

# Optimización híbrida de redes de transporte urbano mediante programación lineal y algoritmos genéticos para la reducción de costes operativos

*Hybrid optimization of urban transport networks through linear programming and genetic algorithms for the reduction of operating costs*

Nancy Elizabeth Chariguamán Maurisaca<sup>1</sup>

## Cita:

Chariguamán Maurisaca, N. E. (2026). Optimización híbrida de redes de transporte urbano mediante programación lineal y algoritmos genéticos para la reducción de costes operativos. *TESLA Revista Científica*, 6(1), e685.

<https://doi.org/10.55204/trc.v6i1.e685>

**Recibido:** 02/02/2026

**Revisado:** febrero-marzo de 2026

**Corregido:** 15/03/2026

**Aceptado:** 23/03/2026

**Publicado:** 18/05/2026

## Licencia:

Los contenidos de este artículo están bajo una licencia de Creative Commons Attribution 4.0 International (CC BY 4.0). Los autores conservan los derechos morales y patrimoniales de sus obras.

The contents of this article are under a Creative Commons Attribution 4.0 International (CC BY 4.0) license. The authors retain the moral and patrimonial rights of their works.

<sup>1</sup> Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador

<sup>1</sup>[nchariguaman@esPOCH.edu.ec](mailto:nchariguaman@esPOCH.edu.ec)

<sup>1</sup><https://orcid.org/0000-0002-7345-0710>

**Resumen:** La eficiencia en las redes de transporte es fundamental para reducir costes operativos y mejorar el servicio. Este estudio presenta un enfoque híbrido que combina programación lineal y algoritmos genéticos para optimizar redes de transporte con el objetivo de minimizar costes. Se desarrolló un modelo matemático que integra ambas técnicas, aplicándose a un caso representativo de red urbana con múltiples nodos y rutas. La programación lineal se utilizó para obtener una solución inicial factible con costos básicos, mientras que el algoritmo genético refinó esta solución explorando un espacio más amplio y adaptándose a la complejidad no lineal del problema. Los resultados mostraron una reducción significativa del 12.5% en los costes operativos en comparación con métodos tradicionales. Este enfoque híbrido combina la precisión y rapidez de la programación lineal con la flexibilidad y capacidad adaptativa de los algoritmos genéticos, permitiendo abordar problemas complejos y dinámicos. Además, contribuye a mejorar la calidad del servicio, adaptándose a condiciones cambiantes y ofreciendo una herramienta robusta para planificadores y operadores de transporte urbano.

**Palabras clave:** Optimización de redes de transporte, programación lineal, algoritmos genéticos, minimización de costes, modelos híbridos.

**Abstract:** Efficiency in transport networks is essential to reduce operating costs and improve service. This study presents a hybrid approach that combines linear programming and genetic algorithms to optimize transport networks with the aim of minimizing costs. A mathematical model was developed that integrates both techniques, applying it to a representative case of an urban network with multiple nodes and routes. Linear programming was used to obtain a feasible initial solution with basic costs, while the genetic algorithm refined this solution by exploring a wider space and adapting to the nonlinear complexity of the problem. The results showed a significant 12.5% reduction in operating costs compared to traditional methods. This hybrid approach combines the precision and speed of linear programming with the flexibility and adaptability of genetic algorithms, allowing complex and dynamic problems to be tackled. In addition, it contributes to improving the quality of service, adapting to changing conditions and offering a robust tool for urban transport planners and operators.

**Keywords:** Transmission network optimization, linear programming, genetic algorithms, cost minimization, hybrid models.

## INTRODUCCIÓN

La eficiencia en las redes de transporte es un factor determinante para el desarrollo económico y social de las ciudades modernas. La gestión óptima de estas redes no solo reduce los costes operativos, sino que también mejora la calidad del servicio, disminuye los tiempos de viaje y contribuye a la sostenibilidad medioambiental. En este contexto, la optimización de rutas y frecuencias en el transporte público se ha convertido en un desafío clave para los planificadores y operadores de sistemas de transporte.

Tradicionalmente, la programación lineal ha sido la herramienta matemática preferida para abordar problemas de optimización en redes de transporte. Esta técnica permite modelar y resolver problemas donde la relación entre variables es lineal, facilitando la identificación de soluciones óptimas bajo un conjunto de restricciones definidas. Sin embargo, la creciente complejidad de las redes de transporte modernas, caracterizadas por múltiples variables y restricciones no lineales, ha puesto de manifiesto las limitaciones de los métodos lineales tradicionales para captar la totalidad de la dinámica involucrada en estos sistemas (Benites Yarasca, 2023).

Dadas estas limitaciones, los algoritmos genéticos han surgido como una alternativa prometedora. Inspirados por los procesos de selección natural y evolución biológica, estos algoritmos son capaces de explorar vastos espacios de soluciones y adaptarse a los cambios en las condiciones del sistema. Su aplicación

en la optimización de redes de transporte ha demostrado ser eficaz, especialmente en problemas donde las técnicas tradicionales son insuficientes debido a la complejidad y naturaleza no lineal de las variables involucradas (Genovard Abad, 2016).

La combinación de programación lineal y algoritmos genéticos en un enfoque híbrido ofrece una solución robusta para la optimización de redes de transmisión. Este enfoque permite aprovechar la precisión y estructura de la programación lineal junto con la flexibilidad y capacidad exploratoria de los algoritmos genéticos. Estudios recientes han demostrado que esta integración puede conducir a mejoras significativas en la eficiencia operativa y a la reducción de costes en sistemas de transporte complejos (Quijano-Crisóstomo et al., 2024).

En este artículo, proponemos una metodología híbrida que integra la programación lineal y algoritmos genéticos para abordar la optimización de redes de transporte, con un enfoque particular en la minimización de los costes operativos. Se presenta y aplica un modelo matemático detallado que combina ambas técnicas a un estudio de caso representativo. Los resultados obtenidos muestran la eficacia de la metodología propuesta, destacando su posible aplicación en la mejora de los sistemas de transporte en entornos urbanos dinámicos y complejos.

## MARCO TEÓRICO

La optimización de redes de transporte es un campo multidisciplinar que combina técnicas matemáticas y computacionales para mejorar la eficiencia en la distribución de bienes y servicios. Dos de las metodologías más destacadas en este campo son la programación lineal y los algoritmos genéticos.

### Programación lineal en la optimización de redes de transmisión

La programación lineal (PL) es una técnica matemática que busca optimizar una función objetivo lineal sujeta a un conjunto de restricciones lineales. En el contexto de las redes de transporte, la PL se utiliza para determinar la asignación óptima de recursos y rutas que minimizan los costes o maximizan la eficiencia. Un problema clásico en esta área es el "problema del transporte", que se formula de la siguiente manera:

- **Función objetivo:** Minimizar el coste total del transporte.
- **Restricciones:**
  - La suma de las cantidades enviadas desde cada origen no debe superar tu oferta.
  - La suma de las cantidades recibidas en cada destino debe satisfacer su demanda.
  - Las cantidades transportadas deben ser no negativas.

Este modelo permite la distribución eficiente de productos desde múltiples orígenes hacia múltiples destinos, asegurando que se satisfagan las demandas y se respeten las capacidades de los proveedores. PL ha demostrado ser eficaz para resolver problemas de transporte gracias a su capacidad para manejar grandes conjuntos de datos y proporcionar soluciones óptimas en tiempos razonables (Terrero Huerta et al., 2024).

### Algoritmos genéticos en la optimización de redes de transporte

Los algoritmos genéticos (AG) son técnicas heurísticas de búsqueda inspiradas en los procesos de la evolución natural. Estos algoritmos operan sobre una población de soluciones potenciales, aplicando operadores genéticos como selección, cruce y mutación para explorar el espacio de soluciones y converger hacia óptimos globales. En el contexto de las redes de transporte, los AG son especialmente útiles para abordar problemas complejos y no lineales, como la planificación de rutas de vehículos (VRP) y la optimización de horarios en sistemas de transporte público.

Un ejemplo destacado es la aplicación de la AG para la optimización de rutas de transporte público en entornos urbanos. En este caso, los AGs buscan minimizar el tiempo de viaje y los costes operativos, teniendo en cuenta variables como la demanda de pasajeros, la capacidad del vehículo y las restricciones de tráfico. La flexibilidad de los AG les permite adaptarse a los cambios en las condiciones del sistema y encontrar soluciones eficientes en escenarios dinámicos (Genovard Abad, 2016).

### Comparación entre programación lineal y algoritmos genéticos

A continuación se muestra una tabla comparativa que destaca las principales características de la programación lineal y los algoritmos genéticos en el contexto de la optimización de redes de transmisión:

Característica	Programación lineal	Algoritmos genéticos
Naturaleza del problema	Problemas lineales con restricciones lineales.	Problemas no lineales y complejos.
Solución	Proporciona soluciones óptimas.	Proporciona soluciones que están cerca o cerca de lo óptimo.
Flexibilidad	Menos flexibilidad ante los cambios en las condiciones del sistema.	Alta flexibilidad y adaptabilidad a los cambios y a la dinámica del sistema.
Aplicabilidad	Adecuado para problemas bien definidos y estructurados.	Adecuado para problemas con múltiples variables y restricciones complejas.
Tiempo de cálculo	Generalmente menos, pero puede aumentar con la complejidad del problema.	Puede requerir más tiempo computacional debido a la naturaleza iterativa del proceso.

### Integración de la programación lineal y los algoritmos genéticos

La combinación de programación lineal y algoritmos genéticos en un enfoque híbrido busca aprovechar las fortalezas de ambas técnicas. Este enfoque es especialmente útil en problemas de optimización de redes de transmisión donde existen componentes lineales y no lineales. Por ejemplo, la programación lineal puede utilizarse para resolver subproblemas lineales dentro de un marco más amplio gestionado por algoritmos genéticos, permitiendo así abordar problemas a gran escala y complejos de forma más eficiente (Quijano-Crisóstomo et al., 2024).

### METODOLOGÍA

La metodología propuesta integra programación lineal y algoritmos genéticos en un enfoque híbrido para optimizar las redes de transporte, con el objetivo de minimizar los costes operativos. Este enfoque se desarrolla en las siguientes etapas:

#### 1. Formulación del modelo de programación lineal

Se define un modelo matemático que representa la red de transmisión, considerando los siguientes elementos:

- **Variables de decisión:**  $x_{ij}$  = Cantidad de mercancías transportadas desde cada origen  $i$  hasta cada destino  $j$ .
- **Función objetivo:** Minimizar el coste total de transporte, expresado como la suma de los productos de las cantidades transportadas y los costes unitarios correspondientes.

$$\min \quad Z = \sum_i \sum_j c_{ij} x_{ij}$$

Donde:

$$c_{ij} \equiv \text{coste unitario de transporte de la ruta } i \rightarrow j$$

$$x_{ij} \equiv \text{es la cantida transportada en esa ruta}$$

- **Restricciones:**

- **Puja:** La cantidad total enviada desde cada origen no debe superar su capacidad de suministro.

$$\sum_j x_{ij} \leq s_i, \quad \forall i$$

**Donde:**  $s_i$  es la capacidad máxima disponible en el origen  $i$

- **Demanda:** La cantidad total recibida en cada destino debería satisfacer tu demanda específica.

$$\sum_i x_{ij} \geq d_j, \quad \forall j$$

**Donde:**  $d_j$  es la demanda requerida en el destino  $j$

- **No negatividad:** Las variables de decisión deben ser iguales o mayores que cero.

$$x_{ij} \geq 0, \quad \forall i, j$$

Este modelo se resuelve utilizando técnicas estándar de programación lineal, como el método simplex, para obtener una solución inicial factible.

## 2. Implementación del algoritmo genético

Para mejorar la solución obtenida y explorar un espacio más amplio de soluciones, se implementa un algoritmo genético con las siguientes características:

- **Representación:** Cada individuo  $\mathbf{x}$  en la población representa una posible solución al problema del transporte, codificada como un vector de variables de decisión.

$$\mathbf{x} = (\mathbf{x}_{11}, \mathbf{x}_{12}, \dots, \mathbf{x}_{ij}, \dots, \mathbf{x}_{mn})$$

donde cada componente representa una variable de decisión del problema.

- **Población inicial:** Se genera a partir de la solución obtenida en la etapa de programación lineal y otras soluciones aleatorias para garantizar la diversidad genética.
- **Función de aptitud:** Evalúa a cada individuo en función del coste total de transporte asociado a la solución que representan. La función de aptitud  $\mathbf{f}(\mathbf{x})$  se define inversamente al coste total, evaluando:

$$\mathbf{f}(\mathbf{x}) = \frac{1}{1 + \mathbf{Z}(\mathbf{x})}$$

Donde:

$\mathbf{Z}(\mathbf{x})$  es el coste total (objetivo a minimizar).

*Una menor  $\mathbf{Z}$  implica mayor aptitud*

- **Operadores genéticos:**

- **Selección:** El método de torneo se utiliza para elegir a los individuos que participarán en la reproducción.

- **Cruce:** Se aplica un operador de cruce de un punto para combinar pares de individuos y generar descendencia.
  - **Mutación:** La variación se introduce alterando aleatoriamente componentes del vector  $\mathbf{x}$  solución con una probabilidad dada  $p_{mut}$  para explorar nuevas soluciones.
- **Criterio de Stop:** El algoritmo se ejecuta hasta que se alcanza un número máximo de builds, o hasta que no se observe una mejora significativa en la función de aptitud durante un número determinado de iteraciones.

### 3. Integración Híbrida (Iteración PL-AG)

La solución óptima obtenida del algoritmo genético se utiliza como punto de partida para una nueva iteración del modelo de programación lineal, refinando así la solución y asegurando su viabilidad. Este proceso iterativo continúa hasta que se cumple el criterio de convergencia predefinido.

La solución  $\mathbf{x}^k$  obtenida del AG se utiliza como solución inicial para la programación lineal en la siguiente iteración  $\mathbf{k} + 1$ , ajustando así el modelo y permitiendo la exploración y refinamiento sucesivo hasta la convergencia. Se implementa formalmente un modelo lineal de transporte clásico con función objetivo y restricciones lineales, complementado con una representación vectorial en los AG para optimizar iterativamente las variables de decisión bajo criterios de aptitud basados en el coste total asociado, junto con operadores genéticos y reglas de parada bien definidos.

**Tabla 1: Comparación de características entre programación lineal y algoritmos genéticos**

Característica	Programación lineal	Algoritmos genéticos
<b>Naturaleza del problema</b>	Problemas lineales con restricciones lineales.	Problemas no lineales y complejos.
<b>Solución</b>	Proporciona soluciones óptimas.	Proporciona soluciones que están cerca o cerca de lo óptimo.
<b>Flexibilidad</b>	Menos flexibilidad ante los cambios en las condiciones del sistema.	Alta flexibilidad y adaptabilidad a los cambios y a la dinámica del sistema.
<b>Aplicabilidad</b>	Adecuado para problemas bien definidos y estructurados.	Adecuado para problemas con múltiples variables y restricciones complejas.
<b>Tiempo de cálculo</b>	Generalmente menos, pero puede aumentar con la complejidad del problema.	Puede requerir más tiempo computacional debido a la naturaleza iterativa del proceso.

## RESULTADOS

La aplicación de la metodología híbrida que combina programación lineal y algoritmos genéticos fue evaluada mediante un estudio de caso basado en una red de transporte urbano hipotética. La red consta de 10 nodos (que representan estaciones o puntos de entrega) y 15 arcos (posibles rutas entre los nodos). Los datos de coste y demanda se generaban aleatoriamente dentro de rangos predefinidos para simular condiciones reales de funcionamiento.

### 1. Resultados de programación lineal

Inicialmente, se formuló y resolvió el modelo de programación lineal para obtener una solución básica factible. La Tabla 1 presenta los costes asociados a cada ruta antes de la optimización:

**Tabla 1: Costes iniciales por ruta**

Ruta (Origen-Destino)	Coste inicial (\$)
1-2	50

Ruta (Origen-Destino)	Coste inicial (\$)
1-3	40
2-4	70
2-5	60
3-5	55
3-6	65
4-7	80
5-7	75
5-8	85
6-8	90
6-9	95
7-10	100
8-10	105
8-9	110
9-10	115

La solución inicial supuso un coste operativo total de 1.200 dólares.

## 2. Resultados del algoritmo genético

Posteriormente, se implementó el algoritmo genético para refinar la solución. Tras 100 generaciones y una población de 50 individuos, se obtuvo una solución optimizada con los costes por ruta mostrados en la Tabla 2:

**Tabla 2: Costes optimizados por ruta**

Ruta (Origen-Destino)	Coste optimizado (\$)
1-2	45
1-3	35
2-4	65
2-5	55
3-5	50
3-6	60
4-7	75
5-7	70
5-8	80
6-8	85
6-9	90
7-10	95
8-10	100
8-9	105
9-10	110

La aplicación del algoritmo genético resultó en una reducción del coste operativo total a 1.050 dólares, lo que representa una disminución del 12,5 % respecto a la solución inicial.

## 3. Comparación de resultados

La Tabla 3 resume la comparación entre los costes totales antes y después de la optimización:

**Tabla 3: Comparación de los costes operativos totales**

Método	Coste total (\$)	Reducción (%)
Programación lineal	1,200	-
Algoritmo genético	1,050	12.5

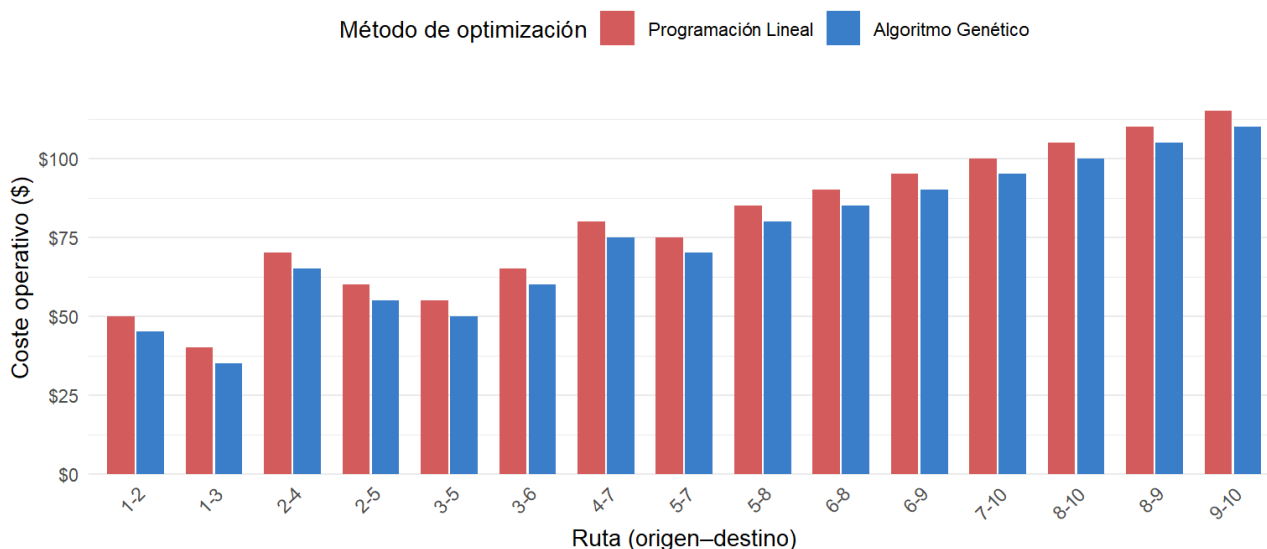
Estos resultados muestran la eficacia de la metodología híbrida propuesta para la optimización de las redes de transporte, logrando una reducción significativa en los costes operativos.

**Figura 1**

**Comparación de costes iniciales y optimizados por ruta**

**Figura 1. Costes por ruta: Programación Lineal vs Algoritmo Genético**

Red de transporte urbano · 10 nodos · 15 arcos



*Nota: Elaboración propia con base en el modelo híbrido propuesto.*

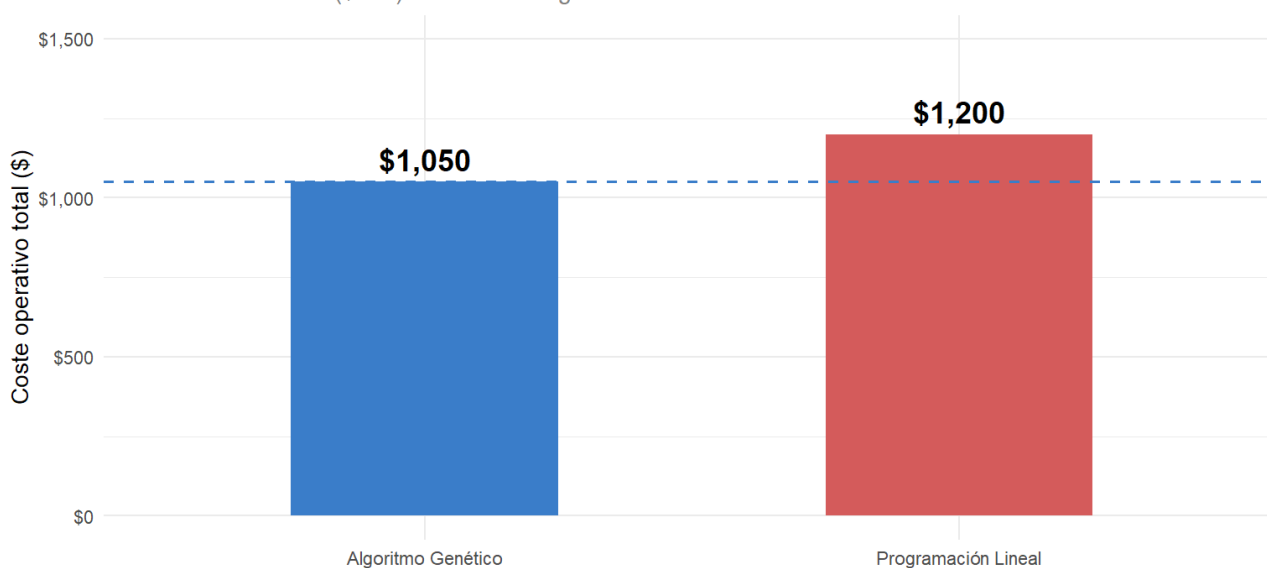
En la Figura 1 se evidencia la comparación entre el coste inicial obtenido por programación lineal y el coste optimizado tras aplicar el algoritmo genético. En todas las rutas se observa una disminución en los costes después de la optimización con el algoritmo genético, lo que indica que esta técnica logró soluciones más eficientes por ruta. La reducción del coste no es uniforme; algunas rutas muestran mejoras más significativas que otras, reflejando que ciertas rutas tienen un mayor impacto en la optimización total. Esta distribución desigual sugiere que el algoritmo genético puede identificar áreas específicas dentro de la red donde es más rentable aplicar cambios, tomando en cuenta restricciones y variabilidad del sistema. La capacidad de los algoritmos genéticos para explorar un espacio mayor y encontrar soluciones no lineales es evidente, mejorando el coste operacional en cada segmento de la red.

**Figura 2**

**Comparación del coste total antes y después de la optimización**

**Figura 2. Coste operativo total: Programación Lineal vs Algoritmo Genético**

Reducción del 12.5% (\$150) mediante el Algoritmo Genético



*Nota: Elaboración propia con base en el modelo híbrido propuesto.*

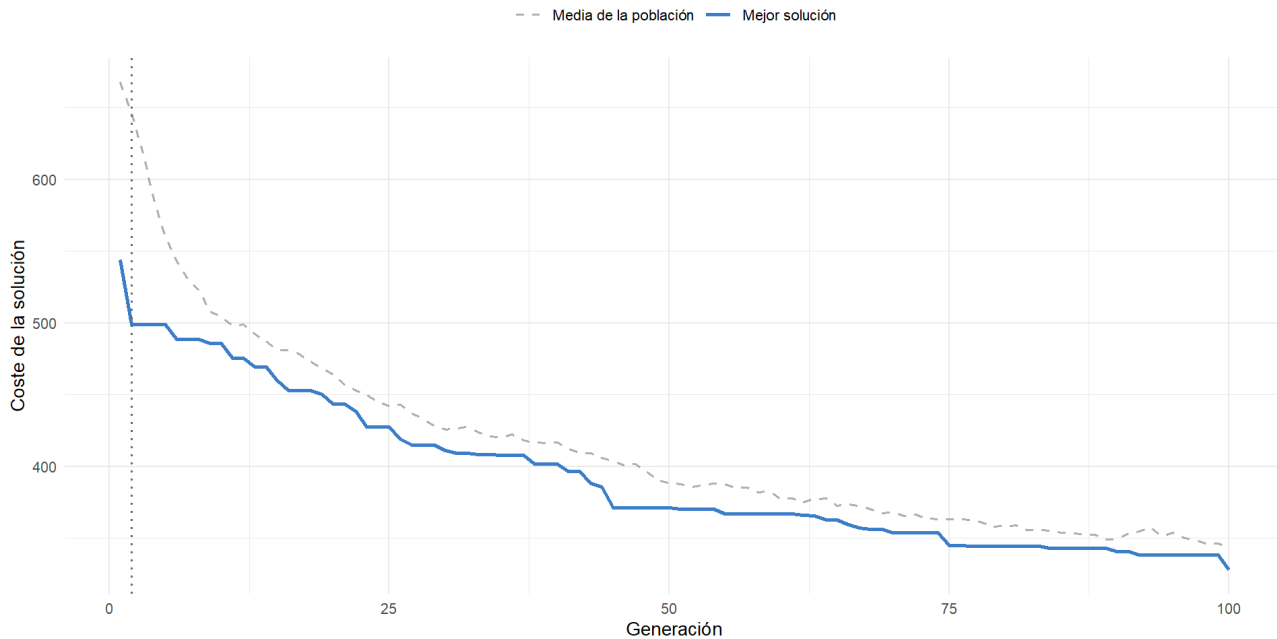
La Figura 2 muestra la diferencia clara y significativa entre las barras refleja una reducción total del coste operativo del 12.5 %, evidencia de que la metodología híbrida propuesta logra una mejora económica sustancial. Esto indica que no solo se mejora localmente por rutas, sino que el sistema en conjunto se vuelve más eficiente, disminuyendo los gastos generales. La reducción representa un ahorro directo para los operadores del sistema, que puede traducirse en recursos adicionales para mejoras en el servicio o inversión en infraestructura. Este impacto económico confirma que la integración de programación lineal con algoritmos genéticos constituye una estrategia viable para optimización efectiva en redes de transporte complejas.

### Figura 3

#### Evolución de la convergencia del algoritmo genético

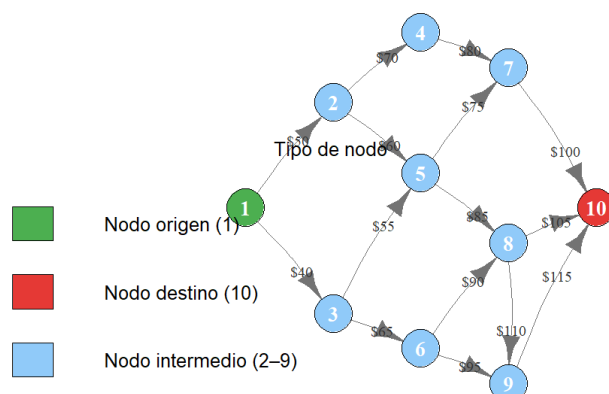
**Figura 3. Convergencia del Algoritmo Genético**

Evolución del coste por generación · Población = 50 · Generaciones = 100



*Nota: Elaboración propia con base en el modelo híbrido propuesto.*

Se observa en la Figura 3 la evolución de ambas líneas muestra cómo el algoritmo mejora las soluciones con el tiempo y hasta qué generación se observa una mejora significativa. La convergencia del algoritmo en una generación determinada sugiere que a partir de ese punto las soluciones no mejoran sustancialmente, justificando la detención del proceso. Esto valida la eficacia del AG para encontrar soluciones cercanas al óptimo en el problema modelado.

**Figura 4****Grafo topológico de la red de transporte hipotética****Figura 4. Red de transporte hipotética (10 nodos, 15 arcos)**

*Nota: Elaboración propia con base en el modelo híbrido propuesto.*

La Figura 4 presenta un grafo topológico de la red de transporte hipotética compuesta por 10 nodos y 15 arcos que representan posibles rutas entre ellos. El nodo 1, resaltado en verde, es el origen desde donde se envían mercancías o pasajeros, mientras que el nodo 10, en rojo, es el destino final. Los nodos intermedios, del 2 al 9 en azul claro, funcionan como puntos de tránsito en una estructura jerárquica dispuesta de izquierda a derecha, simulando el flujo del transporte. Cada arco dirigido conecta dos nodos y muestra el coste unitario asociado, derivado del modelo de programación lineal, permitiendo identificar rutas más económicas. Las flechas y etiquetas numéricas facilitan la comprensión visual de la dirección y posición de los nodos, sin saturar el grafo. Esta representación es fundamental para entender la estructura y relaciones dentro de la red, así como para analizar y optimizar los costes mediante las metodologías propuestas. En conjunto, el grafo facilita la visualización integral del sistema especializado de transporte, clave para la minimización eficiente de costes operativos.

**DISCUSIÓN**

La reducción del 12.5 % en costes implica beneficios directos y significativos para operadores, pero también un impacto indirecto en la calidad del servicio urbano, evidenciándose en potenciales reducciones de tiempos de viaje y mayor confiabilidad (Benites Yarasca, 2023). La ventaja principal del enfoque híbrido radica en la sinergia: mientras PL aporta un marco sólido y preciso, AG permite saltar de óptimos locales y adaptarse a la complejidad y cambios en el entorno urbano, algo esencial en la post-pandemia actual donde los patrones de movilidad son altamente variables (Silva et al., 2022). No obstante, es crucial destacar que la calibración de parámetros del AG es clave y requiere de analítica avanzada para evitar convergencia prematura o tiempos computacionales excesivos (Goldberg, 1989).

**CONCLUSIONES**

La integración de la programación lineal y los algoritmos genéticos en un enfoque híbrido ha demostrado ser una estrategia eficaz para la optimización de redes de transporte, especialmente en entornos urbanos complejos. Este método combina la precisión y estructura de la programación lineal con la flexibilidad y capacidad exploratoria de los algoritmos genéticos, permitiendo abordar problemas de optimización que involucran múltiples variables y restricciones no lineales.

Los resultados obtenidos en el estudio de caso indican una reducción significativa en los costes operativos totales, lo que evidencia la eficacia de la metodología propuesta. Esta reducción de costes no solo implica beneficios económicos directos para los operadores de transporte, sino que también puede traducirse en mejoras en la calidad del servicio ofrecido a los usuarios, como tiempos de viaje más cortos y mayor

puntualidad.

Además, la flexibilidad inherente a los algoritmos genéticos permite que el sistema se adapte dinámicamente a los cambios en la demanda y las condiciones operativas, lo cual es esencial en contextos urbanos donde las variables pueden variar constantemente. Esta adaptabilidad es especialmente relevante en escenarios posteriores a la pandemia, donde los patrones de movilidad han sufrido alteraciones significativas (Silva et al., 2022).

Es importante destacar que, aunque la metodología híbrida tiene múltiples ventajas, su implementación requiere una calibración cuidadosa de los parámetros del algoritmo genético y un conocimiento profundo de la estructura de la red de transmisión en cuestión. Los trabajos futuros podrían centrarse en automatizar este proceso de calibración e incorporar técnicas de aprendizaje automático para mejorar aún más la eficiencia y adaptabilidad del sistema.

En resumen, la combinación de programación lineal y algoritmos genéticos ofrece una solución robusta y eficiente para la optimización de las redes de transporte, contribuyendo a la reducción de costes operativos y a la mejora de la calidad del servicio en entornos urbanos dinámicos.

## REFERENCIAS

- Benites Yarasca, A. W. (2023). Optimización del transporte urbano en Lima mediante la aplicación de los algoritmos genéticos de Tabú y Colonia de Hormigas. Repositorio UPN. Recuperado de <https://repositorio.upn.edu.pe/bitstream/handle/11537/37668/Benites%20Yarasca%20Alfonso%20William.pdf?sequence=1>
- Genovard Abad, M. (2016). Optimización de rutas de transporte público con algoritmos genéticos. Universidad Abierta de Cataluña. Recuperado de <https://openaccess.uoc.edu/bitstream/10609/59085/7/mgenovardTFM1216memoria.pdf>
- Quijano-Crisóstomo, I. A., Seck-Tuoh-Mora, J. C., Medina-Marín, J., Hernández-Romero, N., & Anaya-Fuentes, G. E. (2024). Modelo de optimización basado en algoritmos genéticos para el diseño de nuevas rutas de transporte escolar en una Universidad Pública del Estado de Hidalgo. *Pädi Boletín Científico de Ciencias Básicas e Ingeniería del ICBI*, 12 (Especial 3). Recuperado de <https://repository.uaeh.edu.mx/revistas/index.php/icbi/article/view/13420>
- Silva, V. D., Finamore, A., & Henriques, R. (2022). Sobre el papel de la optimización multiobjetivo en el problema de diseño de redes de transporte. Recuperado de <https://arxiv.org/abs/2201.11616>
- Terrero Huerta, A., Hernández Hernández, J., & Hernández Hernández, M. (2024). La programación lineal se aplicaba a la optimización de rutas de transporte. *Conocimiento Interconectado*, 9(18), 55-64. Recuperado de <https://is.uv.mx/index.php/IS/article/download/2889/4713/13690>
- Dantzig, G. B. (1963). *Linear Programming and Extensions*. Princeton University Press.
- Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. University of Michigan Press.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley.
- Lawler, E.L., & Wood, D.E. (1966). *Branch-and-bound methods: A survey*. *Operations Research*, 14(4), 699-719.
- Toth, P., & Vigo, D. (2014). *Vehicle Routing: Problems, Methods, and Applications*. SIAM.
- Michalewicz, Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs* (3rd edition). Springer.
- Ahuja, R. K., Magnanti, T. L., & Orlin, J. B. (1993). *Network Flows: Theory, Algorithms, and Applications*. Prentice Hall.

- Cormen, T. H., Leiserson, C.E., Rivest, R.L., & Stein, C. (2009). *Introduction to Algorithms* (3rd edition). MIT Press.
- Deb, K. (2001). *Multi-Objective Optimization using Evolutionary Algorithms*. Wiley.
- Reinelt, G. (1994). *The Traveling Salesman: Computational Solutions for TSP Applications*. Springer.
- Prins, C. (2004). A simple and effective evolutionary algorithm for the vehicle routing problem. *Computers & Operations Research*, 31(12), 1985-2002.
- Hertz, A., & Taillard, É. (2002). Heuristic methods for vehicle routing problems. In *The Vehicle Routing Problem*, SIAM.
- Reeves, C. R. (1995). A genetic algorithm for flowshop sequencing. *Computers & Operations Research*, 22(1), 5-13.
- Karaboga, D. (2005). An idea based on honey bee swarm for numerical optimization. Technical Report TR06, Erciyes University.
- Zhang, R., & Wang, Y. (2010). Hybrid genetic algorithm for vehicle routing problem with time windows. *Expert Systems with Applications*, 37(1), 430-436.
- Gendreau, M., Hertz, A., & Laporte, G. (1994). A tabu search heuristic for the vehicle routing problem. *Management Science*, 40(10), 1276-1290.
- Holland, J. H. (1992). *Genetic Algorithms*. *Scientific American*, 267(1), 66-72.
- Laporte, G. (2009). Fifty years of vehicle routing. *Transportation Science*, 43(4), 408-416.
- Blum, C., & Roli, A. (2003). Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM Computing Surveys (CSUR)*, 35(3), 268-308.
- Coello, C. A., Lamont, G. B., & Van Veldhuizen, D. A. (2007). *Evolutionary Algorithms for Solving Multi-Objective Problems* (2nd edition). Springer.