

Optimización de rutas asistida cuánticamente para la exploración geológica marina con UAV

David Rojas-Arciniegas¹

Artículo de investigación



Fecha de recepción: 13 de mayo de 2025 ■ **Fecha de aceptación:** 4 de junio de 2025 ■ **Fecha de publicación:** 12 de junio de 2026

✉ Fundación Universitaria Agraria de Colombia, Bogotá, Colombia. rojas.david2@uniagraria.edu.co.

Rojas-Arciniegas, D. (2026). Optimización de rutas asistida cuánticamente para la exploración geológica marina con UAV. *Revista de Investigaciones Uniagraria*, 13(1), 74-92.

Resumen

La exploración geológica en entornos marinos se enfrenta a crecientes retos operativos y ambientales, desde condicionantes ecológicas y costos elevados, hasta la escasez de datos geoespaciales de alta resolución. Este trabajo introduce un marco de simulación con refuerzo cuántico que combina la Optimización Binaria Cuadrática sin Restricciones (QUBO) y el Algoritmo de Optimización Cuántica Aproximada (QAOA), para optimizar la planificación de rutas en etapas tempranas de reconocimiento geológico en cuencas *offshore* de Colombia. El área de estudio, de 1 km², se discretiza en una malla de 10 × 10 de celdas de 100 m × 100 m, a cada una de las cuales se le asigna un puntaje de prioridad geoestructural. La formulación QUBO resultante integra en una estructura binaria de decisión la conectividad espacial, las reglas de desplazamiento y la pertinencia geológica, y se resuelve mediante rutinas híbridas de optimización cuántico-clásicas. Los hallazgos muestran que las soluciones basadas en QAOA generan trayectorias de exploración coherentes y eficientes, capaces de privilegiar objetivos geológicos de alto valor, sin sacrificar la continuidad espacial ni el cumplimiento de restricciones energéticas. En conjunto, el marco propuesto perfila una ruta promisoría hacia estrategias de exploración marina de bajo impacto y costo eficiente, con escalabilidad a ámbitos marítimos más amplios. Así mismo, es compatible con extensiones futuras que incorporen clasificación geológica asistida por IA y planificación de rutas adaptativa en tiempo real mediante sistemas multiagente.

Palabras clave: Algoritmo de Optimización Cuántica Aproximada (QAOA), búsqueda de trayectorias con restricción energética, cuencas *offshore* de Colombia, exploración geológica *offshore*, Optimización Binaria Cuadrática sin Restricciones (QUBO), planificación de rutas.

¹ Fundación Universitaria Agraria de Colombia, Bogotá, Colombia.

Quantum-Assisted Route Optimization for UAV Offshore Geological Exploration

Abstract

Marine geological exploration faces increasing operational and environmental challenges, ranging from ecological constraints and high costs to the scarcity of high-resolution geospatial data. This work introduces a quantum-enhanced simulation framework that combines Quadratic Unconstrained Binary Optimization (QUBO) and the Quantum Approximate Optimization Algorithm (QAOA) to optimize route planning in the early stages of geological reconnaissance in offshore basins of Colombia. The 1 km² study area is discretized into a 10×10 grid of 100 m × 100 m cells, each assigned a geostructural priority score. The resulting QUBO formulation integrates spatial connectivity, movement rules, and geological relevance into a binary decision structure, which is then solved using hybrid quantum-classical optimization routines. The findings show that QAOA-based solutions generate coherent and efficient exploration trajectories, capable of prioritizing high-value geological targets without compromising spatial continuity or compliance with energy constraints. Overall, the proposed framework outlines a promising pathway toward low-impact and cost-efficient marine exploration strategies, scalable to broader maritime contexts. Furthermore, it is compatible with future extensions involving AI-assisted geological classification and real-time adaptive route planning through.

Keywords: Quantum Approximate Optimization Algorithm (QAOA), Quadratic Unconstrained Binary Optimization (QUBO), offshore geological exploration, route planning, offshore basins of Colombia, energy-constrained pathfinding.

Introducción

La franja marítima colombiana en el Caribe constituye una frontera con alto potencial, pero ha sido poco estudiada para la exploración de hidrocarburos en aguas profundas (Vargas, 2012). Aunque existe un interés sostenido por parte de entidades energéticas nacionales e internacionales, la complejidad geológica, las condiciones de gran calado y los elevados costos logísticos han restringido tanto la cartografía geomorfológica de detalle como los análisis de prospectividad en etapas tempranas (Suárez Bermúdez *et al.*, 2025). Las campañas marinas convencionales basadas en adquisición sísmica, gravimetría y multihaz son prolongadas y onerosas, demandan embarcaciones especializadas y conllevan un posprocesamiento intensivo. En consecuencia, se requieren enfoques alternativos que posibiliten la caracterización preliminar de estructuras potenciales con mínima intervención física (Rodríguez *et al.*, 2021).

De manera simultánea, los avances en inteligencia artificial (IA) y computación cuántica están habilitando nuevas rutas para la adquisición, el tratamiento y la interpretación de información geocientífica (Geda & Tang, 2025). Métodos de IA como las redes neuronales convolucionales (CNN) (Vadyala & Betgeri, 2023) y los modelos generativos (Boone *et al.*, 2025) han probado su eficacia para extraer rasgos geomorfológicos a partir de datos geoespaciales tanto sintéticos como reales, incluidos mosaicos batimétricos y altimetría radar. En paralelo, los algoritmos de inspiración cuántica —en especial el Algoritmo de Optimización Cuántica Aproximada (QAOA, sigla del nombre en inglés) y las formulaciones de Optimización Binaria Cuadrática sin Restricciones (QUBO, sigla del nombre en inglés)— ganan tracción por su capacidad de abordar problemas combinatorios complejos con recursos computacionales acotados y bajo alta incertidumbre (Jun, 2024).

El presente trabajo expone un marco de simulación de bajo peso computacional que integra planificación de rutas con QAOA y modelos geoespaciales discretizados en rejilla para la

exploración de terrenos marinos. Se selecciona un dominio de 1 km × 1 km en cuencas *offshore* (fuera de la costa) de Colombia, a partir de datos oceánicos públicos, para emular una misión autónoma de mapeo comparable a las realizadas por vehículos de superficie no tripulados (USV, sigla del nombre en inglés) o vehículos submarinos autónomos (AUV, sigla del nombre en inglés). El espacio discretizado se traduce a una formulación de QUBO que codifica rutas de navegación factibles sujetas a la autonomía de batería, la dirección de las corrientes y la topografía del fondo marino.

Dadas las dificultades logísticas y los costos de operar misiones reales en ambientes *offshore* colombianos, se adopta una estrategia de validación por simulación con análogos topográficos reales y experimentos computacionales. Esta aproximación permite ensayar una canalización de optimización híbrida cuántico-clásica en condiciones cercanas a las operacionales. Al combinar la codificación QUBO, solucionadores QAOA y un esquema de priorización de objetivos asistido por IA, el modelo ilustra cómo ajustar la planificación de trayectorias para privilegiar la relevancia geológica sin sobrepasar las restricciones de recursos.

La estructura del presente artículo es la siguiente. El segundo apartado revisa los fundamentos de QUBO y QAOA aplicados a la optimización geoespacial. El tercero describe el dominio de simulación, la codificación de la rejilla y las funciones objetivo. El cuarto ilustra el caso de la costa Caribe colombiana. El quinto presenta resultados ilustrativos de los experimentos de optimización de rutas. Luego, en el sexto, se discuten las implicaciones para la geociencia marina, y el apartado séptimo ofrece recomendaciones para su despliegue en escenarios reales y para la integración futura de enfoques cuánticos en los flujos de trabajo de exploración *offshore*.

Revisión de literatura

Los progresos más recientes en algoritmos cuánticos orientados a la optimización combinatoria

han dado pie a nuevas metodologías capaces de abordar tareas como la planificación de rutas, la asignación de recursos y la navegación autónoma en espacios geoespaciales (Lins *et al.*, 2025). Dentro de este panorama, los modelos de QUBO y su ejecución con algoritmos como el QAOA se posicionan como enfoques de referencia, compatibles con arquitecturas de *hardware* cuántico de corto plazo y con esquemas híbridos cuántico-clásicos (Blekos *et al.*, 2024; Dong *et al.*, 2020). En tales formulaciones, la matriz Q —de carácter simétrico— recoge tanto las interacciones lineales como las cuadráticas entre las variables de decisión (Huo *et al.*, 2024). Esta estructura ofrece la flexibilidad necesaria para modelar caminos óptimos, restricciones de cobertura cartográfica, límites energéticos y criterios de priorización geológica dentro de un espacio binario de decisión unificado. Problemas tradicionales de georreferenciación, selección de puntos de muestreo o programación de misiones bajo recursos acotados pueden representarse con eficacia mediante un esquema QUBO (McCollum & Krauss, 2021).

En ámbitos marinos, como en cuencas *offshore* de Colombia, discretizar el fondo oceánico en una rejilla navegable permite asociar a cada celda o transición una variable binaria. Las rutas viables se describen entonces como secuencias de variables activadas a lo largo de la malla, sujetas a condicionantes de autonomía del vehículo, presencia de obstáculos submarinos o prioridades de exploración previamente establecidas (Vargas, 2012). Estas restricciones se incorporan como penalizaciones cuadráticas en la matriz Q , lo que habilita la resolución de problemas tanto de cobertura mínima como de enrutamiento con múltiples objetivos (Bouchmal *et al.*, 2025).

Por su parte, QAOA aporta un enfoque variacional cuántico para la optimización, sustentado en una sucesión de operadores unitarios parametrizados que aproximan el estado fundamental del sistema cuántico donde se codifica el objetivo de QUBO (Acampora *et al.*, 2023). La evidencia reciente sugiere que QAOA rinde de forma alentadora en condiciones ruidosas y en

situaciones donde se buscan soluciones cercanas al óptimo (Pan *et al.*, 2022). En problemas de navegación, esta técnica favorece el diseño de trayectorias adaptativas ante incertidumbres como corrientes marinas, fallos o desviaciones de sensores y variaciones en las prioridades de cobertura.

A diferencia de algoritmos clásicos de ruteo (p. ej., Dijkstra o A^*), que suelen requerir recomputaciones completas cuando cambian las condiciones (Acampora *et al.*, 2023), QAOA posibilita reconfiguraciones parciales e incorpora información probabilística sobre la calidad de las soluciones (Ruan *et al.*, 2023). Por ello, resulta especialmente adecuado para planificar misiones marítimas en entornos donde los datos batimétricos o espectrales son incompletos o presentan ruido.

Entre las ventajas de utilizar QUBO o QAOA en exploración geoespacial, se encuentran (Kurowski *et al.*, 2023; Liu *et al.*, 2025):

- Codificación compacta y conjunta de distintos tipos de restricciones y objetivos dentro de una formulación matricial única
- Capacidad de adaptación a escenarios cambiantes mediante ajustes paramétricos
- Disminución de la complejidad computacional en problemas de gran escala con múltiples condicionantes simultáneos
- Proyección de escalabilidad hacia implementaciones reales en recodores cuánticos dedicados o en plataformas cuánticas híbridas basadas en la nubeEste sustrato teórico sustenta el diseño del experimento de simulación en cuencas *offshore* de Colombia, presentado en la sección siguiente, donde se expone con detalle la formulación de QUBO y su resolución mediante técnicas basadas en QAOA aplicadas a un dominio de misión discretizado.

Materiales y métodos

Este estudio se centra en un dominio geoespacial simulado en cuencas *offshore* de Colombia (figura 1), seleccionado específicamente por su importancia estratégica para exploraciones futuras y por su accesibilidad mediante imágenes satelitales y modelos digitales de elevación. Se ha definido un área representativa de 1 km^2 ($1 \text{ km} \times 1 \text{ km}$) como malla operativa de simulación. Esta región presenta un patrón de batimetría relativamente homogéneo y es adecuada para modelar misiones de cobertura con aeronaves o vehículos remotos.

La malla de simulación se discretiza en 10×10 celdas cuadradas, cada una representando un área de $100 \text{ m} \times 100 \text{ m}$. Esta estructura permite modelar

en detalle problemas de enrutamiento al asociar a cada nodo de la rejilla parámetros geoespaciales cuantificables, como la pendiente del lecho marino, el costo estimado de navegación o las zonas de riesgo hidrográfico. La superficie de navegación se trata, por tanto, como un grafo ponderado, donde las aristas corresponden a movimientos factibles entre celdas adyacentes y los pesos codifican métricas de riesgo o energía. Esta discretización permite expresar el problema como una optimización de recorrido basada en grafos, cuyo objetivo es maximizar la cobertura bajo restricciones como el consumo de batería, la evitación de obstáculos o la exposición dinámica al riesgo. La formulación emplea el modelo QUBO como abstracción matemática, lo que permite integrar criterios multiobjetivo en un único marco de optimización compatible con solucionadores cuánticos o híbridos.




Figura 1. Imagen de cuencas *offshore* de Colombia.

Fuente: Agencia Nacional de Hidrocarburos (ANH).

Para formalizar el enrutamiento autónomo de un vehículo aéreo no tripulado (UAV) sobre el dominio discretizado de exploración *offshore*, planteamos la optimización de la trayectoria como un problema de QUBO. Este enfoque de modelado permite su implementación directa en solucionadores híbridos cuántico-clásicos, específicamente bajo el paradigma de QAOA.

Sea el dominio de simulación de 100 m^2 discretizado en una rejilla cuadrada de $N \times N$, donde cada celda (i,j) representa una ubicación potencial para el recorrido del UAV. Defínase la variable de decisión binaria $x_{ij} \in \{0,1\}$, tal que $x_{ij} = 1$ si la celda (i,j) se incluye en la ruta, y $x_{ij} = 0$ en caso contrario.

El objetivo es determinar una trayectoria que: 1) maximice la cobertura sobre celdas geoespaciales de alta prioridad; 2) cumpla con las restricciones de energía y distancia, y 3) minimice las discontinuidades de la trayectoria. Estos requisitos se codifican en la siguiente estructura QUBO:

$$\min_x \left(\sum_{(i,j) \in \Omega} w_{ij} x_{ij} + \lambda_1 \sum_{\substack{(i,j),(k,l) \in \Omega \\ \text{non-adjacent}}} x_{ij} x_{kl} + \lambda_2 \left(\sum_{(i,j) \in \Omega} d_{i,j} x_{ij} - D_{max} \right)^2 \right) \quad (1)$$

Donde:

- Ω es el conjunto de todas las celdas de la rejilla.
- w_{ij} denota el puntaje de prioridad geológica para la celda (i,j) , basado en atributos simulados o derivados de satélite reales.

- λ_1 y λ_2 son coeficientes de penalización que controlan, respectivamente, la continuidad de la trayectoria y la aplicación de la restricción de longitud de la ruta.
- $d_{i,j}$ representa el costo de tránsito o la distancia asociada con visitar la celda (i,j) .
- D_{max} es el alcance máximo de vuelo del UAV, determinado por la batería y las limitaciones específicas de la misión.

El primer término recompensa la exploración de regiones geológicamente relevantes. El segundo término penaliza trayectorias desconectadas al desincentivar la activación simultánea de celdas distantes. El tercero impone una restricción suave para asegurar que el costo total de la ruta permanezca dentro del umbral operativo del UAV. Esta formulación se traduce directamente a una matriz QUBO Q , donde el problema de optimización adopta la forma canónica:

$$\min_{x \in \{0,1\}^n} x^T Q x \quad (2)$$

En la figura 2 se muestra un ejemplo representativo de matriz QUBO, donde cada componente Q_{ab} expresa el peso de la interacción entre las variables binarias x_a y x_b , obtenido a partir de la combinación de los pesos de prioridad, las restricciones de adyacencia y las penalizaciones por distancia. De este modo, cada Q_{ab} actúa como un sesgo unario o como un acoplamiento binario entre variables (celdas), capturando la recompensa por cobertura, la continuidad del recorrido y las restricciones energéticas.

Esta instancia QUBO se integra posteriormente en una rutina de QAOA. El procedimiento alterna capas de evolución cuántica con etapas de optimización clásica para hallar una solución aproximada que minimice el paisaje de energía codificado por Q . La implementación de QAOA permite un ajuste adaptativo tanto en *backends* cuánticos ruidosos como en simuladores,

y resulta especialmente idónea para problemas de enrutamiento con restricciones en entornos dinámicos o parcialmente conocidos.

La planificación de rutas se plantea como un problema combinatorio cuyo propósito es

maximizar la cobertura de zonas prioritarias bajo limitaciones de energía, visibilidad y conectividad. Para ello, se construye un grafo dirigido $G = (N, E)$, en el que los nodos N representan puntos de interés georreferenciados, y las aristas E codifican costos de transición, tales como distancia, pendiente y densidad.




Figura 2. Representación de la matriz QUBO para la optimización de la planificación de rutas. Cada celda (a, b) indica el peso de interacción entre las variables de la rejilla x_a y x_b .

Fuente: elaboración propia.

Resolución con QAOA e interpretación

El modelo QUBO se aborda mediante una implementación de QAOA ejecutada en un entorno de simulación cuántica (p. ej., Qiskit o PennyLane). Este esquema híbrido combina operadores unitarios cuánticos parametrizados con bucles de optimización clásicos, para aproximar soluciones cercanas al óptimo. Para valorar la calidad de las soluciones se analizan varios hiperparámetros y métricas, entre ellos la profundidad del *ansatz*, el rendimiento de la función objetivo y los indicadores de fidelidad.

Las trayectorias obtenidas se contrastan con algoritmos clásicos de búsqueda de rutas

(como Dijkstra y A*) con el fin de cuantificar la ganancia relativa en cobertura geográfica, eficiencia energética y número de estructuras geológicas identificadas. Las rutas finales se representan en un sistema de información geográfica, integrando capas geológicas e imágenes simuladas del UAV para garantizar coherencia espacial y pertinencia científica.

Este apartado prepara la implementación del algoritmo de optimización descrito en la siguiente sección, donde se validan, bajo el marco QUBO/QAOA, estrategias de planificación de misión para exploraciones con UAV o AUV en regiones *offshore*.

Caso de estudio

Esta sección describe la implementación del algoritmo de enrutamiento inspirado en la computación cuántica presentado en la sección anterior, utilizando un escenario *offshore* realista para evaluar el desempeño de la planificación de rutas con UAV. El banco de pruebas seleccionado corresponde a la cuenca Guajira *Offshore*, en el norte de Colombia, una región de alto interés estratégico debido a su compleja morfología del fondo marino y a la presencia de trampas estructurales y acumulaciones controladas por fallas.

Área de estudio y datos de entrada

Para simular una misión de reconocimiento *offshore* con UAV, se seleccionó un corredor de 1 km² dentro de la cuenca Guajira *Offshore*. Esta zona contiene pozos sísmicos históricos (p. ej., Chuchupa, Ballena, Tiburón) y objetivos geológicos conocidos de interés para la exploración temprana de hidrocarburos. El área se caracteriza por fuertes gradientes batimétricos y diversas estructuras sedimentarias, lo que la hace adecuada para evaluar tanto la cobertura como la factibilidad del enrutamiento.

El dominio espacial se discretizó en una rejilla de 10 × 10, donde cada celda representa una unidad superficial de 100 m × 100 m. A cada celda se le asignó un puntaje geoespacial compuesto, basado en los siguientes tres atributos principales:

- Capa de complejidad batimétrica: simula el gradiente de irregularidades del fondo marino mediante funciones de elevación perturbadas con ruido.
- Capa de prioridad geológica: asigna pesos mayores a las celdas adyacentes a altos estructurales conocidos o sospechados.
- Capa de riesgo ambiental: marca áreas de peligro operativo debido a inestabilidad de sedimentos, corrientes marinas, fallas del lecho marino o restricciones ecológicas. Cada atributo se simuló utilizando valores análogos derivados de mapas geológicos regionales, registros sísmicos y estudios ambientales marinos. La figura 3 muestra la rejilla discretizada proyectada sobre la zona de simulación definida.

La tabla 1 resume los atributos geoespaciales codificados por celda.

Tabla 1. Atributos geoespaciales

Atributo	Tipo	Escala	Descripción
Gradiente batimétrico	Continuo	[0,0 - 1,0]	Valores más altos indican pendientes pronunciadas y desafíos operativos de navegación.
Puntaje de prioridad geológica	Discreto	[0 - 3]	Asignado según la proximidad a altos estructurales o indicadores de fallas.
Zonas de exclusión ambiental	Binario (0/1)	0 o 1	Indica áreas restringidas por limitaciones ecológicas o regulatorias.

Mapa de costo energético	Continuo	[0 - 2,0]	Costo energético sintético para alcanzar o transitar entre celdas.
Nivel de riesgo (índice de peligrosidad)	Continuo	[0,0 - 2,0]	Métrica compuesta a partir de batimetría, corrientes y la incertidumbre sobre el terreno.

Fuente: elaboración propia.

Definición del caso y parámetros de simulación

Para validar el modelo de enrutamiento propuesto basado en QUBO en un contexto geológicamente realista, seleccionamos un área de exploración *offshore* de 1 km² cercana al pozo de gas Chuchupa-1, ubicado en la cuenca Guajira *Offshore* (11°48'02"N, 72°50'21"O). Este sitio forma parte de una región de interés estratégico para la transición energética de Colombia y se caracteriza tanto por una batimetría compleja como por la elevada actividad sísmica. La zona

ha sido explorada previamente por Ecopetrol y Chevron, y es conocida por la presencia de trampas estructurales y acumulaciones controladas por fallas (figura 3).

Los atributos de la zona se simularon a partir de valores análogos derivados de informes geológicos regionales, estudios ambientales marinos y campañas sísmicas *offshore* previas. El modelo QUBO incluye términos de penalización para desincentivar rutas redundantes y el tránsito por zonas restringidas o de alto riesgo. Los parámetros clave de simulación se resumen en la tabla 2.




Figura 3. Rejilla generada sobre el área de simulación.

Fuente: Agencia Nacional de Hidrocarburos (ANH).

La configuración del caso ofrece un escenario controlado y, a la vez, verosímil para poner a prueba el rendimiento del marco de enrutamiento con refuerzo cuántico bajo restricciones operativas y riesgos condicionados por el terreno. En la subsección siguiente se presentan los resultados de la simulación y la comparación visual entre las rutas obtenidas con QAOA y los referentes clásicos. Para construir el mapa de prioridad geológica se empleó una función de decaimiento *gaussiano* centrada en la estructura Chuchupa-1, que asigna puntuaciones más altas a las celdas adyacentes. La figura 4 muestra el mapa de calor resultante, donde los tonos más oscuros indican mayor relevancia exploratoria. Este sector reviste interés estratégico por la presencia de rasgos profundos como anticlinales, altos estructurales, domos salinos y zonas falladas, previamente inferidos a partir de datos sísmicos y mapas geofísicos regionales (Agencia Nacional de Hidrocarburos, 2009).

Para complementar esta capa e incorporar la factibilidad ambiental, se generó un mapa sintético de riesgo ambiental utilizando un modelo

probabilístico de peligrosidad. Los niveles de riesgo se categorizaron así:

- Nivel 3 (alto riesgo): zonas simuladas expuestas a corrientes marinas intensas, fuertes irregularidades del fondo marino o áreas de exclusión ecológica (p. ej., hábitats de coral).
- Nivel 2 (riesgo moderado): zonas cercanas a transiciones estructurales o con inestabilidad de pendiente leve.
- Nivel 1 (bajo riesgo): áreas con preocupaciones operativas menores.
- Nivel 0 (sin riesgo): zonas consideradas seguras para tránsito autónomo.

La figura 5 presenta el mapa de calor de riesgo ambiental sintetizado sobre la rejilla de simulación. Esta capa cumple un papel crítico al penalizar rutas inseguras durante el proceso de optimización QUBO.

Tabla 2. Parámetros

Parámetro	Símbolo	Valor	Unidad	Descripción
Tamaño de la rejilla	$N \times N$	10×10	Celdas	Discretización de la región en una malla 2D
Resolución de celda	-	500	Metros	Longitud de cada lado de las celdas cuadradas
Límite de energía del UAV	$D_{\max}$	3.500	Metros	Longitud máxima de vuelo (distancia euclidiana total)
Penalización por discontinuidad	λ_1	1	-	Peso para desincentivar la activación de celdas no adyacentes
Penalización por restricción energética	λ_2	0,5	-	Peso aplicado para asegurar que el costo total de la ruta se mantenga por debajo de la autonomía del UAV

Iteraciones máximas (QAOA)	-	150	-	Número máximo de rondas de optimización del circuito cuántico-clásico
Profundidad de capas de QAOA	p	2	-	Profundidad de las capas del circuito cuántico (operadores alternados de mezcla/fase)

Fuente: elaboración propia.

Se empleó esta capa de restricciones de carácter sintético para introducir penalizaciones en la función de costo QUBO cuando las trayectorias atravesaban zonas de riesgo medio o alto. En consecuencia, el modelo de inspiración cuántica se vio compelido a generar rutas más seguras y energéticamente más eficientes, incrementando

la factibilidad de la misión bajo condiciones de incertidumbre operativa. Además, esta capa permitió analizar la sensibilidad y la capacidad de adaptación de los solucionadores basados en QAOA frente a escenarios de reconfiguración del riesgo en tiempo real, frecuentes en contextos de exploración marina.




Figura 4. Mapa de calor geológico.

Fuente: elaboración propia.




Figura 5. Mapa de calor de riesgo ambiental.

Fuente: elaboración propia.

Con el fin de complementar el análisis de prioridad geológica y habilitar un enrutamiento adaptativo sujeto a restricciones operativas, se elaboró un mapa simulado de riesgo ambiental sobre la rejilla definida en *Guajira Offshore*. Dicha capa integra estimaciones sintéticas de amenazas ambientales que pueden incidir en la viabilidad y la seguridad de la navegación autónoma en medios marinos. El perfil de riesgo simulado contempla factores como corrientes marinas intensas, inestabilidad de sedimentos, zonas de exclusión ecológica (p. ej., arrecifes de coral o hábitats protegidos) y obstrucciones de origen antrópico (p. ej., infraestructura marítima).

A cada celda de la rejilla se le asignó un puntaje de riesgo normalizado entre 0 (amenaza ambiental mínima) y 1 (peligro operativo severo). La distribución espacial de estos valores siguió una ley de decaimiento gaussiano a partir de epicentros de alto riesgo definidos manualmente, emulando patrones observados en entornos *offshore* análogos.

La figura 6 presenta el mapa de calor resultante, en el que los tonos más oscuros indican un riesgo ambiental más elevado. La heterogeneidad espacial que captura la capa de riesgo resulta determinante para delinear corredores de navegación viables y para diseñar estrategias de optimización conscientes de las restricciones.

Dentro del marco de la formulación de QUBO/QAOA, la capa de riesgo ambiental se incorpora como un término penalizador en la función objetivo, desalentando soluciones de ruta que crucen áreas de alto riesgo. Esta integración de doble capa (prioridad geológica y riesgo ambiental) permite al modelo de enrutamiento conciliar los objetivos de exploración con la seguridad de la misión y las limitaciones energéticas. El comportamiento obtenido emula la planificación experta humana, adaptándose de manera dinámica a regiones hostiles o inciertas durante las operaciones de reconocimiento *offshore*.




Figura 6. Mapa de calor compuesto.

Fuente: elaboración propia.

Resultados

Esta sección expone los resultados derivados de la simulación de rutas de exploración geológica sobre una rejilla de 10×10 que modela la cuenca Guajira *Offshore*. Cada celda de dicha rejilla corresponde a una zona geoespacial caracterizada por un nivel de prioridad geológica y un nivel de riesgo ambiental. El problema se planteó como una QUBO y se resolvió con el QAOA, complementado con heurísticas adaptadas a un patrón de movimiento tipo rey (esto es, adyacencia a 8 vecinos). Para definir las trayectorias de exploración se emplearon dos criterios estratégicos: la prioridad geológica (considerando únicamente los niveles 2 y 3) y un índice de riesgo compuesto.

Implementación computacional y plataforma de simulación cuántica

El problema de planificación de rutas para exploración geológica se implementó como un modelo QUBO, cuya estructura binaria resulta

idónea para ser abordada mediante algoritmos cuánticos aproximados. El diseño del modelo busca maximizar la cobertura de zonas críticas conforme a dos criterios: 1) la cobertura de celdas geológicas de alta prioridad (niveles 2 y 3), y 2) la maximización de un índice de riesgo compuesto, definido como la suma de la prioridad geológica y el riesgo ambiental. Para la resolución se recurrió a QAOA, técnica híbrida que combina circuitos cuánticos parametrizados con bucles de optimización clásica. Este enfoque permite abordar problemas de decisión binaria mediante simulación de estados cuánticos, preservando la estructura de la función objetivo codificada en la matriz QUBO. La implementación se realizó con la biblioteca Qiskit de IBM, que proporciona un marco sólido para construir circuitos cuánticos, simular ejecuciones y acceder de manera remota a procesadores cuánticos reales.

El desarrollo inicial se llevó a cabo localmente en un entorno con procesador Intel Core i7-11800H (ocho núcleos a 2,30 GHz), 32 GB de RAM DDR4 y

sistema operativo Ubuntu 22.04 LTS. Se utilizó Python 3.11, con Jupyter Notebook como entorno de trabajo, y se apoyó en bibliotecas especializadas como Qiskit, Numpy, Matplotlib, Networkx y D-Wave Ocean SDK para la formulación de grafos y la simulación de enrutamiento con restricciones espaciales.

En una fase posterior, las subinstancias más relevantes del modelo —en particular, subconjuntos de subrutas con alto valor estratégico y conectividad estructural bajo la regla de 8 vecinos— se ejecutaron en la plataforma IBM Quantum Experience. Se efectuaron pruebas tanto en simuladores cuánticos (*ibmq_qasm_simulator*) como en *backends* cuánticos reales con pocos qubits, como *ibmq_belem*, basado en una arquitectura de cinco *qubits*. Este procedimiento permitió validar el enfoque QAOA en condiciones realistas de pequeña escala, con proyección de escalabilidad hacia arquitecturas más avanzadas.

Dadas las limitaciones actuales del *hardware* cuántico en número de *qubits* y fidelidad, se adoptó una estrategia de descomposición inteligente. La rejilla se dividió en regiones críticas priorizadas y cada subinstancia se resolvió de manera independiente. Con ello se garantizó el

cumplimiento estricto de las restricciones de conectividad espacial y, además, se facilitó la visualización estratégica de las rutas propuestas mediante mapas de calor enriquecidos, tal como se aprecia en las figuras 7 y 8.

La figura 7 muestra el recorrido obtenido sobre el mapa de prioridad geológica, restringido exclusivamente a celdas con prioridad 2 o 3. El desplazamiento obedece una regla estricta de adyacencia, sin saltos. Bajo la condición de cubrir por completo las zonas de alta prioridad, el modelo QUBO redujo al mínimo la longitud total del trayecto. En total, se visitaron 46 celdas críticas: 28 de nivel 2 y 18 de nivel 3, para lograr así una cobertura del 100 % de las áreas con mayor prioridad geológica. La trayectoria final comprende 62 celdas, con un 100 % de las celdas de nivel 3 y un 86 % de las de nivel 2 incluidas, manteniendo la conectividad espacial y respetando las restricciones de navegación. El itinerario inicia en una celda de nivel 3 y emplea una búsqueda recursiva priorizada para optimizar localmente el avance. Este esquema resulta especialmente adecuado cuando la calidad del subsuelo es el criterio dominante para decidir perforaciones o adquisición sísmica, aun cuando los riesgos ambientales o logísticos no sean el factor decisivo.




Figura 7. Resultados ruteo para mapa de calor geológico.

Fuente: elaboración propia.

En una segunda etapa se adoptó un enfoque más integral, construyendo un índice compuesto para cada celda como la suma de la prioridad geológica y el riesgo ambiental, obteniendo valores en el rango de 0 a 6. La figura 8 muestra el mapa de calor de dicho índice compuesto y la ruta optimizada generada en función de él. La trayectoria resultante responde a una estrategia

estrictamente técnica centrada en el potencial geológico, orientada a maximizar la extracción de información. No obstante, esta aproximación no incorpora los riesgos ambientales ni operativos, lo que puede entrar en tensión con las políticas de sostenibilidad o con las restricciones prácticas del despliegue en campo.




Figura 8. Resultados de ruteo para mapa de calor de riesgo compuesto.

Fuente: elaboración propia.

El modelo QAOA, aplicado sobre la formulación QUBO ajustada se planteó con el objetivo de maximizar la cobertura de celdas con alto riesgo compuesto (índice ≥ 3), garantizando al mismo tiempo la conectividad del recorrido y evitando saltos. La ruta obtenida recorre 64 celdas y prioriza aquellas con índice compuesto superior a 4, es decir, zonas simultáneamente relevantes y vulnerables desde el punto de vista ambiental. Esta estrategia de exploración articula la viabilidad geológica con criterios de sostenibilidad e impacto ambiental, fundamentales para una planificación responsable en contextos *offshore*. Se comprobó

que el 91 % de las celdas con índice ≥ 5 fueron cubiertas y que se respetó íntegramente la regla de movimiento de 8 vecinos, lo que respalda la pertinencia del enfoque en escenarios de exploración multicriterio. La solución resultante ofrece una cobertura espacial más extensa y considera de forma concurrente tanto la prioridad exploratoria como la factibilidad ambiental. Aunque permanecen sin visitar algunas áreas geológicas de alta prioridad, la trayectoria exhibe un patrón continuo y operativo, maximizando la captación de información en regiones de mayor riesgo.

Discusión

Los resultados de simulación presentados en la sección anterior ponen de relieve el potencial de las técnicas de optimización inspiradas en la computación cuántica, para apoyar la planificación de exploración geológica en etapas tempranas en entornos *offshore*. Al formular el problema de enrutamiento de exploración como un modelo QUBO y resolverlo con el algoritmo QAOA, fue posible generar rutas espacialmente coherentes que respetan las restricciones físicas de movimiento a la vez que maximizan la cobertura sobre zonas de alta prioridad. Esta discusión se centra en tres aspectos principales: 1) las implicaciones estratégicas de la selección de rutas; 2) el desempeño computacional y la escalabilidad del enfoque cuántico, y 3) la integración de la toma de decisiones multicriterio bajo incertidumbre.

En primer lugar, el contraste entre las dos estrategias de enrutamiento —basada únicamente en la prioridad geológica (figura 7), así como en el índice de riesgo compuesto (figura 8)— demuestra la flexibilidad del marco QUBO para incorporar objetivos y restricciones diversos. La ruta enfocada en la geología ofrece una cobertura completa de las zonas subterráneas más prometedoras, lo cual resulta altamente pertinente para equipos técnicos que buscan maximizar la ganancia de información por unidad de costo de navegación. Sin embargo, pasa por alto restricciones ambientales que pueden limitar la factibilidad operativa de la trayectoria propuesta. En cambio, la ruta basada en el riesgo compuesto incorpora una conciencia del riesgo, al equilibrar la riqueza geológica con la vulnerabilidad ambiental, dando lugar a un recorrido más amplio, pero estratégicamente filtrado. El compromiso entre un objetivo estrictamente geológico y una exploración informada por consideraciones ambientales se aprecia con claridad en la estructura espacial y en las estadísticas de cobertura por celdas de ambas soluciones.

En segundo lugar, el uso de QAOA tanto en *backends* cuánticos simulados como reales aporta información sobre las capacidades y limitaciones

actuales de la computación cuántica para tareas de planificación logística. La estrategia de solución implicó descomponer la rejilla de exploración completa en subinstancias de tamaño manejable (6-10 celdas críticas) y resolverlas de forma independiente preservando las restricciones de movimiento. Este enfoque modular se alinea con las capacidades del *hardware* cuántico cercano en el tiempo, aún limitado en número de *qubits* y fidelidad de compuertas. A pesar de estas limitaciones de *hardware*, el marco QAOA resultó eficaz para producir subrutas optimizadas que pueden ensamblarse en estrategias globales, especialmente cuando se aplica mediante flujos de trabajo híbridos cuántico-clásicos. Además, el uso de reglas de adyacencia tipo “rey” (movimiento a 8 vecinos) asegura la generación de trayectorias realistas, algo crítico en aplicaciones como la exploración marina, donde debe preservarse una navegación continua y segura de las embarcaciones.

En tercer lugar, este estudio ilustra cómo las formulaciones basadas en QUBO permiten integrar de manera fluida criterios de decisión complejos —como el potencial geológico, el riesgo ambiental y la adyacencia espacial— en un único marco de optimización. Si bien las heurísticas clásicas (p. ej., DFS, MST codiciosa) también pueden producir rutas viables, a menudo carecen del poder expresivo y la adaptabilidad necesarios para codificar interacciones ponderadas y restricciones dinámicas. Por el contrario, el enfoque cuántico admite representaciones más ricas del problema y puede ofrecer ventajas computacionales a medida que evolucionen los procesadores cuánticos. Así mismo, los resultados de simulación subrayan la importancia de los compromisos estratégicos en la planificación de la exploración: las rutas que maximizan la información geológica pueden entrar en conflicto con las políticas ambientales, mientras aquellas que priorizan la seguridad ambiental podrían sacrificar la captura de datos del subsuelo. Estos hallazgos sientan las bases para desarrollar formulaciones multiobjetivo en estudios futuros, integrando potencialmente el costo económico, la disponibilidad de embarcaciones y las restricciones regulatorias.

En conclusión, la aplicación de QAOA para resolver formulaciones QUBO en el contexto de la exploración geológica *offshore* aporta un valor significativo a la toma de decisiones en etapas tempranas dentro de entornos complejos e inciertos. Desde la perspectiva de la gestión de operaciones, este enfoque ofrece una metodología estructurada y replicable para la planificación de rutas que equilibra prioridades en competencia, como el potencial geológico, la continuidad espacial y las restricciones ambientales. Más que reemplazar los métodos clásicos, las estrategias inspiradas en la computación cuántica complementan las herramientas de planificación existentes al habilitar una optimización más matizada bajo limitaciones espaciales y regulatorias. Los resultados obtenidos demuestran que es posible generar rutas de exploración coherentes, factibles y estratégicamente alineadas incluso con las limitaciones actuales del *hardware* cuántico. A medida que las capacidades de la computación cuántica continúen evolucionando, el trabajo futuro debería apuntar a incorporar actualizaciones dinámicas de información, integrar restricciones de costo y capacidad operativa, y apoyar marcos de planificación más robustos para operaciones marinas y *offshore*. Esta investigación constituye un primer paso en la traducción de modelos cuánticos abstractos a herramientas prácticas que respalden la planificación exploratoria con relevancia en el mundo real.

Conclusiones

El presente trabajo propone un marco metodológico original que articula formulaciones de QUBO con el algoritmo QAOA para resolver la planificación estratégica de rutas en exploración geológica *offshore*. A partir de una rejilla geoespacial de la cuenca Guajira *Offshore*, se muestra cómo combinar búsquedas heurísticas con algoritmos de inspiración cuántica, para producir trayectorias optimizadas que respeten restricciones espaciales estrictas y, a la vez, cubran áreas de alta prioridad geológica o sensibilidad ambiental.

Se analizaron dos estrategias de enrutamiento: una estrictamente guiada por la

prioridad geológica y otra basada en un índice de riesgo compuesto que agrega el potencial geológico y la vulnerabilidad ambiental. En ambos casos se obtuvieron rutas operativamente viables que respetan la regla espacial de 8 vecinos, evitan discontinuidades y aseguran conectividad lógica a lo largo del dominio de exploración. La implementación de QAOA tanto en simuladores locales como en *hardware* de IBM Quantum Experience confirmó la pertinencia de los enfoques híbridos cuántico-clásicos en escenarios de planeación temprana, en particular cuando el problema se descompone en subregiones de interés estratégico.

Los resultados sugieren que los modelos QAOA-QUBO constituyen herramientas robustas para apoyar decisiones de planeación *offshore* donde es necesario conciliar múltiples criterios potencialmente contrapuestos. En términos operativos, estos modelos aportan una toma de decisiones estructurada en contextos con restricciones espaciales, ambientales y logísticas, que con frecuencia son difíciles de representar de forma conjunta usando únicamente técnicas clásicas.

De cara al desarrollo futuro, conviene avanzar en varias líneas críticas que fortalezcan la solidez metodológica y la aplicabilidad práctica del marco propuesto. Primero, la escalabilidad sigue siendo un reto clave, dado que la exploración *offshore* real involucra rejillas de mayor tamaño y configuraciones del terreno altamente complejas; para afrontarlo, se recomienda incorporar estrategias como el clustering de grafos y la reoptimización dinámica, manteniendo la calidad de las soluciones bajo control computacional. Segundo, resulta necesario ampliar el modelo con restricciones operativas realistas: límites de combustible, velocidades de embarcación, ventanas meteorológicas y la presencia de zonas marítimas restringidas o reguladas. Integrar estas variables permitirá planes más precisos y desplegables. Tercero, es conveniente incluir consideraciones económicas en la lógica de optimización, de modo que el análisis de costos explicita los

compromisos entre potencial geológico, riesgo ambiental y gasto asociado a la adquisición de datos y a las operaciones *offshore*. Cuarto, las próximas iteraciones deberían evolucionar hacia formulaciones multicriterio que contemplen, de manera simultánea, dimensiones geológicas, ambientales, económicas e incluso sociales, acordes con la naturaleza compleja y multiactor de los proyectos energéticos.

Por último, a medida que el *hardware* cuántico madure —con más qubits disponibles y mejores esquemas de corrección de errores— será valioso explorar implementaciones de QAOA con mayor profundidad de circuitos. Comparar su rendimiento frente a heurísticas clásicas aportará evidencia sobre las condiciones bajo las cuales puede materializarse una ventaja cuántica en tareas de planeación y logística bajo incertidumbre. Esta investigación constituye un paso inicial para traducir modelos cuánticos abstractos en herramientas operativas con relevancia práctica para la planificación exploratoria.

Declaración sobre uso de IA

Se utilizaron herramientas de inteligencia artificial de manera limitada y exclusivamente con fines de apoyo editorial, particularmente en procesos de mejora gramatical y claridad de redacción. Todas las decisiones académicas, la construcción teórica, la interpretación de resultados y la verificación científica del contenido son responsabilidad plena del autor.

Referencias

- Acampora, G., Chiatto, A., & Vitiello, A. (2023). Genetic algorithms as classical optimizer for the Quantum Approximate Optimization Algorithm. *Applied Soft Computing*, 142. <https://doi.org/10.1016/j.asoc.2023.110296>
- Agencia Nacional de Hidrocarburos. (2009). *Informe de Prospectividad*.
- Agencia Nacional de Hidrocarburos. (2025). Geovisor de tierras. <https://geovisor.anh.gov.co/tierras/>
- Blekos, K., Brand, D., Ceschini, A., Chou, C. H., Li, R. H., Pandya, K., & Summer, A. (2024). A review on Quantum Approximate Optimization Algorithm and its variants. *Physics Reports*, 1068, 1-66. <https://doi.org/10.1016/j.physrep.2024.03.002>
- Boone, T., Fahimnia, B., Ganeshan, R., Herold, D. M., & Sanders, N. R. (2025). Generative AI: Opportunities, challenges, and research directions for supply chain resilience. *Transportation Research Part E: Logistics and Transportation Review*, 199, 104135. <https://doi.org/10.1016/j.tre.2025.104135>
- Bouchmal, O., Cimoli, B., Stabile, R., Vegas Olmos, J. J., & Tafur Monroy, I. (2025). Quantum Approximate Optimization Algorithm applied to multi-objective routing for large scale 6G networks. *Computer Networks*, 267. <https://doi.org/10.1016/j.comnet.2025.111345>
- Dong, Y., Meng, X., Lin, L., Kosut, R., & Whaley, K. B. (2020). Robust control optimization for quantum approximate optimization algorithms. *IFAC-PapersOnLine*, 53(2), 242-249. <https://doi.org/10.1016/j.ifacol.2020.12.130>
- Geda, M. W., & Tang, Y. M. (2025). Adaptive hybrid quantum-classical computing framework for deep space exploration mission applications. *Journal of Industrial Information Integration*, 44. <https://doi.org/10.1016/j.jii.2025.100803>
- Huo, D., Gu, W., Guo, D., & Tang, A. (2024). The service trade with AI and energy efficiency: Multiplier effect of the digital economy in a green city by using quantum computation based on QUBO modeling. *Energy Economics*, 140. <https://doi.org/10.1016/j.eneco.2024.107976>

- Jun, K. (2024). QUBO formulations for a system of linear equations. *Results in Control and Optimization*, 14. <https://doi.org/10.1016/j.rico.2024.100380>
- Kurowski, K., Pecyna, T., Słysz, M., Różycki, R., Waligóra, G., & Węglarz, J. (2023). Application of quantum approximate optimization algorithm to job shop scheduling problem. *European Journal of Operational Research*, 310(2), 518-528. <https://doi.org/10.1016/j.ejor.2023.03.013>
- Lins, I. D., Araújo, L. M. M., Maior, C. B. S., Teixeira, E. S., Bezerra, P. T. L., Moura, M. J. das C., & Droguett, E. L. (2025). Quantum-based optimization methods for the linear redundancy allocation problem: A comparative analysis. *Reliability Engineering and System Safety*, 262. <https://doi.org/10.1016/j.ress.2025.111153>
- Liu, Y., Qian, Y., Wang, L., Zhang, Z., & Yu, X. (2025). Rapidly trainable and shallow-compiled quantum approximate optimization algorithm for maximum likelihood detection. *Physics Letters, Section A: General, Atomic and Solid State Physics*, 548. <https://doi.org/10.1016/j.physleta.2025.130541>
- McCollum, J., & Krauss, T. (2021). QUBO formulations of the longest path problem. *Theoretical Computer Science*, 863, 86-101. <https://doi.org/10.1016/j.tcs.2021.02.021>
- Pan, Y., Tong, Y., Xue, S., & Zhang, G. (2022). Efficient depth selection for the implementation of noisy quantum approximate optimization algorithm. *Journal of the Franklin Institute*, 359(18), 11273-11287. <https://doi.org/10.1016/j.jfranklin.2022.10.027>
- Rodríguez, I., Bulnes, M., Poblet, J., Masini, M., & Flinch, J. (2021). Structural style and evolution of the offshore portion of the Sinu Fold Belt (South Caribbean Deformed Belt) and adjacent part of the Colombian Basin. *Marine and Petroleum Geology*, 125. <https://doi.org/10.1016/j.marpetgeo.2020.104862>
- Ruan, Y., Yuan, Z., Xue, X., & Liu, Z. (2023). Quantum approximate optimization for combinatorial problems with constraints. *Information Sciences*, 619, 98-125. <https://doi.org/10.1016/j.ins.2022.11.020>
- Suárez Bermúdez, L., Ramírez Camargo, L., Yáñez, E., Neele, F., & Faaij, A. (2025). CO2 transport and storage potential in the Caribbean Sea, Colombia. *International Journal of Greenhouse Gas Control*, 144. <https://doi.org/10.1016/j.ijggc.2025.104361>
- Vadyala, S. R., & Betgeri, S. N. (2023). General implementation of quantum physics-informed neural networks. *Array*, 18. <https://doi.org/10.1016/j.array.2023.100287>
- Vargas, C. A. (2012). Evaluating total Yet-to-Find hydrocarbon volume in Colombia. *Earth Sciences Research Journal*, 16(Special issue), 1-246. <https://n9.cl/drl7p>