

Planejamento de Dronevias em Ambiente Urbano Real com Meta-Heurísticas: Um Estudo Aplicado ao Centro de Belo Horizonte

Erica Generoso Lima

ericageneroso@ita.br

Instituto Tecnológico de Aeronáutica – ITA

Elcio Hideiti Shiguemori

elciohs@gmail.com

Instituto Nacional de Pesquisas Espaciais – INPE

Rafael Marinho de Andrade

rafael.andrade@inpe.br

Instituto Nacional de Pesquisas Espaciais – INPE

Rafael Duarte Coelho dos Santos

rafael.santos@inpe.br

Instituto Nacional de Pesquisas Espaciais – INPE

Abstract

This work presents a method for urban aerial route planning ("drone corridors") in a real-world environment using single-solution meta-heuristics. The central region of Belo Horizonte was modeled as a geospatial graph with regulatory constraints and a detailed risk map based on population density, buildings, and critical infrastructure. Routes are optimized using Simulated Annealing (SA) and Tabu Search (TS), considering distance, risk, and time objectives. Six operational scenarios are evaluated. The results show that both techniques generate feasible and safe routes, with relevant differences in exploration and convergence behavior. The proposed approach demonstrates practical applicability for supporting UAV Traffic Management (UTM) systems in dense urban environments.

Palavras-chave

Dronevias, Navegação Autônoma, Meta-Heurísticas, Planejamento de Rotas, Gerenciamento de Tráfego de VANTs (UTM).

1 INTRODUÇÃO

A revolução tecnológica impulsionada pelos Veículos Aéreos Não Tripulados (VANTs) ou *Unmanned Aerial Vehicles* tem promovido transformações profundas em setores como logística, resposta a emergências, monitoramento ambiental, agricultura de precisão e inspeção de infraestrutura [1, 2]. Projeções da *Federal Aviation Administration* (FAA) e da *European Union Aviation Safety Agency* (EASA) indicam que o volume de operações com *drones* comerciais pode ultrapassar 2,5 milhões de voos diários em grandes centros urbanos até 2035 [3, 4].

Apesar desse crescimento acelerado, a operação segura de VANTs em ambientes urbanos apresenta desafios substanciais. Regiões densamente povoadas possuem restrições físicas e legais significativas, incluindo a presença de obstáculos verticais (edificações, torres, linhas de transmissão), infraestrutura crítica (hospitais, escolas, subestações elétricas), vias de transporte de alta densidade e zonas sensíveis definidas por regulamentações aeronáuticas [5]. A interação entre esses fatores demanda sistemas avançados de Gerenciamento de Tráfego de VANTs (UTM – *Unmanned Aerial System Traffic Management*), capazes de integrar informações geoespaciais dinâmicas, evitar conflitos e minimizar riscos à população.

Nesse contexto, o conceito de dronevias tem emergido como solução promissora. As dronevias correspondem a corredores aéreos pré-planejados e regulamentados, projetados para suportar tráfego

de VANTs de forma ordenada, eficiente e segura [6]. Assim como ocorre nas rodovias terrestres e aerovias tradicionais, o planejamento dessas rotas depende de múltiplos critérios, tais como minimização de risco, eficiência energética, redução de tempo de voo e mitigação do impacto sonoro. Naturalmente, estes critérios são conflitantes, enquadrando o problema como um caso clássico de otimização multiobjetivo.

O planejamento de rotas em dronevias caracteriza-se ainda como um problema de otimização combinatória NP-difícil, especialmente quando formulações multiobjetivo e restrições geoespaciais são consideradas [7]. Assim, abordagens exatas tornam-se inviáveis para instâncias reais, o que impulsiona o uso de meta-heurísticas de busca, capazes de identificar soluções de alta qualidade em tempo computacional reduzido, mesmo sem garantir um ótimo global.

1.1 Motivação

A região central de Belo Horizonte (BH), capital de Minas Gerais, constitui um cenário urbano desafiador e representativo para estudos de planejamento de dronevias. Com área aproximada de 30 km², essa região apresenta elevada complexidade espacial, caracterizada por intensa verticalização, concentração de equipamentos urbanos sensíveis, como hospitais de referência, infraestrutura de transporte de alta capacidade (linhas de metrô e corredores exclusivos de ônibus), além de redes de transmissão e distribuição de energia elétrica [8].

Do ponto de vista demográfico, a região central de BH apresenta densidade populacional média elevada quando comparada ao restante do município, com bairros que atingem picos superiores a 7.000 habitantes/km², configurando áreas de alta exposição ao risco em operações aéreas de baixa altitude. Essa heterogeneidade espacial da ocupação urbana torna o centro da cidade um ambiente particularmente adequado para avaliar algoritmos de planejamento de rotas sensíveis a critérios de risco, distância e tempo de deslocamento.

Apesar da relevância do problema, observa-se escassez de estudos que realizem comparações sistemáticas entre diferentes meta-heurísticas aplicadas ao planejamento de rotas em ambientes urbanos reais. Grande parte da literatura concentra-se em cenários sintéticos ou em análises restritas a um único método de otimização. Este trabalho busca preencher essa lacuna ao conduzir uma comparação abrangente entre distintas classes de meta-heurísticas

– incluindo abordagens de solução única e métodos populacionais – aplicadas ao contexto realista de dronevias urbanas.

1.2 Contribuições

As principais contribuições deste artigo podem ser resumidas como:

- (1) Uma formulação matemática completa do problema de planejamento de rotas em dronevias como um problema multiobjetivo com restrições geoespaciais;
- (2) A seleção, adaptação e implementação de um conjunto diversificado de meta-heurísticas para solução única e multi-indivíduos aplicadas ao problema urbano real;
- (3) O desenvolvimento de um modelo de risco baseado em dados geoespaciais reais, incluindo edificações, densidade populacional, infraestrutura urbana e restrições aeronáuticas;
- (4) A geração de tabelas detalhadas de atributos de risco para o centro de BH, incorporando pesos, zonas de influência e classificações por categoria;
- (5) Uma metodologia experimental robusta para comparação entre algoritmos, considerando tempo de execução, qualidade da solução, convergência e sensibilidade ao risco; e
- (6) A aplicação prática do modelo ao centro de BH, utilizando dados vetoriais e *rasters* reais de alta resolução.

1.3 Organização do Artigo

O restante deste trabalho está estruturado da seguinte forma: a Seção 2 apresenta a fundamentação teórica sobre UTM, mapeamento de risco e meta-heurísticas; a Seção 3 descreve a formulação matemática do problema; a Seção 4 detalha as meta-heurísticas estudadas; a Seção 5 apresenta a metodologia experimental adotada; a Seção 6 discute os resultados obtidos; e, por fim, a Seção 7 traz as conclusões e trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção são abordados os fundamentos teóricos e conceituais para a compreensão do trabalho, no que diz respeito às particularidades dinâmicas do espaço aéreo com VANTs, riscos envolvidos e técnicas de otimização.

2.1 Gerenciamento de Tráfego de VANTs

O Gerenciamento de Tráfego de VANTs (UTM) é um sistema emergente e crucial para a coordenação segura e eficiente de operações de VANTs em baixas altitudes (tipicamente abaixo de 120 metros) [9]. Diferentemente do Gerenciamento de Tráfego Aéreo (ATM – *Air Traffic Management*) que é utilizado para o controle do tráfego de aeronaves convencionais, o UTM é projetado para acomodar um cenário operacional radicalmente distinto e mais complexo [10]. As principais distinções incluem:

- **Volume exponencialmente maior de aeronaves:** o número de VANTs em operação deve superar em muito o tráfego aéreo tripulado;
- **Características de voo distintas:** inclui voo estacionário (*hovering*), decolagem e pouso vertical (VTOL) e manobras em baixa velocidade;

- **Espaço aéreo não segregado:** onde as operações ocorrem em proximidade com a infraestrutura urbana e o público;
- **Operações autônomas e semi-autônomas:** exige um alto grau de automação no planejamento e execução de voo; e
- **Integração com infraestrutura urbana:** há necessidade de coordenação com serviços de emergência, segurança pública e regulamentações locais.

2.2 Dronevias e Corredores Aéreos Urbanos

As dronevias constituem um componente fundamental do UTM, estabelecendo corredores virtuais tridimensionais que garantem a separação, a previsibilidade e a mitigação de riscos do tráfego de VANTs. A definição destas rotas deve ser um processo de otimização multi-objetivo que considere:

- (1) **Segurança** – minimização de riscos para pessoas e propriedades no solo (risco de terceiros) [11];
- (2) **Eficiência** – otimização de métricas operacionais como distância e tempo de voo;
- (3) **Escalabilidade** – capacidade de adaptação ao crescimento futuro da demanda por serviços de VANTs; e
- (4) **Resiliência** – capacidade de reconfiguração dinâmica e resposta a eventos não planejados (como falhas mecânicas, clima adverso e restrição de áreas de voo).

2.3 Mapeamento de Risco Urbano

O planejamento de rotas seguras para VANTs em ambientes urbanos exige uma avaliação precisa do risco de terceiros (danos a pessoas e bens no solo em caso de falha da aeronave) [12]. O trabalho [13] propõe uma metodologia robusta para a estimação de riscos utilizando um índice de pertinência. O modelo pondera a presença e a proximidade de atributos de risco relevantes, gerando um mapa de calor de risco espacializado.

O valor de risco R_i de um ponto i no espaço aéreo é determinado pela soma ponderada das pertinências aos atributos de risco:

$$R_i = \sum_{j=1}^{N_A} \Omega_j \cdot P_{A_j}(i) \quad (1)$$

onde:

- N_A é o número total de atributos de risco considerados;
- Ω_j é a ponderação do atributo j ;
- $P_{A_j}(i)$ é a pertinência do ponto i ao atributo j , variando entre 0 e 1.

Os atributos de risco considerados na modelagem incluem:

- **Infraestrutura crítica:** hospitais ($\Omega = -40$), escolas ($\Omega = -25$), devido à alta sensibilidade e concentração de pessoas;
- **Densidade populacional:** variando de +50 (baixa) a -50 (alta), refletindo a probabilidade de impacto em solo;
- **Obstáculos verticais:** Edifícios ($\Omega = -30$), torres ($\Omega = -75$), que representam risco de colisão;
- **Rede de transmissão de energia:** linhas de alta tensão ($\Omega = -50$), devido ao risco de interferência eletromagnética e significativos efeitos colaterais em casos de acidentes; e
- **Aeródromos:** zonas de exclusão ($\Omega = -100$), representando áreas de alto risco regulatório e operacional.

A função de pertinência $P_{A_j}(i)$ é definida por uma função de decaimento gaussiano, que modela a influência do atributo em função da distância:

$$P_{A_j}(i) = \begin{cases} 1 & \text{se } d(i, A_j) \leq r_j \\ \exp\left(-\frac{(d(i, A_j) - r_j)^2}{2\sigma_j^2}\right) & \text{se } d(i, A_j) > r_j \end{cases} \quad (2)$$

onde $d(i, A_j)$ é a distância euclidiana do ponto i ao atributo A_j , r_j é o raio de segurança (zona de influência máxima), e σ_j controla a taxa de decaimento da pertinência.

A Figura 1 ilustra a aplicação do modelo de risco proposto à região central de BH, evidenciando as áreas de maior concentração de risco associadas a alta densidade populacional e presença de infraestrutura crítica.

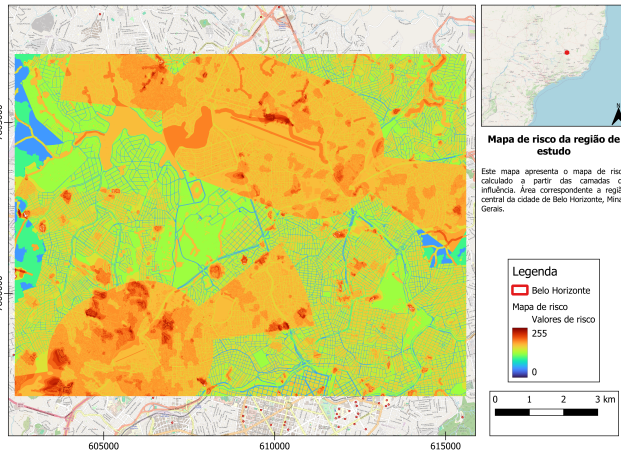


Figure 1: Mapa de risco para operações de VANTs no centro de BH. As cores representam diferentes níveis de risco: vermelho (risco muito alto), laranja-escuro (risco alto), laranja-claro (risco médio), verde (risco baixo) e azul (risco muito baixo). Os atributos de risco incluem densidade populacional, edificações, infraestrutura crítica e zonas de restrição aérea.

2.4 Otimização por Meta-heurísticas

O problema de planejamento de rotas de VANTs é inerentemente complexo, sendo classificado como NP-difícil, especialmente em sua formulação multi-objetivo e com restrições dinâmicas [14]. Meta-heurísticas são estratégias robustas que guiam a busca por soluções de boa qualidade mesmo em espaços combinatórios extensos. Neste trabalho, são consideradas exclusivamente meta-heurísticas de solução única, por sua capacidade de explorar com eficiência vizinhanças estruturadas em problemas de roteamento espacial urbano.

Essas meta-heurísticas operam iterativamente sobre uma única solução corrente, realizando movimentos locais e incorporando mecanismos de diversificação para evitar ótimos locais.

2.5 Meta-heurísticas de Solução Única

Operam e aprimoram uma única solução por iteração, focando na exploração da sua vizinhança, exemplos incluem:

- **SA:** inspirado no processo de recozimento de metais, aceita soluções piores com uma probabilidade que decresce ao longo do tempo (tal como o decaimento de temperatura); e
- **TS:** utiliza memória de curto e longo prazo (lista tabu) para evitar ciclos e diversificar a busca no espaço de soluções.

Essas duas meta-heurísticas são especialmente adequadas para o problema analisado, pois dependem de estruturas de vizinhança bem definidas sobre rotas no grafo urbano e apresentam bom equilíbrio entre intensificação e diversificação.

3 FORMULAÇÃO MATEMÁTICA DO PROBLEMA

Nesta seção é formalmente apresentada a modelagem matemática do problema abordado, de modo a permitir a implementação de técnicas de otimização.

3.1 Representação do Espaço Aéreo

O ambiente operacional, especificamente a região central de BH, é modelado e discretizado como um grafo não-direcionado $G = (V, E)$, o que permite a aplicação de algoritmos de busca em grafos para o planejamento de rotas.

- $V = \{v_1, v_2, \dots, v_n\}$ é o conjunto de nós, que representam os pontos discretos de voo potenciais no espaço aéreo tridimensional.
- $E = \{e_{ij} | v_i, v_j \in V, i \neq j\}$ é o conjunto de arestas, que denotam os segmentos de voo viáveis entre os pontos discretos.

Cada nó $v_i \in V$ é caracterizado por um conjunto de atributos essenciais para a avaliação da rota:

- **Coordenadas geográficas:** $v_i = (lat_i, lon_i, alt_i)$, definindo a posição espacial do ponto;
- **Valor de risco:** R_i , quantificado pela Equação (1), que representa o risco a terceiros no ponto v_i ; e
- **Restrições locais:** $C_i \in \{0, 1\}$, um indicador binário que sinaliza a viabilidade regulatória ou operacional do ponto (0 = proibido, 1 = permitido, como em zonas de exclusão aérea).

Cada aresta $e_{ij} \in E$ é associada a custos de travessia que serão utilizados na função objetivo:

- **Distância euclidiana:** $d_{ij} = \|v_i - v_j\|_2$, representando o comprimento físico do segmento de voo;
- **Risco acumulado:** $R_{ij} = \int_{v_i}^{v_j} R(s) ds \approx \frac{R_i + R_j}{2} \cdot d_{ij}$, que estima o risco total de terceiros ao longo do segmento e_{ij} ; e
- **Tempo de travessia:** $t_{ij} = d_{ij} / v_{cruise}$, onde v_{cruise} é a velocidade de cruzeiro constante do VANT.

O grafo resultante serve como base para os algoritmos de planejamento de rotas implementados neste trabalho. A estrutura de dados adotada permite consultas eficientes de vizinhança e facilita a integração com os mapas de risco geoespaciais, onde cada nó v_i é associado ao valor de risco R_i do ponto correspondente no espaço físico.

3.2 Definição do Problema de Roteamento

O problema consiste em determinar uma rota π que conecte um ponto de origem s a um ponto de destino t . Uma rota π é definida como uma sequência ordenada de nós:

$$\pi = \langle v_s = v_{i_1}, v_{i_2}, \dots, v_{i_k}, v_{i_{k+1}} = v_t \rangle \quad (3)$$

onde a condição $(v_{i_j}, v_{i_{j+1}}) \in E$ deve ser satisfeita para todo $j \in \{1, \dots, k\}$, garantindo que todos os segmentos da rota sejam viáveis no grafo.

3.3 Função Objetivo

O problema de planejamento de rotas é formalizado como um problema de otimização multi-objetivo, buscando a minimização de uma função de custo agregada e ponderada:

$$\min_{\pi \in \Pi} F(\pi) = w_D \cdot D_{norm}(\pi) + w_R \cdot R_{norm}(\pi) + w_T \cdot T_{norm}(\pi) \quad (4)$$

onde Π representa o conjunto de todas as rotas viáveis que atendem às restrições. Os pesos w_D , w_R e w_T permitem ao operador ajustar a prioridade entre os objetivos conflitantes de distância, risco e tempo.

A otimização está sujeita às seguintes restrições operacionais e regulatórias: Pesos de Ponderação; Restrição de viabilidade do nó; Restrição de autonomia de voo e Restrição de risco local máximo.

$$w_D + w_R + w_T = 1, \quad w_D, w_R, w_T \geq 0 \quad (5)$$

$$C_i = 1, \quad \forall v_i \in \pi \quad (6)$$

$$T(\pi) \leq T_{max} \quad (7)$$

$$R_{local}(e_{ij}) \leq R_{threshold}, \quad \forall e_{ij} \in \pi \quad (8)$$

Os componentes da função objetivo são normalizados através do escalonamento *min-max* para garantir que cada objetivo contribua de forma equitativa para o custo total, independentemente da magnitude de suas unidades:

Distância total normalizada:

$$D_{norm}(\pi) = \frac{D(\pi) - D_{min}}{D_{max} - D_{min}} \quad (9)$$

onde a distância total $D(\pi)$ é calculada pela soma das distâncias euclidianas dos segmentos:

$$D(\pi) = \sum_{j=1}^k d_{i_j, i_{j+1}}. \quad (10)$$

Risco acumulado normalizado:

$$R_{norm}(\pi) = \frac{R(\pi) - R_{min}}{R_{max} - R_{min}} \quad (11)$$

onde o risco acumulado $R(\pi)$ é a soma dos riscos estimados para cada segmento da rota:

$$R(\pi) = \sum_{j=1}^k R_{i_j, i_{j+1}}. \quad (12)$$

Tempo total normalizado:

$$T_{norm}(\pi) = \frac{T(\pi) - T_{min}}{T_{max} - T_{min}} \quad (13)$$

onde o tempo total de voo $T(\pi)$ inclui o tempo de travessia e o tempo despendido em manobras de mudança de direção:

$$T(\pi) = \sum_{j=1}^k t_{i_j, i_{j+1}} + \sum_{j=2}^k t_{turn}(\theta_j), \quad (14)$$

sendo $t_{turn}(\theta_j)$ o tempo de manobra necessário para a mudança de ângulo θ_j no nó $v_{i_{j+1}}$.

4 META-HEURÍSTICAS IMPLEMENTADAS

Neste trabalho, para a otimização dos problemas abordados, foram implementadas duas técnicas de meta-heurísticas: o SA e o TS.

4.1 Simulated Annealing (SA)

O SA é uma meta-heurística de solução única inspirada no processo físico de recozimento de metais, na qual um parâmetro denominado temperatura T controla a probabilidade de aceitar soluções piores durante a busca. Essa característica permite ao algoritmo escapar de ótimos locais em estágios iniciais da otimização [15].

O Algoritmo 1 descreve o pseudocódigo do método de SA utilizado neste trabalho.

Algoritmo 1 SA para dronevias

```

1: Entrada: Grafo  $G$ , origem  $s$ , destino  $t$ ,  $T_0$ ,  $T_{min}$ ,  $\alpha$ 
2: Saída: Melhor rota  $\pi^*$ 
3:  $\pi \leftarrow$  GerarRotaInicial( $s$ ,  $t$ ,  $G$ )
4:  $\pi^* \leftarrow \pi$ 
5:  $T \leftarrow T_0$ 
6: while  $T > T_{min}$  do
7:    $\pi' \leftarrow$  GerarVizinho( $\pi$ )
8:    $\Delta F \leftarrow F(\pi') - F(\pi)$ 
9:   if  $\Delta F < 0$  or  $\text{random}() < \exp(-\Delta F/T)$  then
10:     $\pi \leftarrow \pi'$ 
11:    if  $F(\pi) < F(\pi^*)$  then
12:       $\pi^* \leftarrow \pi$ 
13:    end if
14:  end if
15:   $T \leftarrow \alpha \cdot T$ 
16: end while
17: return  $\pi^* = 0$ 

```

4.2 Geração de Vizinhança

A função GerarVizinho utiliza operadores de perturbação adequados ao grafo urbano:

- **2-opt:** reverte segmentos e reduz cruzamentos;
- **Node-insertion:** insere nó intermediário viável;
- **Node-removal:** remove pontos redundantes;
- **Segment-swap:** troca pequenas subseqüências da rota.

4.3 Tabu Search (TS)

A TS é uma meta-heurística baseada em busca local que emprega estruturas de memória de curto prazo para evitar a ciclagem e a revisitação de soluções recentemente exploradas. Adicionalmente, critérios de aspiração permitem a aceitação de movimentos tabu quando estes resultam em soluções superiores à melhor encontrada

até o momento, favorecendo a exploração eficiente do espaço de busca [16].

O Algoritmo 2 apresenta o pseudocódigo TS aplicado ao planejamento de rotas para dronevias urbanas.

Algoritmo 2 TS para dronevias

```

1: Entrada: Grafo  $G$ , origem  $s$ , destino  $t$ ,  $tenure$ ,  $max\_iter$ 
2: Saída: Melhor rota  $\pi^*$ 
3:  $\pi \leftarrow$  GerarRotaInicial( $s$ ,  $t$ ,  $G$ )
4:  $\pi^* \leftarrow \pi$ 
5:  $TabuList \leftarrow \emptyset$ 
6:  $iter \leftarrow 0$ 
7: while  $iter < max\_iter$  do
8:    $N(\pi) \leftarrow$  GerarVizinhanca( $\pi$ )
9:    $\pi' \leftarrow$  MelhorNaoTabu( $N(\pi)$ ,  $TabuList$ ,  $\pi^*$ )
10:   $\pi \leftarrow \pi'$ 
11:  if  $F(\pi) < F(\pi^*)$  then
12:     $\pi^* \leftarrow \pi$ 
13:  end if
14:  AtualizarTabuList( $TabuList$ , movimento( $\pi$ ),  $tenure$ )
15:   $iter \leftarrow iter + 1$ 
16: end while
17: return  $\pi^* = 0$ 

```

5 METODOLOGIA EXPERIMENTAL

Nesta seção são apresentadas as condições práticas do processo experimental da solução explorada.

5.1 Área de Estudo

A Figura 2 apresenta a área de experimentação que corresponde à região central de BH, selecionada por concentrar elevada densidade populacional, diversidade de tipologias urbanas e presença significativa de infraestrutura crítica. Os dados geoespaciais utilizados foram obtidos de fontes oficiais e amplamente reconhecidas: a malha viária, as edificações e os limites administrativos foram extraídos do portal de *Geoprocessamento da Prefeitura de BH* (PBH) [8]; as informações censitárias e os mapas de densidade populacional foram obtidos junto ao *Instituto Brasileiro de Geografia e Estatística* (IBGE) [17]; elementos de infraestrutura crítica, como hospitais, escolas e pontos de interesse urbano, foram incorporados a partir da base colaborativa do *OpenStreetMap* (OSM) [18]; e a localização das linhas e estruturas de transmissão de energia foi obtida no repositório público da *Agência Nacional de Energia Elétrica* (ANEEL) [19].

5.2 Geração do grafo

A região analisada possui aproximadamente $7,5 \times 4,0$ km (cerca de 30 km^2) e foi discretizada em uma grade regular com resolução espacial de 5 m, totalizando aproximadamente 5 milhões de nós. Cada nó armazena sua posição geográfica (coordenadas UTM ou latitude/longitude) e os atributos associados ao ambiente local, como o valor de risco, a classificação do uso do solo e as restrições espaciais.

A etapa seguinte consistiu na definição das arestas que estabelecem a conectividade entre os nós. Foi adotado um modelo de 8-vizinhança, no qual cada nó é conectado aos seus vizinhos imediatamente adjacentes nas direções horizontal, vertical e diagonal.

Essa escolha permite maior flexibilidade na geração de rotas, reduzindo efeitos artificiais de ortogonalidade e aproximando a movimentação possível do veículo aéreo do comportamento contínuo esperado no ambiente urbano.

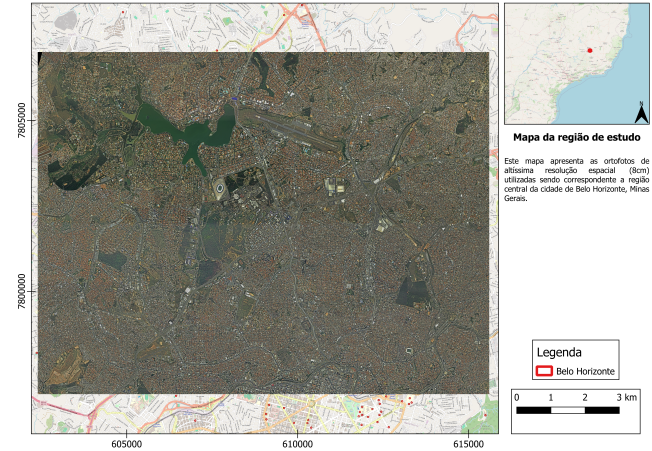


Figure 2: Representação do mapa ortomosaico da região de estudo, sendo correspondente a região central de BH.

5.3 Modelo de Risco Implementado

O modelo de risco adotado segue a formulação abordada na região central da cidade de São Paulo [13], adaptada para a região central de BH. As camadas geoespaciais (PBH [8], IBGE [17], OSM [18], ANEEL [19]) foram convertidas em atributos de risco com valores e zonas de influência (*buffers*) específicos. A construção do mapa de risco consiste em: (i) transformação de cada camada em um campo de contribuição ao risco; (ii) aplicação de zonas de influência e funções de decaimento; (iii) normalização e ponderação das contribuições; e (iv) agregação em um único valor de risco por célula.

As camadas incluem infraestrutura crítica, edificações, densidade populacional, hidrografia, áreas de preservação e zonas de restrição aeronáutica. Cada camada foi convertida para um campo *raster* contínuo, normalizado para o intervalo $[0,1]$ e ponderado conforme Tabelas 1, 2 e 3, contribuindo para o risco final atribuído a cada célula do grafo.

5.4 Cenários de Teste

Os cenários de teste foram definidos a partir de combinações ponderadas dos objetivos de distância, risco e tempo, conforme a formulação multiobjetivo apresentada na Equação (4). Cada cenário representa uma priorização distinta, permitindo avaliar como os algoritmos respondem a diferentes condições operacionais do ambiente urbano.

A Tabela 4 descreve os seis cenários adotados. Os três primeiros representam priorizações extremas, enquanto os demais refletem combinações balanceadas entre os critérios.

Esses cenários foram estruturados de forma a refletir características operacionais reais do centro de BH, especialmente a necessidade de mitigação de risco em áreas densamente edificadas.

Table 1: Atributos de risco por camada – Centro de BH.

Camada	Valor de risco	Zona de influência
QUADRA_VIARIA	255	Área interna
AREA_PRESERVACAO_PERMANENTE	240	Área interna
REPRESA	240	Área interna
ILUM_PUBLICA	130	Área interna
POSTE	130	Raio de 3 m
FERROVIA	170	Margem de 10 m
FAIXA_RODAGEM_RODOVIA	160	Margem de 10 m
LINHA_METRO	200	Margem de 10 m
EDIFICACAO	225	Área interna + 2 m
VIADUTO_PASSARELA_PONTE	195	Área interna + 12 m
LINHA_TRANSMISSAO	210	Margem de 50 m
HELIPONTO	255	Área interna + 75 m
TORRE_TRANSMISSAO	250	Raio de 50 m
RESTRICAO_VOO_DRONE	255	Área interna
PISTA_AEROPORTO	255	Área interna + 1000 m

Table 2: Classificação de risco por altura de edificação.

Camada	Categoria	Altura (m)	Valor de risco	Zona
PREDIO_0_5	Muito Baixa	0–5	150	2 m
PREDIO_5_12	Muito Baixa	5–12	170	2 m
PREDIO_12_30	Baixa	12–30	200	2 m
PREDIO_30_54	Média	30–54	210	3 m
PREDIO_54_100	Alta	54–100	230	5 m
PREDIO_100_mais	Muito Alta	>100	245	5 m

Table 3: Classificação de risco por densidade populacional – Centro de BH.

Camada	Categoria	Intervalo	Valor de risco	Zona
POP_0_20	Muito Baixa	0–20	50	Área interna
POP_20_40	Muito Baixa	20–40	100	Área interna
POP_40_60	Baixa	40–60	145	Área interna
POP_60_80	Média	60–80	190	Área interna
POP_80_100	Alta	80–100	230	Área interna

Table 4: Configurações de pesos para os cenários de testes.

Cenário	w _D	w _R	w _T	Descrição
C01	0.98	0.01	0.01	Mínima distância
C02	0.01	0.98	0.01	Mínimo risco
C03	0.01	0.01	0.98	Mínimo tempo
C04	0.55	0.25	0.20	Balanceado com foco em distância
C05	0.25	0.55	0.20	Balanceado com foco em risco
C06	0.20	0.25	0.55	Balanceado com foco em tempo

Os cenários estabelecidos fornecem uma estrutura experimental consistente para analisar como cada meta-heurística responde a diferentes configurações de prioridade. Além disso, permitem observar variações qualitativas no traçado das rotas geradas (Figura 4), que refletem diretamente a influência dos pesos definidos na Tabela 4.

5.5 Parâmetros dos Algoritmos

A parametrização adotada reflete valores amplamente usados na literatura para algoritmos de busca local aplicados a problemas de roteamento em ambientes urbanos complexos. Os parâmetros foram definidos em faixas para permitir variações sistemáticas durante os experimentos.

A Tabela 5 apresenta os parâmetros utilizados para o SA e para o TS.

Table 5: Parâmetros utilizados nas meta-heurísticas.

Algoritmo	Parâmetro	Valores
SA	T_0	{1500, 5000, 12000}
	α	{0.85, 0.92, 0.98}
	iterações	{500, 1000, 2000}
TS	tenure	{7, 15, 25}
	iterações	{500, 1000, 2000}

A parametrização proposta segue práticas comuns na literatura, mas também foi ajustada empiricamente para refletir as características do grafo descrito na Seção 5.2. O centro de BH apresenta um conjunto de restrições complexas, incluindo áreas densamente verticalizadas e zonas de risco elevado, o que exige mecanismos eficazes de diversificação. Nesse contexto, temperaturas iniciais mais altas no SA e tenures moderados no TS foram particularmente favoráveis ao desempenho observado.

6 RESULTADOS E DISCUSSÃO

Nesta seção são sumarizados e discutidos os resultados obtidos a partir do processo de experimentação do trabalho, cobrindo a análise de convergência e orientada a cenários.

6.1 Análise de Convergência

A Figura 3 apresenta as curvas de convergência dos algoritmos SA e TS ao longo das iterações para os cenários C01 (mínima distância), C02 (mínimo risco) e C03 (mínimo tempo). As curvas representam a evolução do valor da função de custo agregada definida na Equação (4).

O SA apresenta uma redução acentuada do custo nas iterações iniciais, resultado direto do mecanismo probabilístico de aceitação de soluções piores em altas temperaturas. Esse comportamento favorece a exploração do espaço de busca e mostrou-se particularmente relevante em cenários com forte influência do mapa de risco, nos quais a paisagem de custo é altamente não convexa e repleta de ótimos locais associados a zonas urbanas críticas.

À medida que a temperatura decresce, a taxa de aceitação de movimentos que implicam aumento do valor da função objetivo, conduzindo o algoritmo a uma fase de intensificação, na qual a solução converge para um mínimo local estável. Essa transição é

claramente observada pela estabilização das curvas nas iterações finais.

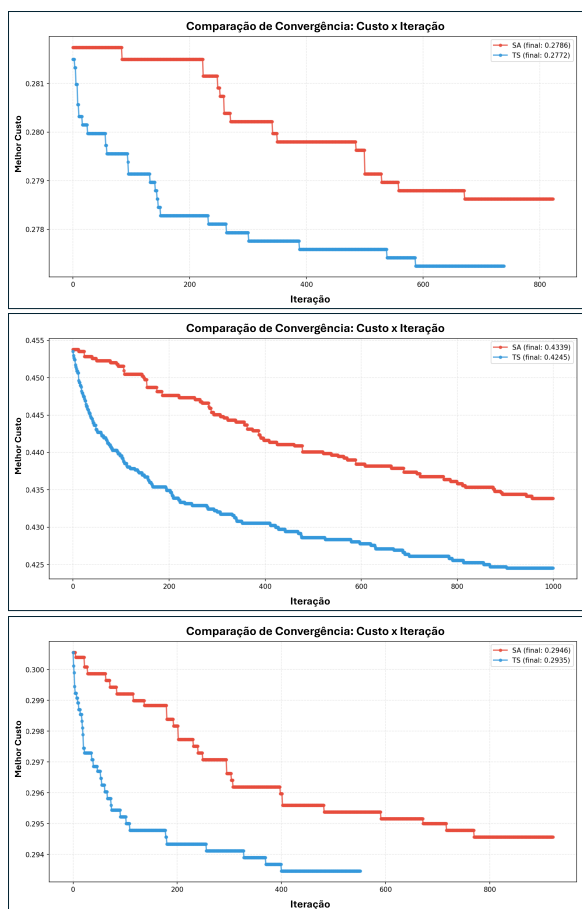


Figure 3: Curvas de convergência dos algoritmos SA (em vermelho) e TS (em azul) para o C01 (distância), C02 (risco) e C03 (tempo).

Já o TS apresenta um comportamento de convergência mais gradual e monotônico. A utilização da lista tabu impede a reversão imediata de movimentos recentes, reduzindo a ocorrência de ciclos e promovendo uma exploração sistemática da vizinhança. Esse mecanismo mostrou-se eficaz especialmente em regiões do grafo com alta conectividade, onde múltiplas rotas alternativas apresentam custos similares.

De forma geral, os resultados indicam que o SA possui maior capacidade exploratória inicial, enquanto o TS apresenta maior estabilidade e previsibilidade no processo de convergência, características desejáveis em ambientes urbanos densos e altamente restritivos.

6.2 Análise por Cenário

A análise por cenário tem como objetivo avaliar a sensibilidade das meta-heurísticas às diferentes configurações de ponderação dos critérios de distância, risco e tempo, conforme definido na Tabela 4.

Cada cenário representa uma prioridade operacional distinta, permitindo observar como a função de custo agregada influencia a geometria e o comportamento das rotas planejadas.

A Figura 4 ilustra um exemplo qualitativo das rotas geradas em dois cenários contrastantes: C01 (mínima distância) e C02 (mínimo risco). As diferenças refletem diretamente a ponderação dos objetivos.

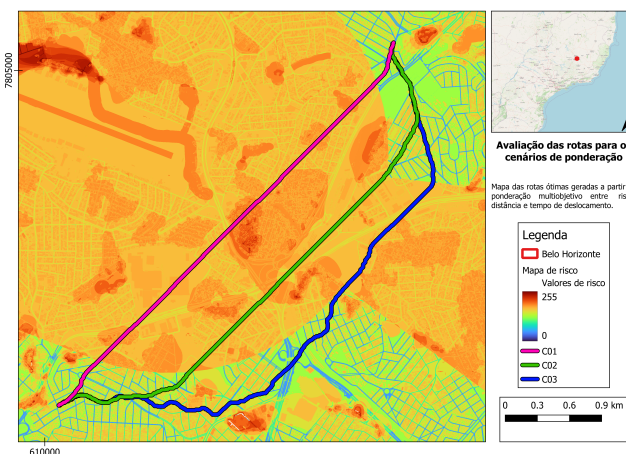


Figure 4: Comparação entre rotas geradas para os cenários C01 (distância), C02 (risco) e C03 (tempo).

No cenário C01, caracterizado pela forte priorização da distância, as rotas obtidas por ambas as meta-heurísticas tendem a se aproximar de trajetórias quase geodésicas entre os pontos de origem e destino. Esse comportamento resulta em percursos com menor comprimento total, porém frequentemente atravessando regiões densamente urbanizadas e com elevada concentração de edificações. Como consequência, observa-se maior exposição a áreas de risco elevado, especialmente em trechos associados a alta densidade populacional e infraestrutura crítica.

No cenário C02, onde o risco assume papel dominante na função objetivo, verifica-se uma alteração significativa na estrutura das rotas. As soluções passam a contornar sistematicamente as zonas identificadas como críticas no mapa de risco, incluindo regiões com alta densidade populacional, edificações de grande porte e áreas sujeitas a restrições regulatórias. Esse desvio resulta em trajetórias mais longas e com maior tempo de voo, porém com redução substancial da exposição ao risco de terceiros, evidenciando a eficácia do modelo de risco integrado ao processo de otimização.

No cenário C03, a minimização do tempo não implica, necessariamente, a escolha da rota mais curta. Isso ocorre porque o modelo de tempo considera reduções na velocidade efetiva do VANT em regiões de maior complexidade urbana, onde manobras frequentes e restrições operacionais aumentam o tempo de voo. Assim, o algoritmo privilegia trajetórias mais fluidas, ainda que mais longas, resultando em menor tempo total de deslocamento.

Nos cenários balanceados (C04, C05 e C06), as rotas resultantes exibem comportamento intermediário, combinando características dos cenários extremos. Esses resultados confirmam que pequenas

variações nos pesos da função objetivo produzem mudanças perceptíveis no traçado das rotas, reforçando a natureza multicritério do problema.

Sendo assim, a análise por cenário evidencia que a definição adequada das ponderações da função objetivo é determinante para a qualidade e o perfil operacional das rotas geradas. Além disso, os resultados demonstram que as meta-heurísticas empregadas são capazes de adaptar-se de forma consistente a diferentes prioridades operacionais, característica essencial para aplicações reais de planejamento de dronevias em sistemas de Gerenciamento de Tráfego de VANTs.

7 CONCLUSÃO

Este trabalho abordou o problema de planejamento de dronevias em ambiente urbano real a partir de uma formulação multicritério que integra distância, risco e tempo em uma única função de custo, explicitamente dependente das características espaciais e operacionais do ambiente urbano. A utilização de dados geoespaciais reais da região central de BH permitiu avaliar o comportamento dos algoritmos em um cenário representativo de alta complexidade e restrições.

A aplicação de meta-heurísticas de solução única demonstrou-se adequada para lidar com a natureza combinatória e não linear do problema, caracterizada por uma paisagem de custo irregular e altamente sensível às restrições urbanas. Nesse contexto, os métodos avaliados mostraram-se capazes de explorar o espaço de busca de forma eficiente, produzindo soluções compatíveis com diferentes perfis operacionais definidos pelas ponderações da função objetivo.

Do ponto de vista do modelo, os resultados obtidos evidenciam que a incorporação de custos fisicamente consistentes, em particular no cálculo do tempo de deslocamento com velocidade efetiva variável, altera de forma significativa o traçado das rotas ótimas quando comparado a abordagens puramente geométricas. Esse aspecto reforça a necessidade de modelos de custo sensíveis ao contexto urbano para o planejamento realista de operações com VANTs.

Como contribuição metodológica, o estudo fornece uma estrutura reprodutível para a avaliação comparativa de meta-heurísticas em problemas de dronevias urbanas, combinando dados reais, múltiplos cenários de ponderação e análise de convergência. Essa abordagem pode ser estendida a outros centros urbanos e integrada a sistemas de Gerenciamento de Tráfego de VANTs.

Como continuidade deste trabalho, destacam-se a incorporação de dinâmica temporal no mapa de risco, o planejamento cooperativo com múltiplos VANTs e o desenvolvimento de estratégias de replanejamento em tempo quase real, ampliando a aplicabilidade do modelo a cenários operacionais de maior escala e complexidade.

AGRADECIMENTOS

Os autores agradecem à Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro concedido à pesquisa em andamento através do processo de número 88887.980087/2024-00, e às Instituições, Instituto Tecnológico de Aeronáutica e Instituto Nacional de Pesquisas Espaciais pelo suporte científico e infraestrutura computacional utilizada no desenvolvimento deste estudo. Agradecemos também às bases de dados públicas

do IBGE, ANEEL, OpenStreetMap e à Prefeitura de Belo Horizonte, essenciais para a construção do modelo geoespacial adotado.

Referências

- [1] Dario Floreano and Robert J Wood. Science, technology and the future of small autonomous drones. *nature*, 521(7553):460–466, 2015.
- [2] Salvatore Manfreda, Matthew F McCabe, Pauline E Miller, Richard Lucas, Victor Pajuelo Madrigal, Giorgos Mallinis, Eyal Ben Dor, David Helman, Lyndon Estes, Giuseppe Ciraolo, et al. On the use of unmanned aerial systems for environmental monitoring. *Remote sensing*, 10(4):641, 2018.
- [3] Federal Aviation Administration. Unmanned aircraft system traffic management (utm). Technical report, Federal Aviation Administration, 2025. URL https://www.faa.gov/uas/research_development/traffic_management.
- [4] European Union Aviation Safety Agency. Study on the societal acceptance of urban air mobility in europe. Technical report, European Union Aviation Safety Agency (EASA), May 2021. URL <https://www.easa.europa.eu/sites/default/files/dfu/uam-full-report.pdf>.
- [5] Parimal Kopardekar, Joseph Rios, Thomas Prevot, Marcus Johnson, Jaewoo Jung, and John E Robinson. Unmanned aircraft system traffic management (utm) concept of operations. In *AIAA Aviation Forum and Exposition*, number ARC-E-DAA-TN32838, 2016.
- [6] Honghai Zhang, Tian Tian, Ouge Feng, Shixin Wu, and Gang Zhong. Research on public air route network planning of urban low-altitude logistics unmanned aerial vehicles. *Sustainability*, 15(15):12021, 2023.
- [7] Yong Zeng, Rui Zhang, and Teng Joon Lim. Wireless communications with unmanned aerial vehicles: Opportunities and challenges. *IEEE Communications magazine*, 54(5):36–42, 2016.
- [8] Prefeitura Municipal de Belo Horizonte. Geoprocessamento - base de dados geoespaciais de belo horizonte. Disponível em: <https://bhmap.pbh.gov.br/v2/mapa/idebgeo#zoom=4&lat=-7796893.0925&lon=609250.9075&baselayer=base>, 2024. Acesso em: Agosto 2025.
- [9] Arwa S Aweiss, Brandon D Owens, Joseph Rios, Jeffrey R Homola, and Christoph P Mohlenbrink. Unmanned aircraft low systems (uas) traffic management (utm) national campaign ii. In *2018 AIAA Information Systems-AIAA Infotech@ Aerospace*, page 1727, 2018.
- [10] Rudolfs Rumba and Agris Nikitenko. The wild west of drones: A review on autonomous-uav traffic-management. In *2020 International conference on unmanned aircraft systems (ICUAS)*, pages 1317–1322. IEEE, 2020.
- [11] Stefano Primatesa, Giorgio Guglieri, and Alessandro Rizzo. A risk-aware path planning strategy for uavs in urban environments. *Journal of Intelligent & Robotic Systems*, 95(2):629–643, 2019.
- [12] Hazha Saeed Yahia and Amin Salih Mohammed. Path planning optimization in unmanned aerial vehicles using meta-heuristic algorithms: A systematic review. *Environmental Monitoring and Assessment*, 195(1):30, 2023.
- [13] Rafael Marinho de Andrade, Elcio Hideiti Shiguemori, and Rafael Duarte Coelho dos Santos. Determinação de riscos de sobrevoos por visão computacional. *Anais do Computer on the Beach*, 16:160–167, 2025.
- [14] Mohammadreza Hooshyar, Mahdi Ghassemi, Mohammad Gholami, and Mohsen Jafari. Meta-heuristic algorithms in uav path planning optimization: A systematic review (2018–2022). *Drones*, 7(12):687, 2023. doi: 10.3390/drones7120687.
- [15] Peter JM Van Laarhoven and Emile HL Aarts. Simulated annealing. In *Simulated annealing: Theory and applications*, pages 7–15. Springer, 1987.
- [16] Fred Glover. Tabu search—part i. *ORSA Journal on computing*, 1(3):190–206, 1989.
- [17] Instituto Brasileiro de Geografia e Estatística (IBGE). Censo demográfico 2022: Resultados do universo – agregados por setor censitário. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/22827-censo-demografico.html>, 2023. Acesso em: novembro 2024.
- [18] OpenStreetMap Contributors. Openstreetmap. Disponível em: <https://www.openstreetmap.org>, 2024. Acesso em: novembro 2024.
- [19] Agência Nacional de Energia Elétrica (ANEEL). Sistema de informações georreferenciadas do setor elétrico – sigel. Disponível em: <https://sigel.aneel.gov.br/portal/home/>, 2024. Acesso em: novembro 2024.