57º SBPO
SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL
Gramado • RS
DE 5 A 9 DE OUTUBRO DE 2025

Otimizando Rotas em Operações de Busca e Resgate com Aeronaves Remotamente Pilotadas

Antonio Josivaldo Dantas Filho
Universidade Federal de São Paulo (UNIFESP)
antonio.josivaldo@unifesp.br

Elcio Hideiti Shiguemori
Instituto de Estudos Avançados (IEAv)
elcio@nucleo.inpe.br

Antonio Augusto Chaves
Universidade Federal de São Paulo (UNIFESP)
antonio.chaves@unifesp.br

RESUMO

O crescimento constante das ocorrências de busca e salvamento (SAR) revela a heterogeneidade de cenários e desafios envolvidos. Aeronaves Remotamente Pilotadas (ARP) proporcionam eficiência, economia e adaptabilidade, mas ainda enfrentam restrições de autonomia energética, agilidade para localizar alvos e coordenação entre múltiplos veículos. Dessa limitação decorre a necessidade de estratégias eficazes de busca. O presente estudo aborda operações de SAR com múltiplos ARPs, modelando um Open Vehicle Routing Problem (OVRP) sob incerteza probabilística. Um sistema computacional multi-objetivo integra técnicas de otimização para planejar rotas que aceleram a localização dos alvos. O estudo inicia com um modelo de Programação Linear Inteira (PLI) seguido de uma estrutura baseada no Random-Key Optimizer (RKO) para resolver problemas combinatórios. Ensaios preliminares usando RKO indicam que a utilização conjunta de múltiplos ARPs com a caracterização dinâmica e iterativa da área de busca poderia reduzir o tempo de identificação dos alvos, melhorando assim a eficiência das operações de SAR.

PALAVRAS CHAVE. Otimização, OVRP, ARP, PLI, RKO.

Outras Aplicações em PO

ABSTRACT

Search and Rescue (SAR) incidents are rising, underscoring the diversity of scenarios and challenges. Unmanned Aerial Vehicles (UAVs) provide operational efficiency, cost-effectiveness, and adaptability, yet still face limitations in energy autonomy, agility in locating targets, and multi-UAV coordination. These constraints demand advanced search strategies. This study addresses UAV-assisted SAR through an Open Vehicle Routing Problem (OVRP) under probabilistic uncertainty. A multi-objective computational framework integrates optimization techniques to plan routes that accelerate target localization. The study begins with an Integer Linear Programming (ILP) model, followed by a Random-Key Optimizer (RKO) framework to solve combinatorial problems. Tests on theoretical instances using RKO indicate that the integration of multiple UAVs with a dynamic and iterative characterization of the search area significantly reduces identification time and enhances SAR efficiency.

KEYWORDS. Optimization, OVRP, UAV, ILP, RKO.

Other Applications in OR

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

1. Introdução

A incidência de eventos que exigem operações de Busca e Resgate (SAR) tem crescido de forma contínua, abarcando um amplo espectro de cenários e desafios. Esse aumento deve-se a vários fatores, incluindo a expansão da atividade humana em áreas remotas, a intensificação de desastres naturais impulsionada pelas mudanças climáticas, a popularização do turismo de aventura e falhas na supervisão de crianças ou de indivíduos com autonomia reduzida. Essa tendência evidencia a importância crucial de metodologias e estratégias de busca avançadas, cujo objetivo primordial é a preservação da vida em situações de risco iminente [Nasar et al., 2023; Dantas et al., 2022].

Aeronaves Remotamente Pilotadas (ARPs) tornaram-se um foco cada vez mais comum da pesquisa em SAR. O emprego de ARPs em operações de SAR destaca-se por menores custos, eficiência e adaptabilidade, entre outros atributos críticos para o êxito da missão. Além disso, os ARPs podem ser empregados em zonas de alto risco, incluindo áreas inacessíveis ou de difícil alcance para os seres humanos [Dantas et al., 2021]. Não obstante, persistem várias limitações inerentes ao uso de ARPs nas operações atuais, incluindo autonomia energética restrita, alcance de comunicação limitado e questões regulatórias complexas que podem restringir a implantação em áreas ou situações específicas da Silva Gomes et al. [2022]. Ademais, a eficácia dos ARPs em missões de SAR pode ser comprometida pelo tempo necessário para identificar o alvo. Superar esses desafios dependerá, em grande medida, de avanços tecnológicos e da integração de sistemas capazes de otimizar o desempenho dos ARPs em condições diversas [Hayat et al., 2017].

Os planos de voo são geralmente elaborados pela da Força Aérea Brasileira (Decreto n° 6.834/2009), embora unidades da Defesa Civil, do Corpo de Bombeiros ou da polícia possam assumir essa função quando necessário. Automatizar essa etapa poderia acelerar as missões, reduzir custos e mitigar riscos para as equipes de resgate, aliviando a carga de trabalho dos planejadores [Fabian et al., 2022]. Investir nessa área é crucial para o sucesso das operações de SAR. Devido às grandes dimensões territoriais do Brasil e recursos limitados disponíveis, as operações de busca frequentemente apresentam grandes desafios, influenciando negativamente o resultado final das intervenções. Além disso, o planejamento prévio para situações emergenciais aumenta consideravelmente a chance de sucesso em eventos inesperados e críticos [Srinivasu et al., 2013; Dantas Filho et al., 2020].

O tempo de resposta é obstáculo bem conhecido a ser superado. Esse fator é crucial, pois operações de SAR são frequentemente situações críticas em que cada minuto conta. Na maioria dos casos, as vítimas precisam ser resgatadas dentro de 72 horas; caso contrário, sua probabilidade de sobrevivência declina. Esse período é conhecido como "*Golden 72 Hours*", durante o qual todos os recursos de socorro devem ser concentrados nas vítimas. Há uma taxa de sobrevivência de 90 % nas primeiras 24 horas, 50 % entre 25 e 48 horas e 20 % entre 49 e 72 horas [Huang et al., 2011].

Dada a urgência das operações de SAR e as limitações das plataformas existentes, é cada vez mais importante utilizar planejadores inteligentes que acelerem a localização do alvo. Dois principais paradigmas de busca são destacados na literatura. O primeiro é o planejamento de cobertura, que gera trajetórias sem obstáculos para percorrer sistematicamente cada parte de uma área predefinida, usado em aplicações que vão de aspiradores domésticos a veículos aéreos e subaquáticos autônomos. O segundo é o planejamento de trajetórias discretas, que orienta um ou mais agentes a localizar um alvo estacionário dentro de uma área limitada, buscando maximizar a probabilidade total de detecção em um período de tempo finito [San Juan et al., 2018].

O planejamento de rotas em SAR pode ser tipicamente formulado como um *Vehicle-Routing Problem (VRP)* [Dantzig e Ramser, 1959], no qual vários veículos devem visitar um conjunto de pontos de grade derivados da região de busca discretizada, de modo a minimizar o tempo total de percurso. Cada veículo parte de um local distinto, voa a uma altitude predefinida para evitar

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

colisões e deve passar por cada ponto; o alvo é único, estacionário e de posição desconhecida, cuja probabilidade espacial é representada por um mapa de densidade que orienta as prioridades de rota. O objetivo é gerar trajetórias que maximizem a probabilidade de detectar esse alvo.

Determinar uma trajetória ótima para um ou mais veículos é um problema NP-difícil [Arkin et al., 2000]. Consequentemente, para o planejamento de rotas, soluções heurísticas e metaheurísticas permanecem as abordagens mais frequentemente utilizadas para resolver o VRP na literatura. Esses métodos oferecem tempos de resolução mais curtos que algoritmos exatos e não requerem fase de treinamento, ao contrário das abordagens de aprendizado de máquina [Lyu et al., 2023].

Este estudo propõe uma estrutura computacional que otimiza repetidamente rotas multiobjetivo de ARPs dentro de um mapa de busca probabilístico discretizado, com o objetivo de reduzir o tempo de identificação do alvo em uma missão de SAR, preservando simultaneamente a precisão posicional. A hipótese desse estudo procura mostrar que a metodologia desenvolvida produz redução no tempo de localização dos alvos. Ao assimilar dados de sensores em tempo real e realocar esforço para os objetivos mais informativos à medida que as condições evoluem, o sistema busca maximizar a eficiência e a precisão globais da missão.

O artigo está estruturado em outras quatro partes: revisão da literatura, descrição da metodologia, análise dos resultados, e, por fim, conclusão com implicações e sugestões para pesquisas futuras.

2. Revisão de Literatura

Este estudo selecionou os três trabalhos mais relevantes de uma Revisão Sistemática da Literatura (RSL) previamente conduzida. Essa RSL mapeia rigorosamente como a comunidade acadêmica tem abordado o problema e fornece uma análise técnica das soluções propostas. Para isso, segue um protocolo de busca predefinido em bases de dados científicas e, com base nos artigos recuperados, responde às questões de pesquisa estabelecidas [Kitchenham, 2004; Martins et al., 2020].

A RSL foi realizada em seis bibliotecas digitais escolhidas conforme o experimento relatado por [Dyba et al., 2007]. Para apoiar o presente estudo, utilizou-se a ferramenta Parsifal [Freitas, 2019]. O Parsifal oferece as principais etapas necessárias à execução de uma RSL, além de colaboração em tempo real entre autores e geração de relatórios analíticos, produzindo assim material extenso que contém todas as informações necessárias dos artigos para sintetizar os resultados aqui relatados.

A questão de pesquisa principal que orientou a revisão foi: Quais técnicas de otimização são mais eficazes e que lacunas existem no estado da arte para o planejamento de rotas em operações de SAR? A expressão de busca final, após refinamento, foi *("Search and Rescue"OR "Rescue missions"OR "Find People") AND ("optimization"OR "pathfinding"OR "pathplanning"OR "Vehicle Routing Problem") AND ("Unmanned Aerial Vehicle"OR "DRONE"OR "Autonomous vehicles").*

A RSL retornou 1 545 artigos: 205 da IEEE, 279 da Scopus, 318 da ACM, 163 da ISI Web of Science, 70 do Google Scholar e 510 da Compendex. Após a fusão dos registros, 711 duplicatas foram identificadas e 803 estudos foram excluídos por serem irrelevantes para as questões de pesquisa. A aplicação dos critérios de inclusão e exclusão em títulos e resumos resultou em 34 artigos, e uma leitura posterior do texto completo, foram removidos dois falsos positivos, produzindo um total final de 31 estudos.

Três estudos fornecem contribuições metodológicas ou empíricas particularmente influentes. Em primeiro lugar, [Xiong et al., 2023] apresenta uma meta–heurística híbrida que combina um Algoritmo Genético Adaptativo com PSO auto-coordenado, reduzindo o tempo total de varredura em cerca de 15 % em simulações sem diminuir a cobertura. Em segundo lugar, [Wu et al., 2022]

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

tem como foco a vigilância marítima, incorporando restrições de energia na função de fitness do PSO e acionando o replanejamento quando os níveis de bateria diminuem; a abordagem reduziu o consumo de energia em aproximadamente 18 % e aumentou a autonomia em 25 minutos por ARP, mantendo o desempenho de detecção. Por fim, [Deng et al., 2018] valida *in loco* um esquema em duas etapas, com Dijkstra para a rota inicial seguido por *Simulated Annealing (SA)* para o refinamento sob restrições de altitude e de zonas restritas. Em voos sobre um parque florestal de 20 ha, esse método reduziu o tempo de voo em 11 %, minimizou a sobreposição de faixas e manteve o erro posicional médio abaixo de 1,8 m mesmo em ventos moderados.

De forma geral, meta-heurísticas e modelos híbridos têm sido eficazes ao melhorar a coordenação entre múltiplos veículos, gerenciar eficientemente a energia disponível e ajustar rotas dinamicamente, resultando em maior cobertura, tempos de resposta reduzidos e autonomia ampliada. No entanto, permanecem lacunas decisivas: ausência de estruturas que integrem garantias de otimalidade de métodos exatos à flexibilidade heurística, limitações de execução a bordo decorrentes de custo computacional, dificuldade de escalonar para áreas extensas e de alta dimensionalidade, carência de experimentos de campo que demonstrem robustez em condições reais e pouca atenção a problemas discretos ou altamente dinâmicos. Superar essas questões pode consolidar ganhos em desempenho e confiabilidade para operações de busca e resgate.

3. Metodologia

A metodologia foi concebida para fornecer soluções otimizadas e práticas de planejamento de rotas. A metodologia apresentada na Figura 1 ilustra as etapas de um processo sequencial, com o objetivo de alcançar uma operação eficaz. Primeiramente, definem-se a *última posição conhecida* (LKP) e os dado(s) relevante(s), que servirão de referência para todas as etapas subsequentes. Em seguida, determina-se a *área de busca* considerando fatores como deriva e movimento do alvo, a velocidade das unidades de busca e o tempo disponível. O passo seguinte consiste em verificar se existe um *mapa de probabilidade* que indique as regiões de maior probabilidade de localizar o alvo. Caso tal mapa não esteja disponível, realiza-se uma busca inicial padrão, cobrindo a área conforme descrito em [DECEA, 2019].

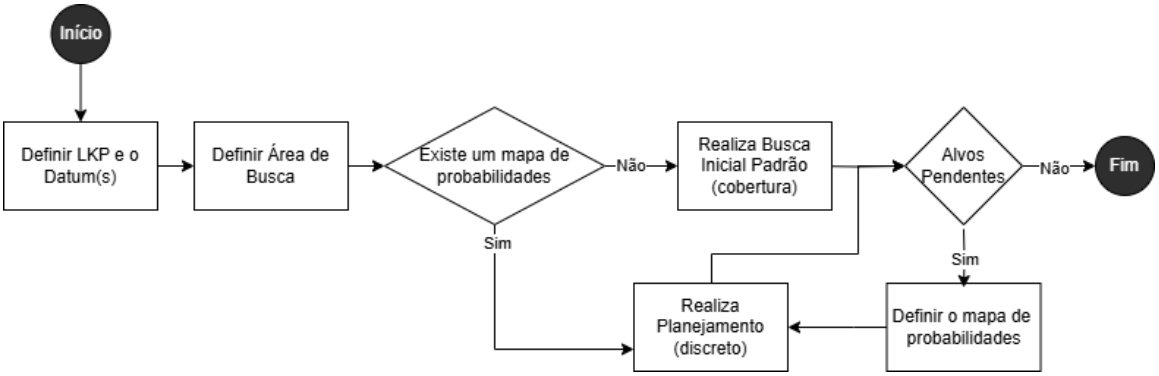

Figura 1: Esquema geral do sistema iterativo nas operações de SAR.

Após a busca inicial, avalia-se a presença de alvos pendentes; se todos os alvos tiverem sido localizados, a operação é encerrada. Caso contrário, gera-se um mapa de probabilidade com base em análise detalhada das informações coletadas, direcionando os esforços para as regiões mais promissoras. Finalmente, um planejamento específico é realizado com base no mapa de probabilidade, permitindo uma cobertura mais eficiente e direcionada. Nesse contexto, é importante observar que os ARPs não precisam retornar ao seu ponto de origem após cada rota.

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

3.1. Mapa de Probabilidade

O mapa de probabilidade é uma ferramenta essencial neste estudo para o planejamento de trajetórias de ARPs em operações de SAR, pois fornece uma representação espacial da probabilidade de encontrar alvos em diferentes regiões da área de busca. O uso desse mapa permite que os ARPs priorizem as áreas com maior probabilidade de detecção, otimizando, assim, a eficiência da missão. Fontes possíveis para obter esses mapas incluem:

- **Imagens de satélite:** No início da missão, imagens de satélite podem fornecer uma visão ampla da área de busca. Essas imagens ajudam a identificar características geográficas e estruturas que podem influenciar a localização do alvo.
- **Dados históricos e conhecimento especializado:** Informações históricas sobre a área de busca e percepções de especialistas locais podem ser usadas para gerar um mapa de probabilidade inicial, baseando-se em dados sobre áreas previamente afetadas por desastres e/ou locais onde vítimas foram encontradas em incidentes passados.
- **Sensores embarcados nos ARPs:** Conforme os ARPs executam a busca, sensores a bordo (câmeras, LiDAR, infravermelho, entre outros) coletam dados em tempo real. Esses dados são processados para atualizar continuamente o mapa de probabilidade a partir das observações recentes, fornecendo alta precisão e refinamento constante.
- **Sensores terrestres:** Sistemas como torres de telefonia celular e redes de segurança podem fornecer dados adicionais para o mapa de probabilidade. Esses sensores podem estar localizados em pontos estratégicos e auxiliarem na restrição da área de busca.

O mapa de probabilidade sustenta uma busca mais eficiente e precisa ao se adaptar iterativamente às condições dinâmicas da missão após cada rota concluída. A incorporação do mapa de probabilidade, juntamente com a atualização automática dos pesos dos objetivos, proporciona uma abordagem de otimização multiobjetivo eficaz para operações de SAR.

3.2. Definição do mapa e do alvo

Como parte da validação da metodologia, emprega-se um algoritmo simples para gerar pontos aleatórios, cada um associado a uma probabilidade distinta de detecção do alvo. O mapa ilustrativo foi traçado sobre uma região florestal da Amazônia, que é subdivido em células para discretização da área, esta possui probabilidades associadas, e as relações espaciais entre essas células são definidas como nós em um grafo onde é possível um ARP executar uma rota. O mapa gerado está apresentado na Figura 2.

Embora o exemplo se baseie em probabilidades aleatórias, a metodologia prevê também a aquisição de dados a partir das rotas realizadas, permitindo a atualização das probabilidades à medida que a operação de busca avança. Essa abordagem permite que as probabilidades sejam definidas de forma apropriada em toda a extensão da área de busca. O mesmo procedimento de estimação pode ser reproduzido em locais conhecidos com o intuito de tentar localizar alvos por meio do modelo proposto.

3.3. Ferramentas

Para implementar os algoritmos e realizar as simulações de planejamento de rotas para ARPs, utilizou-se *Python-MIP*, uma biblioteca que fornece uma interface para modelagem e solução de problemas de programação linear inteira mista. Essa ferramenta possibilita a formulação matemática e a solução de problemas complexos de otimização envolvendo planejamento de rotas. O *Python-MIP* oferece suporte a diversos solvers, incluindo CBC, Gurobi e CPLEX, o que permite lidar com instâncias de grande escala de maneira eficiente [Santos e Toffolo, 2020].

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

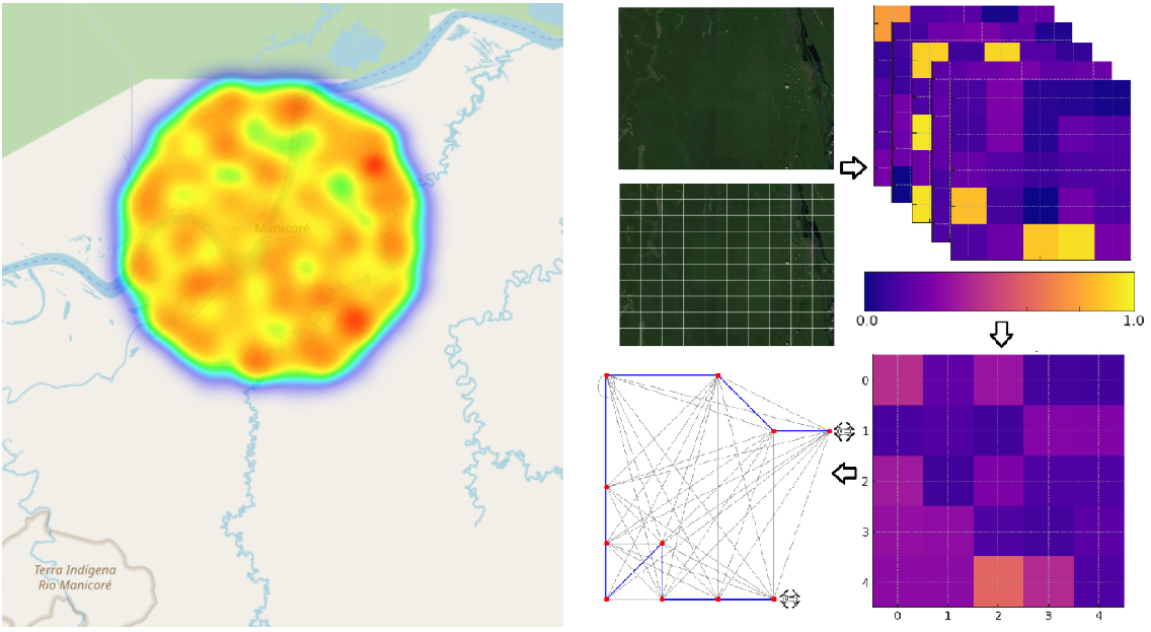

Figura 2: Exemplo de mapa com região de busca e pontos discretizados por probabilidades.

O framework *Random-Key Optimizer* (RKO) [Chaves et al., 2024] também foi empregado para tratar o mesmo modelo de roteirização com meta-heurísticas estocásticas. Nesse ambiente, cada solução é codificada como um vetor de *random keys* e convertida em uma solução viável por um decodificador que reconstrói as variáveis do modelo. O framework executa diversas heurísticas em paralelo, compartilhando soluções promissoras e garantindo automaticamente intensificação e diversificação das buscas, exigindo apenas o decodificador específico do problema em questão, sendo aplicado com sucesso em [Vieira et al., 2025].

As meta-heurísticas disponíveis são: *Simulated Annealing*; *Biased Random-Key Genetic Algorithm*; *Large-Neighborhood Search*; *Genetic Algorithm*; *Particle Swarm Optimization*; *Variable-Neighborhood Search*; *Greedy Randomized Adaptive Search Procedure*; *Iterated Local Search* e *Biased Random-Key Genetic Algorithm with Clustering Search*. Essa abordagem usando meta-heurísticas delimita o tempo de busca por soluções para problemas de otimização combinatória complexos.

3.4. Características do Problema

O modelo, além das especificações que definem o domínio de interesse, incorpora também características particulares que serão aplicadas à metodologia. Estabelecer esses critérios é importante para concentrar-se em uma parte específica do problema; contudo, outros critérios podem ser adicionados ou removidos conforme a necessidade futura.

A revisitação de rotas (sobreposição) torna-se relevante sempre que pontos com alta probabilidade justificam ser visitados mais de uma vez. Essas visitas repetidas podem ser realizadas pelo mesmo ARP ou por ARPs distintos, dependendo da otimização de roteirização e das restrições impostas e determinação do encarregado da operação.

A limitação de energia também pode ser considerada. Cada ARP possui uma capacidade energética específica que determina quantos pontos podem ser visitados em uma *única* rota. A cada nova iteração recalculam-se a capacidade de energia, a garagem inicial (o *último* ponto visitado por cada ARP) e as probabilidades da área.

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

A resolução desse problema exige abordar dois objetivos funcionais: minimizar a distância percorrida pelos ARPs e concentrar-se nos pontos em que a probabilidade de encontrar o alvo seja maior, permitindo sobreposição de rotas sempre que for relevante para o objetivo.

3.5. Modelo Matemático

Uma vez expresso o problema de forma matemática, algoritmos de otimização podem ser empregados para encontrar a melhor combinação de ARPs e rotas, minimizando o tempo total de busca [Shi et al., 2019]. Técnicas de otimização combinatória baseadas em Programação Linear Inteira (PLI) mostram-se adequadas nesse contexto.

Para o *Open Vehicle Routing Problem* (OVRP) formulado como PLI, conforme delineado no referencial teórico, introduzem-se diversas variáveis e restrições a fim de otimizar a operação de roteirização na qual os veículos não retornam ao ponto de partida após concluírem a tarefa.

Neste modelo a variável de decisão x_{ijk} indica se um dado veículo (k) percorre um trajeto específico entre dois pontos (de i até j), é representada no modelo por variáveis binárias. Os parâmetros do modelo são:

- **Área Geográfica** (A): plano cartesiano bidimensional contendo um conjunto de pontos de interesse identificados por latitude e longitude;
- **Número de Pontos** (N): número de pontos contidos em A;
- **ARPs** (D): conjunto finito de k ARPs atribuídos à operação de SAR;
- **Visitação Máxima** (C): escalar que representa o máximo de visitas permitidas;
- **Garagens Iniciais** (I): pontos específicos a partir dos quais cada ARP inicia sua rota;
- **Probabilidades** (P): vetor cujos elementos P_i são as probabilidades associadas ao ponto i, apenas $P_i > 0$ serão utilizadas no modelo;
- **Limitação de Energia** (E): capacidade energética disponível em cada ARP;

Os objetivos de otimização consistem em minimizar a distância total (ou energia) percorrida pelos ARPs e maximizar a cobertura probabilística da área. Ambos são avaliados pelas funções objetivo a seguir; admite-se sobreposição de rotas sempre que isso melhore a cobertura:

$$F_1 = \min \sum_{k \in D} \sum_{\substack{i,j \in A \\ i \neq j}} d_{ij}\, x_{ijk} \tag{1}$$

$$F_2 = \max \sum_{i \in A} \sum_{k \in D} P_i\, x_{ijk} \tag{2}$$

As restrições do modelo garantem a viabilidade operacional das rotas dos ARPs: a restrição de energia (3) assegura que a distância percorrida por cada veículo não ultrapasse sua capacidade energética; as restrições de garagem (4 e 5) obrigam cada ARP a iniciar sua rota a partir de sua base e impedem retornos; a restrição de visita (6) impõe que cada ponto seja visitado pelo menos uma vez e no máximo C vezes; a restrição de fluxo (7) garante continuidade das rotas sem que um ARP chegue a um ponto e não prossiga; e a restrição MTZ (8) elimina sub-rotas desconectadas, assegurando a integridade de cada percurso.

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

$$\sum_{\substack{i,j \in A \\ i \neq j}} d_{ij}\, x_{ijk} \leq E_k, \qquad \forall\, k \in D \tag{3}$$

$$\sum_{j \in A \setminus \{I_k\}} x_{I_k jk} \leq 1, \qquad \forall\, k \in D \tag{4}$$

$$\sum_{i \in A \setminus \{I_k\}} x_{i I_k k} = 0, \qquad \forall\, k \in D \tag{5}$$

$$1 \leq \sum_{i \in A \setminus \{j\}} \sum_{k \in D} x_{ijk} \leq C, \qquad \forall\, j \in A \setminus I \tag{6}$$

$$\sum_{l \in A \setminus \{i\}} x_{lik} \geq \sum_{j \in A \setminus \{i\}} x_{ijk}, \qquad \forall\, i \in A \setminus I_i,\ \forall\, k \in D \tag{7}$$

$$u_{ik} - u_{jk} + N\, x_{ijk} \leq N - 1, \qquad \forall\, i \neq j \in A,\ \forall\, k \in D \tag{8}$$

Essas restrições asseguram um roteamento viável que respeita a situação atual da operação, evita sub-rotas e cumpre os requisitos de visita, promovendo execução segura e eficiente da SAR.

3.6. RKO

O RKO representa cada solução como um vetor de *random keys* uniformemente distribuídas, em que as primeiras chaves estão ligadas aos veículos e as demais aos pontos de destino. A decodificação inicia-se ordenando esse vetor: as maiores chaves funcionam como marcadores que particionam a lista de *índices* ordenados em subsequências, cada qual definindo a carga e a sequência de serviço de um veículo. Uma rotação circular garante que o *último índice* no vetor ordenado seja sempre um marcador de veículo, prevenindo subsequências vazias.

Para cada subsequência, o decodificador constrói uma rota aberta, calculando incrementalmente seu custo sem acrescentar o arco de retorno ao depósito e verifica restrições de limite energético. Se a inserção de um cliente viola alguma restrição, a subsequência é dividida e cria-se nova rota reutilizando o marcador existente.

Quando a rota atende às restrições, seu custo é calculado no decodificador por meio de uma abordagem multiobjetivo, na qual o valor previamente definido de α pondera as funções f_1 e f_2 segundo $f = \alpha f_1 + (1 - \alpha) f_2$, sendo então considerada viável. Essa lógica constitui uma adaptação do decodificador clássico do OVRP com retorno ao contexto de rota aberta, conforme ilustrado na Figura 3.

Uma vez obtida uma solução viável, seu valor de objetivo alimenta a camada de busca estocástica, na qual diversas meta-heurísticas exploram, em paralelo, o hipercubo das chaves compartilhando soluções de elite em um *pool* comum. Heurísticas baseadas em populações fornecem diversidade, enquanto buscas locais refinam as rotas abertas em espaço discreto, tudo em um arcabouço modular que exige apenas o decodificador específico do problema. O algoritmo para quando o *pool* converge ou o limite de tempo é alcançado, entregando rotas que combinam coordenação multiveículo, satisfação de restrições e as vantagens de rota aberta, com custo computacional amortizado pela busca paralela e pela simplicidade da representação por *random keys*.

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

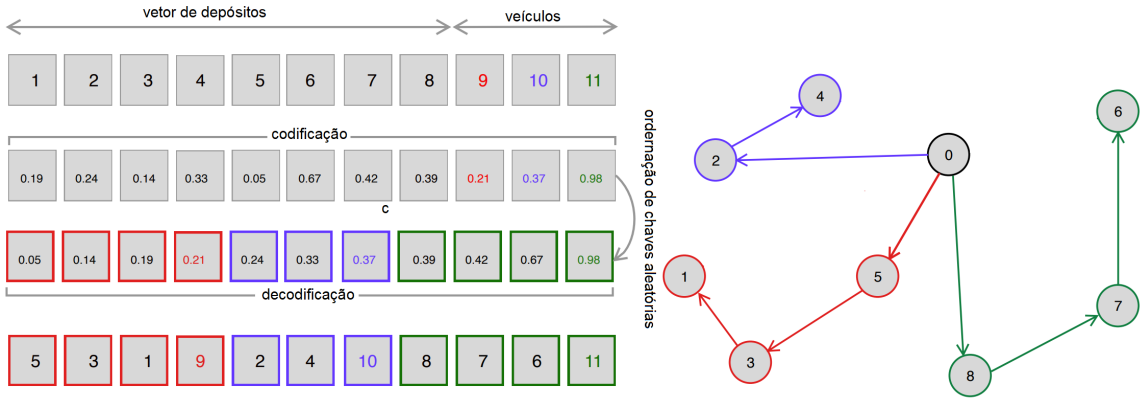

Figura 3: Exemplo de decodificação de um OVRP, mostrando as rotas do vetor decodificado, onde as rotas dos veículos com índices 9, 10 e 11 são coloridas em vermelho, azul e verde, respectivamente.

4. Resultados Computacionais

O modelo matemático de PLI foi inicialmente implementado utilizando a biblioteca *Python-MIP* com o solver CBC. Essa abordagem permitiu validar a corretude da formulação e encontrar soluções ótimas para instâncias de pequena escala. No entanto, para obter uma solução para instâncias maiores com um tempo máximo previamente determinado, como indicado em um cenário operacional de SAR, onde a rapidez na tomada de decisão é crítica, será utilizado o framework RKO. Essa limitação de escalabilidade, comum em problemas NP-difíceis como o OVRP, motivou a adoção e a análise aprofundada da abordagem baseada no RKO, que é projetado para encontrar soluções de alta qualidade em tempo computacionalmente razoável.

Experimentos iniciais foram realizados variando diferentes combinações de parâmetros. Os resultados obtidos pelo RKO estão sintetizados na Tabela 1, apresentando o número de pontos a serem visitados (N), que representam as localizações cobertas pela operação SAR, o número de ARPs empregados (K), variável que pode afetar diretamente a eficiência da missão. A tabela apresenta os valores de custo das funções para 3 soluções, para diferentes valores do parâmetro α variando-os de 0 a 1, ajustado para minimizar o custo total (F_1) ou maximizar a probabilidade (F_2), com um tempo de execução limite de 100 segundos.

Tabela 1: Resultados para o RKO usando $C = 1$ e $E_k = inf$.

N	K	$s1$		$s2$		$s3$	
		F1	F2	F1	F2	F1	F2
100	1	5.14	53.30	5.45	54.56	37.06	54.88
100	3	3.32	45.96	4.24	52.27	37.64	57.87
100	5	1.90	27.83	5.26	53.63	35.94	59.87
300	1	12.82	161.18	15.00	161.79	101.25	163.04
300	3	8.15	142.13	12.09	160.81	104.29	169.04
300	5	6.11	118.57	7.45	144.67	100.24	173.04
500	1	25.00	258.93	25.00	261.80	167.81	263.20
500	3	13.46	225.23	22.23	261.65	173.19	273.20
500	5	12.58	201.37	10.95	218.81	174.89	279.20

Todos os testes utilizaram o mesmo conjunto de pontos pré-gerados, fornecido ao algoritmo do RKO. As instâncias e o código que implementam o framework RKO encontram-se dis-

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

poníveis [Dantas, 2025]. A análise dos resultados apresentados na Tabela 1 correspondem a três soluções representativas para ilustrar os extremos, uma focada na minimização da distância (s1), outra na maximização da cobertura (s3), e uma terceira de equilíbrio (s2). Contudo, a fronteira de Pareto completa, composta por todas as soluções não-dominadas continuam relevantes para o problema.

A escolha final entre essas diversas opções ótimas dependeria das prioridades táticas em um cenário real. Em uma fase inicial da busca com fortes indícios de que o alvo está em esparsas áreas de alta probabilidade e recursos energéticos pouco limitados, uma solução como s3 ou s2 poderia ser mais adequada. Já em uma situação onde há limitação dos recursos e poucos pontos de visitação, uma solução como s1 poderia ser mais indicada. Esta conclusão tem implicações no planejamento de missões, permitindo que os comandantes de operações utilizem frotas de ARPs de forma mais inteligente, adaptando a estratégia e a alocação de ativos com base na urgência e na distribuição de probabilidade da área de busca.

4.1. Plotação Gráfica

Para visualizar a estrutura das rotas geradas e o comportamento iterativo do sistema, a Figura 4 apresenta um exemplo ilustrativo com uma instância de menor porte. O uso de menos pontos nesta representação gráfica tem como objetivo garantir a clareza visual, permitindo distinguir as rotas de cada ARP indicadas por cores distintas, cada ponto é plotado em sua latitude e longitude, cada ARP aparece em cor distinta com sua garagem representada por um quadrado, e a direção do percurso com setas.

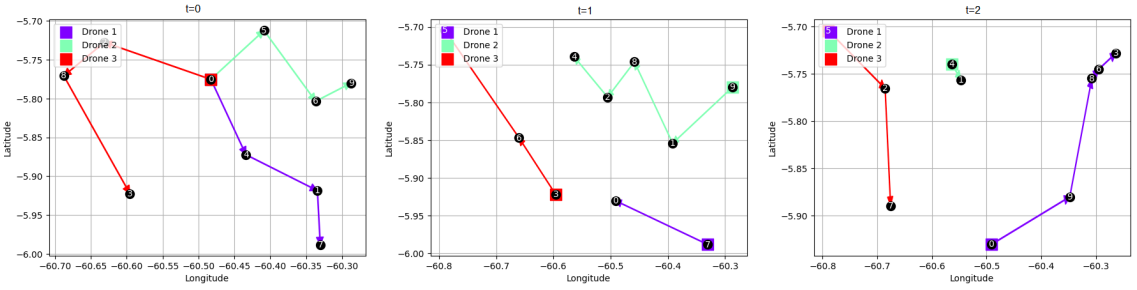

Figura 4: Exemplo de iteração de geração de rotas.

As soluções derivadas da otimização OVRP fornecem amostras de rotas em termos de custo e probabilidades operacionais, a operação do sistema envolve iterações contínuas do modelo de otimização para elevar a eficiência global. No instante inicial ($t = 0$) todos os ARPs partem de uma única garagem; após cada iteração o modelo é reavaliado, e os ARPs partem dos pontos finais alcançados na iteração anterior.

Essas iterações exploram a região de busca enquanto aprimoram a localização do alvo, particularmente em termos de minimização de custo e maximização de probabilidade. A função objetivo pode ser ajustada para equilibrar custo e probabilidade de acordo com as necessidades de cada cenário. As iterações prosseguem até que os alvos sejam localizados.

5. Conclusão

Este estudo em andamento investiga a otimização de roteamento de ARPs para missões de SAR, com ênfase em estratégias iterativas e multiobjetivo que aproveitam múltiplos veículos para elevar a eficiência geral da busca. Um modelo PLI foi inicialmente formulado para elaborar um modelo considerando fatores críticos como energia disponível, prioridades de pontos de interesse e custo. Visando desenvolver uma abordagem meta-heurística, foi utilizado o framework RKO capaz

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

de gerar rotas viáveis dentro de um tempo de execução fixo e curto, adequado para as demandas de operações de emergência.

Os requisitos de aquisição de dados são definidos por registros históricos de missões, localizações de incidentes, tempos de resposta e mapas de probabilidade que capturam distribuições espaciais de provável presença de alvos. Como parte das próximas etapas, planeja-se validar o método proposto inicialmente por meio de simulações detalhadas com dados históricos de ocorrências, além de concentrar-se-ão em aperfeiçoar o desempenho computacional, expandir o modelo e realizar avaliações extensas em condições reais.

6. Agradecimentos

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo número (2024/08848-3). O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Referências

Arkin, E. M., Fekete, S. P., e Mitchell, J. S. (2000). Approximation algorithms for lawn mowing and milling. *Computational Geometry*, 17(1-2):25–50.

Chaves, A. A., Resende, M. G., Schuetz, M. J., Brubaker, J. K., Katzgraber, H. G., de Arruda, E. F., e Silva, R. (2024). A random-key optimizer for combinatorial optimization. *arXiv preprint arXiv:2411.04293*.

da Silva Gomes, M. C., de Jesus, L. D., Dantas, A. J., de Almeida, M. A., Ramos, A. C., Mora-Camino, F., e Mykoniatis, G. (2022). The use of 5g networks to control uavs. In *23ème congrès annuel de la Société Française de Recherche Opérationnelle et d'Aide à la Décision*.

Dantas, A., Jesus, L., Ramos, A., Hokama, P., Mora-Camino, F., Katarya, R., Verma, O., Grupta, P., Singh, G., e Ouahada, K. (2021). Using uav, iomt and ai for monitoring and supplying of covid-19 patients. In *ITNG 2021 18th International Conference on Information Technology-New Generations*, p. 383–386. Springer.

Dantas, A. (2025). Search and rescue random-key optimizer (sar-rko) - c++ framework. URL `https://github.com/AntonioDantas/RKO`.

Dantas, A., Diniz, L., Almeida, M., Olsson, E., Funk, P., Sohlberg, R., e Ramos, A. (2022). Intelligent system for detection and identification of ground anomalies for rescue. In *ITNG 2022 19th International Conference on Information Technology-New Generations*, p. 277–282. Springer.

Dantas Filho, A. J., Ramos, A. C., de Jesus, L. D., de Castro Filho, H. F., e Mora-Camino, F. (2020). A general low cost uav solution for power line tracking. In *17th International Conference on Information Technology–New Generations (ITNG 2020)*, p. 525–530. Springer.

Dantzig, G. B. e Ramser, J. H. (1959). The truck dispatching problem. *Management science*, 6(1): 80–91.

DECEA, D. D. C. D. E. A. *MCA 64-3*. MINISTÉRIO DA DEFESA COMANDO DA AERONÁUTICA, jul 2019. Manual de Coordenação de Busca e Salvamento Aeronáutico.

Deng, L., Yuan, H., Huang, L., Yan, S., e Lai, Y. (2018). Post-earthquake search via an autonomous uav: Hybrid algorithm and 3d path planning. In *2018 14th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, p. 1329–1334.

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br

Dyba, T., Dingsoyr, T., e Hanssen, G. K. (2007). Applying systematic reviews to diverse study types: An experience report. In *First international symposium on empirical software engineering and measurement (ESEM 2007)*, p. 225–234. IEEE.

Fabian, F., Moreira, F., e Araujo, T. (2022). Análise estatística das missões de busca por aeronaves desaparecidas: construção de áreas de probabilidade. *SIGE ITA*. Maj Kuroswiski (adm).

Freitas, V. (2019). Perform systematic literature reviews. URL `https://parsif.al/`.

Hayat, S., Yanmaz, E., Brown, T. X., e Bettstetter, C. (2017). Multi-objective uav path planning for search and rescue. In *2017 IEEE International Conference on Robotics and Automation (ICRA)*, p. 5569–5574.

Huang, J.-S., Huang, Y.-C., Wang, Y.-S., e Lien, Y.-N. (2011). Design of a contingency communication network. In *Submitted to 13th Asia-Pacific Network Operations and Management Symposium*, p. 21–23.

Kitchenham, B. (2004). Procedures for performing systematic reviews. *Keele, UK, Keele University*, 33(2004):1–26.

Lyu, M., Zhao, Y., Huang, C., e Huang, H. (2023). Unmanned aerial vehicles for search and rescue: A survey. *Remote Sensing*, 15(13). ISSN 2072-4292.

Martins, W. M., Dantas Filho, A. J., Dejesus, L. D., Desouza, A. D., Ramos, A. C., e Pimenta, T. C. (2020). Tracking for inspection in energy transmission power lines using unmanned aerial vehicles: a systematic review of current and specific literature. *IAES International Journal of Robotics and Automation*, 9(4):233.

Nasar, W., Da Silva Torres, R., Gundersen, O. E., e Karlsen, A. T. (2023). The use of decision support in search and rescue: A systematic literature review. *ISPRS International Journal of Geo-Information*, 12(5):182.

San Juan, V., Santos, M., e Andújar, J. M. (2018). Intelligent uav map generation and discrete path planning for search and rescue operations. *Complexity*, 2018(1):6879419.

Santos, H. G. e Toffolo, T. (2020). Mixed integer linear programming with python. *COINOR Computational Infrastructure for Operations Research*.

Shi, W., Li, J., Cheng, N., Lyu, F., Zhang, S., Zhou, H., e Shen, X. (2019). Multi-drone 3-d trajectory planning and scheduling in drone-assisted radio access networks. *IEEE Transactions on Vehicular Technology*, 68(8):8145–8158.

Srinivasu, B., Rao, P. S., et al. (2013). Infrastructure development and economic growth: Prospects and perspective. *Journal of business management and Social sciences research*, 2(1):81–91.

Vieira, B. S., Silva, E. M., e Chaves, A. A. (2025). Random-key algorithms for optimizing integrated operating room scheduling. *arXiv preprint arXiv:2501.10243*.

Wu, J., Song, C., Ma, J., Wu, J., e Han, G. (2022). Reinforcement learning and particle swarm optimization supporting real-time rescue assignments for multiple autonomous underwater vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 23(7):6807–6820.

Xiong, T., Liu, F., Liu, H., Ge, J., Li, H., Ding, K., e Li, Q. (2023). Multi-drone optimal mission assignment and 3d path planning for disaster rescue. *Drones*, 7(6). ISSN 2504-446X.

DOI: 10.59254/sbpo-2025-212109
https://proceedings.science/p/212109?lang=pt-br