



ALGORITMOS DE ENJAMBRE PARA PLANIFICACIÓN DE RUTAS EN UAV: UNA REVISIÓN SISTEMÁTICA DE CARACTERÍSTICAS, CLASIFICACIÓN Y DESEMPEÑO OPERATIVO

SWARM ALGORITHMS FOR UAV ROUTE PLANNING: A SYSTEMATIC REVIEW OF CHARACTERISTICS, CLASSIFICATION, AND OPERATIONAL PERFORMANCE

Marcelo Rea-Guamán^{1,*} , Andrea López-López¹ , Andrés Almeida-Jara¹ 

Recibido: 16-11-2025, Recibido tras revisión: 23-03-2026, Aceptado: 28-04-2026, Publicado: 01-07-2026

Resumen


La planificación de rutas para UAV mediante algoritmos de enjambre es clave en la robótica autónoma; sin embargo, faltan revisiones sistemáticas que integren clasificación, características operativas y desempeño. Este estudio propone una taxonomía de cinco categorías, un análisis de frecuencias por dominio y un marco de evaluación con nueve métricas. Siguiendo la metodología PRISMA, se revisaron las bases de datos IEEE Xplore, Scopus, ScienceDirect y ACM Digital Library entre noviembre y diciembre de 2025. De 2761 registros, se incluyeron 31 artículos: 25 estudios primarios y 6 revisiones. Los algoritmos PSO, ACO y ABC concentran el 66 % de las 56 implementaciones identificadas, con especialización en defensa, búsqueda y rescate, y agricultura. Los métodos híbridos constituyen la principal tendencia, mientras que la IA destaca por su potencial de escalabilidad y adaptación. La literatura prioriza la longitud de trayectoria (96 %) y el tiempo de convergencia (88 %), mientras que la eficiencia energética (56 %) y la cobertura de área (48 %) reciben menor atención.

Palabras clave: UAV, inteligencia de enjambre, planificación de rutas, optimización metaheurística, PRISMA

Abstract

Path planning for unmanned aerial vehicles (UAVs) using swarm algorithms is a central topic in autonomous robotics. However, the literature still lacks systematic reviews that jointly address algorithm classification, operational characteristics, and performance evaluation. This study proposes a five-category taxonomy, a domain-based frequency analysis, and a nine-metric evaluation framework. Following PRISMA guidelines, searches were conducted in IEEE Xplore, Scopus, ScienceDirect, and ACM Digital Library between November and December 2025. From an initial set of 2,761 records, 31 articles were included, comprising 25 primary studies and 6 systematic reviews. PSO, ACO, and ABC account for 66% of the 56 identified algorithm appearances, with prominent applications in defense, search and rescue, and agriculture. Hybrid methods emerged as the main research trend, while AI-based approaches show the greatest potential for scalability and autonomous adaptation. The reviewed literature prioritizes path length (96%) and convergence time (88%), whereas energy efficiency (56%) and area coverage (48%) remain comparatively underexplored.

Keywords: UAVs, swarm intelligence, path planning, metaheuristic optimization, PRISMA.

^{1,*}Departamento de Ciencias de la Computación. Universidad de las Fuerzas Armadas ESPE, Sangolquí, Ecuador. 
 Autor para correspondencia ✉: amreal@espe.edu.ec.

Forma sugerida de citación: M. Rea-Guamán, A. López-López y A. Almeida-Jara, "Algoritmos de enjambre para planificación de rutas en UAV: Una revisión sistemática de características, clasificación y desempeño operativo," *Ingenius, Revista de Ciencia y Tecnología*, N.º 36, pp. 110-124, 2026. DOI: <https://doi.org/10.17163/ings.n36.2026.09>.

1. Introducción

1.1. Contexto y motivación

Los vehículos aéreos no tripulados (UAV, por sus siglas en inglés) se han expandido rápidamente en los sectores civil y militar debido a su costo relativamente bajo, flexibilidad operativa y capacidad para acceder a entornos remotos o peligrosos [1, 2]. Actualmente, son ampliamente utilizados en reconocimiento, agricultura de precisión, inspección de infraestructuras, respuesta ante desastres y apoyo en emergencias, contextos en los que el despliegue rápido y la información en tiempo real son esenciales para la toma de decisiones [3–5]. Los avances tecnológicos también han permitido el desarrollo de enjambres de UAV, definidos en este estudio como sistemas compuestos por dos o más UAV que se coordinan mediante mecanismos centralizados o descentralizados para cumplir una misión compartida [6]. Su escalabilidad los hace particularmente adecuados para vigilancia, búsqueda y rescate, monitoreo ambiental y soporte de comunicaciones en entornos inciertos.

La planificación de trayectorias es un desafío fundamental, ya que los UAV deben generar trayectorias seguras y eficientes mientras satisfacen restricciones relacionadas con la distancia, las amenazas, el consumo energético, las ventanas de tiempo, la cobertura y el espacio aéreo permitido [3], [7, 8]. En los enjambres, esto se convierte en un problema de coordinación: los vehículos deben evitar colisiones, superposición de rutas, desperdicio de recursos y cuellos de botella en las comunicaciones mientras actúan de manera cooperativa [6], [9].

Los enfoques de planificación de trayectorias comprenden métodos basados en grafos, basados en enjambres y basados en inteligencia artificial [5, 6]. Los algoritmos tradicionales, incluidos Dijkstra y A*, presentan un buen desempeño en entornos estructurados, mientras que los algoritmos de enjambre, como PSO, ACO y ABC, son más adecuados para la optimización dinámica de múltiples UAV, ya que permiten la búsqueda basada en poblaciones, la adaptabilidad y la coordinación descentralizada [6], [10].

Sin embargo, los métodos fundamentales basados en enjambres también presentan limitaciones: PSO puede converger prematuramente, ACO puede escalar de manera deficiente debido a las actualizaciones de feromonas y ABC puede estancarse durante la explotación [11]. Estas limitaciones explican el reciente cambio hacia enfoques híbridos y aumentados con inteligencia artificial, lo que subraya la necesidad de una síntesis estructurada de los tipos de algoritmos, las características operativas y los compromisos específicos de cada aplicación.

1.2. Marco teórico y trabajos relacionados

La inteligencia de enjambre es un paradigma computacional inspirado en sistemas biológicos descentralizados, en los cuales las interacciones locales generan un comportamiento colectivo adaptativo [12, 13]. Sus principales principios incluyen la autoorganización, la comunicación local o estigmergia, la retroalimentación y la redundancia, que en conjunto proporcionan robustez y adaptabilidad en entornos dinámicos [13]. Entre los algoritmos fundamentales, ACO modela el forrajeo basado en feromonas, PSO modela el comportamiento de bandadas y ABC modela el forrajeo de abejas. Estos algoritmos continúan siendo los principales métodos de referencia en la planificación de trayectorias de UAV [14–16]. Propuestas posteriores, como GWO, WOA y SSA, han ampliado el repertorio bioinspirado, particularmente para la optimización de alta dimensionalidad; sin embargo, la presente revisión muestra que estas técnicas más recientes siguen siendo validadas con menor frecuencia en contextos específicos de UAV [17–20].

Los algoritmos de enjambre son atractivos porque exploran múltiples regiones del espacio de búsqueda simultáneamente, no requieren información de gradiente y se adaptan bien a problemas no lineales o no diferenciables [21, 22]. Estas propiedades han respaldado aplicaciones en robótica, enrutamiento y coordinación autónoma, además de impulsar trabajos recientes sobre hibridación con aprendizaje por refuerzo y otros métodos de inteligencia artificial para entornos dinámicos multiagente [23–25].

Las revisiones recientes abordan la planificación de trayectorias de UAV en general o la inteligencia de enjambre de manera más amplia [26–29], pero no examinan conjuntamente la prevalencia de los algoritmos de enjambre, la estructura taxonómica, las características operacionales y las métricas comparativas para la planificación de trayectorias de UAV. Esta revisión aborda esa brecha al centrarse en estudios publicados entre 2020 y 2025.

1.3. Planteamiento del problema y justificación

A pesar de los avances significativos en el desarrollo de algoritmos de enjambre para la planificación de trayectorias, aún existe una notable falta de revisiones sistemáticas que integren y clasifiquen de manera integral los enfoques algorítmicos, las características operativas y el desempeño comparativo en diversos escenarios de aplicación [30, 31].

Los métodos clásicos, como PSO, ACO y ABC, continúan siendo efectivos, pero cada uno presenta limitaciones en escenarios dinámicos y complejos [11]. Esto ha impulsado el desarrollo de métodos híbridos; sin embargo, el campo aún carece de métricas de evaluación unificadas y protocolos comunes de comparación.

En esta revisión, el desempeño operativo comprende indicadores computacionales, como el tiempo de convergencia, la calidad de la solución y la eficiencia, así como indicadores del nivel de misión, tales como la eficiencia energética, la cobertura de área, la tasa de éxito y la exposición a amenazas. Esta definición más amplia es necesaria porque la planificación de trayectorias de UAV debe evaluarse más allá de las métricas aisladas de optimización.

En consecuencia, esta revisión basada en la metodología PRISMA sintetiza, clasifica y analiza algoritmos de enjambre para la planificación de trayectorias de UAV, con el fin de apoyar la selección de algoritmos, identificar tendencias de investigación y destacar futuras direcciones a partir de 25 estudios primarios y 6 revisiones previas publicadas entre 2020 y 2025.

1.4. Objetivos de investigación y preguntas de investigación

Sobre la base de las brechas identificadas en la literatura, esta revisión sistemática se estructura en torno a tres ejes de investigación interrelacionados. El primero busca determinar qué algoritmos de enjambre son implementados con mayor frecuencia en la planificación de trayectorias de UAV, mediante un análisis cuantitativo para caracterizar el panorama actual del campo y sus enfoques dominantes. El segundo desarrolla una taxonomía fundamentada que clasifica estos algoritmos de acuerdo con sus fundamentos teóricos, mecanismos de optimización y estrategias de coordinación, lo que proporciona un marco organizacional para la diversidad de enfoques existentes.

Finalmente, el tercero examina las características operativas que definen el comportamiento de estos algoritmos, abarcando desde la coordinación multiagente hasta la eficiencia computacional, y analiza cómo estas características afectan el desempeño en diferentes contextos de aplicación.

Las principales contribuciones de este trabajo son tres: 1) una taxonomía fundamentada de cinco categorías de métodos de enjambre para la planificación de trayectorias de UAV, organizada de acuerdo con estrategias de optimización y coordinación y desarrollada empíricamente a partir de patrones identificados en 25 estudios primarios y teóricamente a partir de revisiones sistemáticas previas [26–29], con el propósito de proporcionar una organización general de los diversos enfoques encontrados en la literatura; 2) una evaluación cuantitativa de 56 implementaciones algorítmicas en 25 estudios, que identifica las metodologías predominantes utilizadas en cada dominio de aplicación, incluidos defensa (36.0 %), búsqueda y rescate (32.0 %), agricultura (20.0 %) e inspección (8.0 %), así como su especialización funcional; 3) un marco de evaluación de nueve métricas para valorar el desempeño de métodos de enjambre, con trazabilidad

completa a todos los estudios revisados, lo que permite la comparación sistemática entre diferentes enfoques.

El resto de este artículo está organizado de la siguiente manera: la sección 2 detalla la metodología PRISMA empleada; la sección 3 presenta los resultados y la discusión; y la sección 4 expone las conclusiones, las limitaciones y las futuras líneas de investigación.

2. Materiales y métodos

2.1. Estrategia y diseño de la revisión sistemática

Esta revisión sistemática sigue las directrices PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) para garantizar la transparencia y la replicabilidad durante todo el proceso de identificación, selección y análisis de estudios [32].

Identificación. La búsqueda bibliográfica se realizó entre el 15 de noviembre y el 19 de diciembre de 2025 en cuatro bases de datos académicas relevantes, seleccionadas por su pertinencia en robótica, inteligencia artificial y sistemas autónomos: ACM Digital Library, IEEE Xplore, ScienceDirect y Scopus. La búsqueda se efectuó mediante la cadena de búsqueda estandarizada definida en la sección 2.2, con adaptaciones a los requisitos sintácticos de la interfaz de cada base de datos, pero preservando la equivalencia semántica.

Cribado. En esta etapa, los registros duplicados fueron identificados mediante la función de detección automática de Mendeley Reference Manager basada en la coincidencia de DOI, título y autores. No se detectaron duplicados entre las cuatro bases de datos, probablemente debido a la especificidad de la cadena de búsqueda y al alcance de cobertura distinto de cada una. Posteriormente, los registros sin relación directa con la pregunta de investigación, según su título y resumen, fueron evaluados de manera independiente por los tres autores, quienes resolvieron las discrepancias mediante discusión hasta alcanzar un consenso. La gestión de referencias y el seguimiento bibliográfico se realizaron con Mendeley Reference Manager, mientras que la matriz de cribado y la extracción de datos fueron documentadas en hojas de cálculo compartidas en Google Sheets para garantizar la transparencia y la trazabilidad.

Elegibilidad. La evaluación del texto completo se aplicó a 51 artículos preseleccionados mediante los criterios de inclusión y exclusión descritos en la sección 2.3. Veinte estudios fueron excluidos principalmente porque carecían de coordinación de enjambre, métricas adecuadas, ajuste temporal o validación basada en experimentos/simulaciones.

Inclusión. La selección final comprendió 31 artículos que cumplieron todos los criterios definidos. Estos estudios fueron analizados en profundidad para extraer

implementaciones algorítmicas, características operativas, métricas de evaluación y dominios de aplicación. El corpus final estuvo conformado por 25 estudios primarios sobre implementaciones específicas de algoritmos de enjambre y 6 revisiones sistemáticas que proporcionaron el marco teórico para la taxonomía propuesta.

2.2. Cadena de búsqueda

Se desarrolló una cadena de búsqueda estructurada mediante la combinación de términos relacionados con tres dimensiones principales del estudio: (“drone swarm” OR “swarm intelligence”) AND (“route optimization” OR “path planning”) AND (“algorithms” OR “optimization techniques”).

La cadena de búsqueda fue diseñada para capturar artículos que abordaran simultáneamente tres dimensiones obligatorias: 1) sistemas de enjambres de drones, 2) problemas de planificación u optimización de rutas y 3) soluciones algorítmicas. Todas las búsquedas se

restringieron al período de publicación 2020-2025 y se limitaron a artículos de revistas y actas de congresos.

Se reconoce que la cadena de búsqueda puede no capturar todos los estudios relevantes, particularmente aquellos que utilizan terminología no estandarizada como “formation control”, “cooperative navigation” o “multi-robot planning” sin mencionar explícitamente la inteligencia de enjambre. Esta limitación fue parcialmente mitigada mediante la verificación retrospectiva de referencias de las seis revisiones sistemáticas incluidas y el seguimiento prospectivo de citas de estudios primarios altamente citados.

2.3. Criterios de selección

Se establecieron criterios de inclusión (IC) y exclusión (EC) para delimitar los artículos relevantes y garantizar la pertinencia de los resultados.

Los criterios considerados se detallan en la Tabla 1.

Tabla 1. Criterios de inclusión y exclusión.

Criterios de inclusión	Criterios de exclusión
IC1: Los estudios deben presentar algoritmos de enjambre aplicados específicamente a la planificación de trayectorias de UAV.	EC1: Enfoque exclusivo en UAV individuales sin coordinación de enjambre o cooperación multiagente.
IC2: Deben describir al menos tres características operativas de los algoritmos, tales como cooperación entre drones, distribución dinámica de tareas y equilibrio del consumo energético, entre otras.	EC2: Aplicaciones no relacionadas con la planificación de trayectorias (por ejemplo, únicamente control de vuelo, estabilización o sistemas de comunicación sin impacto en las trayectorias).
IC3: Deben incluir métricas de evaluación cuantitativa o comparaciones con otros algoritmos del estado del arte.	EC3: Literatura gris sin revisión por pares, como informes técnicos, tesis de pregrado, documentos de trabajo).
IC4: Deben ser artículos de investigación, artículos de conferencia o revisiones sistemáticas publicadas en fuentes académicas revisadas por pares.	EC4: Información metodológica insuficiente o ausencia de resultados cuantitativos.
IC5: Deben estar escritos en inglés o español.	

La exclusión de literatura gris (EC3) requiere una justificación específica. Los informes técnicos, las tesis de pregrado y los documentos de trabajo fueron excluidos para garantizar que todos los estudios analizados hubieran pasado por un proceso de revisión por pares, lo que proporciona una línea base mínima de calidad para la evidencia sintetizada en esta revisión.

Aunque este criterio puede omitir implementaciones relevantes de la industria relacionadas con la tecnología de enjambres de UAV, se tomó la decisión de priorizar el rigor metodológico y la reproducibilidad sobre una cobertura exhaustiva. Esta limitación se reconoce explícitamente en la sección 4.

2.4. Evaluación de la calidad

Dada la naturaleza heterogénea de los estudios incluidos, que abarcaron experimentos basados en simula-

ción, comparaciones de referencia y propuestas algorítmicas con diferentes niveles de validación, se realizó una evaluación formal de calidad para contextualizar la solidez de la evidencia que sustenta las conclusiones de la revisión.

En lugar de aplicar una herramienta estandarizada diseñada para investigación clínica o experimental, como la herramienta Cochrane de riesgo de sesgo, que sería poco adecuada para la literatura de optimización computacional, se desarrolló un marco de evaluación de calidad apropiado para el dominio, basado en cinco criterios:

Q1. Descripción algorítmica: ¿El estudio proporciona suficiente detalle para comprender y reproducir potencialmente el algoritmo propuesto?

Q2. Diseño experimental: ¿El estudio define escenarios de prueba claros con parámetros especifi-

cados, tales como dimensiones del mapa, densidad de obstáculos, número de UAV y límites de iteración?

Q3. Comparación de referencia: ¿El estudio compara el método propuesto con al menos un algoritmo base establecido?

Q4. Reporte estadístico: ¿El estudio presenta resultados obtenidos a partir de múltiples ejecuciones independientes con medidas de tendencia central y variabilidad, tales como media y desviación estándar?

Q5. Cobertura de métricas: ¿El estudio evalúa el desempeño mediante al menos tres de las nueve métricas identificadas en esta revisión?

Cada criterio fue evaluado como cumplido (1) o no cumplido (0), con lo cual se obtuvo una puntuación de calidad de 0 a 5. La evaluación fue realizada de manera independiente por dos autores, mientras que el tercer autor resolvió las discrepancias. Dos estudios inicialmente clasificados como primarios (IEEE7 e IEEE8) fueron reclasificados como revisiones sistemáticas durante este proceso, ya que obtuvieron una puntuación de 1/5 debido a la ausencia de propuestas algorítmicas novedosas o validación experimental. Tras esta reclasificación, el conjunto final de 25 estudios primarios alcanzó una puntuación media de calidad de 4.3/5 (DE = 0.9), con 24 estudios (96.0 %) que obtuvieron una puntuación igual o superior a 3. El criterio incumplido con mayor frecuencia fue Q4, relativo al reporte estadístico con medidas de variabilidad, satisfecho por el 52.0 % de los estudios, seguido de Q5, cobertura de al menos tres métricas de evaluación, cumplido por el 80.0 %. Ningún estudio fue excluido con base en las puntuaciones de calidad.

Las afirmaciones de desempeño en esta revisión, particularmente aquellas relacionadas con las mejoras del 15-50 % atribuidas a métodos híbridos, se reportan tal como fueron establecidas por los autores originales dentro de sus contextos experimentales específicos. Por lo tanto, no deben interpretarse como hallazgos generalizables en bancos de prueba estandarizados, los cuales aún no existen en este campo. La ausencia de dichos bancos de prueba se identifica como una limitación crítica en la sección 4.

2.5. Proceso de selección de estudios

La búsqueda inicial, realizada entre el 15 de noviembre y el 19 de diciembre de 2025 mediante las cadenas de búsqueda definidas, identificó 2761 registros en las cuatro bases de datos académicas. ScienceDirect aportó la mayor proporción, con 1404 registros (50.9 %), seguida de Scopus con 771 (27.9 %), IEEE Xplore con 314 (11.4 %) y ACM Digital Library con 272 (9.9 %). Después del cribado por título y resumen, 51 artículos fueron evaluados para determinar su elegibilidad mediante la revisión del texto completo; de estos, 20 fueron excluidos con base en los criterios detallados en la sección 2.1. La Figura 1 presenta el diagrama de flujo PRISMA para cada fase del proceso de selección.

La muestra final estuvo compuesta por 25 estudios primarios y 6 revisiones sistemáticas. Solo los estudios primarios fueron utilizados para el conteo de implementaciones, la cobertura de métricas y el análisis comparativo. Esta distribución se muestra en la Tabla 2.

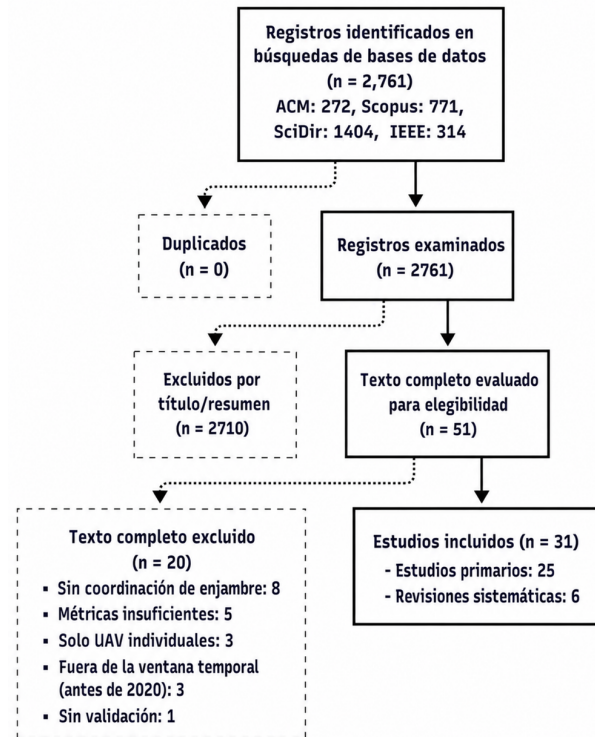


Figura 1. Diagrama de flujo del proceso de selección en cada fase PRISMA.

Tabla 2. Distribución de artículos por fuente.

Fuente	Artículos	Porcentaje	Rango de años
Science Direct	7	22.60 %	2020-2025
ACM Digital Library	6	19.40 %	2021-2025
IEEE Xplore	9	29.00 %	2020-2025
Scopus	9	29.00 %	2021-2025
Total	31	100 %	2020-2025

Cada artículo fue codificado de acuerdo con su fuente para facilitar la trazabilidad.

- SC11–SC17: ScienceDirect (7 artículos)
- ACM1–ACM6: ACM Digital Library (6 artículos)
- IEEE1–IEEE9: IEEE Xplore (9 artículos)
- SCO1–SCO9: Scopus (9 artículos)

La Tabla 3 resume los 31 artículos incluidos según su ID, título, algoritmo principal o tipo de estudio, objetivo y año de publicación.

Tabla 3. Análisis completo de los algoritmos de los artículos incluidos.

ID	Título	Algoritmo principal	Objetivo	Año
SCI1	Planificación de trayectorias de AUV en un entorno marino 3D	MCO (coevolutivo de múltiples enjambres)	Minimizar la distancia, la altitud, el ángulo y el efecto de las corrientes	2024
SCI2	De PID a enjambres: una década de avances	Revisión sistemática	Sintetizar avances del período 2013-2023	2024
SCI3	Juego caótico híbrido y optimización de lobo gris	HCGO (GWO + CGO)	Minimizar la longitud de trayectoria, las amenazas y la altitud	2025
SCI4	Planificación de trayectorias para grandes enjambres de UAV	PO-WMFDDPG	Maximizar la tasa de éxito y la recompensa	2025
SCI5	MMPA: algoritmo depredador marino modificado	MMPA	Minimizar una función multiobjetivo	2024
SCI6	Nuevo TD3 multiagente con descomposición de tareas	TD-MATD3	Coordinar múltiples UAV	2024
SCI7	Planificación de trayectorias con tareas cambiantes en línea	ORPFOA	Planificar rutas 3D para inspección de oleoductos	2020
ACM1	Optimización mejorada de polilla-llama	EMFO	Optimizar la planificación de trayectorias 3D	2025
ACM2	Algoritmos mejorados de optimización por enjambre de partículas	DMSQPSO	Evitar la convergencia prematura	2022
ACM3	Planificación submarina de trayectorias 3D de AUV basada en optimización por enjambre de partículas	PSO-ASCS	Planificar rutas submarinas eficientes	2022
ACM4	Métodos de planificación de trayectorias para UAV: revisión	Revisión de métodos	Clasificar técnicas de planificación de trayectorias	2024
ACM5	Planificación de trayectorias de UAV con PSO mejorado	PSO con vuelo de Lévy	Evitar la convergencia prematura	2024
ACM6	Búsqueda robótica basada en inteligencia de enjambre en entornos desconocidos tipo laberinto	PSO + algoritmo bat	Localizar un objetivo fijo	2021
IEEE1	Algoritmo cooperativo multigrupo de enjambre de partículas	PSO multigrupo	Mejorar la precisión en IoV	2024
IEEE2	Una revisión de algoritmos de inteligencia de enjambre	Revisión de inteligencia de enjambre	Clasificar técnicas de inteligencia de enjambre	2025
IEEE3	Algoritmo de colibrí artificial	AHA	Optimizar trayectorias	2022
IEEE4	Cooperación distribuida multi-UAV	NTVPSO-ADE	Lograr coordinación distribuida	2022
IEEE5	Algoritmo bat mejorado para UAV	IBA (BA + ABC)	Optimizar trayectorias 3D	2021
IEEE6	Método de evitación de obstáculos para formación multi-UAV	PSO	Mantener una formación triangular	2025
IEEE7	Inteligencia de enjambre para UAV	Revisión de inteligencia de enjambre	Analizar algoritmos de inteligencia de enjambre	2024
IEEE8	Inteligencia de enjambre UAV: avances recientes	Revisión multicapa	Sintetizar arquitecturas de inteligencia de enjambre	2020
IEEE9	Planificación de trayectorias UCAV basada en CPSO	CPSO	Minimizar amenazas y consumo de combustible	2020
SCO1	Estudio comparativo de algoritmos de inteligencia de enjambre	12 algoritmos SI	Minimizar el costo combinado	2021
SCO2	MPA mejorado multi-estrategia	MEMPA	Minimizar una función multiobjetivo	2025
SCO3	Planificación biónica de trayectorias 3D	Bionic-Krill	Minimizar la longitud, el tiempo y el consumo	2024
SCO4	Tecnología de programación inteligente	DQN-SISA	Minimizar costo dinámico	2024
SCO5	Planificación óptima de trayectorias para drones	ACO mejorado	Minimizar la distancia y el tiempo	2022
SCO6	Planificación de trayectorias mediante algoritmos de inteligencia de enjambre	ABC vs PSO	Minimizar la distancia total	2023
SCO7	Investigación sobre planificación de trayectorias de vehículos aéreos no tripulados	A* + BiLSTM	Minimizar la distancia y el tiempo	2024
SCO8	Inteligencia de enjambre: revisión de clasificación de modelos y aplicaciones	Revisión integral	Sintetizar métodos de inteligencia de enjambre	2025
SCO9	Planificación de trayectorias UAV basada en E-RRT	E-RRT	Minimizar el número de nodos y la distancia	2024

3. Resultados y discusión

3.1. Extracción y clasificación de datos

El análisis sistemático de los 25 estudios primarios permitió responder a las tres preguntas de investigación planteadas. Antes de presentar los hallazgos, es necesario aclarar una importante distinción metodológica entre los dos sistemas de conteo utilizados en este análisis. La Tabla 4 reporta la frecuencia total de apariciones de algoritmos base en todos los estudios ($n = 56$). Esta tabla presenta los bloques algorítmicos fundamentales del campo, mientras que la Tabla 5 resume las contribuciones de investigación organizadas según el enfoque metodológico.

RQ1: ¿Qué algoritmos son utilizados con mayor frecuencia en la planificación de trayectorias de UAV? El análisis cuantitativo revela un claro predominio de tres algoritmos base en el campo de la planificación de trayectorias de UAV. La Tabla 4 resume la frecuencia de implementación de los cinco grupos algorítmicos más representativos.

Tabla 4. Frecuencia de implementación de algoritmos base.

Algoritmo	Implementaciones	Porcentaje
PSO	18	32.1 %
ACO	11	19.6 %
ABC	8	14.3 %
GWO	7	12.5 %
Otros	12	21.4 %
Total	56	100 %

Como indican los datos, PSO lidera con 18 apariciones (32.1 %), seguido de ACO con 11 (19.6 %) y ABC con 8 (14.3 %). GWO representa 7 apariciones (12.5 %), mientras que otros algoritmos, como GA, DE y MPA, contribuyen en conjunto con 12 casos adicionales (21.4 %). PSO, ACO y ABC representan el 66 % de todas las apariciones algorítmicas identificadas, lo que consolida su estatus como los algoritmos de referencia fundamentales en este dominio. La Figura 2 proporciona una representación visual de esta distribución.

Este predominio no es arbitrario: cada algoritmo ha demostrado fortalezas específicas según su contexto operativo. PSO es ampliamente utilizado en escenarios de defensa que requieren convergencia rápida [33, 34]; ACO destaca en búsqueda y rescate debido a su precisión en la optimización de rutas [35]; y ABC parece especialmente útil en entornos agrícolas, donde la eficiencia energética es crítica [36].

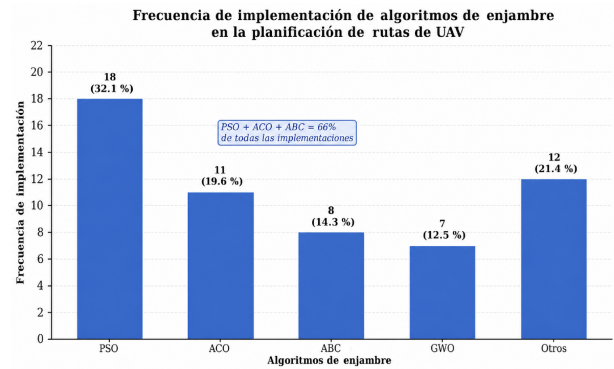


Figura 2. Frecuencia de implementación de algoritmos de enjambre en la planificación de trayectorias de UAV.

RQ2: ¿Cómo se clasifican los algoritmos de enjambre? Los algoritmos identificados fueron organizados en cinco categorías taxonómicas fundamentadas en sus bases teóricas, mecanismos de optimización y estrategias de coordinación. Esta clasificación fue construida de manera ascendente a partir de los 25 estudios primarios y validada frente a las seis revisiones sistemáticas que constituyen el marco teórico del estudio. Las categorías se definen de la siguiente manera: 1) algoritmos de optimización, que abarcan métodos metaheurísticos clásicos que optimizan funciones objetivo mediante búsqueda basada en poblaciones; 2) métodos híbridos, que combinan dos o más enfoques algorítmicos distintos para superar limitaciones individuales; 3) algoritmos de control cooperativo, que abordan específicamente la coordinación multiagente mediante reglas de comportamiento local; 4) algoritmos bioinspirados, que simulan comportamientos biológicos específicos más allá de los paradigmas clásicos de enjambre; y 5) algoritmos basados en IA, que emplean aprendizaje automático o aprendizaje profundo para la planificación de trayectorias. Estas categorías son mutuamente excluyentes en el nivel primario; sin embargo, ciertos estudios contribuyen a múltiples categorías cuando presentan innovaciones metodológicas distintas, como un mecanismo de control cooperativo combinado con un componente bioinspirado. La Tabla 5 presenta la distribución.

La Figura 3 complementa la tabla al visualizar tanto el conteo absoluto como el peso proporcional de cada categoría en las 36 implementaciones clasificadas, lo que hace inmediatamente evidente la jerarquía estructural de la taxonomía.

Tabla 5. Distribución de algoritmos por categoría taxonómica.

Categoría	Cantidad	Principales ejemplos	Tendencia
Algoritmos de optimización	13	PSO, ACO, GWO, ABC, DE, MPA	Estable
Métodos híbridos	10	MCO, HCGO, MMPA, PSO-ASCS, TD-MATD3	En crecimiento
Algoritmos de control cooperativo	6	Boids, formaciones UAV, coordinación multigrupo	Emergente
Algoritmos bioinspirados	4	AHA, Bat Algorithm, Bionic-Krill, EMFO	Emergente
Algoritmos basados en IA	3	PO-WMFDDPG, DQN-SISA, BiLSTM	Emergente

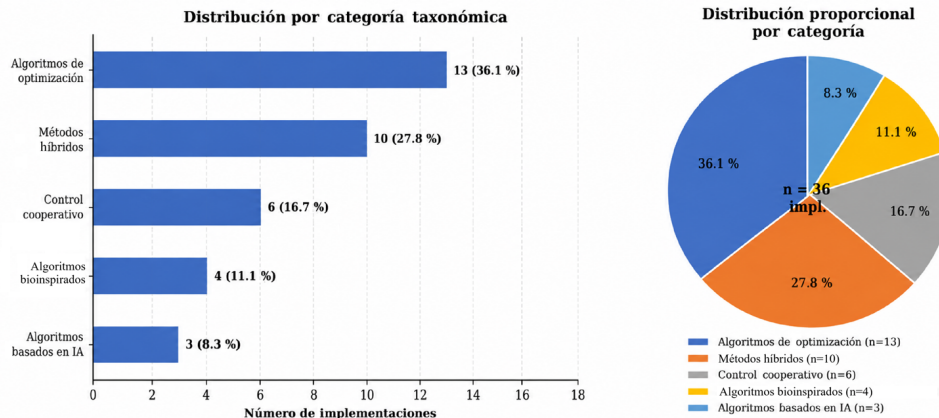


Figura 3. Distribución de implementaciones de algoritmos de enjambre por categoría taxonómica: frecuencia absoluta (izquierda) y distribución proporcional (derecha).

La categoría de algoritmos de optimización constituye la base del campo, con 13 implementaciones de algoritmos metaheurísticos clásicos inspirados en el comportamiento colectivo animal. Los estudios representativos incluyen ACM2 [37], ACM5 [38], IEEE1 [39], IEEE5 [40], IEEE6 [41], ACM6 [42], SCO6 [43], IEEE9 [34], SCO1 [44], ACM3 [45] y SCO5 [35].

Los métodos híbridos emergen como la dirección de investigación predominante, con 10 implementaciones, lo que representa el 27.8 % del total de categorías. Estos enfoques combinan estratégicamente múltiples técnicas para superar las limitaciones inherentes a los algoritmos individuales. Por ejemplo, MCO integra AOA con SSA mediante coevolución, HCGO combina GWO con CGO, e incorpora variación caótica y TD-MATD3 fusiona aprendizaje por refuerzo multiagente con descomposición de tareas. Esta categoría incluye SCI1 [46], SCI3 [33], SCI5 [47], SCI6 [48], ACM3 [45], IEEE5 [40], SCO2 [49], SCO3 [36], SCI7 [50] y SCO9 [51].

Los algoritmos de control cooperativo, identificados en seis estudios, abordan específicamente la coordinación de múltiples UAV mediante reglas de comportamiento local. La característica distintiva de estos métodos es la coordinación descentralizada: no requieren un controlador central y operan exclusivamente mediante comunicación local entre agentes vecinos. Estas implementaciones están documentadas en IEEE1 [39], ACM6 [42], IEEE4 [52], IEEE6 [41], SCI6 [48] y SCO6 [43].

Los algoritmos bioinspirados comprenden cuatro implementaciones que simulan comportamientos específicos de organismos naturales más allá de los paradigmas clásicos de enjambre: AHA (Artificial Hummingbird Algorithm), Bionic-Krill, EMFO (Enhanced Moth-Flame Optimization) e IBA. Estos estudios reportan mejoras en la calidad de la trayectoria que oscilan entre el 1.1 % y el 17.5 % en sus respectivas comparaciones [36], [53, 54]. Los estudios correspondientes son IEEE3 [53], IEEE5 [40], SCO3 [36] y ACM1 [54].

Finalmente, los algoritmos basados en IA representan la frontera tecnológica más prometedora, con tres implementaciones, equivalentes al 8.3 % del total. PO-WMFDDPG emplea aprendizaje profundo por refuerzo con teoría de campo medio, y alcanza tasas de éxito superiores al 90 % en enjambres de hasta 120 UAV y una latencia inferior a 0.05 segundos [55]. DQN-SISA utiliza una red Q profunda para la selección dinámica de algoritmos, y logra reducciones del 8-15 % en los costos operativos [56]. A*+BiLSTM integra planificación clásica con redes neuronales bidireccionales para la predicción de trayectorias [57]. Estos métodos destacan por su capacidad para adaptarse dinámicamente a entornos cambiantes mediante aprendizaje continuo.

El análisis de tendencias revela patrones significativos: los algoritmos clásicos de optimización mantienen una presencia estable como columna vertebral del campo, los métodos híbridos muestran un crecimiento acelerado y las tres categorías emergentes

—control cooperativo, bioinspirados y basados en IA— representan en conjunto el 36.1 % de todas las implementaciones clasificadas, lo que evidencia la diversificación activa del campo hacia enfoques cada vez más sofisticados.

RQ3: ¿Cuáles son las características operativas y su impacto? El análisis cualitativo de los 25 estudios primarios identificó 12 características operativas fundamentales que definen el comportamiento de los algoritmos de enjambre. Estas características fueron extraídas sistemáticamente mediante análisis temático de las implementaciones reportadas y posteriormente contrastadas con las taxonomías propuestas en seis revisiones sistemáticas previas del campo: SCI2 [26], que cubre el período 2013-2023; ACM4 [27], una revisión de métodos; IEEE2 [28], una revisión de inteligencia de enjambre; IEEE7 [58], un análisis de inteligencia de enjambre aplicada a UAV; IEEE8 [59], una revisión de arquitecturas de inteligencia de enjambre; y SCO8 [29], una revisión integral. Estas revisiones proporcionan marcos conceptuales consolidados para clasificar y evaluar algoritmos de enjambre en la planificación de trayectorias.

Las 12 características fueron agrupadas por función en cuatro dimensiones: 1) coordinación, que incluye cooperación mediante intercambio de información, distribución dinámica de tareas en caso de fallos y comunicación local sin infraestructura centralizada; 2) optimización, que incluye minimización global de distancia, tiempo y costos, balance entre exploración y explotación, y métodos avanzados como PSO, GA y ACO; 3) seguridad, que incluye evitación de colisiones mediante separación mínima y adaptación en tiempo real a obstáculos; y 4) eficiencia, que incluye escalabilidad con mantenimiento del desempeño, operación en tiempo real y gestión energética.

El desempeño fue reportado mediante nueve métri-

cas principales, resumidas en la Tabla 6.

Tabla 6. Cobertura de métricas de evaluación en los estudios.

Métrica	Estudios	Cobertura
Longitud de trayectoria	24	96 %
Tiempo de convergencia	22	88 %
Robustez	20	80 %
Eficiencia computacional	19	76 %
Tasa de éxito	18	72 %
Exposición a amenazas	16	64 %
Eficiencia energética	14	56 %
Suavidad de trayectoria	14	56 %
Cobertura de área	12	48 %

La longitud de trayectoria domina con una cobertura del 96 %, lo que refleja la prioridad otorgada a la eficiencia espacial en la investigación sobre planificación de trayectorias. Le siguen el tiempo de convergencia (88 %) y la robustez (80 %), ambos esenciales para aplicaciones en tiempo real. Cabe destacar que las métricas críticas para el despliegue en entornos reales, como la eficiencia energética (56 %) y la cobertura de área (48 %), reciben comparativamente menor atención, lo que revela una brecha persistente entre las prioridades de la investigación académica y los requerimientos operativos reales.

La importancia relativa de las características y métricas varía según el dominio de aplicación. Como se detalla en la sección 3.3, las misiones militares y las operaciones de búsqueda y rescate representan las mayores proporciones de estudios (36.0 % y 32.0 %, respectivamente), seguidas de la agricultura de precisión (20.0 %) y la inspección de infraestructuras (8.0 %). Cada dominio impone prioridades métricas distintas que reflejan sus demandas operativas específicas. La Figura 4 ilustra esta distribución.

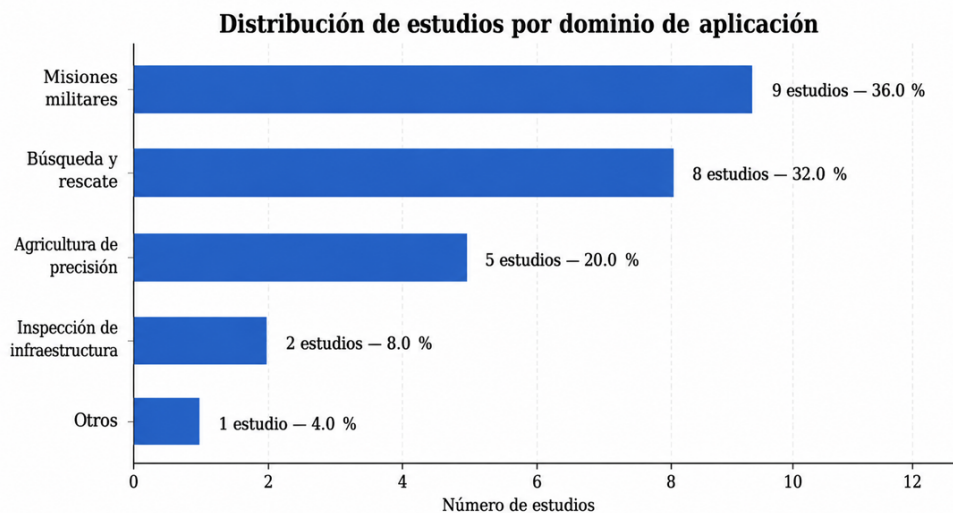


Figura 4. Distribución de estudios por dominio de aplicación.

3.2. Análisis de datos

El análisis comparativo se organizó en torno a la convergencia, la calidad de la solución, la robustez y la complejidad computacional.

Debido a que no existen bancos de prueba estandarizados, las cifras reportadas deben interpretarse como tendencias específicas de cada estudio y no como comparaciones directas bajo condiciones idénticas. La Tabla 7 sintetiza los perfiles de desempeño resultantes.

Tabla 7. Comparación de algoritmos base versus híbridos.

Algoritmo	Convergencia	Calidad	Robustez	Complejidad
PSO	Media	Alta	Media	$O(n)$
ACO	Baja	Muy alta	Alta	$O(n^2)$
ABC	Media	Alta	Media	$O(n)$
Híbridos	Muy alta	Muy alta	Muy alta	$O(n \log n)$

PSO generalmente converge más rápido que ACO y ABC, mientras que los métodos híbridos tienden a mejorar la convergencia, la robustez y la adaptabilidad en los experimentos revisados. ACO suele favorecer la calidad de la solución, mientras que los métodos basados en IA proporcionan la adaptación dinámica más sólida en entornos cambiantes.

La complejidad computacional determina la viabilidad práctica según el contexto operativo. PSO y ABC, con complejidad lineal $O(n)$, son escalables para problemas de gran escala y aplicaciones en tiempo real. ACO presenta complejidad cuadrática $O(n^2)$ debido a la actualización iterativa de la matriz de feromonas, lo que limita su aplicabilidad en escenarios críticos en cuanto al tiempo, pero justifica su uso cuando la calidad de la solución es la prioridad. Los métodos híbridos, con complejidad $O(n \log n)$, ofrecen un equilibrio entre eficiencia y desempeño. Las mejoras reportadas incluyen reducciones en la longitud de trayectoria del 1.1–17.5 % y reducciones de costos del 10 % al 13 % en estudios específicos, mientras que los métodos basados en aprendizaje profundo reportan tiempos de inferencia inferiores a 0.05 s [36], [49], [55].

Una limitación importante es la brecha entre la simulación y la realidad: ninguno de los 25 estudios primarios validó los resultados con enjambres físicos de UAV. La mayoría de los experimentos involucraron entre 3 y 10 UAV, y solo un estudio evaluó la escalabilidad hasta 120 unidades [55]. No pudo establecerse una correlación sistemática entre el tamaño del enjambre y la optimalidad de la trayectoria a partir de los datos disponibles, ya que los estudios variaron significativamente en sus configuraciones experimentales, funciones objetivo y criterios de optimalidad. Establecer dichas correlaciones requeriría bancos de prueba estandarizados que controlen estas variables de confusión.

3.3. Análisis por dominio de aplicación

La distribución de los estudios analizados por dominio de aplicación revela patrones de especialización algorítmica. Como se muestra en la Tabla 8, las misiones militares representan el 36.0 % de los estudios, seguidas de la búsqueda y el rescate, con 32.0 %; la agricultura, con 20.0 %; la inspección, con 8.0 %, y otros dominios, con 4.0 %.

Tabla 8. Distribución de estudios por dominio de aplicación.

Dominio	Estudios	Porcentaje	Algoritmos predominantes
Misiones militares	9	36.0 %	PSO, HCGO, CPSO
Búsqueda y rescate	8	32.0 %	ACO, PO-WMFDDPG
Agricultura	5	20.0 %	ABC, Bionic-Krill
Inspección	2	8.0 %	PSO-ASCS, métodos híbridos
Otros (IoV)	1	4.0 %	PSO multigrupo
Total	25	100 %	—

El dominio militar se beneficia particularmente de PSO debido a su estabilidad y rápida convergencia, con variantes como HCGO [33] aplicadas a la minimización de amenazas y CPSO [34] aplicadas a la optimización de combustible. En búsqueda y rescate, ACO destaca

por su precisión en la evitación de obstáculos, mientras que PO-WMFDDPG [55] alcanza tasas de éxito superiores al 90 % al coordinar hasta 120 UAV. Las aplicaciones agrícolas favorecen ABC por su eficiencia energética, con aportes complementarios de Bionic-Krill [36],

que logra reducciones de distancia de trayectoria del 1.1 % al 17.5 % en relación con ACO y ABC. Las tareas de inspección favorecen métodos híbridos como PSO-ASCS [45] por su adaptabilidad en entornos variables.

Debe señalarse que la distribución observada puede estar influenciada por un sesgo de publicación, ya que las aplicaciones militares se benefician de fuentes de financiamiento consolidadas y de formulaciones estandarizadas de problemas que facilitan la publicación académica, mientras que las aplicaciones civiles en logística, monitoreo ambiental y movilidad aérea urbana pueden estar subrepresentadas debido a restricciones de propiedad intelectual o al estado incipiente de los marcos regulatorios. Adicionalmente, la distribución geográfica de la producción científica no fue analizada en esta revisión; las preferencias regionales en financiamiento de investigación y la accesibilidad a revistas pueden influir en los enfoques algorítmicos que reciben mayor atención en la literatura indexada.

4. Conclusiones

Esta revisión sintetizó 31 estudios publicados entre 2020 y 2025, compuestos por: 25 estudios primarios y 6 revisiones sistemáticas, con el propósito de caracterizar los algoritmos de enjambre para la planificación de trayectorias de UAV siguiendo las directrices PRISMA. La evidencia confirma el predominio de PSO, ACO y ABC, que en conjunto representan el 66 % de las 56 apariciones algorítmicas identificadas, al mismo tiempo que muestra que la selección del algoritmo está fuertemente determinada por las demandas específicas de cada dominio.

La taxonomía propuesta de cinco categorías indica que los algoritmos clásicos de optimización continúan siendo la columna vertebral del campo, mientras que los métodos híbridos constituyen la principal tendencia de crecimiento. El control cooperativo, los métodos bioinspirados y los enfoques basados en IA sugieren un cambio hacia soluciones más descentralizadas, adaptativas y orientadas al aprendizaje. El marco de nueve métricas muestra además que la literatura prioriza la longitud de trayectoria, el tiempo de convergencia y la robustez, mientras que la eficiencia energética y la cobertura de área permanecen comparativamente poco exploradas.

Deben reconocerse varias limitaciones. Los estudios revisados son heterogéneos en el diseño de escenarios, objetivos y formas de reporte, lo que impide un metaanálisis estricto y limita la comparación numérica directa. Además, todos los estudios primarios están basados en simulaciones; por lo tanto, aspectos como la latencia, el ruido de sensores, la degradación de baterías y la interferencia aerodinámica permanecen insuficientemente validados en enjambres reales de

UAV.

Los trabajos futuros deberían priorizar bancos de prueba estandarizados, reportes estadísticos más sólidos, implementaciones públicas y validación física con enjambres de UAV. Las oportunidades de investigación son especialmente evidentes en la hibridación mejorada con IA, la escalabilidad extrema, los enjambres heterogéneos, la resiliencia ante entornos adversariales, el replanteamiento de trayectorias con conciencia energética y la planificación de trayectorias conforme a regulaciones. En términos generales, la hibridación parece ser la dirección más productiva a corto plazo, mientras que la inteligencia artificial representa la frontera más prometedora para la escalabilidad a largo plazo y la adaptación autónoma.

Rol de los autores

- **Marcelo Rea-Guamán:** conceptualización, investigación, metodología, supervisión, validación, redacción del borrador original y redacción – revisión y edición.
- **Andrea López-López:** conceptualización, análisis formal, investigación, metodología, supervisión, validación y redacción – revisión y edición.
- **Andrés Almeida-Jara:** curación de datos, análisis formal, investigación, metodología, visualización y redacción – revisión y edición.

Referencias

- [1] H. A. Hashim, “Advances in UAV avionics systems architecture, classification and integration: A comprehensive review and future perspectives,” *Results in Engineering*, vol. 25, p. 103786, Mar. 2025. [Online]. Available: <https://doi.org/10.1016/j.rineng.2024.103786>
- [2] S. A. H. Mohsan, N. Q. H. Othman, Y. Li, M. H. Alsharif, and M. A. Khan, “Unmanned aerial vehicles (UAVs): practical aspects, applications, open challenges, security issues, and future trends,” *Intelligent Service Robotics*, vol. 16, no. 1, pp. 109–137, Jan. 2023. [Online]. Available: <https://doi.org/10.1007/s11370-022-00452-4>
- [3] F. Outay, H. A. Mengash, and M. Adnan, “Applications of unmanned aerial vehicle (UAV) in road safety, traffic and highway infrastructure management: Recent advances and challenges,” *Transportation Research Part A: Policy and Practice*, vol. 141, pp. 116–129, Nov. 2020. [Online]. Available: <https://doi.org/10.1016/j.tra.2020.09.018>

- [4] Q. Wang, H. Zhu, G. Pan, J. Wei, C. Zhang, Z. Huang, and G. Ling, "Distributed decision making for unmanned aerial vehicle inspection with limited energy constraint," *Energy and AI*, vol. 18, p. 100429, Dec. 2024. [Online]. Available: <https://doi.org/10.1016/j.egyai.2024.100429>
- [5] L. Mu, W. Liu, H. Wang, and Y. Zhang, "Research of UAV 3D path planning based on improved DWARF mongoose algorithm with multiple strategies," *Scientific Reports*, vol. 15, no. 1, 2025. [Online]. Available: <https://doi.org/10.1038/s41598-025-11492-y>
- [6] K. Arshid, A. Krayani, L. Marcenaro, D. M. Gómez, and C. Regazzoni, "Toward autonomous UAV swarm navigation: A review of trajectory design paradigms," *Sensors*, vol. 25, no. 18, p. 5877, 2025. [Online]. Available: <https://doi.org/10.3390/s25185877>
- [7] S. Aggarwal and N. Kumar, "Path planning techniques for unmanned aerial vehicles: A review, solutions, and challenges," *Computer Communications*, vol. 149, pp. 270–299, Jan. 2020. [Online]. Available: <https://doi.org/10.1016/j.comcom.2019.10.014>
- [8] M. Jones, S. Djahel, and K. Welsh, "Path-planning for unmanned aerial vehicles with environment complexity considerations: A survey," *ACM Computing Surveys*, vol. 55, no. 11, pp. 1–39, Feb. 2023. [Online]. Available: <https://doi.org/10.1145/3570723>
- [9] E. Dhulkefl, A. Durdu, and H. Terzioglu, "Dijkstra algorithm using UAV path planning," *Konya Journal of Engineering Sciences*, vol. 8, pp. 92–105, Dec. 2020. [Online]. Available: <https://doi.org/10.36306/konjes.822225>
- [10] M. Dorigo, G. D. Caro, and L. M. Gambardella, "Ant algorithms for discrete optimization," *Artificial Life*, vol. 5, no. 2, pp. 137–172, Apr. 1999. [Online]. Available: <https://doi.org/10.1162/106454699568728>
- [11] H. M. Zangana, Z. B. Sallow, M. H. Alkawaz, and M. Omar, "Unveiling the collective wisdom: A review of swarm intelligence in problem solving and optimization," *Inform : Jurnal Ilmiah Bidang Teknologi Informasi dan Komunikasi*, vol. 9, no. 2, pp. 101–110, May 2024. [Online]. Available: <https://doi.org/10.25139/inform.v9i2.7934>
- [12] E. Bonabeau, M. Dorigo, and G. Theraulaz, *Swarm Intelligence: From Natural to Artificial Systems*. Oxford University Press, Oct. 1999. [Online]. Available: <https://doi.org/10.1093/oso/9780195131581.001.0001>
- [13] S. Garnier, J. Gautrais, and G. Theraulaz, "The biological principles of swarm intelligence," *Swarm Intelligence*, vol. 1, no. 1, pp. 3–31, 2007. [Online]. Available: <https://doi.org/10.1007/s11721-007-0004-y>
- [14] M. Dorigo and L. Gambardella, "Ant colony system: a cooperative learning approach to the traveling salesman problem," *IEEE Transactions on Evolutionary Computation*, vol. 1, no. 1, pp. 53–66, Apr. 1997. [Online]. Available: <https://doi.org/10.1109/4235.585892>
- [15] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of ICNN95 – International Conference on Neural Networks*, vol. 4. IEEE, 1995, pp. 1942–1948. [Online]. Available: <https://doi.org/10.1109/ICNN.1995.488968>
- [16] D. Karaboga and B. Basturk, "A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm," *Journal of Global Optimization*, vol. 39, no. 3, pp. 459–471, Apr. 2007. [Online]. Available: <https://doi.org/10.1007/s10898-007-9149-x>
- [17] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey wolf optimizer," *Advances in Engineering Software*, vol. 69, pp. 46–61, Mar. 2014. [Online]. Available: <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- [18] S. Mirjalili and A. Lewis, "The whale optimization algorithm," *Advances in Engineering Software*, vol. 95, pp. 51–67, May 2016. [Online]. Available: <https://doi.org/10.1016/j.advengsoft.2016.01.008>
- [19] A. D. Boursianis, M. S. Papadopoulou, M. Salucci, A. Polo, P. Sarigiannidis, K. Psannis, S. Mirjalili, S. Koulouridis, and S. K. Goudos, "Emerging swarm intelligence algorithms and their applications in antenna design: The GWO, WOA, and SSA optimizers," *Applied Sciences*, vol. 11, no. 18, p. 8330, 2021. [Online]. Available: <https://doi.org/10.3390/app11188330>
- [20] C. Li, B. Yan, C. Zhu, X. Zhou, and Y. Jia, "Swarm intelligence-optimized deep neural network for intelligent diagnosis of lithium-ion battery state of health," *Scientific Reports*, vol. 16, no. 1, Dec. 2025. [Online]. Available: <https://doi.org/10.1038/s41598-025-34022-2>
- [21] M. Clerc, *Particle Swarm Optimization*. Hoboken, NJ, USA: John Wiley & Sons, 2010, accessed: 2026-05-19. [Online]. Available: <https://upsalesiana.ec/ing36ar9r21>

- [22] A. G. Gad, "Particle swarm optimization algorithm and its applications: A systematic review," *Archives of Computational Methods in Engineering*, vol. 29, no. 5, pp. 2531–2561, Apr. 2022. [Online]. Available: <https://doi.org/10.1007/s11831-021-09694-4>
- [23] R. Ghanbarzadeh and S. Mirjalili, "A structured review of large language models in metaheuristic optimisation," *Decision Analytics Journal*, vol. 15, p. 100587, 2025. [Online]. Available: <https://doi.org/10.1016/j.dajour.2025.100587>
- [24] Y. Qiu, X. Yang, and S. Chen, "An improved gray wolf optimization algorithm solving to functional optimization and engineering design problems," *Scientific Reports*, vol. 14, no. 1, 2024. [Online]. Available: <https://doi.org/10.1038/s41598-024-64526-2>
- [25] Y. Ji, Q. Liu, C. Zhou, Z. Han, and W. Wu, "Hybrid swarm intelligence and human-inspired optimization for urban drone path planning," *Biomimetics*, vol. 10, no. 3, p. 180, Mar. 2025. [Online]. Available: <https://doi.org/10.3390/biomimetics10030180>
- [26] B. Cetinsaya, D. Reiners, and C. Cruz-Neira, "From PID to swarms: A decade of advancements in drone control and path planning - a systematic review (2013–2023)," *Swarm and Evolutionary Computation*, vol. 89, p. 101626, Aug. 2024. [Online]. Available: <https://doi.org/10.1016/j.swevo.2024.101626>
- [27] X. Chen, J. Tang, Y. Ruan, and J. Zhan, "Path planning methods for UAVs: A survey," in *Proceedings of the 3rd International Conference on Computer, Artificial Intelligence and Control Engineering*, ser. CAICE 2024. ACM, Jan. 2024, pp. 894–903. [Online]. Available: <https://doi.org/10.1145/3672758.3672905>
- [28] C. Y. Jie, M. B. Jasser, S.-S. M. Ajibade, H. N. Chua, R. T. Wong, A. S. Rafsanjani, and A. P. A. Majeed, "A survey on swarm intelligence algorithms for optimizing path planning," in *2025 21st IEEE International Colloquium on Signal Processing & Its Applications (CSPA)*. IEEE, Feb. 2025, pp. 283–288. [Online]. Available: <https://doi.org/10.1109/CSPA64953.2025.10933006>
- [29] C. Wang, S. Zhang, T. Ma, Y. Xiao, M. Z. Chen, and L. Wang, "Swarm intelligence: A survey of model classification and applications," *Chinese Journal of Aeronautics*, vol. 38, no. 3, p. 102982, Mar. 2025. [Online]. Available: <https://doi.org/10.1016/j.cja.2024.03.019>
- [30] G. E. M. Abro, A. M. Abdallah, F. Zahid, and S. Ahmed, "A comprehensive review of next-gen uav swarm robotics: Optimisation techniques and control strategies for dynamic environments," *Intelligent Automation & Soft Computing*, vol. 40, no. 1, pp. 99–123, 2025. [Online]. Available: <https://doi.org/10.32604/iasc.2025.060364>
- [31] M. Kaur, A. Kaur, and P. Singh, "Uav swarm clustering and trajectory planning: A taxonomy, systematic review, current trends and research challenges," *Computers and Electrical Engineering*, vol. 128, p. 110697, Dec. 2025. [Online]. Available: <https://doi.org/10.1016/j.compeleceng.2025.110697>
- [32] M. J. Page, J. E. McKenzie, P. M. Bossuyt, I. Boutron, T. C. Hoffmann, C. D. Mulrow, L. Shamseer, J. M. Tetzlaff, E. A. Akl, S. E. Brennan, R. Chou, J. Glanville, J. M. Grimshaw, A. Hróbjartsson, M. M. Lalu, T. Li, E. W. Loder, E. Mayo-Wilson, S. McDonald, L. A. McGuinness, L. A. Stewart, J. Thomas, A. C. Tricco, V. A. Welch, P. Whiting, D. Moher, J. J. Yepes-Núñez, G. Urrútia, M. Romero-García, and S. Alonso-Fernández, "Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas," *Revista Española de Cardiología*, vol. 74, no. 9, pp. 790–799, 2021. [Online]. Available: <https://doi.org/10.1016/j.recesp.2021.06.016>
- [33] J. Yang, F. Yan, J. Zhang, and C. Peng, "Hybrid chaos game and grey wolf optimization algorithms for uav path planning," *Applied Mathematical Modelling*, vol. 142, p. 115979, 2025. [Online]. Available: <https://doi.org/10.1016/j.apm.2025.115979>
- [34] P. Wu, T. Li, and G. Song, "Ucav path planning based on improved chaotic particle swarm optimization," in *2020 Chinese Automation Congress (CAC)*. IEEE, Nov. 2020, pp. 1069–1073. [Online]. Available: <https://doi.org/10.1109/CAC51589.2020.9326556>
- [35] R. A. Saeed, M. Omri, S. Abdel-Khalek, E. S. Ali, and M. F. Alotaibi, "Optimal path planning for drones based on swarm intelligence algorithm," *Neural Computing and Applications*, vol. 34, no. 12, pp. 10 133–10 155, Apr. 2022. [Online]. Available: <https://doi.org/10.1007/s00521-022-06998-9>
- [36] N. Xu, H. Zhu, and J. Sun, "Bionic 3D path planning for plant protection UAVs based on swarm intelligence algorithms and krill swarm behavior," *Biomimetics*, vol. 9, no. 6, p. 353, 2024. [Online]. Available: <https://doi.org/10.3390/biomimetics9060353>

- [37] C. Li and D. C. Coster, "Improved particle swarm optimization algorithms for optimal designs with various decision criteria," *Mathematics*, vol. 10, no. 13, p. 2310, 2022. [Online]. Available: <https://doi.org/10.3390/math10132310>
- [38] X. Deng, J. Chen, C. Chen, Y. Zhang, and Z. Zhang, "UAV path planning with improved PSO algorithm based on levy flight," in *Proceedings of the 2024 6th International Conference on Control and Computer Vision*, ser. ICCCV 2024. ACM, 2024, pp. 86–91. [Online]. Available: <https://doi.org/10.1145/3674700.3674714>
- [39] Y. Wang, F. Hu, H. Xu, and J. Zeng, "A multigroups cooperative particle swarm algorithm for optimization of multivehicle path planning in internet of vehicles," *IEEE Internet of Things Journal*, vol. 11, no. 22, pp. 35 839–35 851, Nov. 2024. [Online]. Available: <https://doi.org/10.1109/JIOT.2024.3367328>
- [40] X. Zhou, F. Gao, X. Fang, and Z. Lan, "Improved bat algorithm for UAV path planning in three-dimensional space," *IEEE Access*, vol. 9, pp. 20 100–20 116, 2021. [Online]. Available: <https://doi.org/10.1109/ACCESS.2021.3054179>
- [41] B. Ma, Y. Ji, and L. Fang, "A multi-UAV formation obstacle avoidance method combined with improved simulated annealing and an adaptive artificial potential field," *Drones*, vol. 9, no. 6, p. 390, May 2025. [Online]. Available: <https://doi.org/10.3390/drones9060390>
- [42] K. A.-R. Youssefi and M. Rouhani, "Swarm intelligence based robotic search in unknown maze-like environments," *Expert Systems with Applications*, vol. 178, p. 114907, 2021. [Online]. Available: <https://doi.org/10.1016/j.eswa.2021.114907>
- [43] M. Cosar, "Path planning via swarm intelligence algorithms in unmanned aerial vehicle population," *The Eurasia Proceedings of Science Technology Engineering and Mathematics*, vol. 26, pp. 439–450, Dec. 2023. [Online]. Available: <https://doi.org/10.55549/epstem.1411059>
- [44] H. Zhu, Y. Wang, Z. Ma, and X. Li, "A comparative study of swarm intelligence algorithms for ucav path-planning problems," *Mathematics*, vol. 9, no. 2, p. 171, Jan. 2021. [Online]. Available: <https://doi.org/10.3390/math9020171>
- [45] L. Wang, J. Li, J. Qi, and J. He, "Auv underwater 3d path planning based on particle swarm optimization-adaptive step-size cuckoo search algorithm," in *Proceedings of the 2022 11th International Conference on Networks, Communication and Computing*, ser. ICNCC 2022. ACM, Dec. 2022, pp. 215–225. [Online]. Available: <https://doi.org/10.1145/3579895.3579929>
- [46] Z. Liu, D. Ning, J. Hou, F. Zhang, and G. Liang, "Auv path planning in a three-dimensional marine environment based on a novel multiple swarm co-evolutionary algorithm," *Applied Soft Computing*, vol. 164, p. 111933, Oct. 2024. [Online]. Available: <https://doi.org/10.1016/j.asoc.2024.111933>
- [47] L. Lyu and F. Yang, "Mmpa: A modified marine predator algorithm for 3D UAV path planning in complex environments with multiple threats," *Expert Systems with Applications*, vol. 257, p. 124955, Dec. 2024. [Online]. Available: <https://doi.org/10.1016/j.eswa.2024.124955>
- [48] Y. Zhou, X. Kong, K.-P. Lin, and L. Liu, "Novel task decomposed multi-agent twin delayed deep deterministic policy gradient algorithm for multi-UAV autonomous path planning," *Knowledge-Based Systems*, vol. 287, p. 111462, Mar. 2024. [Online]. Available: <https://doi.org/10.1016/j.knosys.2024.111462>
- [49] Z. Wang, Y. Zhang, J. Yu, Y. Gao, G. Zhao, E. H. Houssein, and R. Zhong, "Multi-strategy enhanced marine predator algorithm: performance investigation and application in intrusion detection," *Journal of Big Data*, vol. 12, no. 1, Feb. 2025. [Online]. Available: <https://doi.org/10.1186/s40537-025-01080-2>
- [50] K. Li, F. Ge, Y. Han, Y. Wang, and W. Xu, "Path planning of multiple UAVs with online changing tasks by an ORPFOA algorithm," *Engineering Applications of Artificial Intelligence*, vol. 94, p. 103807, 2020. [Online]. Available: <https://doi.org/10.1016/j.engappai.2020.103807>
- [51] H. Zhang, M. Wang, Y. Ping, C. Wu, J. Qi, W. Wu, and E. Zhou, "UAV path planning based on expert experience strategy RRT algorithm," in *2024 43rd Chinese Control Conference (CCC)*. IEEE, 2024, pp. 2124–2129. [Online]. Available: <https://doi.org/10.23919/CCC63176.2024.10662062>
- [52] Y. Wang, K. Li, Y. Han, and X. Yan, "Distributed multi-UAV cooperation for dynamic target tracking optimized by an SAQPSO algorithm," *ISA Transactions*, vol. 129, pp. 230–242, Oct. 2022. [Online]. Available: <https://doi.org/10.1016/j.isatra.2021.12.014>
- [53] W. Zhao, L. Wang, and S. Mirjalili, "Artificial hummingbird algorithm: A new bio-inspired optimizer with its engineering applications," *Computer Methods in Applied Mechanics and Engineering*, vol. 388, p. 114194, Jan. 2022. [Online]. Available: <https://doi.org/10.1016/j.cma.2021.114194>

- [54] S. Sharma, A. Bhardwaj, A. Singh, and V. Singh, “Enhanced moth flame optimization algorithm entropy-based centroid svm-based software defect prediction,” *Journal of Electronic Testing*, vol. 41, no. 5-6, pp. 631–649, Nov. 2025. [Online]. Available: <https://doi.org/10.1007/s10836-025-06203-4>
- [55] Y. Zhan, M. Ding, Y. Yuan, J. Zhang, Q. Yang, G. Shi, and J. Jiang, “Large-scale UAV swarm path planning based on mean-field reinforcement learning,” *Chinese Journal of Aeronautics*, vol. 38, no. 9, p. 103484, 2025. [Online]. Available: <https://doi.org/10.1016/j.cja.2025.103484>
- [56] Z. Meng, D. Li, Y. Zhang, and H. Yan, “Intelligent scheduling technology of swarm intelligence algorithm for drone path planning,” *Drones*, vol. 8, no. 4, p. 120, Mar. 2024. [Online]. Available: <https://doi.org/10.3390/drones8040120>
- [57] J. Luo, Y. Tian, and Z. Wang, “Research on unmanned aerial vehicle path planning,” *Drones*, vol. 8, no. 2, p. 51, Feb. 2024. [Online]. Available: <https://doi.org/10.3390/drones8020051>
- [58] T. Volovoda, “Swarm intelligence for UAV,” in *2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD)*. IEEE, Oct. 2024, pp. 313–316. [Online]. Available: <https://doi.org/10.1109/APUAVD64488.2024.10765878>
- [59] Y. Zhou, B. Rao, and W. Wang, “UAV swarm intelligence: Recent advances and future trends,” *IEEE Access*, vol. 8, pp. 183 856–183 878, 2020. [Online]. Available: <https://doi.org/10.1109/ACCESS.2020.3028865>