo operativo y la probabilidad de retraso. Este planteamiento mantiene correspondencia con el propósito original del estudio, que implementa las tres metaheurísticas bajo un mismo marco de evaluación para analizar su convergencia y eficiencia computacional.

Digitalización, Internet de las cosas y gemelos digitales en la gestión logística

De acuerdo con Wang et al. (2022), la transformación de las cadenas de suministro hacia modelos inteligentes depende de la conectividad, visibilidad e integración de información, condiciones que pueden fortalecerse mediante gemelos digitales capaces de representar virtualmente los procesos físicos y apoyar decisiones en tiempo real. De esta manera, Bhandal et al. (2022) sostienen que los gemelos digitales han ampliado su aplicación en la gestión de operaciones y cadenas de suministro, al permitir sincronizar información procedente de diferentes procesos, mejorar la visibilidad operacional y facilitar la simulación de escenarios antes de modificar el sistema real.

En esta misma línea, Moshood et al. (2021) señalan que la visibilidad de las cadenas logísticas constituye uno de los principales beneficios derivados de la incorporación de gemelos digitales, puesto que facilita el seguimiento de activos, mercancías y operaciones dentro de redes cada vez más complejas. Por su parte, Zhu et al. (2023) explican que los gemelos digitales aplicados a la logística de producción integran datos físicos y virtuales para supervisar, simular y mejorar continuamente los procesos, aunque todavía persisten desafíos relacionados con interoperabilidad, calidad de datos y aplicación a gran escala. Complementariamente, Le y Fan (2024) plantean que la integración de modelos digitales con sistemas logísticos puede incrementar la transparencia y rapidez de la toma de decisiones, especialmente cuando se utilizan datos dinámicos para reproducir situaciones operativas y evaluar distintas alternativas de actuación.

Toma de decisiones multicriterio y equilibrio entre objetivos

Según Jayarathna et al. (2021), la optimización multiobjetivo adquiere especial importancia en logística porque las decisiones reales rara vez responden a un único criterio; su revisión de 95 investigaciones evidencia que los modelos suelen combinar objetivos económicos y ambientales y destaca la necesidad de continuar desarrollando métodos metaheurísticos e híbridos para problemas complejos. De manera concordante, Tadaros y Migdalas (2022) establecen que los problemas de localización y distribución presentan objetivos frecuentemente contrapuestos y que, en lugar de una única respuesta óptima, la decisión puede expresarse mediante un conjunto de soluciones no dominadas que representan distintos compromisos entre los criterios considerados.

A su vez, Lai et al. (2023) explican que cuando aumenta el número de objetivos también se incrementa la dificultad para diferenciar y seleccionar alternativas eficientes, motivo por el cual los enfoques paretianos y lexicográficos cumplen una función relevante en la estructuración de problemas con numerosos criterios. Desde otra perspectiva, Chejarla et al. (2022), mediante una revisión de más de 120 investigaciones, identificaron una presencia creciente de métodos de decisión multicriterio en la evaluación del desempeño logístico, debido a que indicadores de costo, servicio, utilización de recursos y calidad pueden requerir una valoración simultánea. Desde el punto de vista de Petchrompo et al. (2022)

<https://doi.org/10.70577/s.e.v4i3.131>

señalan que un Frente de Pareto excesivamente amplio puede dificultar la selección gerencial y proponen entender la reducción o *pruning* de soluciones como un mecanismo para concentrar el análisis en alternativas representativas de acuerdo con preferencias, diversidad o eficiencia.

Resiliencia, sostenibilidad e incertidumbre en las cadenas de suministro

Conforme a Suryawanshi y Dutta (2022), la gestión de riesgos y la resiliencia se han convertido en dimensiones centrales de la investigación logística; su revisión examinó 3.672 publicaciones y permitió identificar siete grandes áreas de investigación relacionadas con modelos cuantitativos, incertidumbre, riesgos y capacidad de recuperación de las cadenas de suministro. En correspondencia, Vali-Siar y Roghanian (2022) desarrollaron un modelo de red que integra sostenibilidad, resiliencia y capacidad de respuesta bajo incertidumbre híbrida, mostrando que las estrategias de resiliencia contribuyen simultáneamente al desempeño económico, ambiental y social y que existe un compromiso entre rapidez de respuesta y otros objetivos organizacionales.

Por otro lado, Ivanov y Dolgui (2022) proponen analizar las cadenas mediante pruebas de estrés que permitan estudiar su comportamiento frente a perturbaciones y sostienen que los gemelos digitales pueden contribuir a valorar anticipadamente la capacidad del sistema para resistir y recuperarse ante eventos disruptivos. Para Abdul-Hamid et al. (2023) destacan que la incertidumbre puede surgir tanto del abastecimiento como de la demanda y del entorno, por lo que las organizaciones han recurrido a estrategias basadas en agilidad, enfoques *lean* y resiliencia para conservar la continuidad de sus operaciones. Han y Um (2024) muestran que los riesgos económicos, ambientales y sociales aumentan la incertidumbre de las cadenas globales y sostienen que la capacidad de resiliencia debe complementarse con estrategias específicas de mitigación, tales como aceptar, evitar, controlar o transferir determinados riesgos.

MATERIALES Y MÉTODOS

Según Jayarathna et al. (2021), los problemas logísticos multiobjetivo requirieron procedimientos cuantitativos capaces de evaluar simultáneamente criterios económicos, temporales y operativos, debido a que una mejora en un objetivo podía generar compromisos sobre los restantes. En correspondencia con este planteamiento, la investigación se desarrolló bajo un enfoque cuantitativo, de tipo aplicado y comparativo, mediante experimentación computacional, puesto que se evaluó el comportamiento de tres metaheurísticas sobre un mismo problema de asignación y ruteo: Algoritmo Genético basado en NSGA-II, Colonia Artificial de Abejas y Colonia de Hormigas. El diseño fue no experimental, debido a que los registros originales no fueron manipulados ni recolectados mediante intervención directa, sino procesados mediante un modelo matemático y procedimientos computacionales de optimización. El trabajo base definió precisamente una metodología cuantitativa, comparativa y aplicada apoyada en análisis de datos, formulación matemática, implementación algorítmica y evaluación comparativa.

De acuerdo con Wang et al. (2022), la incorporación de datos procedentes de sistemas conectados permitió representar de manera más detallada las condiciones operativas de las cadenas logísticas y suministrar información útil para la toma de decisiones. En este estudio se empleó como fuente secundaria el Smart Logistics Supply Chain Dataset, disponible públicamente en Kaggle y atribuido a Ziya07 (2024). La base estuvo conformada por registros generados durante 2024 y contenía información

<https://doi.org/10.70577/s.e.v4i3.131>

correspondiente a 10 vehículos o camiones, identificados individualmente como activos logísticos. El archivo original comprendió 16 variables, entre ellas fecha y hora, identificador del activo, latitud, longitud, nivel de inventario, estado del envío, temperatura, humedad, condición del tráfico, tiempo de espera, transacciones, frecuencia de compra, motivo del retraso, utilización del activo, demanda pronosticada y retraso logístico.

De igual forma, la población operativa estuvo constituida por 1.000 registros de entrega, correspondientes a los eventos logísticos disponibles para los 10 camiones. Debido a que todo el subconjunto seleccionado fue utilizado en la construcción del escenario experimental, la muestra coincidió con la población analizada, $n = 1.000$ registros, por lo que se trabajó mediante un criterio censal dentro del escenario seleccionado. Cada registro representó una unidad primaria de análisis asociada a una combinación camión-fecha, mientras que los 10 vehículos se consideraron unidades secundarias para la evaluación agregada de eficiencia. Esta estructura se correspondió con la operacionalización establecida en el documento, donde el modelo trabajó con el mismo subconjunto de 1.000 entregas y con el número disponible de vehículos.

Por otra parte, conforme a Le y Fan (2024), el análisis de sistemas logísticos digitalizados dependió de la calidad, consistencia y estandarización de la información utilizada como entrada del modelo. Por esta razón, los datos fueron sometidos a depuración, búsqueda de duplicados, revisión de valores incompletos, codificación de variables categóricas y escalamiento de variables continuas. La variable *Logistics_Delay* fue transformada en formato binario, donde 0 representó una entrega normal y 1 una entrega retrasada. Posteriormente se seleccionaron como variables particularmente relevantes *Waiting_Time*, *Asset_Utilization*, *Demand_Forecast*, *Traffic_Status*, *Temperature*, *Humidity* y *Logistics_Delay*, junto con los demás atributos requeridos para construir las funciones objetivo y restricciones. Este proceso coincidió con el pretratamiento documentado en la investigación original. DEPOSITO TFM -040326-ARRIOLA MA...

Además, según Suryawanshi y Dutta (2022), los modelos logísticos bajo incertidumbre debieron incorporar indicadores capaces de representar no solo costos y tiempos, sino también riesgos derivados del contexto operacional. En consecuencia, antes de ejecutar las metaheurísticas se estimó la probabilidad individual de retraso mediante una regresión logística binaria. Como variables predictoras se utilizaron *Waiting_Time*, *Temperature*, *Humidity*, *Demand_Forecast* y *Asset_Utilization*, junto con las variables binarias *Traffic_Heavy* y *Traffic_Detour*, tomando *Traffic_Clear* como categoría de referencia. Las variables continuas se estandarizaron mediante *StandardScaler*, con media cero y desviación estándar igual a uno, mientras que las variables de tráfico permanecieron codificadas como 0 y 1.

De acuerdo con Hosmer et al. (2013), la regresión logística resultó apropiada cuando la variable dependiente presentó dos categorías y se buscó estimar probabilidades individuales a partir de predictores cuantitativos y categóricos. Bajo este criterio, el conjunto de datos se dividió mediante un esquema 80% para entrenamiento y 20% para prueba, con estratificación de la variable dependiente y semilla aleatoria igual a 42. El modelo fue ejecutado con un máximo de 1.000 iteraciones. Como métricas de desempeño predictivo se calcularon exactitud de entrenamiento, exactitud de prueba y área bajo la curva ROC. El modelo alcanzó una exactitud de 0,7562 en entrenamiento, 0,7700 en prueba y un ROC AUC de 0,7843; adicionalmente, la matriz de confusión del subconjunto de prueba presentó 86 casos sin retraso

<https://doi.org/10.70577/s.e.v4i3.131>

correctamente clasificados, 68 casos con retraso correctamente clasificados, 1 falso positivo y 45 falsos negativos.

Posteriormente, según Tadaros y Migdalas (2022), los problemas de ruteo con múltiples objetivos se caracterizaron por incorporar funciones simultáneas y restricciones de capacidad, servicio y operación. En correspondencia, el modelo matemático se estructuró mediante tres funciones objetivo: f_1 , minimización del tiempo total de operación; f_2 , minimización del costo total; y f_3 , minimización del riesgo agregado de retraso. La demanda de cada punto fue obtenida de *Demand_Forecast*; la capacidad de los vehículos se definió a partir de la demanda global y un factor de holgura; y el tiempo de servicio por entrega se fijó en 5 minutos. Las distancias entre puntos fueron calculadas mediante una matriz Haversine, utilizando latitud y longitud, y posteriormente se integraron tanto en el componente temporal como en el costo de desplazamiento.

La condición del tráfico fue incorporada mediante factores diferenciados para las categorías *Clear*, *Heavy* y *Detour*, modificando la velocidad efectiva y, por tanto, el tiempo estimado de desplazamiento. El riesgo agregado se construyó mediante la suma de las probabilidades individuales de retraso correspondientes a los pedidos asignados a cada ruta. El modelo incluyó restricciones asociadas con capacidad del vehículo, utilización mínima y máximo de entregas por camión. Estas restricciones no se trataron exclusivamente como condiciones rígidas, sino mediante una función de penalización, donde las violaciones de capacidad, máximo de entregas y utilización se sumaron al valor de cada objetivo mediante un factor de penalización positivo.

De manera complementaria, conforme a Petchrompo et al. (2022), en optimización multiobjetivo resultó necesario preservar un conjunto de soluciones no dominadas y emplear criterios auxiliares para seleccionar alternativas representativas. Por ello, los tres objetivos se optimizaron simultáneamente y adicionalmente se empleó la función agregada

$$f_{total} = f_1 + f_2 + f_3$$

como indicador auxiliar para comparar soluciones, sin sustituir el análisis multiobjetivo basado en Pareto. Para todos los algoritmos se mantuvo el mismo subconjunto de 1.000 entregas, la misma matriz de distancias, los mismos factores de tráfico y un máximo de 8 entregas por camión. También se fijaron los mismos parámetros económicos: costo de combustible de 0,1, costo de mantenimiento de 10 y penalización por retraso de 50.

En cuanto al primer método de optimización, conforme a Deb et al. (2002), NSGA-II utilizó clasificación no dominada y distancia de hacinamiento para aproximar simultáneamente soluciones eficientes preservando diversidad. En el presente estudio, el Algoritmo Genético se configuró con una población de 100 individuos, 250 generaciones, tasa de cruce de 0,90, tasa de mutación de 0,10 y selección por torneo de tamaño 2. En cada generación, las soluciones fueron evaluadas mediante la misma función de asignación y ruteo, organizadas en frentes de Pareto y sometidas al criterio de *crowding distance* para mantener diversidad.

En relación con el segundo método, de acuerdo con Karaboga y Basturk (2007), la Colonia Artificial de Abejas reprodujo mecanismos de búsqueda mediante abejas empleadas, observadoras y exploradoras, favoreciendo el equilibrio entre exploración y explotación. En esta investigación, ABC fue configurado

<https://doi.org/10.70577/s.e.v4i3.131>

con un número de soluciones comparable al empleado en el GA y con un horizonte máximo del orden de 1.000 iteraciones, manteniendo exactamente la misma representación de soluciones y las mismas tres funciones objetivo. Esta homogeneidad metodológica permitió que las diferencias observadas entre GA y ABC se atribuyeran al mecanismo de búsqueda y no a modificaciones en el problema evaluado.

Respecto al tercer método, según Dorigo y Stützle (2019), el ACO se sustentó en mecanismos probabilísticos guiados por feromonas y heurísticas locales para reforzar progresivamente las rutas de mayor calidad. Para el experimento, se utilizaron parámetros $\alpha = 1$ y $\beta = 1$, una tasa de evaporación de feromonas $\rho = 0,1$ y un parámetro de refuerzo $Q_{pher} = 1$. El máximo de entregas por camión permaneció fijado en 8. Cada hormiga construyó una alternativa de asignación y secuencia de visitas en función de la información de feromonas, la distancia y la carga residual, actualizándose posteriormente las feromonas con base en la aptitud de las soluciones obtenidas.

Conforme a Jayarathna et al. (2021), la comparación de técnicas multiobjetivo no debía limitarse a un único valor escalar, sino que debía considerar convergencia, diversidad y compromiso entre objetivos. Por ello, para cada algoritmo se distinguieron dos tipos de solución: una solución interna, obtenida directamente sobre las funciones expresadas en sus escalas originales, y una solución balanceada, determinada después de normalizar los objetivos para reducir el efecto de sus diferentes magnitudes. El desempeño comparativo se evaluó mediante tiempo total de operación, costo total, riesgo esperado, valor agregado (f_{total}) , generación o iteración óptima, porcentaje de mejora respecto a la configuración inicial y porcentaje de mejora frente al GA cuando correspondió. Para NSGA-II también se examinó el Frente de Pareto, que posteriormente produjo 17 soluciones no dominadas, mientras que para ABC y ACO se analizaron las curvas de convergencia y las soluciones finales internas y balanceadas.

RESULTADOS Y DISCUSIÓN

Según Cabrales et al. (2023), los problemas contemporáneos de localización y ruteo requieren evaluar simultáneamente criterios que pueden entrar en conflicto, situación en la cual las metaheurísticas multiobjetivo permiten identificar alternativas eficientes en lugar de reducir la decisión a un solo indicador. Bajo este enfoque, el Algoritmo Genético basado en NSGA-II produjo un Frente de Pareto integrado por 17 soluciones no dominadas, lo que confirmó la existencia de distintos compromisos entre tiempo, costo y riesgo. La solución interna alcanzó 8.439,11 horas, un costo de USD 19.862,64 y un riesgo de 33,72, frente a una asignación aleatoria de 13.022,65 horas, USD 29.795,32 y 39,72 eventos de riesgo. De esta forma, el objetivo agregado disminuyó de 42.857,69 a 28.335,47, equivalente a una mejora aproximada de 33,9 % frente al escenario aleatorio. Este comportamiento respaldó la capacidad del algoritmo genético para transformar una configuración inicial ineficiente en una solución logística considerablemente más favorable, aunque también mostró que el margen de mejora continuó siendo amplio frente a los algoritmos de inteligencia de enjambre.

De manera complementaria, Fernández Gil et al. (2022) identificaron que NSGA-II y otros algoritmos genéticos multiobjetivo han sido empleados ampliamente en problemas de ruteo verde y distribución precisamente por su capacidad para aproximar Frentes de Pareto cuando deben armonizarse objetivos como costos, emisiones, distancias o calidad del servicio. En el estudio, la solución interna del GA evolucionó hasta la generación 240, obteniendo 8.439,11 horas, USD 19.862,64 y 33,72 eventos esperados de riesgo; mientras que la solución balanceada alcanzó su mejor configuración en la generación

<https://doi.org/10.70577/s.e.v4i3.131>

249, con 8.562,39 horas, USD 20.665,37 y riesgo de 37,64. Estos resultados revelaron que la normalización produjo un equilibrio diferente entre objetivos, pero no necesariamente una mejora simultánea en todos ellos, aspecto característico de la optimización multiobjetivo, donde el beneficio alcanzado en un criterio puede acompañarse de una pérdida relativa en otro.

En relación con el algoritmo de Colonia Artificial de Abejas, Zarzycki y Skubisz (2022) demostraron que el comportamiento cooperativo utilizado por ABC puede adaptarse al problema de ruteo vehicular, aprovechando los mecanismos de exploración y explotación para encontrar soluciones competitivas en espacios combinatorios. En correspondencia con ese antecedente, el ABC mostró una reducción considerable desde su configuración inicial. Para la solución interna, el tiempo pasó de 11.618,08 a 5.460,28 horas, representando una reducción de 53,00%; el costo disminuyó de USD 26.986,29 a USD 13.801,63, equivalente a 48,86%, mientras que el riesgo se redujo de 36,86 a 35,78, correspondiente a 2,93%. El objetivo agregado pasó de 38.833,02 a 19.297,69, es decir, disminuyó aproximadamente 50,30%. En la solución balanceada, alcanzada en la iteración 600, se registraron 5.765,38 horas, USD 13.992,64 y riesgo de 34,84, representando mejoras de 50,38 %, 48,15% y 5,48%, respectivamente.

Este comportamiento permitió interpretar que ABC no solo redujo sustancialmente los componentes de tiempo y costo, sino que la solución balanceada consiguió disminuir el riesgo en mayor magnitud que su solución interna. En otras palabras, el proceso de normalización desplazó ligeramente la solución desde un perfil predominantemente económico-operativo hacia una alternativa con mayor equilibrio entre eficiencia y confiabilidad. Este hallazgo es consistente con lo señalado por Rajwar et al. (2023), quienes sostienen que el rendimiento de las metaheurísticas depende de la capacidad de mantener un equilibrio adecuado entre exploración global y explotación local, especialmente en problemas con espacios de búsqueda grandes y no lineales.

En cuanto al Algoritmo de Colonia de Hormigas, los resultados mostraron una convergencia más temprana y niveles inferiores de tiempo y costo. La solución interna alcanzó su mejor resultado en la iteración 317, reduciendo el tiempo de 6.340,43 a 4.111,36 horas, equivalente a 35,20%, mientras que el costo pasó de USD 15.200,87 a USD 10.465,11, correspondiente a una disminución de 31,20%. El riesgo presentó una modificación menor, de 36,33 a 36,18, equivalente a 0,40%, y el objetivo agregado disminuyó de 21.577,63 a 14.612,65, representando una mejora de 32,30%. La solución balanceada se alcanzó incluso antes, en la iteración 229, con 4.202,34 horas, USD 10.486,61 y riesgo de 34,94, por lo que las mejoras frente al estado inicial fueron 33,70%, 31,00% y 3,80%, respectivamente.

Al respecto, Pratiwi et al. (2023) sostienen que la combinación del Frente de Pareto con ACO permite abordar problemas de ruteo dependientes del tiempo sin reducir la decisión a un único objetivo, puesto que la información de feromonas puede conducir progresivamente hacia regiones más competitivas del espacio de soluciones. Igualmente, los resultados guardaron relación con la literatura revisada por Cbrales et al. (2023), quienes identificaron un empleo creciente de métodos metaheurísticos en problemas multiobjetivo de localización-ruteo debido a la dificultad de obtener soluciones exactas cuando aumentan las variables, restricciones y criterios. En el caso evaluado, la convergencia del ACO en la iteración 229 para la solución balanceada fue particularmente relevante porque requirió menos iteraciones que ABC, cuya solución balanceada se obtuvo en la iteración 600, aunque estos valores no deben interpretarse como tiempos computacionales equivalentes debido a que una iteración puede implicar

<https://doi.org/10.70577/s.e.v4i3.131>

diferentes cantidades de evaluaciones dependiendo del algoritmo.

A partir de los resultados individuales, se realizó la comparación conjunta de las mejores soluciones internas. Como se presenta en la Tabla 1, el ABC superó al GA en tiempo, costo y riesgo; mientras que ACO presentó la mayor disminución de tiempo y costo, aunque su solución interna aumentó el riesgo respecto al GA.

Tabla 1

Comparación de las soluciones internas óptimas

Indicador	GA (NSGA-II)	ABC	ACO	Mejora ABC vs. GA	Mejora ACO vs. GA
Iteración/generación óptima	240	1.080	317	—	—
Tiempo (horas)	8.439,11	5.831,24	4.111,36	30,90%	51,28%
Costo (USD)	19.862,64	13.932,67	10.465,11	29,85%	47,31%
Riesgo	33,72	32,71	36,18	3,00%	-7,30%
Objetivo agregado	28.335,47	19.796,62	14.612,65	30,13%	48,43%

Nota. Valores correspondientes a las soluciones internas seleccionadas para la comparación global; un porcentaje negativo en riesgo indica deterioro respecto al GA.

Como evidencia la Tabla 1, ACO redujo el tiempo en 51,28% y el costo en 47,31% respecto al GA; sin embargo, incrementó el riesgo aproximadamente 7,30%. Este resultado fue importante porque demostró que la alternativa con menor función agregada no necesariamente fue la más conservadora en todas las dimensiones. En contraste, ABC obtuvo reducciones más moderadas de 30,90% en tiempo y 29,85% en costo, pero también mejoró el riesgo en 3,00%. Por tanto, la solución interna del ABC mostró un comportamiento más homogéneo, mientras que la del ACO priorizó con mayor intensidad la eficiencia temporal y económica. Este tipo de intercambio coincide con Yan et al. (2023), quienes señalaron que los problemas multiobjetivo de localización-ruteo producen soluciones de compromiso y requieren analizar simultáneamente los criterios antes de seleccionar una configuración operativa.

La situación cambió al evaluar las soluciones balanceadas. Como se observa en la Tabla 2, tanto ABC como ACO mejoraron simultáneamente los tres objetivos con respecto al GA, lo cual permitió realizar una comparación más apropiada desde una perspectiva gerencial.

Tabla 2

Comparación de las soluciones balanceadas óptimas

Indicador	GA (NSGA-II)	ABC	ACO	Mejora ABC vs. GA	Mejora ACO vs. GA
Generación/iteración óptima	249	600	229	—	—
Tiempo (horas)	8.562,39	5.765,38	4.202,34	32,67%	50,92%


Costo (USD)	20.665,37	13.992,64	10.486,61	32,29%	49,26%
Riesgo	37,64	34,84	34,94	7,44%	7,17%
Objetivo agregado	29.265,40	19.792,86	14.723,88	32,3 %	49,69%

Nota. Las soluciones balanceadas fueron seleccionadas después de normalizar los objetivos, por lo que expresaron un compromiso más equilibrado entre tiempo, costo y riesgo.

Los datos de la Tabla 2 mostraron que ABC disminuyó el tiempo en 32,67%, el costo en 32,29% y el riesgo en 7,44% respecto al GA. ACO, por su parte, registró reducciones de 50,92% en tiempo, 49,26% en costo y 7,17% en riesgo. De esta manera, ABC consiguió una reducción ligeramente mayor en el componente de riesgo, mientras que ACO obtuvo reducciones considerablemente superiores en tiempo y costo. El objetivo agregado confirmó esta diferencia: 29.265,40 para GA, 19.792,86 para ABC y 14.723,88 para ACO. Para visualizar estas diferencias, la Figura 1 representa las mejoras porcentuales de ABC y ACO respecto al GA en las soluciones balanceadas.


Figura 1

Mejoras porcentuales de las soluciones balanceadas respecto al GA



Nota. Los porcentajes positivos representan reducciones de la función correspondiente respecto al GA.

Tal como se aprecia en la Figura 1, la ventaja de ACO se concentró principalmente en los componentes temporal y económico, donde las mejoras se aproximaron a 50%, mientras que ABC se situó alrededor de 32%. En el riesgo, en cambio, ambos algoritmos mostraron mejoras relativamente próximas: 7,44% para ABC y 7,17% para ACO. Este patrón permitió establecer que la diferencia entre ambas estrategias no radicó principalmente en la confiabilidad, sino en la capacidad para reducir tiempo y costo. Desde la perspectiva planteada por Fernández et al. (2022), este comportamiento es coherente con la naturaleza de los problemas de ruteo multiobjetivo, en los cuales una metaheurística puede dominar determinados criterios y aproximarse a otra en objetivos secundarios, razón por la cual las comparaciones no deberían basarse únicamente en un indicador. Además, el desempeño conjunto quedó reflejado en el valor del objetivo agregado. La Figura 2 presenta la reducción obtenida para las tres soluciones balanceadas.

Figura 2*Comparación del objetivo agregado en las soluciones balanceadas*

Nota. Un menor valor del objetivo agregado representó un mejor resultado conjunto de tiempo, costo y riesgo dentro de la formulación empleada.

Como muestra la Figura 2, el objetivo agregado se redujo de 29.265,40 en GA a 19.792,86 en ABC y 14.723,88 en ACO. Por consiguiente, ABC disminuyó aproximadamente 32,37% respecto al GA, mientras que ACO alcanzó una disminución de 49,69%. En términos comparativos directos, el objetivo agregado de ACO también fue aproximadamente 25,61% menor que el de ABC, lo que evidenció una distancia considerable entre ambas soluciones balanceadas. Sin embargo, esta diferencia debe interpretarse considerando la estructura matemática de la función agregada, puesto que las escalas absolutas de tiempo y costo son muy superiores a la escala del riesgo; por ello, la valoración del Frente de Pareto y de los objetivos normalizados continuó siendo necesaria para evitar que las variables de mayor magnitud dominaran la decisión.

Este resultado coincide conceptualmente con Pratiwi et al. (2023), quienes mostraron que el principio de Pareto permitió analizar rutas óptimas considerando múltiples objetivos y evitar que la elección dependiera únicamente de una función escalar. De manera similar, Yan et al. (2023) demostraron que las metaheurísticas híbridas resultan pertinentes en problemas multiobjetivo de localización-ruteo cuando se requiere obtener una colección de soluciones factibles con diferentes compromisos operativos, en vez de una única respuesta universalmente óptima.

También resultó relevante analizar la velocidad con la que se alcanzaron las soluciones seleccionadas. El GA necesitó 249 generaciones para su solución balanceada, ABC alcanzó su resultado en la iteración 600 y ACO lo hizo en la iteración 229. Aunque estos datos mostraron que ACO localizó su mejor solución balanceada en un número menor de iteraciones, no fue metodológicamente correcto concluir únicamente con este dato que poseyó menor tiempo computacional, porque el costo de una iteración no fue necesariamente equivalente entre los tres procedimientos. No obstante, dentro del experimento

<https://doi.org/10.70577/s.e.v4i3.131>

desarrollado sí evidenció una convergencia relativamente temprana hacia una solución competitiva. El documento original también destacó que ACO alcanzó su solución balanceada en la iteración 229, simultáneamente con reducciones de 50,92% en tiempo y 49,26% en costo respecto al GA.

En términos generales, los resultados permitieron distinguir tres comportamientos. El GA funcionó adecuadamente como referencia evolutiva, generando un Frente de Pareto de 17 soluciones y mejoras sustanciales respecto a una asignación aleatoria; el ABC presentó un perfil equilibrado, reduciendo tiempo, costo y riesgo sin deteriorar ninguno de los tres criterios en su solución balanceada; y el ACO obtuvo los menores valores absolutos de tiempo, costo y objetivo agregado, manteniendo además una reducción del riesgo en la solución balanceada. Este resultado es congruente con la literatura sobre inteligencia de enjambre, debido a que los mecanismos de feromonas favorecen el aprendizaje colectivo de rutas prometedoras y la explotación progresiva de conexiones recurrentemente eficientes, mientras que ABC mantiene una búsqueda distribuida que favorece la diversidad y evita concentrar prematuramente la exploración. Zarzycki et al. (2022) también destacaron diferencias de comportamiento entre algoritmos inspirados en la naturaleza para optimización de rutas, confirmando que el mecanismo de búsqueda puede determinar la calidad y estabilidad de las soluciones obtenidas.

Por tanto, la comparación respondió a la pregunta central del estudio al demostrar que los tres algoritmos fueron capaces de mejorar la configuración logística, pero presentaron patrones distintos. No se trató de afirmar que un algoritmo sea universalmente superior en todos los problemas, sino de establecer que, bajo los 1.000 registros, los 10 camiones, las restricciones y la formulación empleadas en este caso de estudio, ACO produjo la mayor reducción conjunta en tiempo y costo; ABC presentó un comportamiento especialmente competitivo cuando se consideró el riesgo; y GA constituyó una línea base sólida para demostrar el beneficio de la optimización frente a la asignación aleatoria. Esta interpretación resulta coherente con Rajwar et al. (2023), quienes subrayan que no existe una metaheurística universalmente dominante y que su rendimiento depende de la naturaleza del problema, la representación, los parámetros y el equilibrio entre exploración y explotación.

CONCLUSIONES

El análisis comparativo evidenció que los tres algoritmos fueron capaces de mejorar la configuración logística respecto a los escenarios iniciales y aleatorios; sin embargo, mostraron comportamientos diferenciados. El Algoritmo Genético basado en NSGA-II funcionó como una referencia sólida al generar un Frente de Pareto con 17 soluciones no dominadas y reducir el objetivo agregado desde 42.857,69 hasta 28.335,47 en su solución interna, lo que confirmó la utilidad de los enfoques evolutivos para resolver problemas logísticos con múltiples criterios.

La Colonia Artificial de Abejas presentó un comportamiento equilibrado entre eficiencia y confiabilidad. En su solución balanceada alcanzó 5.765,38 horas, un costo de USD 13.992,64 y un riesgo de 34,84, lo que representó mejoras de 32,67% en tiempo, 32,29% en costo y 7,44% en riesgo frente al GA balanceado. Estos resultados mostraron que ABC constituyó una alternativa competitiva cuando se buscó reducir simultáneamente los tres objetivos sin concentrar la optimización únicamente en tiempo y costo.

El Algoritmo de Colonia de Hormigas alcanzó el mejor desempeño global dentro del escenario evaluado. Su solución balanceada obtuvo 4.202,34 horas, USD 10.486,61 de costo y un riesgo de 34,94, reduciendo

<https://doi.org/10.70577/s.e.v4i3.131>

frente al GA balanceado el tiempo en 50,92%, el costo en 49,26% y el riesgo en 7,17%, mientras que el objetivo agregado disminuyó en 49,69%. En consecuencia, para los 1.000 registros y 10 vehículos analizados, ACO mostró la mayor capacidad para encontrar soluciones logísticas eficientes, aunque estos resultados deben interpretarse dentro de las condiciones y parámetros específicos del experimento.

REFERENCIAS BIBLIOGRÁFICAS

- Abdul-Hamid, A.-Q., Osman, L. H., Che Omar, A. R., Che Abdul Rahman, M. R., & Ali, M. H. (2023). What have we learned? A bibliometric review of a three-decade investigation into the supply chain uncertainty and a revised framework to cope with the challenges. *Sustainability*, 15(22), 15911. <https://doi.org/10.3390/su152215911>
- Bhandal, R., Meriton, R., Kavanagh, R. E., & Brown, A. (2022). The application of digital twin technology in operations and supply chain management: A bibliometric review. *Supply Chain Management: An International Journal*, 27(2), 182–206. <https://doi.org/10.1108/SCM-01-2021-0053>
- Cabralles-Navarro, P. A., Arias-Osorio, J. E., & Camacho-Pinto, J. C. (2023). El problema de localización y ruteo con múltiples objetivos: Una revisión de literatura. *Ingeniería*, 28(2), e18734. <https://doi.org/10.14483/23448393.18734> Revistas Universidad Distrital
- Chejarla, K. C., Vaidya, O. S., & Kumar, S. (2022). MCDM applications in logistics performance evaluation: A literature review. *Journal of Multi-Criteria Decision Analysis*, 29(3–4), 274–297. <https://doi.org/10.1002/mcda.1774>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182–197. <https://doi.org/10.1109/4235.996017>
- Djebbar, A. M., & Boudia, C. (2022). A comparison of Artificial Bee Colony algorithm and the Genetic Algorithm with the purpose of minimizing the total distance for the Vehicle Routing Problem. *Romanian Journal of Information Technology and Automatic Control*, 32(3), 51–64. <https://doi.org/10.33436/v32i3y202204>
- Dorigo, M., & Stützle, T. (2018). Ant colony optimization: Overview and recent advances. En M. Gendreau & J.-Y. Potvin (Eds.), *Handbook of metaheuristics* (3rd ed., pp. 311–351). Springer. https://doi.org/10.1007/978-3-319-91086-4_10
- Fernández Gil, A., Lalla-Ruiz, E., Gómez Sánchez, M., & Castro, C. (2022). A review of heuristics and hybrid methods for green vehicle routing problems considering emissions. *Journal of Advanced Transportation*, 2022, 5714991. <https://doi.org/10.1155/2022/5714991> Wiley Online Library
- Gu, Z., Zhu, Y., Wang, Y., Du, X., Guizani, M., & Tian, Z. (2022). Applying artificial bee colony algorithm to the multidepot vehicle routing problem. *Software: Practice and Experience*, 52(3), 756–771. <https://doi.org/10.1002/spe.2838>
- Han, N., & Um, J. (2024). Risk management strategy for supply chain sustainability and resilience capability. *Risk Management*, 26, Article 6. <https://doi.org/10.1057/s41283-023-00138-w>
- Hosmer, D. W., Jr., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (3rd ed.). John

<https://doi.org/10.70577/s.e.v4i3.131>

Wiley & Sons. <https://doi.org/10.1002/9781118548387>

- Ivanov, D., & Dolgui, A. (2022). Stress testing supply chains and creating viable ecosystems. *Operations Management Research*, 15, 475–486. <https://doi.org/10.1007/s12063-021-00194-z>
- Jayarathna, C. P., Agdas, D., Dawes, L., & Yigitcanlar, T. (2021). Multi-objective optimization for sustainable supply chain and logistics: A review. *Sustainability*, 13(24), 13617. <https://doi.org/10.3390/su132413617>
- Karaboga, D., & Basturk, B. (2007). A powerful and efficient algorithm for numerical function optimization: Artificial bee colony algorithm. *Journal of Global Optimization*, 39(3), 459–471. <https://doi.org/10.1007/s10898-007-9149-x>
- 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>
- Lai, L., Fiaschi, L., Cococcioni, M., & Deb, K. (2023). Pure and mixed lexicographic-paretian many-objective optimization: State of the art. *Natural Computing*, 22, 227–242. <https://doi.org/10.1007/s11047-022-09911-4>
- Le, T. V., & Fan, R. (2024). Digital twins for logistics and supply chain systems: Literature review, conceptual framework, research potential, and practical challenges. *Computers & Industrial Engineering*, 187, 109768. <https://doi.org/10.1016/j.cie.2023.109768>
- Moshood, T. D., Nawanir, G., Sorooshian, S., & Okfalisa. (2021). Digital twins driven supply chain visibility within logistics: A new paradigm for future logistics. *Applied System Innovation*, 4(2), 29. <https://doi.org/10.3390/asi4020029>
- Petchrompo, S., Coit, D. W., Brintrup, A., Wannakrairot, A., & Parlikad, A. K. (2022). A review of Pareto pruning methods for multi-objective optimization. *Computers & Industrial Engineering*, 167, 108022. <https://doi.org/10.1016/j.cie.2022.108022>
- Pratiwi, A., Nasution, M. K. M., & Herawati, E. (2023). Pareto frontier approach to determining the optimal path on multi-objectives. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 7(3), 1379–1388. <https://doi.org/10.33395/sinkron.v8i3.12465> Jurnal Politeknik Ganesha Medan
- Rajwar, K., Deep, K., & Das, S. (2023). An exhaustive review of the metaheuristic algorithms for search and optimization: Taxonomy, applications, and open challenges. *Artificial Intelligence Review*, 56, 13187–13257. <https://doi.org/10.1007/s10462-023-10470-y> doi.org
- Su, Y., Liu, J., Xiang, X., & Zhang, X. (2021). A responsive ant colony optimization for large-scale dynamic vehicle routing problems via pheromone diversity enhancement. *Complex & Intelligent Systems*, 7, 2543–2558. <https://doi.org/10.1007/s40747-021-00433-7>
- Suryawanshi, P., & Dutta, P. (2022). Optimization models for supply chains under risk, uncertainty, and resilience: A state-of-the-art review and future research directions. *Transportation Research Part E: Logistics and Transportation Review*, 157, 102553. <https://doi.org/10.1016/j.tre.2021.102553>
- Tadaros, M., & Migdalas, A. (2022). Bi- and multi-objective location routing problems: Classification and literature review. *Operational Research*, 22, 4641–4683. <https://doi.org/10.1007/s12351->

<https://doi.org/10.70577/s.e.v4i3.131>
022-00734-w

- Thammano, A., & Rungwachira, P. (2021). Hybrid modified ant system with sweep algorithm and path relinking for the capacitated vehicle routing problem. *Heliyon*, 7(9), e08029. <https://doi.org/10.1016/j.heliyon.2021.e08029>
- Vali-Siar, M. M., & Roghanian, E. (2022). Sustainable, resilient and responsive mixed supply chain network design under hybrid uncertainty with considering COVID-19 pandemic disruption. *Sustainable Production and Consumption*, 30, 278–300. <https://doi.org/10.1016/j.spc.2021.12.003>
- Wang, L., Deng, T., Shen, Z.-J. M., Hu, H., & Qi, Y. (2022). Digital twin-driven smart supply chain. *Frontiers of Engineering Management*, 9, 56–70. <https://doi.org/10.1007/s42524-021-0186-9>
- Yan, T., Lu, F., Wang, S., Wang, L., & Bi, H. (2023). A hybrid metaheuristic algorithm for the multi-objective location-routing problem in the early post-disaster stage. *Journal of Industrial and Management Optimization*, 19(6), 4663–4691. <https://doi.org/10.3934/jimo.2022145> AIMS Sciences
- Zarzycki, H., & Skubisz, O. (2022). A new artificial bee colony algorithm approach for the vehicle routing problem. En C. Kahraman, S. Cebi, S. Cevik Onar, B. Oztaysi, A. C. Tolga, & I. U. Sari (Eds.), *Intelligent and fuzzy techniques for emerging conditions and digital transformation* (pp. 562–569). Springer. https://doi.org/10.1007/978-3-030-85626-7_66 Akademia Zamojska
- Zhu, Y., Cheng, J., Liu, Z., Cheng, Q., Zou, X., Xu, H., Wang, Y., & Tao, F. (2023). Production logistics digital twins: Research profiling, application, challenges and opportunities. *Robotics and Computer-Integrated Manufacturing*, 84, 102592. <https://doi.org/10.1016/j.rcim.2023.102592>
- Ziya07. (2024). *Smart Logistics Supply Chain Dataset* [Data set]. Kaggle. <https://www.kaggle.com/datasets/ziya07/smart-logistics-supply-chain-dataset>