

Route Optimization Using Genetic Algorithm for Visitors to Legends Park

Optimización de Rutas Empleando Algoritmo Genético para los Visitantes del Parque de las Leyendas

Hugo Vega-Huerta

hvegah@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos UNMSM, Lima, Perú

David Tupayachi Rivas

david.tupayachi@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos UNMSM, Lima, Perú

Jahir Hernandez Mayhuay

jahir.hernandez@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos UNMSM, Lima, Perú

Marcelo Damian Chapañan

marcelo.damian@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos UNMSM, Lima, Perú

María Puelles-Bulnes

mpuellesb@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos UNMSM, Lima, Perú

Rubén Gil-Calvo

rgilc@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos UNMSM, Lima, Perú

Javier Cabrera-Díaz

jcabrerad@unmsm.edu.pe

Universidad Nacional Mayor de San Marcos UNMSM, Lima, Perú

Gisella Luisa Elena Maquen-Niño

gmaquenn@unprg.edu.pe

Universidad Nacional Pedro Ruiz Gallo, Lambayeque-Perú

Abstract

This study presents a route optimization model based on genetic algorithms applied to Parque de las Leyendas, located in the district of San Miguel, in Lima, Peru. This space is the largest zoo in the country, with an approximate area of 130 hectares and 215 species of animals distributed in various thematic areas, which generates a complex environment for the efficient planning of routes. The proposed model simultaneously integrates three fundamental criteria: distance, time and rating of points of interest, approaching the problem from a multi-objective perspective. Unlike traditional approaches that optimize a single factor, the methodology developed allows the generation of balanced routes adapted to different visitor profiles and time constraints. The results obtained

through computational simulation show improvements in the efficiency of the route and in the strategic distribution of attractions visited. In this sense, the model constitutes a tool to support the management and planning of large-scale tourist spaces, with the potential for replicability in other regional destinations that have similar territorial and operational characteristics.

Keywords: Genetic algorithm, route optimization, Legends Park, Peru, traveling salesman problem, tourism management.

JEL Codes: C61; R11; Z32.

Resumen

Este estudio presenta un modelo de optimización de rutas basado en algoritmos genéticos aplicado al Parque de las Leyendas, ubicado en el distrito de San Miguel, en Lima, Perú. Este espacio constituye el zoológico más grande del país, con una extensión aproximada de 130 hectáreas y 215 especies de animales distribuidas en diversas zonas temáticas, lo que genera un entorno complejo para la planificación eficiente de recorridos. El modelo propuesto integra simultáneamente tres criterios fundamentales: distancia, tiempo y calificación de los puntos de interés, abordando el problema desde una perspectiva multiobjetivo. A diferencia de los enfoques tradicionales que optimizan un único factor, la metodología desarrollada permite generar rutas equilibradas adaptadas a distintos perfiles de visitante y restricciones temporales. Los resultados obtenidos mediante simulación computacional evidencian mejoras en la eficiencia del recorrido y en la distribución estratégica de atracciones visitadas. En este sentido, el modelo constituye una herramienta de apoyo a la gestión y planificación de espacios turísticos de gran escala, con potencial de replicabilidad en otros destinos regionales que presenten características territoriales y operativas similares.

Palabras-clave: Algoritmo genético, optimización de rutas, Parque de las Leyendas, problema del viajero, gestión turística.

Códigos JEL: C61; R11; Z32.

1. INTRODUCCIÓN

El Parque de las Leyendas, inaugurado en 1964, constituye el parque zoológico más grande del Perú y uno de los destinos turísticos más emblemáticos de Lima. Con una extensión de 130 hectáreas y una rica variedad de atracciones que incluyen 215 especies de animales distribuidas en diferentes zonas temáticas, el parque ofrece una experiencia única para sus visitantes (Municipalidad de Lima, 2023; Perez Ruiz, 2007). Sin embargo, debido a su gran tamaño y la dispersión de sus principales puntos de interés, recorrerlo eficientemente representa un desafío significativo para los turistas. Este contexto hace que la optimización de rutas dentro del parque se presente como un problema relevante, cuyo abordaje permite mejorar sustancialmente la experiencia de los visitantes al reducir tiempos de desplazamiento y maximizar el acceso a las atracciones más destacadas.

Esta investigación tiene como objetivo diseñar un sistema de optimización de rutas que permita a los visitantes recorrer eficientemente el parque. La solución propuesta genera rutas personalizadas considerando las distancias entre los puntos de interés, el tiempo disponible del visitante y la valoración de las atracciones, con el fin de maximizar la satisfacción del usuario y optimizar el aprovechamiento del espacio turístico.

En este contexto, los algoritmos genéticos han demostrado ser herramientas eficaces para resolver problemas complejos de enrutamiento en diversos escenarios, como la optimización de rutas de vehículos o la planificación logística. Por ejemplo, en un estudio realizado en la Universidad Nacional Tenaga (UNITEN), se utilizó un algoritmo genético para optimizar las rutas de ocho buses que operaban en un campus universitario, logrando una reducción significativa en la distancia y el tiempo de recorrido, además de disminuir costos asociados al transporte, consumo de combustible y mantenimiento vehicular (Mohammed et al., 2017). Este caso de estudio resalta la capacidad de

los algoritmos genéticos para abordar problemas de enrutamiento y su aplicabilidad en contextos reales, lo que respalda su uso en la optimización de recorridos en el Parque de las Leyendas.

La novedad científica de la investigación radica en la utilización de algoritmos genéticos, una técnica avanzada de inteligencia artificial en un contexto turístico específico. A través de la adaptación de este método al contexto del Parque de las Leyendas, se busca ofrecer rutas personalizadas que consideren factores como la distancia, el tiempo y las calificaciones de los puntos de interés. Esto contribuye al campo de la informática aplicada, así como también crea precedentes para la gestión de grandes espacios turísticos a nivel nacional. La integración de herramientas tecnológicas en el turismo abre nuevas posibilidades para mejorar la sostenibilidad, la experiencia de usuario y la eficiencia operativa en destinos turísticos de gran extensión geográfica.

En las siguientes secciones, se detallan los fundamentos teóricos del algoritmo genético, la metodología implementada y los resultados obtenidos, destacando las contribuciones específicas de este trabajo en el ámbito de la gestión turística y la optimización de recursos, finalizando con la discusión de resultados, conclusiones, limitaciones y líneas de investigación futuras.

2. REVISIÓN BIBLIOGRÁFICA

2.1. Tecnología e innovación en espacios turísticos

Existen varias investigaciones que han tratado de abordar el tema de destinos turísticos con la aplicación de sistemas y herramientas informáticas.

Una investigación explora como las dimensiones experienciales de la realidad virtual (RV) impactan en la percepción de los visitantes en los centros de juegos de destinos turísticos, influyendo en la satisfacción del visitante, utilizando un conjunto de datos recopilado mediante encuestas a visitantes de diferentes centros turísticos equipados con tecnologías de RV, centrándose la investigación en el análisis descriptivo y estadístico de las respuestas. Los resultados reflejan que las dimensiones experienciales como la inmersión y la interactividad tienen un impacto positivo en la percepción general del visitante y su intención de regreso al centro turístico. Concluye que la integración de la RV en los centros de juego de destinos turísticos es una herramienta efectiva para mejorar la experiencia del visitante lo que sugiere un potencial mercado para el crecimiento del turismo basado en tecnología (Rina & Joby, 2024).

Otra investigación explora cómo los chatbots pueden usarse como herramientas alternativas de comunicación en la gestión de desastres turísticos, evaluando la efectividad de la difusión de información crítica durante emergencias, utilizando un conjunto de acontecimientos en los que se utilizaron chatbots en destinos turísticos de Turquía afectados por desastres. Los resultados demuestran que los chatbots son efectivos para proporcionar información relevante reduciendo la ansiedad de los turistas en situaciones difíciles. Se concluye que los chatbots son herramientas de bajo costo que permiten mejorar la comunicación en caso de crisis en destinos turísticos (Sharon Treasa & Bindu Vazhakkatte, 2023).

Rodríguez Correa et al., (2023) analizan las tendencias actuales de la adopción de inteligencia artificial (IA) en el sector turístico, resaltando la importancia de estas tecnologías en la transformación de operaciones y experiencias de los turistas, realizando una revisión bibliográfica mediante análisis cualitativo de artículos sobre el tema, encontrándose como resultados que la IA permite una personalización avanzada y una mayor eficiencia operativa, concluyendo que la IA es una tendencia en aumento que redefine las estrategias del negocio en el sector turismo.

Otra investigación sobre los paradigmas inteligentes 4.0 indica cómo fomentan la innovación en destinos turísticos para mejorar la sostenibilidad y experiencia del turista, realizando un estudio de casos en varios destinos donde se han adoptado estas tecnologías.

Los resultados muestran que los destinos que adoptan estas tecnologías mejoran la experiencia del turista y promueven una gestión más eficiente de los recursos, concluyendo que los paradigmas inteligentes son esenciales para el futuro del turismo sostenible (Rodrigues et al., 2022).

2.2. Algoritmos genéticos para optimización de rutas

La investigación de Huarote Zegarra et al., (2021) se centra en la aplicación de algoritmos genéticos para encontrar la ruta más corta entre puntos geográficos utilizando la distancia de Haversine para calcular distancias en coordenadas dadas por el GPS, el mapa de nodos incluye las coordenadas de los puntos geográficos a buscar y el algoritmo genético incluye operadores de selección cruce y mutación para evolucionar una población de rutas, buscando minimizar la distancia total, los resultados indican que se pueden encontrar rutas óptimas en tiempos aceptables incluso al aumentar el número de puntos geográficos considerados inicialmente. Se concluye que los algoritmos genéticos ofrecen soluciones cercanas al óptimo con una complejidad media para resolver problemas de optimización de rutas en contextos geográficos.

Otra investigación desarrolló un algoritmo genético para determinar una ruta óptima turística en la ciudad de Panamá, siendo esencial encontrar una ruta que pase por varios puntos de interés una sola vez y que minimice la distancia total recorrida abordando el clásico problema de Traveling Salesman Problem (TSP), utilizando como nodos ubicaciones de sitios turísticos de la ciudad. El algoritmo genético utiliza la representación de rutas como cromosomas y aplica operadores genéticos para evolucionar hacia soluciones óptimas. El autor concluye que los algoritmos genéticos proporcionan soluciones eficientes en tiempos aceptables para la búsqueda de rutas turísticas, siendo recomendable su implementación en otros problemas de optimización de rutas en el ámbito turístico (Trujillo-González, 2019).


Los algoritmos genéticos también han demostrado importante eficacia en optimizar rutas urbanas, como en la recolección de residuos sólidos en Lima (Vega-Huerta et al., 2025)

Estas investigaciones destacan la importancia de utilizar algoritmos genéticos y herramientas tecnológicas para mejorar la eficiencia en el sector turístico y poder optimizar la experiencia del visitante a destinos turísticos.

La efectividad de los sistemas de optimización depende también de factores organizacionales y humanos, cuya integración con herramientas tecnológicas ha sido documentada en trabajos recientes en contextos latinoamericanos (Bravo-Jaico et al., 2025; De-la-cruz-vdv et al., 2023; De-La-Cruz-VdV et al., 2025; López-Córdova et al., 2025; Vega-huerta et al., 2023, 2025; Vega-Huerta, Chunga-Vargas, et al., 2025; Vega-Huerta, Gutierrez-Mejía, et al., 2025; Vega-Huerta, Vilca Velasquez, et al., 2025).


En los últimos años, los algoritmos metaheurísticos se utilizan para resolver problemas complejos de la vida real que surgen de diferentes campos, como la economía, la ingeniería, la política y la gestión; como se aprecia en la figura 1, estos algoritmos se clasifican ampliamente en dos categorías, a saber, solución única y algoritmo metaheurístico basado en la población. Los algoritmos metaheurísticos basados en una solución única utilizan una solución candidata única y mejoran esta solución mediante el uso de la búsqueda local. Estos algoritmos generalmente utilizan una estrategia de búsqueda exhaustiva para examinar todas las posibles soluciones y seleccionar la mejor. Sin embargo, la solución obtenida a partir de metaheurísticas basadas en una sola solución puede quedar atrapada en los óptimos locales. Las metaheurísticas basadas en la población utilizan múltiples soluciones candidatas durante el proceso de búsqueda. Estas metaheurísticas mantienen la diversidad en la población y evitan que las soluciones se atasquen en los óptimos locales. Algunos de los algoritmos metaheurísticos basados en poblaciones más conocidos son el algoritmo genético (GA), la optimización de enjambre de partículas (PSO), la optimización de colonias de hormigas, entre otros (Katoch et al., 2021).

Figura 1. Clasificación de algoritmos metaheurísticos



(Katoch et al., 2021)

Figura 2. Flujo de un algoritmo genético




(Hassanat et al., 2019)

El algoritmo genético (GA) es un algoritmo de optimización inspirado en la selección natural. Es un algoritmo de búsqueda basado en la población, que utiliza el concepto de supervivencia del más apto. Las nuevas poblaciones se producen mediante la aplicación iterativa de operadores genéticos sobre individuos presentes en la población. La representación cromosómica, la selección, el cruce, la mutación y el cálculo de la función de aptitud son los elementos clave de GA. GA cambia dinámicamente el proceso de búsqueda a través de las probabilidades de cruce y mutación y llega a la solución óptima. GA puede modificar los genes codificados. GA puede evaluar múltiples individuos y producir múltiples soluciones óptimas. Por lo tanto, GA tiene una mejor capacidad de búsqueda global (Katoch et al., 2021), (Zhou et al., 2020), (Chen et al., 2020), (MyMov, 2022), (Sancho Caparrini, 2019).

En la figura 2 se puede ver el flujo que sigue comúnmente un algoritmo genético. Los componentes comunes dependientes del problema en un algoritmo genético incluyen lo siguiente: la codificación y las funciones de evaluación (Hassanat et al., 2019).

La figura 3 muestra el proceso de iteraciones sucesivas hasta obtener soluciones suficientemente buenas para resolver el problema. La entrada del Algoritmo Genético son un conjunto de soluciones potenciales a resolver el problema, estas se codifican y son evaluadas por una función llamada fitness que elegirá a las soluciones más aptas para el objetivo. A estas soluciones que llamaremos candidatas se les permite reproducirse. Seguidamente los descendientes de estos que son la nueva población serán sometidos al proceso de mutación y continuar con el ciclo en una nueva iteración.


Figura 3: Proceso iterativo del Algoritmo Genético


(Sancho Caparrini, 2019)


En el contexto específico de la optimización de rutas, los algoritmos genéticos han demostrado su eficacia para resolver problemas complejos, como el Problema del Viajante y el Problema de enrutamiento de vehículos (Baker & Ayechev, 2003), (Thangiah, 2014). Estos problemas comparten similitudes con la gestión de rutas en el Parque de las Leyendas, ya que implican encontrar la secuencia más eficiente para visitar una serie de ubicaciones, minimizando la distancia recorrida o el tiempo de viaje.

Recientemente (Bourbonnais et al., 2019) proponen un diseño de una red de tránsito mediante algoritmos genéticos donde demuestran que la realización de optimizaciones de algoritmos genéticos utilizando datos de la red de carreteras local, de la red de tránsito y datos de la demanda de transporte público en tres ciudades de Canadá (Sherbrooke, Saguenay and Trois-Rivières) que tienen de 100.000 a 200.000 habitantes, generando escenarios de un 10% y un 20% más de eficiencia que las redes existentes.

La figura 4 muestra el conjunto de 708 paradas actuales que existen en el recorrido de la ciudad Sherbrooke. Luego de la agregación de paradas estratégicas se realiza la selección con las simulaciones se obtiene 332 paradas seleccionadas.

Figura 4: Paradas existentes (círculos grises), paradas agregadas (círculos blancos) y paradas de simulación (pentágono).


Adaptado de (Bourbonnais et al., 2019).

Figura 5: Comparación de recorrido convencional (línea continua) y recorrido simulado (línea discontinua).


Adaptado de (Bourbonnais et al., 2019).

La figura 5 muestra una comparación entre el recorrido actual de las rutas en Trois-Rivières y el recorrido estratégico simulado. Donde el tiempo de viaje simulado es 2,3 veces más rápido respecto al actual.

En la literatura existente, se han realizado estudios sobre la optimización de rutas utilizando algoritmos genéticos en diversos contextos, sin embargo, hasta donde sabemos, no se ha explorado específicamente la aplicación de algoritmos genéticos para la optimización de rutas en el Parque de las Leyendas (Campos Vasquez et al., 2021).

3. METODOLOGÍA


En este artículo, se presenta un enfoque basado en algoritmos genéticos para optimizar las rutas peatonales de visita turística en el Parque de las Leyendas, que incluye preparación de los datos donde se elaborará el mapa de nodos y coordenadas, luego selección de individuos usando la técnica de ruleta o Roulette Wheel Selection, cruzamiento usando el operador PMX - Partially Mapped Crossover y mutación usando el operador flip-bit que son procesos de los algoritmos genéticos. En cuanto a los perfiles de visitante considerados en el modelo, estos se definen como un único grupo genérico diferenciado únicamente por la restricción de tiempo disponible para el recorrido: visitantes con tiempo acotado (entre 60 y 120 minutos) y visitantes sin restricción temporal. No se modelaron segmentos específicos como familias, estudiantes o visitantes con sensibilidad ambiental, dado que la función fitness ya incorpora la calificación de atracciones como proxy de preferencia agregada. La segmentación por motivación o perfil demográfico constituye una extensión natural de la modelo propuesta como línea de trabajo futuro.

3.1 . Preparación de datos

En la Figura 6 se presenta la representación espacial de los puntos de interés en el Parque de las Leyendas, mapeados sobre un plano cartesiano para determinar las coordenadas exactas de cada destino. Estos datos constituyen el espacio de búsqueda para el algoritmo genético propuesto. Como base cartográfica, se empleó el mapa oficial del centro recreativo.

En esta visualización, los nodos representados por cuadrados corresponden a los lugares de entretenimiento principales y puntos de destino clave. Por otro lado, los nodos representados por triángulos funcionan como puntos de paso o nodos secundarios; estos últimos permiten interconectar las rutas principales, optimizando la topología del grafo y agilizando la eficiencia computacional durante la ejecución del experimento.

Figura 6: Plano del Parque de las Leyendas con coordenadas de cada lugar de visita.



En las Tablas 1 y 2 se detallan los nodos que conforman el grafo del parque, incluyendo su numeración, el nombre del punto de interés y sus coordenadas cartesianas (x, y). Para facilitar la identificación en la cartografía de la Figura 6, los nodos de la Tabla 1 (Nodos Principales) se representan mediante cuadrados, mientras que los de la Tabla 2 (Nodos Secundarios) se identifican con triángulos.

Asimismo, la valoración de las atracciones se visualiza mediante una escala de intensidad de grises. Los nodos principales presentan tonos oscuros proporcionales a su nivel de calificación; por el contrario, los nodos secundarios se muestran en color blanco, debido a que poseen una calificación nula (0) al funcionar estrictamente como puntos de transición y no como destinos de interés turístico.

La Tabla 3 muestra una parte de la matriz de adyacencia donde se muestra la relación de adyacencia de cada nodo con cada uno del total de nodos.

La Tabla 4 muestra una parte de la matriz de distancia donde se muestra la relación de cercanía en metros de cada nodo respecto a cada uno del total de nodos.

La Tabla 5 presenta un segmento de la matriz de tiempo, la cual detalla el costo de desplazamiento expresado en minutos entre cada par de nodos del sistema. A diferencia de la métrica de distancia, esta matriz permite considerar la velocidad promedio de caminata del visitante y la topología de los senderos, proporcionando una base temporal para que el algoritmo genético optimice las rutas en función de la eficiencia del recorrido y la disponibilidad de tiempo del usuario.

La Tabla 6 presenta la matriz de calificación de las atracciones, cuya estructura difiere de las métricas de distancia y tiempo. Mientras que el tiempo y la distancia presentan una naturaleza simétrica entre dos nodos, la calificación se define en función del nodo de destino.

Bajo esta lógica, el valor asignado a un arco entre el nodo i y el nodo j corresponde al nivel de interés del nodo j. Por ejemplo, en un desplazamiento desde el nodo 5 hacia el nodo 6, se asigna la calificación del nodo 6 (valor de 5); no obstante, en el sentido inverso (del nodo 6 al 5), el peso del arco asume la calificación del nodo 5. Esta asimetría en la matriz es fundamental para que el algoritmo genético priorice rutas que culminen en puntos de alto valor, maximizando la experiencia del visitante en cada transición del recorrido.

Tabla 1: Conjunto de nodos principales del Parque con coordenadas cartesianas.

Nodo	Nº	Nodo	x	y
A	1	Boletería	40	20
B	2	Pingüinos	27.5	29
C	3	Acuario	28	32
D	4	Villa Carmelo	22.5	38
E	5	Mariposario	22	43
F	6	Caballeriza	22.5	47
G	7	Laguna Recreativa	26	41
H	8	Jardín Botánico	31	37.7
I	9	Vivero Casa Verde	41.5	55.5
J	10	Granja Interactiva	37	51
K	11	Museo Kalinowski	44	35
L	12	Felinario	49	43
M	13	Museo de sitio Ernst W.	54.5	35
N	14	Huaca Cruz Blanca	51.5	37
O	15	Huaca San Miguel	38	27.5
P	16	Anfiteatro Chabuca Granda	41.5	34.5
Q	17	Estacionamiento Playa 1	35.5	12.5
R	18	Estacionamiento Playa 2	58	54.5
S	19	Camping Felinario	50.5	40.5
T	20	Isla de Monos	47.5	34
U	21	Camping Selva	49.5	29
V	22	Pampa Galeras	40	11
W	23	Mina Modelo	43	13
X	24	Camping Sierra	37	8
Y	25	Cine 5D	34.7	27
Z	26	Tópico	36	25

Tabla 2: Conjunto de nodos secundarios del Parque con coordenadas cartesianas.

Nodo	Nº	Nodo	x	y
NC1	27	NC1	58	44.5
NC2	28	NC2	53	45
NC3	29	NC3	48	39.5
NC4	30	NC4	43.5	45
NC5	31	NC5	39	45.5
NC6	32	NC6	36.5	48
NC7	33	NC7	34.5	39
NC8	34	NC8	32.5	37
NC9	35	NC9	23	42.5
NC10	36	NC10	24.5	37
NC11	37	NC11	30	27.5
NC12	38	NC12	37.4	35
NC13	39	NC13	44	23
NC14	40	NC14	42.5	20.5
NC15	41	NC15	38.5	17.6
NC16	42	NC16	40.2	17
NC17	43	NC17	38.4	12
NC18	44	NC18	46	18.5
NC19	45	NC19	50	32.5
NC20	46	NC20	52.5	32

Las distancias entre nodos registradas en la matriz de distancia, mostrada en la Tabla 4, no corresponden a distancias euclidianas directas, sino a distancias reales de recorrido peatonal medidas sobre los senderos transitables del parque. Estas distancias fueron obtenidas mediante el trazado manual de rutas sobre el plano oficial del parque, siguiendo únicamente los caminos habilitados para visitantes, e incorporadas directamente en la matriz de adyacencia como pesos de las aristas del grafo. De este modo, el grafo resultante refleja la red de senderos reales y no conexiones en línea recta entre puntos de interés.

De manera similar se cuenta con la matriz de tiempos que almacena la relación de tiempo en minutos de cada nodo respecto a llegar a cada uno del total de nodos, la matriz de calificación que almacena la estimación que tienen los visitantes respecto a cada lugar que visitan con calificaciones de 1 al 5.

Las calificaciones de cada atracción fueron obtenidas de la plataforma Google Maps, consultada en diciembre de 2024, tomando el promedio de valoraciones disponibles para cada punto de interés con un mínimo de 50 reseñas por nodo. En los casos en que la atracción no contaba con valoración propia en dicha plataforma, se asignó la calificación promedio del área temática a la que pertenece. Se reconoce que estas calificaciones representan una aproximación basada en percepciones agregadas de usuarios y no constituyen una medición empírica directa con visitantes del parque; su validación mediante encuestas presenciales constituye una línea prioritaria de trabajo futuro. El tiempo registrado en la matriz de tiempos fue estimado considerando dos componentes: (i) el tiempo de tránsito entre nodos, calculado asumiendo una velocidad media de caminata de 3.6 km/h (equivalente a 1 metro por segundo), valor estándar para entornos peatonales recreativos con afluencia moderada (Yang et al., 2020); y (ii) un tiempo de permanencia estimado por atracción, asignado en función de la categoría del nodo: 5 minutos para nodos de tránsito o conexión, 10 minutos para atracciones de tamaño pequeño y 15 minutos para las principales exhibiciones. Este tiempo de permanencia fue incorporado como un atributo fijo de cada nodo y sumado al tiempo de tránsito en el cálculo total de la ruta. Se reconoce que factores como la densidad de visitantes, colas de espera y condiciones climáticas pueden alterar estos valores, razón por la cual se consideran como estimaciones base susceptibles de calibración en implementaciones futuras.

3.2 Algoritmos genéticos

El primer paso es generar la población inicial con cierto número de individuos, y cada individuo se expresa como el código genético del cromosoma. La convergencia, el rendimiento y la eficacia se ven afectados por la definición de la población inicial (Wang et al., 2022). La función fitness es el estándar de evaluación del plan de la ruta a tomar y esta representa la capacidad de supervivencia del individuo genético (Yang et al., 2020). La aptitud es importante porque permite saber la calidad del individuo con respecto a los otros dentro de la población, esto permite al momento de realizar la selección escoger individuos con una aptitud mejor para lograr cruzar estos individuos para así sus genes aparezcan para la próxima generación (Rodríguez Cevallos et al., 2020).

La función fitness fue diseñada con base en una función heurística que evalúa la calidad de cada solución candidata dentro de la población, considerando simultáneamente los factores de distancia, tiempo y calificación de las atracciones

Los factores que seleccionamos son la distancia (d) de la ruta entre dos lugares específicos, el tiempo (t) que demora tanto para llegar a un lugar específico y aprovechar el tiempo de observarlo, y la calidad (c) que ofrece la ruta; además también tenemos en cuenta la repetición ($r1$ y $r2$) de los segmentos de ruta donde lo realizamos con la visita seguida de un mismo lugar.

Al combinar estos factores con su respectivo peso y relevancia, se tiene función fitness (1):

$$F = \sum (c * 0.25 - d * 0.1875 - t * 0.1875 - \sum (r1 * 0.125 - r2 * 0.25)) \quad (1)$$

La selección de los pesos asignados a cada factor en la función fitness responde a tres criterios. Primero, la calificación (c) recibe el mayor peso (0.25) dado que el objetivo central del sistema es maximizar la experiencia del visitante, lo cual está alineado con estudios previos que priorizan la satisfacción del usuario sobre la eficiencia física en contextos de turismo recreativo (Yang et al.,

2020). Segundo, la distancia (d) y el tiempo (t) reciben pesos iguales (0.1875 cada uno), reflejando que ambas variables contribuyen de forma equivalente al esfuerzo físico del recorrido; esta simetría es consistente con la literatura de optimización de rutas peatonales (Huarote Zegarra et al., 2021). Tercero, los pesos de penalización por repetición de segmentos ($r_1=0.125$, $r_2=0.25$) fueron asignados de forma proporcional a la severidad del fenómeno: una primera repetición penaliza menos que una segunda, siguiendo un criterio de penalización escalonada. Los valores específicos fueron calibrados mediante pruebas piloto sobre el grafo del parque, evaluando cinco pares origen-destino representativos (Q-F, Q-R, Q-Z, Q-S y Q-U) y comparando el fitness promedio, el número de nodos principales visitados y la calificación acumulada bajo 12 configuraciones de pesos candidatas. Se seleccionó la configuración que produjo de forma consistente el mayor número de nodos de alta calificación visitados dentro de un tiempo de recorrido no superior a 90 minutos. Se reconoce que esta calibración tiene carácter heurístico y que la determinación empírica de los pesos mediante preferencias declaradas por visitantes reales, o mediante técnicas de optimización de hiperparámetros como búsqueda en cuadrícula (grid search) o algoritmos bayesianos, constituye una limitación metodológica abordada como línea prioritaria de trabajo futuro.

3.2.1 Selección de Individuos

La etapa de la selección hace que los individuos con alta aptitud sobrevivan con una alta probabilidad (Wang et al., 2022), (Cruz-Piris et al., 2019). La función fitness es el estándar. En este trabajo se implementa el método de selección por ruleta (Roulette Wheel Selection), elegido por su capacidad de mantener la diversidad poblacional mientras favorece a los individuos más aptos. Este operador asigna probabilidades de selección proporcionales al fitness de cada individuo, permitiendo que las mejores soluciones tengan mayor probabilidad de ser seleccionadas sin eliminar completamente las soluciones menos óptimas. La aplicación de este método a nuestro problema se aplica generando una probabilidad de selección por cada individuo en un rango de 0 a 1, donde los valores generados indican la probabilidad relativa de selección de cada elemento.

```
def seleccion_ruleta(poblacion, num_seleccionados):
    aptitud_total = sum([f.fitness_3v(ruta) for ruta in poblacion])

    if aptitud_total <= 0:
        return [] # Control de aptitud no válida

    # Cálculo de probabilidades basado en fitness
    probabilidades = [f.fitness_3v(ruta) / aptitud_total for ruta in poblacion]

    seleccionados = []
    repetidosSEL = []
    for i in range(num_seleccionados):
        if len(poblacion) == 0:
            break

        # Selección ponderada basada en fitness
        indice = random.choices(range(len(poblacion)), weights=probabilidades, k=1)[0]
        elemento = poblacion[indice]
        seleccionados.append(elemento)
        repetidosSEL.append(elemento)

        # Control de diversidad
        if contar_repeticiones(elemento, repetidosSEL) >= 2:
            poblacion.remove(elemento)
            probabilidades.pop(indice)

    return seleccionados
```

El proceso de selección opera en tres fases principales:

1. Cálculo de probabilidades:
 - Suma el fitness total de la población
 - Asigna a cada individuo una probabilidad proporcional a su fitness
2. Selección de individuos:
 - Utiliza el método random.choices con pesos basados en el fitness
 - Realiza selecciones ponderadas hasta alcanzar el número deseado

3. Control de diversidad:

- Monitorea la frecuencia de cada individuo seleccionado
- Elimina individuos que exceden dos apariciones
- Actualiza las probabilidades después de cada eliminación

3.2.2 Cruzamiento

El algoritmo implementa una variante del operador de cruzamiento PMX (Partially Mapped Crossover) adaptado para problemas de ruteo. Este operador fue seleccionado por su capacidad de preservar el orden y la posición de los segmentos de ruta, características cruciales en problemas de optimización de rutas con restricciones de conectividad. El cruzamiento utilizado es similar al cruzamiento de orden (OX) o cruzamiento parcialmente mapeado (PMX), pero para nuestro caso seleccionamos un segmento de uno de los padres y ese segmento lo tendrá el hijo, después el otro padre completará los elementos faltantes si es que tiene alguna relación; pues en el caso de rutas se sigue una secuencia de lugares con rutas establecidas donde hay lugares que no tienen conexiones.

El cruzamiento opera seleccionando aleatoriamente pares de padres para generar dos hijos por cada operación.

```
def cruzar(padre1, padre2):
    hijo = [None] * len(padre1)
    hijo, guardar, origen, destino, ini, fin, cantidad = gp1s.padre1_segmento(padre1)
    inicio = ini - 1
    final = fin + 1

    segmento2 = gp2s.segmentos(padre2, origen, destino, cantidad)
    if len(segmento2) == 0:
        if origen == destino:
            if cantidad == 3:
                lugar = gna1.lugares_interconectados(origen)
                hijo[inicio+1] = random.choice(lugar)
            else:
                rutas_igual = grii1.rutas_intermedias_x_cantidad_igual_quitando_final(origen, destino, cantidad)
                if len(rutas_igual) > 0:
                    segmento_aleatorio = random.choice(rutas_igual)
                    for i in range(len(segmento_aleatorio)):
                        hijo[inicio+i] = segmento_aleatorio[i]
                else:
                    hijo[ini:fin+1] = guardar[ini:fin+1]
            else:
                ruta_total = juntar(origen, destino, cantidad)
                if len(ruta_total) != 0:
                    segmento_aleatorio = random.choice(ruta_total)
                    for i in range(len(segmento_aleatorio)):
                        hijo[inicio+i] = segmento_aleatorio[i]
                else:
                    hijo[ini:fin+1] = guardar[ini:fin+1]
            else:
                segmento_aleatorio = random.choice(segmento2)
                for i in range(len(segmento_aleatorio)):
                    hijo[inicio+i] = segmento_aleatorio[i]

    return hijo
```

El proceso mantiene la validez de las rutas mediante tres mecanismos principales:

1. Preservación de segmentos válidos del primer padre
2. Incorporación de segmentos compatibles del segundo padre
3. Generación de nuevos segmentos válidos cuando la herencia directa no es posible

3.2.3 Mutación

La mutación introduce variabilidad genética en la población al modificar aleatoriamente características de los individuos, evitando así la convergencia prematura hacia óptimos locales. La variante más utilizada es la mutación binaria, la cual invierte el valor de un gen entre 0 y 1 según una probabilidad predefinida (Rodríguez Cevallos et al., 2020).

En esta etapa se implementa una variante del operador de mutación flip-bit, adaptada específicamente para el problema de optimización de rutas. Se emplea una tasa de mutación del 2.5%, valor seleccionado por ser lo suficientemente bajo para preservar las características positivas de las soluciones mientras mantiene la diversidad genética necesaria para evitar la convergencia prematura.

```
def metodo_mutacion(individuo, tasa_mutacion):
    for i in range(1, len(individuo)-1):
        if random.random() < tasa_mutacion:
            origen = individuo[i-1]
            destino = individuo[i+1]

            if origen == destino:
                # Caso especial: usar nodo adyacente cuando origen y destino son iguales
                ruta = ad.lugares_interconectados(origen)
                indice = random.randint(0, len(ruta)-1)
                individuo[i] = ruta[indice]
            else:
                # Obtener rutas intermedias válidas entre origen y destino
                array = juntar(origen, destino)

                if len(array) == 1:
                    individuo[i] = array[0][1]
                else:
                    if len(array) != 0:
                        indiceR = random.randint(0, len(array)-1)
                        individuo[i] = array[indiceR][1]
    return individuo
```

El operador realiza una mutación controlada que:

1. Preserva los nodos de origen y destino
2. Modifica nodos intermedios considerando la conectividad con sus adyacentes
3. Garantiza la factibilidad de las nuevas rutas generadas

4. RESULTADOS

En este apartado, evaluaremos los resultados del algoritmo genético aplicado al recorrido entre un lugar de origen y un destino, considerando cuatro perspectivas diferentes entre estos puntos. Primero, aplicaremos nuestro algoritmo genético tomando como base tres variables. Luego, analizaremos la ruta tradicional utilizando una sola variable en cada caso, es decir, distancia, tiempo o calificación. De esta manera, podremos analizar las ventajas obtenidas que se generan al incrementar la complejidad del recorrido mediante nuestro algoritmo.

En las figuras 7, 8, 9 y 10 se muestra el recorrido óptimo según el algoritmo comenzando en el estacionamiento 1 (nodo Q o 17) hasta ir a la Caballeriza (nodo F o 6) en base a 4 estrategias.

Figura 7: Ruta óptima Q-F empleando métricas de distancia, tiempo y calificación.



Figura 8: Ruta óptima Q-F empleando métrica de solo distancia.




Figura 9: Ruta óptima Q-F empleando métrica de solo tiempo.**Figura 10: Ruta óptima Q-F empleando métrica de solo calificación.**

Comparando las cuatro estrategias de optimización, se observa que la ruta que incluye más lugares (nodos) es la que utiliza la calificación como criterio principal. Esto se debe a que esta variable se relaciona de manera aditiva, incrementándose al sumarse al valor total del fitness. Es decir, una ruta con más nodos tendrá un mayor valor de calificación.

Por el contrario, las rutas que optimizan distancia y tiempo de forma independiente se relacionan de manera aditiva negativa, priorizando la selección de la ruta más corta según su respectiva variable.

Finalmente, la ruta que utiliza las tres variables considera un equilibrio óptimo entre ellas. Por esta razón, incluye en su recorrido lugares como el Acuario (nodo 3), Pingüinos (nodo 2) y Laguna Recreativa (nodo 7), que poseen la calificación máxima, además de optimizar la distancia y el tiempo.

En la Tabla 7 se muestran las métricas obtenidas para las rutas optimizadas considerando diferentes pares de origen y destino empleando las 3 variables. Se incluyeron parámetros como el valor de fitness, la distancia total recorrida, el tiempo estimado de recorrido, la calificación acumulada, el recorrido realizado por la ruta y el número de lugares (nodos principales) que se han visitado con dicha ruta.

Tabla 7: Resumen de Rutas empleando métricas de distancia, tiempo y calificación.

Ruta	Mejor fitness	Distancia (metros)	Tiempo (minutos)	Calif. total	Recorrido	Lugares visitados
Q - R	1000.41842	1155.58	55.12	63	[Q', 'NC15', 'A', 'Z', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'D', 'NC9', 'G', 'H', 'NC8', 'NC12', 'P', 'K', 'T', 'NC19', 'NC20', 'M', 'N', 'NC3', 'L', 'S', 'NC2', 'NC1', 'R']	18
Q - M	1000.61809	852.82	36.96	51	[Q', 'NC15', 'A', 'Z', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'D', 'NC9', 'G', 'H', 'NC8', 'NC12', 'P', 'K', 'T', 'NC3', 'N', 'M']	15
Q - F	1000.61358	512.51	18.91	34	[Q', 'NC15', 'A', 'Z', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'G', 'NC9', 'E', 'F']	10
Q - Z	1000.06592	1151.37	55.46	56	[Q', 'NC15', 'A', 'NC14', 'NC13', 'K', 'T', 'NC19', 'NC20', 'M', 'N', 'NC3', 'NC4', 'NC5', 'NC6', 'NC7', 'NC8', 'H', 'G', 'NC9', 'D', 'NC10', 'C', 'B', 'NC11', 'Y', 'O', 'Z']	12
K - C	1000.34003	282.25	10.93	19	[K', 'P', 'NC12', 'O', 'Y', 'NC11', 'B', 'C']	6
R - T	1000.25195	1423.10	69.39	73	[R', 'NC1', 'NC2', 'S', 'L', 'NC3', 'N', 'M', 'NC20', 'NC19', 'U', 'NC18', 'W', 'V', 'NC17', 'NC16', 'NC14', 'A', 'Z', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'D', 'NC9', 'G', 'H', 'NC8', 'NC12', 'P', 'K', 'T']	20
V - J	1000.33059	1063.87	50.94	57	[V', 'NC17', 'NC16', 'NC14', 'A', 'Z', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'G', 'H', 'NC8', 'NC12', 'P', 'K', 'T', 'NC19', 'NC20', 'M', 'N', 'NC3', 'NC4', 'NC5', 'NC6', 'J']	15
K - D	1000.43542	471.64	20.27	30	[K', 'P', 'NC12', 'O', 'Y', 'NC11', 'B', 'C', 'H', 'G', 'NC10', 'D']	9
V - U	1000.53378	834.95	35.07	48	[V', 'NC17', 'NC16', 'NC14', 'A', 'Z', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'D', 'NC9', 'G', 'H', 'NC8', 'NC12', 'P', 'K', 'T', 'NC19', 'U']	14
W - B	1000.33316	829.75	39.82	46	[W', 'NC18', 'U', 'NC19', 'NC20', 'M', 'N', 'NC3', 'T', 'K', 'P', 'NC12', 'NC8', 'H', 'G', 'NC9', 'D', 'NC10', 'C', 'B']	12
Total		8577.84	392.87	477		131

En la Tabla 8 se muestran las métricas obtenidas para las rutas optimizadas considerando diferentes pares de origen y destino empleando solo la variable distancia.

Tabla 8: Resumen de Rutas tradicionales empleando solo métrica de distancia.

Ruta	Mejor fitness	Distancia (metros)	Tiempo (minutos)	Calificación total	Recorrido	Lugares visitados
Q - R	999.20553	617.65	32.83	22	[Q', 'NC15', 'A', 'P', 'K', 'T', 'NC3', 'L', 'S', 'NC2', 'NC1', 'R']	8
Q - M	999.50369	385.84	22.44	16	[Q', 'NC15', 'A', 'P', 'K', 'T', 'NC19', 'NC20', 'M']	6
Q - F	999.39137	473.16	23.38	24	[Q', 'NC15', 'A', 'Z', 'O', 'NC12', 'NC8', 'H', 'G', 'NC9', 'E', 'F']	8
Q - Z	999.80512	151.5	8.35	4	[Q', 'NC15', 'A', 'Z']	3
K - C	999.74187	200.68	9.21	11	[K', 'P', 'NC12', 'NC8', 'H', 'C']	4
R - T	999.58516	322.51	15.64	14	[R', 'NC1', 'NC2', 'S', 'L', 'NC3', 'T']	4
V - J	999.34241	511.23	30.47	18	[V', 'W', 'NC18', 'U', 'NC19', 'T', 'NC3', 'NC4', 'NC5', 'NC6', 'J']	5
K - D	999.64627	275.00	12.46	15	[K', 'P', 'NC12', 'NC8', 'H', 'G', 'NC9', 'D']	5
V - U	999.73067	209.38	14.13	6	[V', 'W', 'NC18', 'U']	3
W - B	999.50954	381.29	16.68	20	[W', 'V', 'NC17', 'NC16', 'NC14', 'A', 'Z', 'O', 'Y', 'NC11', 'B']	7
Total		3608.56	185.59	150		53

En la Tabla 9 se muestran las métricas obtenidas para las rutas optimizadas considerando diferentes pares de origen y destino empleando solo la variable tiempo.

Tabla 9: Resumen de Rutas tradicionales empleando solo métrica de tiempo.

Ruta	Mejor fitness	Distancia (metros)	Tiempo (minutos)	Calificación total	Recorrido	Lugares visitados
Q - R	999.27733	621.03	31.99	22	[Q', 'NC15', 'A', 'NC14', 'NC13', 'K', 'T', 'NC3', 'L', 'S', 'NC2', 'NC1', 'R']	7
Q - M	999.51182	389.22	21.60	16	[Q', 'NC15', 'A', 'NC14', 'NC13', 'K', 'T', 'NC19', 'NC20', 'M']	5
Q - F	999.60015	493.57	17.70	27	[Q', 'NC15', 'A', 'Z', 'O', 'Y', 'NC11', 'C', 'NC10', 'D', 'NC9', 'E', 'F']	9
Q - Z	999.81137	151.5	8.35	4	[Q', 'NC15', 'A', 'Z']	3
K - C	999.75308	282.25	10.93	19	[K', 'P', 'NC12', 'O', 'Y', 'NC11', 'B', 'C']	6
R - T	999.64646	322.51	15.64	14	[R', 'NC1', 'NC2', 'S', 'L', 'NC3', 'T']	4
V - J	999.44766	533.64	24.45	16	[V', 'NC17', 'NC16', 'NC14', 'NC13', 'K', 'P', 'NC12', 'NC8', 'NC7', 'NC6', 'J']	4
K - D	999.72823	355.32	12.03	18	[K', 'P', 'NC12', 'O', 'Y', 'NC11', 'C', 'NC10', 'D']	6
V - U	999.68079	209.38	14.13	6	[V', 'W', 'NC18', 'U']	3
W - B	999.62319	381.29	16.68	20	[W', 'V', 'NC17', 'NC16', 'NC14', 'A', 'Z', 'O', 'Y', 'NC11', 'B']	7
Total		3739.71	176.6	162		51

En la Tabla 10 se muestran las métricas obtenidas para las rutas optimizadas considerando diferentes pares de origen y destino empleando solo la variable calificación.

Tabla 10: Resumen de Rutas tradicionales empleando solo métrica de calificación.

Ruta	Mejor fitness	Distancia (metros)	Tiempo (minutos)	Calificación total	Recorrido	Lugares visitados
Q - R	1003.2	1587.21	77.98	64	['Q', 'NC15', 'A', 'NC14', 'NC16', 'NC17', 'V', 'W', 'NC18', 'U', 'NC19', 'T', 'K', 'P', 'NC12', 'O', 'Y', 'NC11', 'C', 'NC10', 'D', 'NC9', 'G', 'H', 'NC8', 'NC7', 'NC6', 'NC5', 'NC4', 'NC3', 'L', 'S', 'NC2', 'NC1', 'R']	17
Q - M	1003.15	1495.55	70.61	63	['Q', 'NC15', 'A', 'Z', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'D', 'NC9', 'G', 'H', 'NC8', 'NC7', 'NC6', 'NC5', 'NC4', 'NC3', 'T', 'K', 'NC13', 'NC14', 'NC16', 'NC17', 'V', 'W', 'NC18', 'U', 'NC19', 'NC20', 'M']	16
Q - F	1003.55	1690.11	87.30	71	['Q', 'NC15', 'A', 'Z', 'O', 'NC12', 'P', 'K', 'NC13', 'NC14', 'NC16', 'NC17', 'V', 'W', 'NC18', 'U', 'NC19', 'NC20', 'M', 'N', 'NC3', 'NC4', 'NC5', 'NC6', 'NC7', 'NC8', 'NC11', 'B', 'C', 'H', 'G', 'NC10', 'D', 'NC9', 'E', 'F']	18
Q - Z	1003.05	1531.77	78	61	['Q', 'NC15', 'A', 'P', 'K', 'NC13', 'NC14', 'NC16', 'NC17', 'V', 'W', 'NC18', 'U', 'NC19', 'NC20', 'M', 'N', 'NC3', 'NC4', 'NC5', 'NC6', 'NC7', 'NC8', 'H', 'G', 'NC10', 'C', 'B', 'NC11', 'Y', 'O', 'Z']	16
K - C	1002.45	1152.92	58.37	49	['K', 'P', 'NC12', 'NC8', 'NC7', 'NC6', 'NC5', 'NC4', 'NC3', 'N', 'M', 'NC20', 'NC19', 'U', 'NC18', 'W', 'V', 'NC17', 'NC16', 'NC14', 'A', 'Z', 'O', 'Y', 'NC11', 'B', 'C']	13
R - T	1003.15	1722.59	85.86	69	['R', 'NC1', 'NC2', 'S', 'L', 'NC3', 'NC4', 'NC5', 'NC6', 'NC7', 'NC8', 'H', 'G', 'NC9', 'D', 'NC10', 'C', 'B', 'NC11', 'Y', 'O', 'Z', 'A', 'P', 'K', 'NC13', 'NC14', 'NC16', 'NC17', 'V', 'W', 'NC18', 'U', 'NC19', 'T']	18
V - J	1002.8	1443.73	70.45	63	['V', 'W', 'NC18', 'U', 'NC19', 'NC20', 'M', 'N', 'NC3', 'T', 'K', 'NC13', 'NC14', 'A', 'P', 'NC12', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'D', 'NC9', 'G', 'H', 'NC8', 'NC7', 'NC6', 'J']	17
K - D	1002.1	925.81	45.15	42	['K', 'T', 'NC19', 'NC20', 'M', 'N', 'NC3', 'NC4', 'NC5', 'NC6', 'NC7', 'NC8', 'NC12', 'O', 'Y', 'NC11', 'C', 'H', 'G', 'NC10', 'D']	10
V - U	1002.6	1228.75	55.91	52	['V', 'NC17', 'NC16', 'NC14', 'A', 'P', 'NC12', 'O', 'Y', 'NC11', 'B', 'C', 'NC10', 'D', 'NC9', 'G', 'H', 'NC8', 'NC7', 'NC6', 'NC5', 'NC4', 'NC3', 'N', 'M', 'NC20', 'NC19', 'U']	13
W - B	1002.7	1142.13	56.43	54	['W', 'V', 'NC17', 'NC16', 'NC14', 'A', 'P', 'K', 'T', 'NC19', 'NC20', 'M', 'N', 'NC3', 'NC4', 'NC5', 'NC6', 'NC7', 'NC8', 'H', 'G', 'NC9', 'D', 'NC10', 'C', 'NC11', 'B']	13
Total		13920.57	686.06	588		151

En las tablas 7, 8, 9 y 10 se empleó una población inicial de 200 individuos y 200 generaciones dado que nuestro mapa contiene 46 nodos y se emplean tres factores. Con una población muy pequeña no se podría tener una diversidad genética para explorar eficazmente el espacio de soluciones óptimas.

Los resultados obtenidos al aplicar el algoritmo genético al diseño de rutas en el Parque de las Leyendas destacan una mejora sustancial en comparación con las rutas tradicionales, evaluadas bajo tres métricas principales: distancia, tiempo y calificación total. La Tabla 7 evidencia que las rutas optimizadas integran de manera equilibrada los tres criterios, permitiendo visitar más nodos mientras se mantiene un recorrido eficiente en términos de distancia y tiempo. Por ejemplo, la ruta Q-R optimizada registra una distancia total de 1,555.58 metros, un tiempo estimado de 55.12 minutos y una calificación total acumulada de 63, visitando 18 lugares. En contraste, su equivalente tradicional, enfocada exclusivamente en distancia (Tabla 8), logra una menor distancia (617.65 metros) pero sacrifica significativamente la calificación total (22) y el número de nodos visitados (8).

La comparación entre las tablas 8, 9 y 10 ilustra cómo la elección de una única métrica afecta las rutas generadas. Las rutas basadas únicamente en distancia o tiempo tienden a ser más cortas en términos de recorrido físico o duración, como es el caso de la ruta Q-Z basada en distancia (151.5 metros y 8.35 minutos). Sin embargo, estas rutas incluyen menos nodos, limitando la experiencia del visitante. Por otro lado, las rutas optimizadas exclusivamente para calificación (Tabla 10) sacrifican distancia y tiempo en favor de un mayor número de nodos visitados y calificaciones acumuladas superiores. La ruta Q-F, por ejemplo, alcanza una calificación de 71 pero a costa de recorrer 1,690.11 metros en 87.30 minutos.

Esta tendencia demuestra que el algoritmo puede adaptarse de manera flexible a las preferencias del visitante, ajustando las ponderaciones en la función fitness para priorizar el criterio deseado. Una aplicación práctica notable es el caso del recorrido entre el estacionamiento 1 y la Caballeriza, donde la ruta optimizada no solo minimiza la distancia, sino también prioriza lugares con alta calificación, según los parámetros definidos en la función fitness. Esto sugiere que el algoritmo no solo busca la eficiencia espacial, sino también mejorar la calidad de la experiencia del visitante.

5. DISCUSIÓN DE RESULTADOS

La búsqueda de la ruta óptima está respaldada por trabajos como los de (Bourbonnais et al., 2019), que destacan la aplicación de algoritmos genéticos en el diseño de redes de tránsito. Además, estudios como los de (Huarote Zegarra et al., 2021) han demostrado la eficacia de estos algoritmos en la optimización de rutas geográficas, validando su aplicación en contextos con múltiples restricciones y variables. En el ámbito turístico, la integración de calificaciones de usuarios representa una contribución única que no había sido explorada previamente.

A pesar de los avances, se identifican importantes brechas en la literatura. La mayoría de los estudios previos se centran en la optimización de rutas considerando exclusivamente uno o dos factores (por ejemplo, distancia y tiempo), sin integrar aspectos cualitativos como las calificaciones otorgadas por los visitantes. Además, existe una limitada aplicación de estos algoritmos en contextos turísticos específicos, lo que deja abierta la posibilidad de explorar modelos más integrales y adaptativos.

La comunicación de sostenibilidad en redes sociales potencia la congruencia entre turistas y causas ambientales, lo que incrementa la intención de compartir prácticas responsables. Este hallazgo refuerza la necesidad de optimizar rutas que integren criterios sostenibles en el Parque de las Leyendas, favoreciendo tanto la experiencia del visitante como la reputación social del destino (García de los Salmones et al., 2025). En este sentido, el modelo propuesto contribuye indirectamente a la sostenibilidad operativa del parque al reducir la congestión en zonas de alta afluencia, distribuir el flujo de visitantes de forma más equilibrada entre las distintas áreas temáticas y prolongar el tiempo de permanencia en atracciones con mayor valor ecológico y educativo.

El turismo en ecosistemas revela importantes sinergias entre conservación ecológica, generación de ingresos y conciencia ambiental, estos resultados apoyan la integración de principios de sostenibilidad en la planificación de recorridos turísticos urbanos, como en el Parque de las Leyendas, asegurando beneficios ambientales y socioeconómicos de largo plazo (Suresh et al., 2025).

Adicionalmente, es importante resaltar que la validación del modelo no se limita únicamente a la reducción de distancia recorrida, sino que considera la coherencia entre las preferencias del visitante y la secuencia óptima generada. Este enfoque permite superar la visión clásica del problema del viajante, incorporando un componente de personalización que incrementa la pertinencia de la solución en contextos reales. En comparación con modelos tradicionales de optimización mono objetivo, la propuesta presentada ofrece una estructura flexible capaz de adaptarse a diferentes escenarios turísticos, lo que amplía significativamente su potencial de aplicación en sistemas de planificación inteligente. No obstante, es necesario señalar de manera explícita que el modelo ha sido evaluado íntegramente mediante simulación computacional y carece de validación empírica con visitantes reales del parque. Las afirmaciones sobre mejora de la experiencia del visitante son, por tanto, de naturaleza inferencial y no han sido contrastadas con datos de satisfacción, patrones de desplazamiento reales ni encuestas de usuario. Esta constituye la principal limitación del estudio y la línea de investigación futura de mayor prioridad.

6. CONCLUSIONES Y TRABAJOS FUTUROS

Los resultados obtenidos demuestran que los algoritmos genéticos son herramientas efectivas y flexibles para lograr la optimización de rutas en el Parque de las Leyendas. El modelo desarrollado diseña rutas que equilibran tres factores clave: distancia, tiempo y calificación de los puntos de interés. Por ejemplo, la ruta Q-R optimizada registró una distancia de 1,155.58 metros, con una

calificación acumulada de 63, en contraste con la ruta tradicional, que priorizó distancia con 617.65 metros, pero sacrificó calificación (22).

La comparación de métricas mostró que las rutas basadas únicamente en distancia o tiempo tienden a ser más rápidas y cortas, pero limitan la cantidad de lugares visitados. Por otro lado, las rutas optimizadas exclusivamente para calificación incluyeron más nodos y lograron mayores puntuaciones, aunque con recorridos más largos y tiempos elevados. En cambio, las rutas optimizadas considerando simultáneamente los tres factores (distancia, tiempo y calificación) lograron un equilibrio notable entre eficiencia y calidad. Estas rutas no solo minimizaron la distancia recorrida y el tiempo empleado, sino que también incluyeron lugares con altas calificaciones, por ejemplo, la ruta Q-F optimizada integró puntos como el Acuario (nodo 3), Pingüinos (nodo 2) y Laguna Recreativa (nodo 7), alcanzando un balance con 512.51 metros recorridos, 18.91 minutos de tiempo y una calificación acumulada de 34. Este enfoque permitió maximizar la experiencia del visitante al equilibrar la eficiencia espacial y temporal con la calidad del recorrido.

En comparación con las rutas tradicionales, que optimizan de manera independiente un solo criterio, el enfoque propuesto integra simultáneamente distancia, tiempo y calificación, ofreciendo una solución equilibrada orientada a mejorar la experiencia del visitante. La incorporación de preferencias del usuario en el diseño de las rutas permite una mayor adaptación a distintos perfiles de recorrido y favorece una gestión más eficiente del espacio turístico. En este sentido, la metodología desarrollada constituye una aplicación relevante de técnicas de optimización en la planificación de recorridos en espacios recreativos de gran escala, con potencial de replicabilidad en otros destinos de características similares.

A pesar de los resultados positivos, se identifican algunas limitaciones. La principal es la dependencia de los datos de entrada, conformados por las coordenadas de los puntos de interés y las calificaciones asignadas por los usuarios. Cambios en la infraestructura del parque o en las preferencias de los visitantes podrían requerir ajustes en los parámetros del modelo o actualizaciones en la base de datos.

Adicionalmente, los pesos de la función fitness fueron definidos mediante criterios heurísticos y pruebas piloto, lo que constituye una limitación metodológica. Su determinación empírica, ya sea mediante encuestas de preferencias declaradas a visitantes reales, técnicas de búsqueda en cuadrícula (grid search) o algoritmos bayesianos, dotaría al modelo de una base más rigurosa y generalizable.

Otra limitación es el impacto de factores externos como la densidad de visitantes o restricciones físicas como condiciones climáticas o eventos especiales no considerados, lo que podría influir significativamente en la aplicabilidad del modelo propuesto. Adicionalmente, las distancias empleadas en el modelo corresponden a mediciones sobre el plano del parque siguiendo los senderos habilitados, sin considerar variaciones por mantenimiento, cierre temporal de accesos o eventos especiales que pudieran bloquear rutas específicas. Los tiempos de recorrido están basados en una velocidad de caminata estándar de 3.6 km/h con tiempos de permanencia fijos por tipo de atracción, sin modelar dinámicamente el efecto de la afluencia de visitantes sobre la velocidad de desplazamiento o los tiempos de espera en las exhibiciones más concurridas.

Entre las líneas prioritarias de investigación futura destacan: la validación empírica del modelo mediante pruebas piloto con visitantes reales del parque, incluyendo encuestas de satisfacción y análisis de patrones de desplazamiento; la integración de aprendizaje automático para ajustar dinámicamente los parámetros del algoritmo; y la incorporación de variables adicionales como flujos de tráfico interno, densidad de visitantes en tiempo real y cierres temporales de senderos.

REFERENCIAS BIBLIOGRÁFICAS

- Baker, B. M., & Ayechew, M. A. (2003). *A genetic algorithm for the vehicle routing problem*. 30, 787–800. [https://doi.org/10.1016/S0305-0548\(02\)00051-5](https://doi.org/10.1016/S0305-0548(02)00051-5)
- Bourbonnais, P. L., Morency, C., & Trépanier, M. (2019). Transit network design using a genetic algorithm with integrated road network and disaggregated O – D. In *Transportation* (Issue 0123456789). Springer US. <https://doi.org/10.1007/s11116-019-10047-1>
- Bravo-Jaico, J., Maquen-Niño, G. L. E., Germán, N., Valdivia, C., Alarcón, R., Aquino, J., & Serquén, O. (2025). Assessing digital transformation maturity in higher education institutions: a correlational analysis by actors and dimensions. *Frontiers in Computer Science*, 7, 1549262.

<https://doi.org/10.3389/FCOMP.2025.1549262/BIBTEX>

Campos Vasquez, N., Cueva Clemente, C., Bautista Zuñiga, L., & Sotomayor Burga, J. (2021). *Métodos Algorítmicos para la optimización de rutas en el Sistema del Transporte Urbano*. 1–9. <https://doi.org/10.18687/LEIRD2021.1.1.32>

Chen, R., Yang, B., Li, S., & Wang, S. (2020). A self-learning genetic algorithm based on reinforcement learning for flexible job-shop scheduling problem. *Computers & Industrial Engineering*, 149(January), 106778. <https://doi.org/10.1016/j.cie.2020.106778>

Cruz-Piris, L., Marsa-Maestre, I., & Lopez-Carmona, M. A. (2019). A Variable-Length Chromosome Genetic Algorithm to Solve a Road Traffic Coordination Multipath Problem. *IEEE Access*, 7, 111968–111981. <https://doi.org/10.1109/ACCESS.2019.2935041>

De-La-Cruz-VdV, P., Arce-Esteban, D., Fajardo-Inca, M., Vega-Huerta, H., Maquen-Niño, G. L. E., & Barrera-Cajachagua, M. L. (2025). Web Scraping and Machine Learning Applied to Decision-Making: A Systematic Review. In Y. Iano, O. Saotome, R. Arthur, M. A. Quispe-Barra, M. Z. Vizuite, K. K. Patel, & G. de Oliveira (Eds.), *Proceedings of the 10th Brazilian Technology Symposium (BTSym '24)* (pp. 236–247). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-92651-8_25

De-la-cruz-vdv, P., Carhuavilca-carlos, M., Vega-huerta, H., Moquillaza-Henriquez, S., Cámara-figueroa, A., Cancho-Rodriguez, E., & Maquen Niño, G. (2023). *Robotic Automation of Application Registry Processes in State Organizations*. 12(6). <https://doi.org/10.18178/ijeetc.12.6.442-449>

García de los Salmenes, M. del M., Herrero, Á., & Martínez García de Leaniz, P. (2025). The intention to share a sustainability communication about a tourism destination. *Spanish Journal of Marketing - ESIC*, 29(3), 371–398. <https://doi.org/10.1108/SJME-01-2024-0003>

Hassanat, A., Almohammadi, K., Alkafaween, E., & Abunawas, E. (2019). *Choosing Mutation and Crossover Ratios for Genetic Algorithms — A Review with a New Dynamic Approach*. <https://doi.org/10.3390/info10120390>

Huarote Zegarra, R. E., Vega Luján, Yensi, R., Valencia Mónica, P., Castañeda Hilario, A., Flores Masías, E. J., Larios Franco, A. C., & Jhonatan Isaac, V. H. (2021). Genetic Algorithm for Geographic Route Optimization. *Proceedings of the LACCEI International Multi-Conference for Engineering, Education and Technology, 2021-July*. <https://doi.org/10.18687/LACCEI2021.1.1.541>

Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm : past , present , and future. *Multimedia Tools and Applications*, 80(6), 8091–8126. <https://doi.org/10.1007/s11042-020-10139-6>

López-Córdova, F., Vega-Huerta, H., Maquen-Niño, G., Cáceres-Pizarro, J., Adrianzén-Olano, I., & Benito-Pacheco, O. (2025). Construction of a New Data Set of Pleural Fluid Cytological Images for Research. *International Journal of Online and Biomedical Engineering*, 21(7), 138–151. <https://doi.org/10.3991/ijoe.v21i07.54323>

Mohammed, M., Abd Ghani, M., Hamed, R., Mostafa, S., Ahmad, M., & Ibrahim, D. (2017). Solving vehicle routing problem by using improved genetic algorithm for optimal solution. *J Comput Sci*, 21, 255–262. <https://doi.org/10.1016/j.jocs.2017.04.003>

Municipalidad de Lima. (2023). *Parque de las Leyendas*. Patronato Del Parque de Las Leyendas Felipe Benavides Barreda. <https://leyendas.gob.pe>

MyMov. (2022). *IA y algoritmos genéticos en logística urbana de última milla*. Tecnología. <https://mymov.app/tecnologia/ia-algoritmos-geneticos-problema-vrptw/%0A%0A>

Perez Ruiz, W. (2007). *Parque de Las Leyendas: Una expresión del Perú*.

Rina, D., & Joby, T. (2024). Analyzing the Virtual Reality Experiential Dimensions at the Game Centers of Tourist Destinations. *Revista Turismo & Desenvolvimento*, 46, 213–235. <https://doi.org/10.34624/RTD.V46I0.33373>

Rodrigues, V., Stevic, I., & Breda, Z. (2022). Smart and 4.0 paradigms fostering innovation dynamics within tourism destinations. *Revista Turismo & Desenvolvimento*, 39, 65–82. <https://doi.org/10.34624/RTD.V39I0.27694>

Rodríguez Cevallos, M., Andrade-Albán, M., Maldonado Palacios, R., & Cobos-Cevallos, C. (2020). *Implementación de un algoritmo genético mediante una aplicación informática basado en la computación neuronal y evolutiva para obtener el cromosoma mejor adaptado*. 8, 116–131. <https://revista.redipe.org/index.php/1/article/view/1045/949>

- Rodríguez Correa, P., Valencia-Arias, A., Garcés-Giraldo, L. F., Rodríguez, L. D. R. C., López, G. A. M., & Benjumea-Arias, M. (2023). Tendencias en el uso de inteligencia artificial en el sector del turismo. *Revista Turismo & Desarrollo*, 40, 81–92. <https://doi.org/https://doi.org/10.34624/rtd.v40i0.31447>
- Sancho Caparrini, F. (2019). *Algoritmos Genéticos*. Dpto. de Ciencias de La Computación e Inteligencia Artificial Universidad de Sevilla. <http://www.cs.us.es/~fsancho/?e=65>
- Sharon Treasa, A., & Bindu Vazhakkatte, T. (2023). Tourism Disaster Management through Chatbots as an Alternative Tool of Communication. *Revista Turismo & Desarrollo*, 41, 349–367. <https://doi.org/10.34624/RTD.V41I0.30195>
- Suresh, A., Wartman, M., Rasheed, A. R., & Macreadie, P. I. (2025). Tourism and recreation in blue carbon ecosystems: Exploring synergies, trade-offs and pathways to sustainability. *Ocean and Coastal Management*, 266, 107697. <https://doi.org/10.1016/j.ocecoaman.2025.107697>
- Thangiah, S. R. (2014). *Vehicle Routing with Time Windows using Genetic Algorithms*. August 1995. <https://doi.org/10.1201/9781420050073.ch11>
- Trujillo-González, J. (2019). Algoritmo genético aplicado al turismo de Panamá. *Investigación y Pensamiento Crítico*, 12(1), 41–47. <https://doi.org/10.37387/IPC.V12I1.373>
- Vega-Huerta, H., Chunga-Vargas, M., Guerra-Grados, L., Lázaro-Guillermo, J., Benito-Pacheco, O., Pantoja-Collantes, J., & Gil-Calvo, R. (2025). Web System with Gamification to Enhance Reading Comprehension in a Secondary-Level Educational Institution. *Ingenierie Des Systemes d'Information*, 30(1), 61–70. <https://doi.org/10.18280/isi.300106>
- Vega-Huerta, H., Gutierrez-Mejía, F., Calcina-Aguilar, B., Benito-Pacheco, O., De-La-Cruz-Vdv, P., Maquen-Niño, G. L. E., & Lázaro-Guillermo, J. C. (2025). ChatGPT-Based Conversational Artificial Intelligence System for Virtual University Admissions Office Client Attention. *Ingenierie Des Systemes d'Information*, 30(4), 945–952. <https://doi.org/10.18280/isi.300411>
- Vega-huerta, H., Iturre, D. M., Zegarra, P. P., Palomino, R. T., Sanchez, N. Y., Maquen-niño, G. L. E., & Pantoja-collantes, J. (2025). Intelligent Facial Recognition System for Vehicles. *Springer International Publishing*. https://doi.org/https://doi.org/10.1007/978-981-97-3859-5_9
- Vega-huerta, H., Marlon Pillaca, P., Velasquez-Quiroz, R., Maquen-niño, G., Camara-figueroa, A., Pantoja-collantes, J., & Gil-calvo, R. (2023). *Reconocimiento facial mediante aprendizaje por transferencia para el control de acceso a áreas restringidas*. 261–273.
- Vega-Huerta, H., Vilca Velasquez, J., Anicama Espinoza, N., Maquen-Niño, G. L. E., Guerra-Grados, L., Pantoja-Collantes, J., Benito-Pacheco, O., Lázaro-Guillermo, J. C., Camara-Figueroa, A., Cabrera-Díaz, J., Gil-Calvo, R., & López-Córdova, F. (2025). Mobile application based on KDD to predict high-crime areas and promote sustainability in citizen security in a district of Lima-Perú. *Frontiers in Computer Science*, 7(August), 1–13. <https://doi.org/10.3389/fcomp.2025.1585632>
- Wang, H., Li, W., Hou, Y., Li, M., & Lee, S. (2022). *The Construction of Urban Park Green Infrastructure Network Based on Genetic Algorithm*. 2022. <https://doi.org/https://doi.org/10.1155/2022/9719633>
- Yang, Z., Li, J., & Li, L. (2020). *Time-Dependent Theme Park Routing Problem by Partheno-Genetic Algorithm*. <https://doi.org/10.3390/math8122193>
- Zhou, Y., Wang, Y., Wang, K., Kang, L., Peng, F., Wang, L., & Pang, J. (2020). Hybrid genetic algorithm method for efficient and robust evaluation of remaining useful life of supercapacitors. *Appl Energy*, 260. <https://doi.org/10.1016/j.apenergy.2019.114169>