



Evaluación de Estrategias Metaheurísticas en la Planificación de Rutas para Robots

Dizahab Sehuveret Hernández, Jorge A. García Muñoz, Alejandro I. Barranco Gutiérrez

RESUMEN / ABSTRACT

Los Vehículos Autónomos Terrestres son fundamentales para diversas industrias, requiriendo una planificación de rutas eficiente para el éxito de la misión sin intervención humana. Este estudio evalúa dos enfoques de optimización metaheurística, Algoritmos Genéticos y Optimización por Colonias de Hormigas, en el contexto de la planificación de rutas para estas estructuras robóticas. La metodología integral emplea diseños de estos métodos metaheurísticos, y se lleva a cabo un análisis comparativo mediante experimentos simulados en entornos diversos. Los resultados revelan que los Algoritmos Genéticos sobresalen en terrenos simples, mientras que la Optimización por Colonia de Hormigas demuestra capacidades de exploración robustas en entornos complejos con obstáculos y restricciones adicionales. Esto subraya la importancia de seleccionar la metaheurística adecuada basada en requisitos específicos de la misión y condiciones ambientales. La investigación brinda información a diseñadores y operadores, permitiendo tomar decisiones fundamentadas para la selección de estrategias de planificación de rutas, mejorando así la eficiencia y seguridad de las operaciones robóticas autónomas en diversos escenarios.

Palabras claves: Algoritmos genéticos; Metaheurística; Optimización por colonia de hormigas; Planificación de caminos; Robots móviles; Vehículos autónomos terrestres

Autonomous Ground Vehicles play a vital role in various industries, necessitating efficient route planning for mission success without human intervention. This study examines two metaheuristic optimization approaches, Genetic Algorithms and Ant Colony Optimization, within the context of route planning for these robotic entities. The comprehensive methodology utilizes the designs of these metaheuristic methods, and a comparative analysis is conducted through simulated experiments in diverse environments. The findings unveil that Genetic Algorithms excel in simple terrains; while Ant Colony Optimization demonstrates robust exploration capabilities in complex environments with obstacles and additional constraints. This underscores the importance of selecting the appropriate metaheuristic based on specific mission requirements and environmental conditions. The research furnishes insights to designers and operators, enabling informed decisions in route planning strategy selection, thereby enhancing the efficiency and safety of autonomous robotic operations across various scenarios.

Keywords: *Ant colony optimization; Autonomous ground vehicles; Genetic algorithms; Metaheuristic; Movil robots; Path planning*

Evaluation of Metaheuristic Strategies in Robot Path Planning.

Recibido: 08/2023 Aceptado: 11/2023

1. -INTRODUCCIÓN.

Los Vehículos Autónomos Terrestres (AGV, *Autonomous Ground Vehicles*) son sistemas robóticos avanzados diseñados para navegar y operar en tierra sin intervención humana. Estos vehículos utilizan una combinación de sensores avanzados, inteligencia artificial y algoritmos de control para llevar a cabo disímiles tareas, que abarcan desde logística y agricultura hasta defensa y manufactura. La planificación de rutas para un AGV es una tarea de gran relevancia en diversos contextos industriales y logísticos. La eficiencia de esta planificación es esencial, puesto que un diseño de ruta inadecuado puede conllevar a colisiones, daños al equipo y un uso ineficiente de la energía. La literatura científica ha hecho numerosas referencias a esta cuestión [1-6], subrayando su importancia y su desafío inherente.

Para poder realizar un seguimiento de caminos sin restricciones temporales, el diseño de rutas se enfrenta a dos objetivos fundamentales. El primero es la evasión de obstáculos, que garantiza la seguridad y la integridad física del robot durante su trayecto. El segundo objetivo es minimizar la longitud de la ruta, que contribuye a la eficiencia en términos de tiempo y consumo de energía. Estos dos objetivos confluyen en un problema de optimización.

Para abordar eficazmente este desafío de planificación de rutas, se han desarrollado diversas estrategias, que varían en su nivel de complejidad, precisión y aplicabilidad. Entre estas estrategias, destacan los métodos metaheurísticos, los cuales se derivan de conceptos relacionados con la inteligencia artificial y técnicas estadísticas. Estos métodos ofrecen una perspectiva distinta, al tratar la planificación como un problema de búsqueda donde hay que encontrar, dentro de un amplio espacio de soluciones posibles, aquella solución que optimice ciertos parámetros físicos o alguna combinación de estos.

Para llegar a la solución óptima, los métodos metaheurísticos hacen uso de estrategias de diversificación e intensificación del espacio de búsqueda. La diversificación se refiere a la capacidad para investigar rápidamente zonas del espacio de búsqueda que no han sido consideradas aún. El proceso de intensificación se centra en perfeccionar las soluciones encontradas para incrementar su calidad. El rendimiento del método depende en gran medida de su capacidad para equilibrar estas dos estrategias [7], lo que se logra a través de la selección cuidadosa de los operadores del algoritmo.

A veces, estos métodos pueden tener inconvenientes computacionales, como demasiados parámetros de control, convergencia prematura y tiempo de ejecución elevado [8,9]. Sin embargo, pueden favorecer un correcto diseño del controlador, evitando cálculos exhaustivos y aportando ventajas como robustez, amplia capacidad de búsqueda global y búsqueda paralela [10].

Este artículo presenta las bases de dos de los métodos metaheurísticos más utilizados en la literatura para resolver problemas de optimización: Algoritmos Genéticos (GA, *Genetic Algorithms*) [11] y Optimización por Colonia de Hormigas (ACO, *Ant Colony Optimization*) [10,12]. En general, estos métodos representan polos opuestos en lo que respecta a su enfoque de búsqueda. GA se caracteriza por adoptar una perspectiva esencialmente determinista, que favorece la intensificación a través de la adaptación gradual de las generaciones al medio ambiente. En contraste, ACO hace amplio uso de la estocasticidad, donde la incorporación de elementos aleatorios o probabilísticos fomenta activamente la diversificación. Estos enfoques, sin embargo, pueden ser modificados a intención del diseñador.

La mayoría de los estudios previos en este tema se centran en evaluar algoritmos para escenarios específicos o bajo condiciones preestablecidas; sin embargo, la particularidad de este trabajo es que adopta un enfoque diferente. Su objetivo principal es comparar los métodos seleccionados en entornos de complejidad variable, lo que permite identificar las situaciones donde cada uno exhibe un desempeño óptimo. Esta perspectiva ofrece una comprensión más completa y aplicable de cómo estos algoritmos pueden ser utilizados en diferentes contextos, lo que potencialmente impulsará avances significativos en la eficiencia y seguridad de las operaciones robóticas autónomas.

El artículo examina el rendimiento de los métodos presentados en módulos de planificación de rutas formadas por tramos rectos, basándose en experimentos simulados.

2.- METODOLOGÍA.

2.1.- MODELO DEL AMBIENTE.

Para llevar a cabo la planificación de rutas de manera efectiva, es esencial contar con un modelo del entorno en el que los AGV operarán o, en su defecto, tener la capacidad de estimarlo con precisión. Existen diversas representaciones posibles del entorno y, en este contexto, se opta por un mapa de cuadrícula bidimensional [13]. En este modelo, el entorno se describe mediante una imagen cenital que se traduce en una matriz de valores binarios, como se ilustra en la Fig. 1. La complejidad

del entorno está determinada por la cantidad y distribución de los obstáculos, pues un terreno que requiere más maniobras evasivas se considera más complejo de navegar.

Una ruta se define, entonces, como un conjunto finito de celdas accesibles conectadas en el mapa de cuadrícula. Matemáticamente, se representa mediante un vector que contiene las coordenadas de las celdas extremas de los segmentos de la ruta, también conocidas como nodos.

Los siguientes epígrafes describen la teoría implementada en cada método metaheurístico seleccionado.

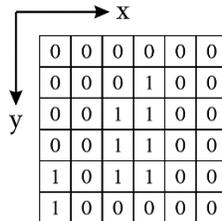


Figura 1

Representación en cuadrículas de una imagen cenital del ambiente, donde “ceros” denotan áreas libres y “unos” indican obstáculos.

2.2.- ALGORITMOS GENÉTICOS.

Un Algoritmo Genético es una técnica de optimización y búsqueda basada en principios inspirados en la evolución biológica [14-16]. Su base teórica se deriva de la teoría de la evolución de Darwin, donde las soluciones a un problema se representan como “cromosomas” que codifican posibles soluciones. Estos cromosomas son sometidos a procesos que simulan la reproducción, mutación y selección natural para generar mejores soluciones en cada generación.

En su funcionamiento, un conjunto inicial de soluciones candidatas, conocido como población, se crea aleatoriamente. Luego, en cada iteración, las soluciones se evalúan en función de un criterio objetivo, y se seleccionan para reproducirse proporcionalmente a su aptitud. El criterio utilizado para la evaluación de las soluciones se muestra en la Ecuación 1.

$$F_{sol} = \omega_l l + \omega_c c \quad (1)$$

Esta expresión algebraica se compone de dos partes. l representa la longitud total del camino que se genera y c , la cantidad de colisiones ocurridas a lo largo del recorrido. $\omega_l > 0$ y $\omega_c > 0$ son pesos que indican la prioridad de cada uno de estos elementos en la evaluación general de la solución. F_{sol} debe minimizarse con el paso de las generaciones para alcanzar los objetivos de optimización.

Una vez seleccionadas las parejas de soluciones padres se produce la recombinación genética, que simula la reproducción (sexual o asexual, en dependencia del operador de cruce *CROSS*). En este punto se combinan las características de dos soluciones seleccionadas para producir una descendencia, en la Fig. 2 se muestra el esquema de cruce sexual empleado en este trabajo. En menor medida, la descendencia sufre cambios aleatorios mediante la mutación.

El proceso se repite generación a generación hasta que la producción de nuevos cromosomas arroje una solución adecuada.

Los GA se caracterizan por una serie de parámetros clave que influyen en su rendimiento. Estos incluyen el tamaño de la población (N), que determina cuantas soluciones se mantienen en cada generación; la tasa de mutación (*MUT*), que regula la probabilidad de que una solución sufra cambios aleatorios; y el operador de selección (*SEL*), que define como se eligen las soluciones para la reproducción. La elección de estos parámetros y operadores puede afectar significativamente el comportamiento del algoritmo y su capacidad para converger hacia soluciones óptimas.

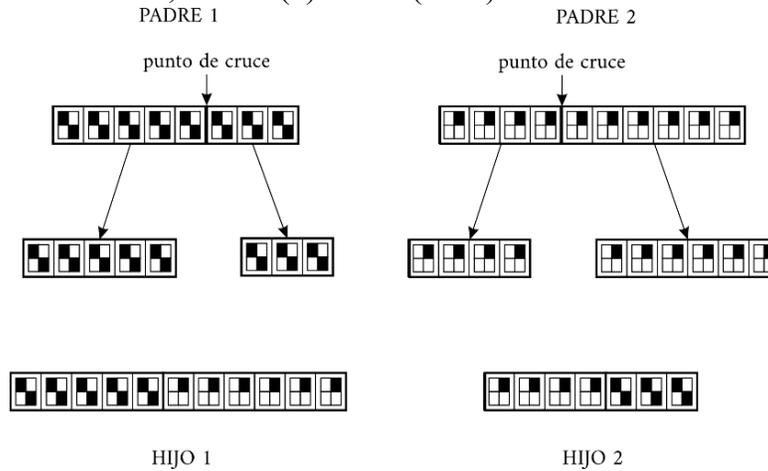


Figura 2

Esquema de recombinação que ilustra la división de cromosomas parentales en un punto y la formación de cromosomas hijos mediante la unión de sus fragmentos, garantizando la herencia de características de ambos padres.

2.3.- ALGORITMOS GENÉTICOS MODIFICADOS. GA+

Habitualmente se complementan las operaciones de reproducción con otras operaciones, llamadas operaciones de remplazo, con la finalidad de mejorar el comportamiento de los valores de evaluación a través de las iteraciones. Dos modificaciones se proponen en este artículo:

- **Elitismo:** Es usual en GA incluir procedimientos que funcionen como un “ancla” para las mejores soluciones de la población. Como el método utilizado para el proceso de selección incluye cálculo de probabilidades, existe una posibilidad real de que el mejor individuo de una generación se pierda y no forme parte de la siguiente. Para evitar lo anterior se impone, en la población generada, el remplazo de los peores individuos descendientes por los mejores padres, siempre y cuando los padres posean mayor aptitud que los hijos que se remplazan [17].
- **Migración:** Cada vez que se crea una nueva generación, un parámetro *MIG* regula la inclusión de nuevos individuos generados al azar. Los individuos inmigrantes remplazan a los de peor evaluación, si resultan ser más aptos que estos últimos. La migración se utiliza para aumentar aún más de diversidad de la población y evitar el estancamiento del algoritmo [18].

La estrategia resultante de incorporar estas operaciones de remplazo es conocida como GA+ (*Genetic Algorithms plus*).

2.4.- OPTIMIZACIÓN POR COLONIA DE HORMIGAS.

La Optimización por Colonia de Hormigas es un método de búsqueda heurística perteneciente a la familia de la inteligencia de enjambre, inspirado en el comportamiento de búsqueda de alimento de las hormigas en la naturaleza [19,20]. En su búsqueda de alimentos, las hormigas depositan feromonas y ajustan sus movimientos basándose en la concentración de feromonas en su entorno. Aquellas hormigas que encuentran la ruta más corta hacia el alimento regresan al nido rápidamente, lo que aumenta la cantidad de feromonas depositadas en ese camino. Con el tiempo, este proceso elimina las rutas más largas y guía a las hormigas hacia el camino más corto. De manera análoga, ACO emplea M hormigas artificiales para navegar desde la ubicación inicial del vehículo hasta su destino, evitando obstáculos y modificando un mapa de feromonas artificiales en el proceso. Después de múltiples iteraciones, la distribución de feromonas en el mapa orienta a todas las hormigas hacia la solución óptima.

Cada hormiga puede moverse en un máximo de ocho direcciones, correspondientes a las celdas vecinas, mientras que el movimiento no provoque colisiones o choques con los extremos del mapa. En la iteración t , la hormiga g se traslada desde su celda actual e a una celda f según una regla de probabilidad de transición detallada en la Ecuación 2. En esta ecuación, $\tau_{ef}(t)$ representa la concentración de feromonas entre e y f y, $\eta_{ef}(t)$ es una función heurística que refleja la conveniencia del movimiento hacia f . α y β son coeficientes del algoritmo, que determinan la influencia relativa del rastro de feromonas y de la información heurística, respectivamente. B representa el conjunto de todos los nodos candidatos para los que la hormiga tiene una oportunidad real de trasladarse.

$$p_{ef}^g = \begin{cases} \frac{[\tau_{ef}(t)]^\alpha [\eta_{ef}(t)]^\beta}{\sum_{s \in \mathcal{B}} [\tau_{es}(t)]^\alpha [\eta_{es}(t)]^\beta} & j \in \mathcal{B} \\ 0 & j \notin \mathcal{B} \end{cases} \quad (2)$$

Después de que todas las hormigas completen su ciclo, los niveles de feromonas se disipan gradualmente y se renuevan mediante la Ecuación 3. El coeficiente ρ controla la tasa de disipación ($0 < \rho < 1$), y \mathcal{P} comprende todas las hormigas que pasaron por el segmento $e - f$. La contribución de feromonas de la hormiga g al segmento es inversamente proporcional a la longitud total del camino (L).

$$\tau_{ef}(t+1) = (1 - \rho)\tau_{ef}(t) + \sum_{g \in \mathcal{P}} \frac{1}{L} \quad (3)$$

El algoritmo finaliza después de It_{max} iteraciones.

2.5.- OPTIMIZACIÓN POR COLONIA DE HORMIGAS MODIFICADA. IACO.

ACO suele involucrar operaciones matemáticas complejas que pueden afectar de manera negativa su rendimiento. Se han desarrollado versiones mejoradas del algoritmo para simplificar estas operaciones. Este artículo introduce las siguientes modificaciones clave:

- **Simplificación del Mapa de Feromonas:** Usualmente, el mapa de feromonas se representa como una matriz multidimensional basada en los segmentos potenciales que las hormigas pueden atravesar. Sin embargo, se puede simplificar transformándolo en una matriz bidimensional del tamaño del modelo del ambiente, donde la notación $\tau_{ef}(t)$ se reduce a $\tau_f(t)$ [21].
- **Paso de Longitud Libre:** ACO originalmente establece la longitud de paso como la distancia entre celdas adyacentes, lo que limita las opciones de movimiento y reduce la velocidad de convergencia. Para superar estos desafíos, se adopta la noción de paso de longitud libre [22]. En lugar de restringir el movimiento a celdas adyacentes, las hormigas pueden realizar movimientos más extensos determinados por un valor rv , que representa la extensión de cierto entorno llamado rango visual, como se muestra en la Fig. 3. La función heurística $\eta_{ef}(t)$ se ajusta en consecuencia, premiando movimientos que se acerquen al destino.

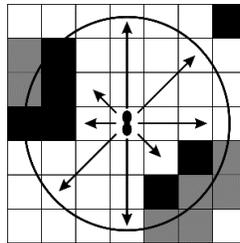


Figura 3

La hormiga se puede desplazar en las direcciones permitidas dentro de la circunferencia o rango visual, evitando obstáculos (celdas negras) y áreas bloqueadas (celdas grises).

El algoritmo resultante de incorporar estas adaptaciones es conocido como IACO (*Improved Ant Colony Optimization*).

3.- RESULTADOS Y DISCUSIÓN.

Para evaluar la eficacia de los algoritmos en la planificación de trayectorias, se llevan a cabo experimentos simulados utilizando la herramienta de software Matlab. Las variables seleccionadas para evaluar el rendimiento son el tiempo total de ejecución hasta que se alcanza una ruta adecuada y el valor alcanzado de longitud de la ruta.

Los métodos de optimización se ejecutan 500 veces en tres escenarios diferentes para evitar la aleatoriedad en los datos. Los escenarios difieren en la cantidad de obstáculos y en las distribuciones que presentan:

- Escenario 1: Este entorno es el menos complejo de los tres utilizados y consta de un solo obstáculo.
- Escenario 2: Este entorno tiene una complejidad moderada y presenta cinco obstáculos con formas regulares.
- Escenario 3: En este entorno, aumenta tanto la cantidad de obstáculos como su complejidad geométrica. Presenta ocho obstáculos con diversas formas.

Cada uno de estos entornos se modela como un mapa de celdas de 100×100. El vehículo inicia su trayectoria cerca de la esquina superior izquierda del terreno y finaliza cerca de la esquina inferior derecha.

La calibración inicial de los parámetros de diseño se realiza de acuerdo con las pautas establecidas en la bibliografía [22,23]. A partir de ahí, se ajustan mediante procedimientos empíricos. En la Tabla 1 se muestran los parámetros seleccionados.

Tabla 1
Parámetros de diseño seleccionados para los algoritmos.

	GA+				IACO		
	Esc. 1	Esc. 2	Esc. 3		Esc. 1	Esc. 2	Esc. 3
N	300	500	4000	M	20	20	20
SEL	3	3	30	It_{max}	50	50	50
$CROSS$	0.8	0.8	0.8	rv	25	25	25
MUT	0.05	0.05	0.050	α	1	1	1
MIG	0.1	0.1	0.1	β	6	6	6
ω_l	1	1	1	ρ	0.3	0.3	0.3
ω_c	0.0001	0.0001	0.0001				

La Fig. 4 muestra la mejor trayectoria generada por cada algoritmo en los tres escenarios discutidos.

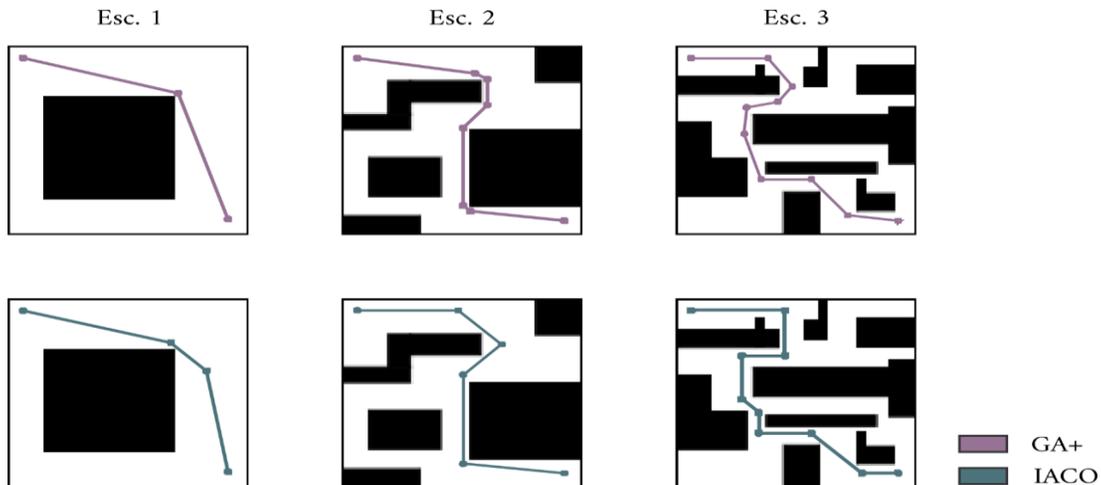


Figura 4

Mejores caminos generados por los algoritmos para cada escenario considerado.

De acuerdo con los resultados de longitud óptima mostrados en la Tabla 2, ambos algoritmos tienen la capacidad de minimizar correctamente la distancia si se permite un número suficientemente grande de iteraciones. Sin embargo, la propuesta de GA+ proporciona trayectorias generadas con longitudes más cortas que IACO.

Tabla 2
Parámetros de diseño seleccionados para los algoritmos.

	GA+			IACO		
	Esc. 1	Esc. 2	Esc. 3	Esc. 1	Esc. 2	Esc. 3
l_{min}	137.268	167.273	173.480	138.802	176.600	190.044
\bar{l}	139.153	170.433	183.866	146.279	182.763	199.906
l_{max}	140.769	233.683	197.190	161.456	187.740	210.527
σ_l	0.996	4.325	2.619	2.293	2.176	3.584
Q_1	138.602	169.366	182.484	145.907	181.338	197.435
Q_2	139.290	169.689	184.231	147.397	182.853	200.132
Q_3	139.990	170.219	185.458	147.397	184.371	202.385
\bar{t}	0.028	0.667	10.571	1.185	2.155	3.495
σ_c	0.010	0.264	3.776	0.096	0.127	0.226

La Fig. 5 es una presentación gráfica de los datos de longitud en diagramas de violín. Un diagrama de violín se utiliza para visualizar la distribución de los datos y su densidad de probabilidad. Es particularmente útil para interpretar muestras en las que puede existir asimetría estadística, pues disminuye en el análisis la influencia de valores atípicos. La forma característica de este tipo de gráficas muestra la distribución de densidad de los datos [24]. En cada diagrama, el intervalo intercuartil de la muestra ($Q_3 - Q_1$) se representa por una sombra dentro del cuerpo de la campana y se interpreta como una medida visual de la dispersión del conjunto de datos. Un segmento recto indica el valor de la mediana de la muestra, que corresponde al segundo cuartil registrado (Q_2).

En primer lugar, es esencial señalar algunos datos atípicos generados por IACO en el primer escenario y por GA+ en el segundo escenario, que justifican la utilización de los diagramas de violín para el análisis. Estos valores extremos afectan negativamente los valores de distancia media y desviación estándar.

En el Escenario 1, IACO proporciona distancias más largas y una mayor dispersión de datos. En el diagrama, la mediana y los valores máximos de IACO son iguales, lo que implica que aproximadamente el 50% de las ejecuciones devuelven soluciones más grandes. Por otro lado, GA+ presenta valores más bajos de media, mediana y dispersión de la muestra.

En el segundo escenario de evaluación, IACO continúa generando rutas planificadas más extensas y presenta una desviación cuartil más alta. En contraste, GA+ muestra un rendimiento más eficaz en la reducción de la longitud de la trayectoria, logrando una distancia media de 170.433 unidades y una desviación cuartil de 0.853 unidades. Estos valores estadísticos representan una disminución del 6.7% y del 71.9% en comparación con los respectivos valores obtenidos por IACO. Nótese que el comportamiento de GA+ es particularmente favorable: la moda de la muestra se encuentra en el primer cuartil de la distribución lo que implica que tiende a generar menores datos de distancia para este entorno.

IACO exhibe, una vez más, los valores más altos en las tendencias estadísticas en el Escenario 3. La longitud media de las trayectorias generadas por IACO es de 199.906 unidades, lo que representa un aumento del 8.7% en comparación con la longitud media producida por GA+. Estos hallazgos resaltan las diferencias significativas en el desempeño de ambos algoritmos en entornos de complejidad creciente.

El hecho de que IACO converja hacia valores de longitud mayores que GA+ no debe asociarse a la presencia de un mínimo local que el algoritmo no pueda superar. Las gráficas de la Fig. 5 presentan características unimodales en la distribución de datos, sugiriendo que no existe tal mínimo local. Esta diferencia puede ser el resultado de otros factores que reducen la movilidad de las hormigas, como son las restricciones impuestas en las direcciones de movimiento.

Un retraso excesivo por parte del módulo de planificación de trayectorias puede influir negativamente en el rendimiento y la estabilidad de los módulos de control subsiguientes implementados en el vehículo. Por lo tanto, llevar a cabo un análisis del tiempo de ejecución es esencial. La Fig. 6 contiene una representación gráfica de los datos de tiempo de la Tabla 2.

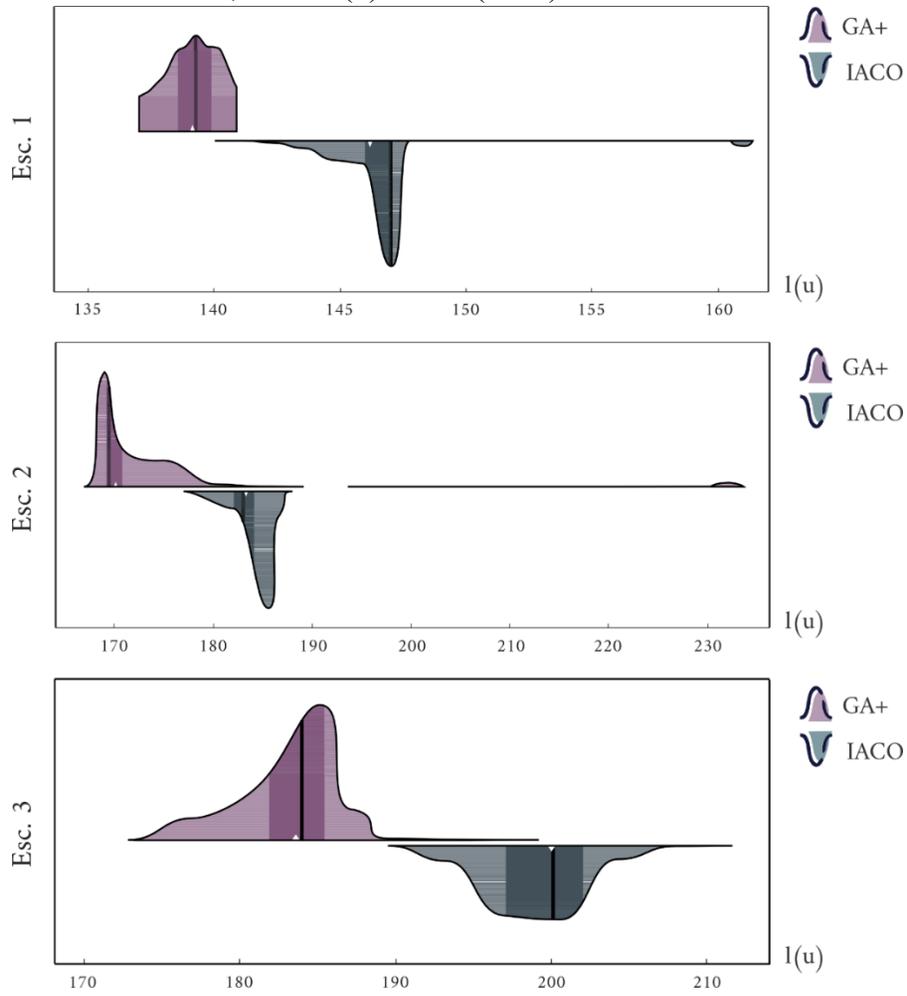


Figura 5

Comparación de longitudes de ruta obtenidas para los escenarios considerados. Los perfiles de violín representan la distribución de las longitudes en unidades de celdas que ocupan (u), con campanas orientadas hacia arriba para GA+ y hacia abajo para IACO.

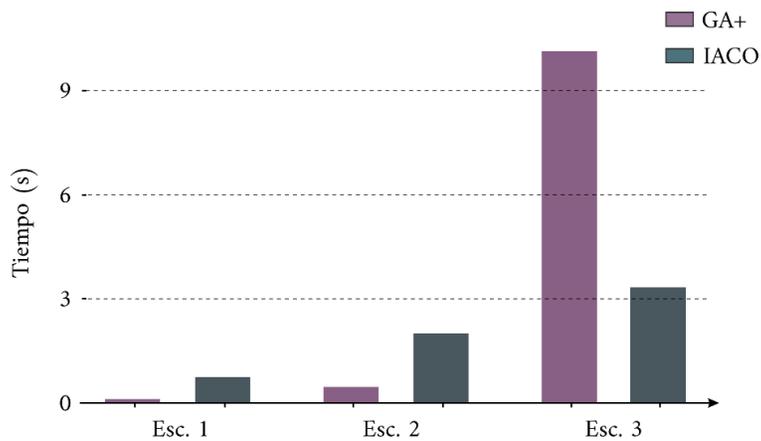


Figura 6

Tiempos medios de ejecución de los algoritmos para cada escenario, en segundos (s).

IACO muestra un tiempo medio de ejecución más alto en entornos más simples, lo cual es esperado debido a que las probabilidades de selección de nodos implican numerosas operaciones computacionales en cada iteración. Por otro lado, IACO utiliza solo trayectorias libres de colisiones para la búsqueda, tratando los dos objetivos de planificación de manera separada. Este enfoque, en general, perjudica el tiempo de ejecución, pero le proporciona robustez ante cambios en la complejidad de la trayectoria. Nótese el comportamiento casi lineal que exhibe el aumento del tiempo de ejecución al complejizarse el escenario.

Por su parte, el rendimiento de GA+ en términos de tiempo medio de ejecución se degrada significativamente a medida que el entorno se vuelve más complejo. En el Escenario 3 GA+ se ejecuta, en promedio, quince veces más lento que en el Escenario 2 y trescientas setenta y ocho veces más lento que en el Escenario 1. Esto se debe a que GA+ incluye los dos objetivos de control en la función de evaluación. Por lo tanto, la expansión de las áreas de obstáculos aumenta el número de soluciones inválidas y dificulta la búsqueda de soluciones. Esto produce un mayor gasto de tiempo y recursos.

Cuando se trata de entornos complejos, es esencial tener en cuenta tanto la precisión requerida por la misión como la dinámica del sistema de guía y control. En términos generales, se observa que el aumento en el tiempo de ejecución en GA+ es significativamente mayor que la reducción en la distancia lograda en comparación con IACO. Por lo tanto, es recomendable el uso de IACO en la planificación de trayectorias para entornos complejos, a menos que los requisitos específicos de la misión indiquen lo contrario.

3.- CONCLUSIONES.

La tarea de planificación de trayectorias para un Vehículo Terrestre Autónomo (AGV) implica minimizar la longitud del recorrido y evitar obstáculos. Este artículo realiza una comparación entre dos métodos metaheurísticos para resolver el problema de planificación de trayectorias en un escenario bidimensional. Se utiliza un método de cuadrícula para modelar el entorno y se llevan a cabo diversas simulaciones en terrenos operativos variados. Al estudiar las estrategias de optimización, se observa que las técnicas metaheurísticas pueden adaptarse con éxito para encontrar una ruta óptima. Sin embargo, los experimentos demuestran que, en comparación con IACO, GA+ funciona mejor en la búsqueda de soluciones en escenarios de complejidad menor o media. A medida que aumenta la zona de obstáculos, el rendimiento mencionado anteriormente se deteriora rápidamente; por lo tanto, IACO es preferible en escenarios altamente complejos.

AGRADECIMIENTOS

Los autores agradecen sinceramente el apoyo financiero proporcionado por CONACHyT (Consejo Nacional de Ciencia y Tecnología, en México) a través de la beca otorgada a Dizahab Sehuveret Hernández para sus estudios de posgrado. Este apoyo ha sido invaluable para facilitar sus metas académicas y contribuir al éxito tanto de los proyectos de investigación en curso como de este artículo.

REFERENCIAS

1. Xiangde L, Xiang Z, Yi Z, Hua L, Wentao H. Global Dynamic Path Planning Algorithm Based on Harmony Search Algorithm and Artificial Potential Field Method. In: IEEE 6th Information Technology and Mechatronics Engineering Conference; 2022. p. 346-51.
2. Quan Y, Wei W, Ouyang H, Lan X. New Harmony Search Algorithm for Mobile Robot Path Planning. In: Yan L, Duan H, Yu X, editors. Advances in Guidance, Navigation and Control. Singapore: Springer Singapore; 2022. p. 3463-73.
3. Xiao J, Yu X, Sun K, Zhou Z, Zhou G. Multiobjective path optimization of an indoor AGV based on an improved ACO-DWA. *Mathematical Biosciences and Engineering*. 2022;19(12).
4. Charis N, Lyridis DV. A comparative study on Ant Colony Optimization algorithm approaches for solving multi-objective path planning problems in case of unmanned surface vehicles. *Ocean Engineering*. 2022;255(111418).
5. Bautista-Camino P, Barranco-Gutiérrez AI, Cervantes I, Rodríguez-Licea M, Prado-Olivarez J, Pérez-Pinal FJ. Local Path Planning for Autonomous Vehicles Based on the Natural Behavior of the Biological Action-Perception Motion. *Energies*. 2022;15(1769):1-23.
6. Candeloro M, Lekkas AM, Sørensen AJ. A Voronoi-diagram-based dynamic path-planning system for underactuated marine vessels. *Control Engineering Practice*. 2017 Apr;61:41-54.
7. Al-omoush AA, Alsewari AA, Alamri HS, Zamli KZ. Comprehensive Review of the Development of the Harmony Search Algorithm and its Applications. *IEEE Access*. 2019 Enero;7:14233-14245.

8. Kumar S, Sikander A. An intelligent optimize path planner for efficient mobile robot path planning in a complex terrain. *Microsystem Technologies*. 2022;28(6).
9. Aghay Kaboli SH, Selvaraj J, Rahim NA. Rain-fall optimization algorithm: A population based algorithm for solving constrained optimization problems. *Journal of Computational Science*. 2017 Mar;19:31-42.
10. Xiaolin D, Long S, Zhang Z, Gong D. Mobile Robot Path Planning Based on Ant Colony Algorithm With A* Heuristic Method. *Frontiers in neurorobotics*. 2019 Apr;13(15):1-9.
11. Xin J, Zhong J, Yang F, Cui Y, Sheng J. An Improved Genetic Algorithm for Path-Planning of Unmanned Surface Vehicle. *Sensors*. 2019 Jun;19:2640.
12. Deng W, Xu J, Zhao H. An Improved Ant Colony Optimization Algorithm Based on Hybrid Strategies for Scheduling Problem. *IEEE Access*. 2019 Feb;7:20281-20292.
13. Wang Q, Li J, Yang L, Yang Z, Li P. Distributed Multi-Mobile Robot Path Planning and Obstacle Avoidance Based on ACO-DWA in Unknown Complex Terrain. *Electronics*. 2022;11(14).
14. Jiménez-Carrión M, Jiménez-Panta AB, Coaquira-Velásquez MA. Algoritmo evolutivo generador de rutas eficientes para el transporte público. *Información tecnológica*. 2023 Feb 1;34(1):71-88.
15. Lamini C, Benhlma S, Elbekri A. Genetic Algorithm Based Approach for Autonomous Mobile Robot Path Planning. *Procedia Computer Science*. 2018;127(2018):180-189.
16. Elhoseny M, Tharwat A, Hassanien AE. Bezier Curve Based Path Planning in a Dynamic Field using Modified Genetic Algorithm. *Journal of Computational Science*. 2018;25:339-350.
17. Guariso G, Sangiorgio M. Improving the Performance of Multiobjective Genetic Algorithms: An Elitism-Based Approach. *Information*. 2020 Dec 18;11(12):587-587.
18. Hao K, Zhao J, Yu K, Li C, Wang C. Path Planning of Mobile Robots Based on a Multi-Population Migration Genetic Algorithm. *Sensors*. 2020 Oct 17;20(20):5873-5873.
19. Ali KW, Kareem SW, Askar SK, Hawezi RS, Khoshabai FS. Metaheuristic Algorithms in Optimization and its Application: A Review. *Journal on Advanced Research in Electrical Engineering*. 2022;6(1).
20. Agrawal A, Sudheer AP, Ashok S. Ant Colony Based Path Planning for Swarm Robots. In: *Proc. of Conference on Advances In Robotics*. AIR '15. Goa, India: ACM; 2015. p. 611-615.
21. Wang L, Kan J, Guo J, Wang C. 3D Path Planning for the Ground Robot with Improved Ant Colony Optimization. *Sensors*. 2019 Feb;19(4):815.
22. Akka K, Khaber F. Mobile robot path planning using an improved ant colony optimization. *International Journal of Advanced Robotic Systems*. 2018 May;15(3):1-7.
23. Kougiaris I, Theodossiou N, Kakoudakis K, Doikos K. Harmony Search Algorithm, a novel optimization technique. Parameter calibration and applications on water resources management problems. In: *Proc. International CEMEPE & SECOTOX Conference*. Skiathos, Grecia; 2011. p. 245-250.
24. Tanious R, Manolov R. Violin plots as visual tools in the meta-analysis of Single-Case Experimental Designs. *Methodology: European Journal of Research Methods for The Behavioral and Social Sciences*. 2022 Sep 30;18(3):221-38.

CONFLICTO DE INTERESES

Ninguno de los autores manifestó la existencia de posibles conflictos de intereses que debieran ser declarados en relación con este artículo.

CONTRIBUCIONES DE LOS AUTORES

Dizahab Sehuveret Hernández: conceptualización, curación de datos, análisis formal, investigación, metodología, administración de proyecto, recursos, software, validación-verificación, visualización, redacción-borrador original, redacción-revisión y edición

Jorge A. García Muñoz: conceptualización, adquisición de fondos, metodología, recursos, supervisión, redacción-revisión y edición

Alejandro I. Barranco Gutiérrez: conceptualización, metodología, recursos, validación-verificación, redacción-revisión y edición

AUTORES

Dizahab Sehuveret Hernández, Ingeniero en Automática, Máster en Ciencias en Ingeniería Electrónica, Instituto Nacional de México en Celaya, Celaya, Gto. México, d2203006@itcelaya.edu.mx, ORCID: <https://orcid.org/0000-0002-1836-2574>, principales intereses de investigación: Análisis de datos, Autotrónica e Inteligencia Artificial.

Jorge Alberto García Muñoz, Ingeniero en Electrónica, Doctor en Ciencias en Ingeniería Eléctrica, Instituto Nacional de México en Celaya, Celaya, Gto. México, jorge.garcia@itcelaya.edu.mx, ORCID: <https://orcid.org/0000-0003-3568-4804>, principales intereses de investigación: Robótica, Inteligencia Artificial y Control.

Alejandro Israel Barranco Gutiérrez, Ingeniero en Telemática, Doctor en Ciencias en Tecnología Avanzada, Instituto Nacional de México en Celaya, Celaya Gto., México, Israel.barranco@itcelaya.edu.mx, ORCID: <https://orcid.org/0000-0002-5050-6208>, principales intereses de investigación: Visión Artificial, Telemática, Autotrónica.



Esta revista se publica bajo una Licencia Creative Commons Atribución-No Comercial-Sin Derivar 4.0 Internacional