



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Análise Comparativa de Algoritmos Meta-heurísticos na Solução de Posicionamento de UAV-BS

Davi Ketley Sousa Moraes

DM 14/2025

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

2025

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Davi Ketley Sousa Moraes

**Análise Comparativa de Algoritmos Meta-heurísticos na Solução de
Posicionamento de UAV-BS**

Dissertação submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para obtenção do Grau de Mestre em Engenharia Elétrica na Área de Computação Aplicada, elaborada pela orientação do Prof. Dr. Diego Lisboa Cardoso.

Orientador: Prof. Dr. Diego Lisboa Cardoso

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil

2025

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

M827a Moraes, Davi Ketley Sousa.
Análise Comparativa de Algoritmos Meta-heurísticos na
Solução de Posicionamento de UAV-BS / Davi Ketley Sousa
Moraes, . — 2025.
97 f. : il. color.

Orientador(a): Prof. Dr. Diego Lisboa Cardoso
Dissertação (Mestrado) - Universidade Federal do Pará,
Instituto de Tecnologia, Programa de Pós-Graduação em
Engenharia Elétrica, Belém, 2025.

1. UAV-BS. 2. Meta-heurísticas. 3. Posicionamento. 4.
Otimização. I. Título.

CDD 384.3

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Análise Comparativa de Algoritmos Meta-heurísticos na Solução de Posicionamento de UAV-BS

AUTOR: **DAVI KETLEY SOUSA MORAES**

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA APROVADA PARA OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM: 12/06/2025

BANCA EXAMINADORA:

Prof. Dr. Diego Lisboa Cardoso
(Orientador - PPGEE / UFPA)

Prof. Dr. Glauco Estácio Gonçalves
(Avaliador Interno - PPGEE / UFPA)

Prof. Dr. Tassio Costa de Carvalho
(Avaliador Externo - CAMPUS Castanhal / UFPA)

VISTO:

Prof. Dr. Diego Lisboa Cardoso
(Coordenador do PPGEE/ITEC/UFPA)

Dedico este trabalho a minha amada avó: Maria Ferreira dos Santos (in memoriam).

Agradecimentos

A Deus, fonte de toda sabedoria, força e vida, por me sustentar em cada passo dessa jornada e por Sua infinita graça em minha vida.

À minha esposa, Dayanny, pelo amor, paciência, e apoio incondicional em todos os momentos. Você é a luz que me guia e meu maior presente nesta caminhada.

Ao meu filho, Rafael, que é uma das razões de eu estar vivo e com forças para continuar. Seu sorriso é a maior motivação para seguir em frente e vencer os desafios.

Aos meus pais, Nabor e Moraes, por todo amor, educação e por acreditarem em mim mesmo nas adversidades. Vocês são exemplos de dedicação e inspiração.

Aos meus irmãos, Elionay, Heber e Elayne, e a todos os amigos e familiares, por todo carinho e apoio durante essa caminhada.

Ao meu orientador, Prof. Dr. Diego Cardoso, e meu coorientador, Rogério, pela paciência e por acreditarem no potencial deste trabalho. A dedicação e conhecimento de vocês foram fundamentais para o desenvolvimento desta dissertação.

Ao Laboratório de Pesquisa Operacional (LPO), que me acolheu e proporcionou um ambiente de aprendizado e crescimento. Em especial, ao professor Marcos Serrufo, por seu apoio e ensinamentos valiosos.

Aos colegas de mestrado e amigos do LPO, por compartilharem experiências, conhecimento e momentos inesquecíveis que enriqueceram essa trajetória, especialmente aos amigos Albert, Douglas e João Lúcio, pela parceria e amizade ao longo desse percurso.

Aos professores do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da Universidade Federal do Pará (UFPA), por todo o suporte, dedicação e pelo compromisso em proporcionar uma formação de excelência. Suas aulas e orientações foram pilares para a construção deste trabalho.

Ao Instituto Federal de Educação do Maranhão (IFMA) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro que tornaram possível a realização das pesquisas para este trabalho.

A todos vocês, minha gratidão eterna. Essa conquista não é apenas minha, mas de todos que contribuíram direta ou indiretamente para que este sonho se tornasse realidade.

“O coração do prudente adquire conhecimento, e o ouvido dos sábios busca o saber.”

Provérbios 18:15

Resumo

Em desastres naturais, a infraestrutura de comunicação costuma ser comprometida, dificultando ações de resgate e suporte. Nesse cenário, Veículos Aéreos Não Tripulados (UAV), atuando como Estações Base (UAV-BS), surgem como alternativa promissora para restabelecer a conectividade. Embora diversos estudos explorem algoritmos meta-heurísticos para otimizar o posicionamento desses UAVs, muitos utilizam cenários idealizados, ignorando a distribuição aleatória de usuários típica de situações emergenciais. Este trabalho realiza uma análise comparativa entre cinco algoritmos meta-heurísticos: Algoritmo Genético (AG), Enxame de Partículas (PSO), Colônia de Abelhas (ABC), Colônia de Formigas (ACO) e Ensino-Aprendizagem (TLBO), considerando métricas como cobertura de usuários, vazão, tempo de execução e qualidade do sinal. Os testes estatísticos indicaram diferenças significativas entre os métodos. O PSO e o TLBO obtiveram os melhores desempenhos gerais, enquanto o ACO teve o pior resultado em cobertura e tempo. O TLBO se mostrou o mais equilibrado, mas o PSO foi superior em cenários que priorizam economia no número de UAVs. O estudo oferece subsídios para decisões mais eficazes em redes móveis emergenciais.

Palavras-chave: UAV-BS, Meta-heurísticas, Posicionamento, Otimização.

Abstract

In natural disaster scenarios, communication infrastructure is often compromised, hindering rescue and support operations. In this context, Unmanned Aerial Vehicles (UAVs), acting as Base Stations (UAV-BS), emerge as a promising alternative to restore connectivity. Although several studies investigate metaheuristic algorithms for optimizing UAV positioning, many rely on idealized conditions and overlook the random distribution of users typical of emergency situations. This study presents a comparative analysis of five metaheuristic algorithms: Genetic Algorithm (GA), Particle Swarm Optimization (PSO), Artificial Bee Colony (ABC), Ant Colony Optimization (ACO), and Teaching-Learning-Based Optimization (TLBO). The comparison considers key performance metrics such as user coverage, throughput, execution time, and signal quality. Statistical tests revealed significant differences among the algorithms. PSO and TLBO achieved the best overall performance, while ACO delivered the weakest results in terms of coverage and execution time. TLBO proved to be the most balanced approach, whereas PSO stood out in scenarios that prioritize reducing the number of UAVs. The findings provide valuable insights to support more effective decision-making in emergency mobile network deployments.

Key-words: UAV-BS, Meta-heuristics, Positioning, Optimization.

Lista de figuras

Figura 1 – Escopo da tecnologia de comunicação com drones.	3
Figura 2 – Classificação de UAVs baseado na configuração de asas e funções operacionais.	14
Figura 3 – Ambiente de uso dos UAV-BSs.	16
Figura 4 – Classificação dos algoritmos meta-heurísticos.	19
Figura 5 – Área de cobertura de um UAV-BS	36
Figura 6 – Distribuição dos usuários no espaço de busca.	59
Figura 7 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística ABC.	60
Figura 8 – Histograma de Frequência com curva de distribuição normal – Algoritmo ABC.	61
Figura 9 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística ACO.	63
Figura 10 – Histograma de Frequência com curva de distribuição normal – Algoritmo ACO.	64
Figura 11 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística AG.	65
Figura 12 – Histograma de Frequência com curva de distribuição normal – AG.	66
Figura 13 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística PSO.	67
Figura 14 – Histograma de Frequência com curva de distribuição normal - PSO.	68
Figura 15 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística TLBO.	69
Figura 16 – Histograma de Frequência com curva de distribuição normal – TLBO.	70
Figura 17 – Desempenho dos Algoritmos para Usuários Conectados por UAV-BSs.	71
Figura 18 – Desempenho de cada algoritmo em termos de vazão.	73
Figura 19 – Desempenho dos algoritmos em razão do tempo por UAV-BSs.	74

Lista de tabelas

Tabela 1 – Síntese dos trabalhos correlatos para posicionamento de UAV-BSs	9
Tabela 2 – Vantagens, Limitações e Relevância do Algoritmo ABC	22
Tabela 3 – Vantagens, Limitações e Relevância do Algoritmo ACO	25
Tabela 4 – Vantagens, Limitações e Relevância do Algoritmo Genético	27
Tabela 5 – Vantagens, Limitações e Relevância do Algoritmo PSO	30
Tabela 6 – Vantagens, Limitações e Relevância do Algoritmo TLBO	33
Tabela 7 – Parâmetros do cenário de simulação	37
Tabela 8 – Tabela de parâmetros da simulação.	40
Tabela 9 – Parâmetros utilizados nos algoritmos de otimização	54
Tabela 10 – Dados estatísticos de usuários conectados por quantidade de UAV-BS para a meta-heurística ABC.	62
Tabela 11 – Dados estatísticos de usuários conectados por Quantidade de UAV para a meta-heurística ACO.	64
Tabela 12 – Dados estatísticos de usuários conectados por Quantidade de UAV-BS para a meta-heurística AG.	66
Tabela 13 – Dados estatísticos de usuários conectados por Quantidade de UAV-BS para a meta-heurística PSO.	68
Tabela 14 – Dados estatísticos de usuários conectados por Quantidade de UAV-BS para a meta-heurística TLBO.	70
Tabela 15 – Análise descritiva dos resultados por quantidade de UAV-BSs	72

Lista de abreviaturas e siglas

5G	Fifth Generation
6G	Sixth Generation
ABC	Artificial Bee Colony
ACO	Ant Colony Optimization
AG	Algoritmo Genético
ANATEL	Agência Nacional de Telecomunicações
AOA	Angle Optimizer Algorithm
AP	Access Point
A2G	Air-To-Ground
AWGN	Additive White Gaussian Noise
BS	Base Station
B5G	Beyond 5G
CPLEX	IBM ILOG CPLEX Optimization Studio
CPU	Central Processing Unit
DE	Differential Evolution
ENCOM	Conferência Nacional Comunicações, Redes e Segurança da Informação
EO	Equilibrium Optimizer
EU	Equipamento do Usuário
GB	Gigabyte
GHz	Gigahertz
GSMA	Global System for Mobile Communications Association
IoT	Internet of Things
LPA	Load Prediction Algorithm

LoS	Line-of-Sight
MEC	Multi-Access Edge Computing
MIMO	Multiple-Input Multiple-Output
mMTC	massive Machine-Type Communications
MOEA/D	Multi-objective Evolutionary Algorithm based on Decomposition
ms	Milissegundo
NFV	Network Functions Virtualization
NLoS	Non-Line-of-Sight
NSGA-III	Non-dominated Sorting Genetic Algorithm III
PSO	Particle Swarm Optimization
QoS	Quality of Service
RAM	Random Access Memory
SCA	Sine Cosine Algorithm
SDN	Software Defined Networking
SINR	Signal-to-Interference-plus-Noise Ratio
TLBO	Teaching-Learning-Based Optimization
UAM	Urban Air Mobility
UAV	Unmanned Aerial Vehicle
UAV-BS	Unmanned Aerial Vehicle Base Station
UCPA	UAV Clustering and Positioning Algorithm
UFPA	Universidade Federal do Pará
URLLC	Ultra-Reliable Low-Latency Communications

Sumário

1	INTRODUÇÃO	1
1.1	Trabalhos Correlatos	5
1.2	Justificativa	9
1.3	Objetivos	11
1.3.1	Objetivo Geral	11
1.3.2	Objetivos Específicos	11
1.4	Estrutura do documento	11
2	REFERENCIAL TEÓRICO	13
2.1	Classificação, aplicação e planejamento de Veículos Aéreos Não Tripulados (UAVs).	13
2.2	Veículos Aéreos Não Tripulados servindo como Estações Base (UAV-BSs)	16
2.3	Meta-heurísticas	18
2.3.1	Meta-heurística Artificial Bee Colony (ABC)	20
2.3.2	Meta-heurística Ant Colony Optimization (ACO)	23
2.3.3	Meta-heurística Algoritmo Genético (AG)	25
2.3.4	Meta-heurística Particle Swarm Optimization (PSO)	28
2.3.5	Meta-heurística Teaching-Learning-Based Optimization (TLBO)	30
3	ASPECTOS METODOLÓGICOS	34
3.1	Considerações Iniciais	34
3.2	Metodologia	34
3.2.1	Ambiente de Simulação	34
3.2.2	Planejamento de posicionamento dos Veículos Aéreos não Tripulados, servindo com Estação Base (UAV-BSs).	35
3.2.3	Distribuição de Usuários e Configuração iniciais dos Veículos Aéreos não Tripulados, servindo com Estação Base (UAV-BSs).	36
3.2.4	Modelos Matemáticos Utilizados	37
3.2.4.1	Modelo de Propagação	37
3.2.4.2	Relação Sinal-Interferência mais Ruído	38
3.2.4.3	Capacidade do canal	39
3.2.4.4	Parâmetros de simulação	40
3.2.5	Metodologia aplicada aos algoritmos Meta-Heurísticos	41
3.2.5.1	Implementação do algoritmo Artificial Bee Colony (ABC)	42
3.2.5.2	Implementação do algoritmo Ant Colony Optimization (ACO)	44
3.2.5.3	Implementação do Algoritmo Genético (AG)	45
3.2.5.4	Implementação do Particle Swarm Optimization (PSO)	47

3.2.5.5	Implementação do Teaching-Learning-Based Optimization (TLBO)	49
3.2.6	Justificativa para escolha dos Algoritmos	52
3.2.7	Metodologia para escolha dos parâmetros	52
3.2.8	Avaliação Comparativa dos Algoritmos	54
3.2.8.1	Cálculo de superioridade	54
3.2.9	Função Fitness	54
4	RESULTADOS	58
4.1	Considerações Iniciais	58
4.2	Resultados do posicionamento	59
4.2.1	Resultado do posicionamento - Meta-heurística ABC	60
4.2.1.1	Dados Estatísticos - Meta-heurística ABC	61
4.2.2	Resultado do posicionamento - Meta-heurística ACO	62
4.2.2.1	Dados Estatísticos - Meta-heurística ACO	63
4.2.3	Resultado do posicionamento - Meta-heurística AG	64
4.2.3.1	Dados Estatísticos - Meta-heurística AG	65
4.2.4	Resultado do posicionamento - Meta-heurística PSO	66
4.2.4.1	Dados Estatísticos - Meta-heurística PSO	67
4.2.5	Resultado do posicionamento - Meta-heurística TLBO	68
4.2.5.1	Dados Estatísticos - Meta-heurística TLBO	69
4.2.5.2	Considerações Finais	70
4.3	Análise comparativa	71
5	CONCLUSÃO	76
5.1	Considerações finais	76
5.1.1	Contribuições	76
5.2	Trabalhos Futuros	77
	Referências	79

1 INTRODUÇÃO

Nos últimos anos, a demanda por conectividade móvel de alta qualidade tem crescido exponencialmente, impulsionada pelo aumento significativo no número de usuários de dispositivos móveis e pelo consumo intensivo de dados. Estudos indicam que, na América Latina, o uso médio de dados móveis por usuário aumentará de 7 GB mensais em 2023 para 32 GB em 2030 (GSMA, 2024), representando um crescimento de mais de 350% no período.

Esse crescimento é atribuído a diversos fatores, incluindo a proliferação de smartphones, a popularização de aplicações de streaming de vídeo e áudio, e a crescente utilização de redes sociais e serviços baseados em nuvem. No Brasil, segundo dados da ANATEL (2025), o número de acessos móveis atingiu 263,4 milhões em 2024, um aumento de 7 milhões em relação ao ano anterior.

A implementação de novas gerações de tecnologias, chamadas de B5G (*Beyond 5G*) ou 6G (*Sixth Generation*), vai ser de suma importância para atender a essa demanda crescente de conexão aos usuários (ALWIS et al., 2021). Entretanto, a rápida expansão do número de usuários e do consumo de dados impõe desafios significativos à infraestrutura das redes móveis. As operadoras enfrentam a necessidade de investir continuamente na modernização de suas redes, implementando tecnologias em suas BS (*Base Stations*) capazes de evitar congestionamentos e garantir a qualidade do serviço. Além disso, a crescente complexidade das redes exige soluções inovadoras e versáteis, como a virtualização de funções de rede, automação das operações e implementação de algoritmos inteligentes, para manter a eficiência e a escalabilidade necessária.

Compreender a necessidade de tecnologias adicionais ou complementares para provimento de serviços de dados tornou-se essencial para o planejamento estratégico das operadoras de telecomunicações. Sistemas integrados que contemplem congestionamento no consumo da rede e/ou cenários de emergências devem ser empregados para atender a capacidade da rede conforme necessário, especialmente em eventos temporários de grande porte ou em casos emergenciais que possam afetar a infraestrutura terrestre de forma inesperada, como enchentes, queimadas, terremotos e furacões.

A adoção dessas medidas é fundamental para assegurar a resiliência e a qualidade das redes móveis diante do cenário dinâmico e desafiador imposto pelo aumento contínuo no número de usuários, pelo crescimento no consumo de dados e pela necessidade de manutenção dos serviços de telecomunicações. Dessa forma, a conectividade tornou-se um dos pilares essenciais da sociedade moderna, viabilizando atividades críticas em áreas como comunicação, comércio, saúde, segurança, desenvolvimento tecnológico e assistência emergencial.

Para assegurar a conectividade em cenários nos quais a infraestrutura tradicional de

comunicação entra em colapso, como ocorre em casos de desastres naturais, é imprescindível adotar abordagens altamente flexíveis (SÁNCHEZ-GARCÍA; REINA; TORAL, 2019). A implementação de estações base móveis posicionadas estrategicamente permite maximizar a cobertura dos usuários e garantir a qualidade de serviço (QoS), assegurando não apenas a continuidade das operações críticas, mas também o suporte essencial às equipes de emergência, proporcionando a conectividade necessária para ações de resgate e salvamento de vítimas.

Entretanto, em situações críticas, como enchentes, terremotos ou incêndios, nas quais as estações base tradicionais não podem ser ativadas, torna-se necessário planejar alternativas para garantir a disponibilidade dos serviços de comunicação. Uma dessas alternativas são as estações base móveis terrestres, instaladas emergencialmente em veículos para suprir temporariamente a demanda por conectividade. Porém, essa abordagem possui limitações importantes, incluindo restrições à mobilidade devido ao posicionamento terrestre, tempo prolongado de implantação e elevados custos operacionais.

Nesse contexto, uma alternativa promissora é o uso dos Veículos Aéreos Não Tripulados (UAVs - *Unmanned Aerial Vehicles*), popularmente conhecidos como drones, são aeronaves que operam sem a necessidade de um piloto a bordo, podendo ser controladas remotamente ou de forma autônoma (PASANDIDEH et al., 2023). Com o avanço da tecnologia, esses dispositivos se tornaram amplamente utilizados em diversas aplicações militares, industriais e comerciais, com destaque para funções de navegação, comunicação segura e reconhecimento em contextos de defesa, bem como para atividades civis como computação em borda, redes de comunicação, entregas, assistência médica inteligente, vigilância, agricultura de precisão, inspeção de infraestrutura, sensoriamento remoto, busca e salvamento, e operações de socorro em desastres (MOHSAN et al., 2023).

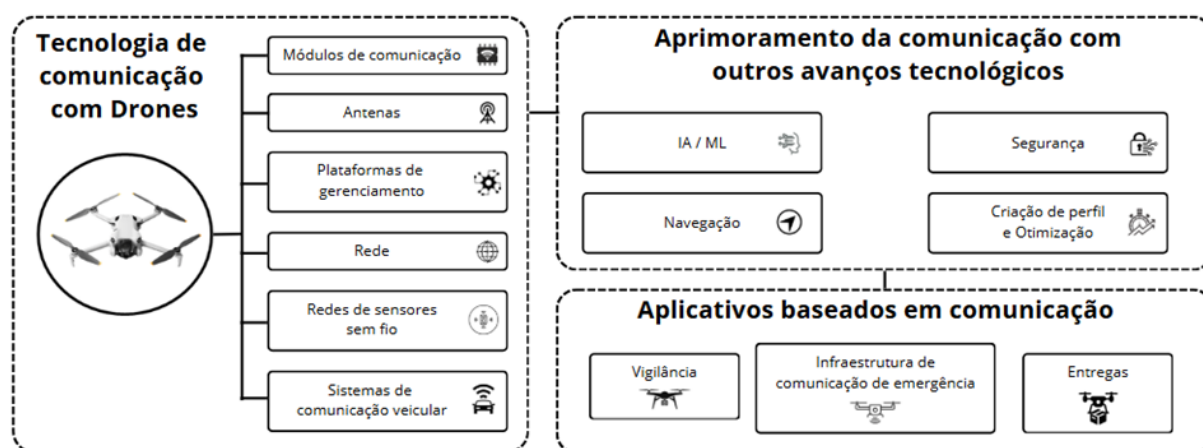
Sua capacidade de acessar áreas remotas ou de difícil alcance, aliada à obtenção de imagens de alta resolução e à atuação em ambientes complexos, dinâmicos ou hostis, os torna instrumentos estratégicos para monitoramento e tomada de decisão. Além disso, essas aeronaves não tripuladas contribuem significativamente para a otimização de recursos operacionais, uma vez que reduzem o esforço humano necessário para tarefas como inspeção, mapeamento e amostragem em campo. Sua autonomia e flexibilidade operacional favorecem a atuação em ambientes dinâmicos, hostis e de acesso limitado, onde sistemas convencionais enfrentam limitações. Sua crescente utilização se deve à capacidade de operar em áreas de difícil acesso, realizar tarefas com alta precisão, reduzir custos operacionais em comparação com métodos tradicionais e responder rapidamente em cenários de urgência (PASANDIDEH et al., 2023).

Da mesma forma, as inovações em algoritmos de controle e otimização têm melhorado a eficácia dos UAVs em uma variedade de cenários, de operações humanitárias até aplicações comerciais (HAQUE; CHOWDHURY; HASSANALIAN, 2023). A crescente intersecção de tecnologia de aprendizado de máquina e drones está em rápida ascensão, possibilitando melhorias nas capacidades de detecção e classificação, além da automação em diversas funções operacionais.

Esta evolução não apenas otimiza a funcionalidade dos UAVs, mas também apresenta desafios significativos, motivando investigações contínuas para identificar riscos e desenvolver soluções (RAHMAN et al., 2024).

No trabalho de (SHARMA et al., 2020) foi proposto um diagrama que sintetiza de forma integrada as tecnologias de comunicação associadas ao uso de drones, relacionando-as aos avanços tecnológicos recentes e às suas aplicações em diversos contextos. A estrutura da figura é composta por três partes principais: à esquerda, encontram-se os atributos fundamentais das tecnologias de comunicação de drones; seguida de uma interligação dessas tecnologias com quatro disciplinas-chave; que se conecta a suas aplicações práticas, como vigilância e atendimento emergencial. Todos os itens de um grupo se interligam com todos os itens do grupo subsequente para formar ou atender a uma demanda específica no contexto do uso dos drones. A análise visual proposta destaca não apenas a complexidade das interações tecnológicas, mas também a amplitude das possibilidades de pesquisa nesse domínio. Dessa forma, a Figura 1 traz o escopo de tecnologias que servem como base para a compreensão das conexões existentes no uso de UAVs em sistemas de comunicação avançados.

Figura 1 – Escopo da tecnologia de comunicação com drones.



Fonte: Adaptada de (SHARMA et al., 2020).

Para uso no contexto das telecomunicações, os UAVs multirrotores possuem um destaque na literatura, e no uso comercial, como plataformas aéreas móveis, sendo equipados com dispositivos de comunicação, funcionando como estações base aéreas móveis (*UAV-BSs – Unmanned Aerial Vehicle Base Stations*). Esses dispositivos podem ser rapidamente posicionados em locais estratégicos, proporcionando cobertura emergencial para restabelecer ou ampliar a conectividade, especialmente em situações críticas como desastres naturais ou grandes eventos temporários. Ao oferecer conectividade sob demanda, os UAV-BSs contribuem significativamente para a comunicação entre equipes de resgate, facilitam o envio rápido de informações essenciais sobre as condições locais e garantem suporte à população afetada, proporcionando uma solução eficaz para cenários onde a infraestrutura terrestre esteja comprometida.

Além disso, esses sistemas podem ser integrados para operar em redes modernas de quinta geração (5G), pois, como essas redes proporcionam maior capacidade de transmissão de dados, os UAV-BSs podem fornecer uma conexão de alta velocidade para os usuários simultaneamente. Quando se fala em integração das redes 5G com UAV-BSs, é devido a uma maior capacidade de transmissão e latência ultrabaixa, alcançando valores menores que 1 milissegundo. Essa característica permite comunicações quase instantâneas entre UAV-BSs e os Equipamentos dos Usuários (EU), sendo um fator determinante para operações críticas em tempo real. Adicionalmente, a tecnologia 5G emprega técnicas avançadas como Multiple-Input Multiple-Output (MIMO) e beamforming, que otimizam o uso do espectro de rádio e melhoram significativamente a eficiência da transmissão de sinais. Isso garante que os UAV-BSs consigam fornecer cobertura estável e de alta qualidade mesmo em ambientes com alta densidade de usuários, reduzindo interferências e maximizando o desempenho da rede.

A integração dos UAV-BSs com redes 5G promove o uso da massive Machine-Type Communications (mMTC) e Ultra-Reliable Low-Latency Communications (URLLC), que possibilita, além de aplicações voltadas para cidades inteligentes, o uso em redes de sensores IoT e operações de segurança pública, onde a comunicação confiável entre dispositivos é essencial para garantir a eficácia das operações.

A implementação da virtualização de funções de rede (NFV) e das redes definidas por software (SDN) nas infraestruturas de rede 5G representa um avanço significativo na forma como as redes são concebidas e geridas. A utilização dessas tecnologias permite a criação de redes altamente configuráveis, escaláveis e flexíveis, que não dependem de uma infraestrutura física complexa, facilitando a implementação e gestão dos UAV-BSs. Por meio do SDN, a lógica de controle é centralizada em um controlador, que possibilita uma visão abrangente da topologia da rede e otimiza a distribuição e configuração dos UAV-BSs em cenários dinâmicos ([HENTATI et al., 2023](#)), permitindo ajustes remotos de forma eficiente.

Além disso, a segmentação de rede (network slicing), possibilitada pelo 5G, permite que diferentes tipos de serviços coexistam de maneira isolada e segura, realizando a separação lógica dos serviços para melhorar a eficiência na alocação de recursos, permitindo que os UAV-BSs adaptem dinamicamente sua capacidade conforme a demanda. A utilização de UAV-BSs representa uma solução inovadora e viável para prover conectividade em situações de emergência e até mesmo em regiões carentes de infraestrutura, como é o caso de comunidades ribeirinhas da região amazônica, contribuindo para a continuidade das comunicações mesmo em situações críticas.

Entretanto, o posicionamento dos UAV-BSs apresenta desafios de complexidade considerável, destacando-se a necessidade de maximização da cobertura da área atendida, com melhoria no QoS (Quality of Service), bem como a redução da interferência e a adaptação a mudanças na distribuição geográfica dos usuários e se caracteriza como um campo aberto no campo acadêmico e industrial ([MOHSAN et al., 2023](#)). Além disso, a complexidade computacional das

técnicas empregadas pode impactar no tempo de resposta e, assim, inviabilizar a otimização em tempo real, especialmente em cenários altamente urgentes, como na comunicação das equipes de resposta a desastres e à população que está em estado de emergência.

Dessa forma, o desenvolvimento de métodos eficazes para o posicionamento inteligente de UAV-BSs continua sendo um campo ativo de pesquisa, visando não apenas melhorar o desempenho das redes móveis, mas também garantir resiliência e escalabilidade em diferentes cenários operacionais (RUKAIYA et al., 2024).

Para isso, diversas técnicas e métodos inteligentes de posicionamento de UAV-BSs vêm sendo estudados para maximizar a cobertura da rede e otimizar a qualidade do serviço (QoS) oferecida aos usuários. Entre essas abordagens, destacam-se os métodos baseados em aprendizado de máquina, incluindo redes neurais, e as meta-heurísticas de otimização, que são abordagens simplificadas, em relação às outras apresentadas, por obterem soluções aceitáveis em períodos considerados razoáveis.

Estudos recentes demonstram que diversas meta-heurísticas têm sido aplicadas ao posicionamento de UAV-BSs, um exemplo é a meta-heurística Particle Swarm Optimization (PSO) proposta por (KENNEDY; EBERHART, 1995), Teaching-Learning-Based Optimization (TLBO) idealizada por (RAO; SAVSANI; VAKHARIA, 2011), Algoritmo Genético (AG) sugerido por (HOLLAND, 1975), dentre outros. Essas técnicas contribuem com estratégias de busca do posicionamento ótimo ou subótimo dos UAV-BSs, considerando fatores restritivos como: espaço de busca, a densidade de usuários, a variação da demanda por conectividade e as condições do ambiente operacional.

Em resumo, o posicionamento adequado dos UAV-BSs no provimento de serviços de redes móveis representa um desafio de alta complexidade, e a utilização de algoritmos meta-heurísticos de otimização desempenha um papel fundamental na superação desses problemas. No entanto, diante da ampla variedade de meta-heurísticas disponíveis na literatura, a escolha do modelo mais adequado para um determinado tipo de cenário torna-se essencial no âmbito da pesquisa sobre a utilização de dispositivos UAV-BSs. Essa decisão deve considerar fatores como a natureza do problema, a dinamicidade e características do ambiente, o tamanho e a complexidade do espaço de busca, além da eficiência computacional e do tempo de convergência da solução.

1.1 Trabalhos Correlatos

No trabalho de (PALADIN et al., 2023) os autores exploraram o uso dos UAV-BSs integrados a redes 5G para resposta a emergências. O estudo apresenta uma análise do uso de UAVs integrados à rede 5G para melhorar a resposta a emergências, destacando a transmissão contínua de dados e a coordenação eficiente entre os UAVs e os centros de resgate. Os autores demonstraram que a combinação de UAV-BSs com 5G melhora significativamente a cobertura e

a latência em cenários onde a infraestrutura tradicional foi danificada. Além disso, destacaram o potencial de integração de UAV-BSs em operações de resgate, permitindo maior resiliência em redes críticas.

Em (GHAMBARI et al., 2018), foi realizado um estudo comparativo do desempenho de algoritmos meta-heurísticos para UAVs. O problema foi modelado como uma otimização de objetivo único em um espaço bidimensional estático. Diversos métodos foram analisados para planejamento de trajetória de UAVs, incluindo abordagens baseadas em grafos, métodos baseados em grade, programação matemática, otimização por controle e algoritmos inspirados na natureza. Os meta-heurísticos foram destacados por sua capacidade de busca global eficiente. O algoritmo TLBO demonstrou melhor desempenho na maioria dos casos testados, enquanto também teve o melhor desempenho no tempo de convergência, tornando-o mais adequado para aplicações em tempo real.

No estudo de (RAHMAN et al., 2024), é apresentada uma abordagem de programação estocástica para otimizar o posicionamento 3D de UAVs e a alocação de recursos em redes celulares, considerando a incerteza nas condições de propagação para melhorar o atendimento aos usuários com o menor número de UAVs. O estudo utiliza a programação estocástica para incorporar a incerteza nas condições de propagação, afetando a taxa de dados recebida e a perda de percurso. A formulação matemática proposta busca minimizar o número de UAVs necessários, determinando suas posições 3D e a melhor associação de usuários. Foram utilizadas funções não lineares aproximadas linearmente para resolver o modelo de forma precisa usando o solver CPLEX.

Em (GUPTA; VARMA, 2021) foi proposto dois algoritmos híbridos de otimização meta-heurística, sendo um baseado no AG, para o posicionamento tridimensional de UAVs em redes mesh aéreas, considerando múltiplos objetivos relevantes em situações de emergências. A pesquisa também destaca a importância da afinação de parâmetros para melhorar o desempenho dos algoritmos e utiliza testes estatísticos para validar a superioridade das abordagens híbridas em relação aos algoritmos tradicionais. A afinação dos parâmetros desses algoritmos foi realizada utilizando o método de Taguchi. Os algoritmos foram testados em diferentes cenários de escala, e os resultados foram analisados por meio de testes estatísticos. No entanto, foi identificado que os algoritmos híbridos demandam maior tempo computacional em comparação com os originais.

Estudos como (SIVALINGAM et al., 2020) propuseram o uso de um algoritmo para posicionar múltiplos UAV-BSs em redes mmWave, garantindo que todos os usuários sejam atendidos dentro das restrições de Relação Sinal-Interferência mais Ruído (*SINR - Signal-to-Interference-plus-Noise-Ratio*) e operacionais. Para o problema original combinatório e NP-difícil foi feita a aproximação, mesmo não garantindo a solução ótima global. Para isso, foi formulado o problema como uma minimização de norma, aproximada por uma minimização de norma não combinatória, resultando em um algoritmo subótimo para determinar posições viáveis para UAV-BSs. O desenvolvimento do algoritmo que posiciona múltiplas UAV-BSs

simultaneamente, considerando restrições práticas de SINR, assegura cobertura completa dos usuários, respeitando as restrições impostas.

A integração do aprendizado de máquina com algoritmos de otimização tem expandido significativamente as capacidades dos UAV-BSs. Nos estudos de (ALFAIA et al., 2022), os autores exploraram o uso de UAV-BSs como solução para o gerenciamento de redes móveis sobrecarregadas devido ao crescimento exponencial da demanda por dados. A proposta apresenta um sistema inteligente baseado em aprendizado de máquina, utilizando o Load Prediction Algorithm (LPA) para prever estações bases sobrecarregadas e o Clustering and Positioning Algorithm (UCPA) para definir a alocação e o posicionamento de UAV-BSs. Resultados demonstram que a abordagem proposta reduziu significativamente a sobrecarga e melhorou a qualidade de serviço.

Em (FERNANDEZ; CARVALHO; SILVA, 2020) os autores enfrentam o problema de posicionar UAVs para estabelecer uma infraestrutura de comunicação aérea eficiente, tratando-o como um problema de otimização p-hub median. Eles propõem um algoritmo híbrido meta-heurístico que combina técnicas para maximizar a cobertura da rede e a capacidade de link entre UAVs e estações terrestres. Os resultados demonstram que o algoritmo proposto supera ferramentas de otimização tradicionais em termos de qualidade de solução e tempo de execução. No entanto, o estudo não aborda cenários de emergência, não considera SINR como qualidade para QoS e nem realiza comparações diretas com meta-heurísticas de variados comportamentos para posicionamento de UAV-BS.

Os autores em (OZDAG; YANIKÖMEROĞLU, 2019) propuseram uma abordagem para o posicionamento tridimensional de múltiplas estações base aéreas (UAV-BSs), com o objetivo de maximizar a cobertura de usuários em redes sem fio. O trabalho introduz o algoritmo MDDA-EML (*Maximum Drone Deployment Algorithm baseado em ElectroMagnetism-Like*), uma meta-heurística adaptada para operar em cenários de posicionamento 3D, considerando as particularidades do modelo de propagação ar-terra (*A2G Air-To-Ground*). A solução mostrou-se eficaz ao comparar-se com métodos tradicionais como o Pure-EML em termos de cobertura global, fornecendo uma alternativa promissora para aplicações emergenciais e ambientes com infraestrutura de comunicação comprometida. No entanto, algumas lacunas permanecem: o estudo considera os usuários estáticos, não aborda a qualidade do serviço (QoS) aos usuários e nem a mobilidade dinâmica dos usuários ou das próprias estações base, além de não avaliar a interferência em operação simultânea. Além disso, a comparação com outras meta-heurísticas consolidadas é limitada, o que restringe a generalização dos resultados. Esses aspectos abrem espaço para investigações futuras que explorem o posicionamento adaptativo e cooperativo em cenários mais amplos.

Um estudo comparativo de doze algoritmos meta-heurísticos de última geração aplicados ao design conceitual de UAVs de asa fixa, enfrentando problemas de otimização com múltiplos objetivos é realizado por (ANOSRI S., 2023). O estudo avalia a eficácia de cada algoritmo em termos de desempenho estrutural e eficiência computacional. A metodologia

empregada envolve a aplicação desses algoritmos em quatro configurações distintas de VANTs: convencional, convencional com winglet, twin boom e canard. Os algoritmos avaliados incluem variantes do Differential Evolution (DE), NSGA-III, MOEA/D, entre outros. Embora forneça uma análise abrangente das capacidades dos algoritmos, o foco está no design de UAVs, não no posicionamento de UAV-BSs para cobertura de rede.

Os trabalhos analisados neste capítulo propõem abordagens distintas para enfrentar o desafio do posicionamento ideal de UAVs, considerando critérios como a maximização da cobertura com o objetivo de aprimorar a comunicação com os usuários e a eficiência da rede. A revisão realizada permitiu evidenciar o papel estratégico dos UAVs como elementos complementares à infraestrutura de redes móveis convencionais. Conforme demonstrado, a integração de UAV-BSs às redes terrestres apresenta elevado potencial de impacto positivo tanto na atual quanto nas futuras gerações de redes móveis.

A escolha dos critérios analisados nesta dissertação, como cenários emergenciais, ambientes dinâmicos, eficiência computacional, SINR (*Signal-to-Interference plus Noise Ratio*) e modelo A2G (*Air-to-Ground*), fundamenta-se na complexidade e na natureza crítica dos desafios impostos à utilização de UAV-BSs em contextos de provisão emergencial de conectividade. Diferentemente de aplicações convencionais, que operam com infraestrutura previamente instalada, planejamento estático e menor exigência de resposta imediata, os cenários emergenciais demandam resiliência, mobilidade e capacidade de atuação sob imprevisibilidade extrema.

A presença de ambientes dinâmicos representa o posicionamento variado dos usuários, podendo ser alterado de forma abrupta, exigindo que os algoritmos implementem estratégias adaptativas para a solução do problema. Para que essa adaptação seja viável operacionalmente, torna-se importante a eficiência computacional das técnicas aplicadas: algoritmos lentos ou com alta complexidade de execução são inviáveis, especialmente quando decisões precisam ser tomadas em questão de minutos. Ainda, a consideração do SINR como métrica de desempenho é essencial, pois reflete diretamente a qualidade do enlace de comunicação, que pode ser severamente degradada em ambientes ruidosos e congestionados, típicos de situações de emergência. Por fim, a incorporação do modelo A2G permite representar de forma mais aproximada a propagação do sinal entre os UAVs e os usuários em solo, considerando obstruções, altura de operação e condições de visada.

Dessa forma, a Tabela 1 apresenta uma síntese comparativa dos principais trabalhos correlatos relacionados ao problema de posicionamento de UAV-BSs em distintos contextos de aplicação. Observa-se que a presente dissertação se destaca por alinhar sua modelagem aos requisitos operacionais mais exigentes, voltados à atuação em situações críticas que demandam rápida implementação, capacidade de adaptação a ambientes dinâmicos e consideração da inclinação angular entre UAVs e usuários no modelo de propagação, refletindo um compromisso com a fidelidade ao contexto real de emergência e com a aplicabilidade prática das soluções propostas.

Tabela 1 – Síntese dos trabalhos correlatos para posicionamento de UAV-BSs

Referência	Cenários Emergenciais	Uso de Meta-heurísticas	Comparação de Meta-heurísticas	Ambientes Dinâmicos	Eficiência Computacional	SINR	Modelo A2G
(GHAMBARI et al., 2018)	Não	Sim	Sim	Não	Sim	Não	Não
(OZDAG; YANIKO-MEROGLU, 2019)	Não	Sim	Não	Não	Sim	Não	Sim
(SIVALINGAM et al., 2020)	Sim	Não	Não	Não	Não	Sim	Sim
(FERNANDEZ et al., 2020)	Não	Sim	Não	Não	Sim	Não	Sim
(GUPTA; VARMA, 2021)	Sim	Sim	Sim	Não	Sim	Não	Sim
(ALFAIA et al., 2022)	Não	Não	Não	Sim	Não	Sim	Sim
(PALADIN et al., 2023)	Sim	Não	Não	Sim	Não	Sim	Sim
(ANOSRI et al., 2023)	Não	Sim	Sim	Não	Sim	Não	Não
(RAHIMI et al., 2024)	Não	Não	Não	Sim	Sim	Sim	Sim
Esta dissertação	Sim	Sim	Sim	Sim	Sim	Sim	Sim

Fonte: Elaborada pelo autor com base nos trabalhos analisados.

Embora se observe um notório avanço nas pesquisas sobre o posicionamento de UAV-BSs, ainda são escassas as análises comparativas envolvendo múltiplas meta-heurísticas aplicadas a esse problema. Identificam-se lacunas metodológicas e de escopo nos estudos existentes, tais como a ausência de comparações diretas entre diferentes algoritmos, a limitação a cenários específicos ou a carência de testes abrangentes que considerem métricas de rede como SINR, vazão e número de usuários conectados. Diante disso, torna-se essencial a análise comparativa de resultados baseados em métricas de desempenho no posicionamento dos UAV-BSs para apoiar o desenvolvimento de soluções que maximizem os benefícios dessa tecnologia, sobretudo no que se refere à determinação de posicionamento ideal.

1.2 Justificativa

A crescente demanda por conectividade móvel em cenários emergenciais, como desastres naturais, falhas em infraestruturas de comunicação ou eventos de grande porte, tem impulsionado a busca por soluções eficientes e adaptáveis para garantir o fornecimento de serviços de rede. Neste contexto, os UAV-BSs surgem como uma alternativa viável para restabelecer a conectividade de forma rápida e eficaz, especialmente em áreas onde a infraestrutura terrestre foi comprometida.

No entanto, a eficiência da cobertura e da qualidade do serviço oferecido pelos UAV-BSs está diretamente relacionada ao seu posicionamento no espaço, o que representa um desafio complexo devido à variabilidade da distribuição dos usuários e às limitações operacionais dos drones. A otimização desse posicionamento pode ser abordada por meio de técnicas de inteligência computacional, como os algoritmos meta-heurísticos, que demonstram alto potencial para lidar com problemas de otimização combinatória de forma eficiente.

O uso de meta-heurísticas tem se destacado como uma alternativa de busca de alto nível que combinam exploração e intensificação para otimizar funções complexas, sendo amplamente aplicadas em problemas de engenharia e telecomunicações. Métodos como Algoritmos Genéticos (AG), Otimização por Enxame de Partículas (PSO), Otimização baseada em Colônias de Formigas (ACO), Teaching-Learning-Based Optimization (TLBO) e Artificial Bee Colony (ABC) demonstram alto potencial na otimização do posicionamento de UAV-BSs, pois lidam eficientemente com múltiplos objetivos e restrições do ambiente, além de não fazerem parte de um nicho específico de otimização.

A seleção destes algoritmos se justifica por sua aplicabilidade comprovada, diversidade metodológica, eficiência computacional e alinhamento com pesquisas anteriores, garantindo um estudo relevante e comparável com o estado da arte. Alguns outros não foram incluídos por não demonstrarem um desempenho competitivo em aplicações de UAV-BSs na literatura recente ou exigirem ajustes complexos de parâmetros, dificultando sua implementação eficiente em cenários emergenciais. Sobretudo, a inclusão de um número excessivo de algoritmos poderia tornar a análise excessivamente extensa sem agregar valor proporcional ao estudo.

Apesar dos avanços na literatura sobre o uso de algoritmos meta-heurísticos na otimização de UAV-BSs, muitos estudos consideram cenários idealizados ou determinísticos, sem levar em conta a distribuição aleatória normal (gaussiana) dos usuários, que reflete melhor a dinâmica real das situações emergenciais. Além disso, não há um consenso sobre quais algoritmos meta-heurísticos são mais adequados para diferentes cenários, o que reforça a necessidade de uma análise comparativa detalhada.

Dessa forma, esta dissertação se justifica pela necessidade de investigar e comparar o desempenho de diferentes algoritmos meta-heurísticos no posicionamento de UAV-BSs em cenários emergenciais, utilizando métricas como a quantidade de usuários conectados, SINR, vazão e tempo de execução. Os resultados obtidos contribuirão não apenas para o avanço do conhecimento científico na área de otimização aplicada a redes móveis aéreas, mas também fornecerão subsídios práticos para o desenvolvimento de sistemas mais eficientes de gerenciamento de UAV-BSs, beneficiando tanto aplicações civis quanto operações de resposta a emergências.

1.3 Objetivos

1.3.1 Objetivo Geral

O principal objetivo desta dissertação é implementar, avaliar e comparar sistemas inteligentes para o posicionamento de UAV-BSs, considerando a distribuição aleatória normal dos usuários, a fim de analisar o desempenho de diferentes algoritmos meta-heurísticos. A pesquisa busca fornecer informações relevantes para o gerenciamento e a aplicação desses modelos, utilizando como métricas a quantidade de usuários conectados, o SINR, a vazão e o tempo de execução. O estudo foca em cenários emergenciais, nos quais o provimento de serviços de rede móvel aérea é essencial.

1.3.2 Objetivos Específicos

Para atingir o objetivo geral, os seguintes objetivos específicos são estabelecidos:

- Desenvolver um modelo computacional robusto para o problema de posicionamento de UAV-BSs, capaz de simular cenários emergenciais com distribuição aleatória de usuários e incorporar métricas de desempenho de rede essenciais.
- Otimizar as posições tridimensionais de UAV-BSs em cenários emergenciais, aplicando e adaptando cinco algoritmos meta-heurísticos distintos: Algoritmo Genético (AG), Particle Swarm Optimization (PSO), Artificial Bee Colony (ABC), Ant Colony Optimization (ACO) e Teaching-Learning-Based Optimization (TLBO).
- Quantificar e analisar o desempenho de cada uma das meta-heurísticas (ABC, ACO, AG, PSO, TLBO) no problema de posicionamento de UAV-BSs.
- Comparar e discernir as vantagens e limitações intrínsecas de cada algoritmo meta-heurístico avaliado (ABC, ACO, AG, PSO, TLBO) para a aplicação no posicionamento de UAV-BSs em redes móveis aéreas emergenciais.
- Prover subsídios técnicos e recomendações fundamentadas na análise comparativa dos algoritmos meta-heurísticos, auxiliando no gerenciamento e na aplicação eficaz de UAV-BSs para o restabelecimento e provimento de serviços de comunicação em situações de desastre ou falha de infraestrutura terrestre.

1.4 Estrutura do documento

Esta dissertação está estruturada de forma a proporcionar uma compreensão abrangente e sistemática sobre o tema do posicionamento de UAV-BSs utilizando algoritmos meta-heurísticos. Cada capítulo foi cuidadosamente desenvolvido para abordar diferentes aspectos da pesquisa,

desde a contextualização e fundamentação teórica até os resultados obtidos e suas implicações práticas. A seguir, apresenta-se uma visão detalhada da organização do trabalho:

- **Capítulo 2 - Referencial Teórico:** Neste capítulo, são aprofundados os fundamentos teóricos e práticos dos algoritmos meta-heurísticos e sua aplicação em problemas de otimização, especialmente no posicionamento de UAV-BSs. São exploradas as características principais de funcionamento dos algoritmos ABC, ACO, AG, PSO e TLBO, enfatizando suas vantagens, limitações e relevância conforme descrito na literatura;
- **Capítulo 3 - Metodologia:** Este capítulo detalha as etapas da pesquisa, começando pela descrição do ambiente de simulação. Ele também aborda como cada algoritmo meta-heurístico foi implementado para o caso específico e descreve seus parâmetros. Além disso, o capítulo apresenta as métricas de avaliação empregadas e explica como os dados foram analisados para garantir a validade e a confiabilidade dos resultados;
- **Capítulo 4 - Resultados:** Este capítulo apresenta os resultados obtidos a partir das simulações realizadas. Os dados são organizados e discutidos com base nas métricas de desempenho, como eficiência de cobertura, qualidade de serviço e tempo médio de execução dos algoritmos analisados. Gráficos, tabelas e análises estatísticas são utilizados para ilustrar e fundamentar as conclusões, permitindo uma compreensão das vantagens relativas dos algoritmos estudados e seu adequado uso para diferentes cenários;
- **Capítulo 5 - Conclusão:** O capítulo final sintetiza as principais descobertas da pesquisa, destacando as contribuições teóricas e práticas do trabalho. Ele reforça a relevância e limitações dos algoritmos analisados para o problema de posicionamento de UAV-BSs, considerando seus resultados. Além disso, são discutidas as limitações do estudo e propostas direções para trabalhos futuros.

Cada capítulo visa proporcionar ao leitor uma compreensão clara e detalhada do tema, oferecendo uma visão ampla sobre o estado da arte, os métodos empregados e os avanços obtidos nesta pesquisa. Dessa forma, espera-se contribuir para a literatura acadêmica e para o desenvolvimento de soluções práticas para problemas de otimização do posicionamento de UAV-BSs.

2 REFERENCIAL TEÓRICO

Este capítulo tem como propósito principal construir o arcabouço teórico e literário que fundamenta o presente estudo, conectando as principais questões relacionadas ao tema com as contribuições propostas. A seção Classificação, aplicação e planejamento de Veículos Aéreos Não Tripulados (UAVs) introduz os conceitos gerais dos UAVs, suas classificações e diversas aplicações, estabelecendo a base para o uso desses dispositivos no contexto de comunicação. Progressivamente, a seção Veículos Aéreos Não Tripulados servindo como Estações Base (UAV-BSs) aprofunda-se na funcionalidade específica dos UAVs como estações base, destacando seus benefícios e desafios no restabelecimento da conectividade em cenários emergenciais. Por fim, a seção Meta-heurísticas apresenta os fundamentos dessas técnicas de otimização, suas classificações e características gerais, e detalha individualmente os cinco algoritmos meta-heurísticos analisados (ABC, ACO, AG, PSO e TLBO), que são centrais para a solução do problema de posicionamento de UAV-BSs. O encadeamento desses tópicos visa proporcionar uma compreensão abrangente dos conceitos essenciais que guiam o desenvolvimento e a análise dos resultados desta dissertação.

2.1 Classificação, aplicação e planejamento de Veículos Aéreos Não Tripulados (UAVs).

A classificação dos UAVs está intrinsecamente ligada ao seu design estrutural, ao sistema de propulsão e ao perfil da missão que serão empregados. Duas das principais categorias de UAVs são os de asa fixa e os de asa rotativa (PENKOV; ALEKSANDROV, 2017). Os UAVs de asa fixa são conhecidos por sua capacidade de voar longas distâncias e por sua eficiência em termos de consumo de energia em comparação com outras categorias de UAVs (NORAZMAN et al., 2024). Essa categoria de asa fixa é particularmente vantajosa para aplicações que exigem cobertura de grandes áreas, como monitoramento ambiental e mapeamento geográfico (MOHSAN et al., 2023). Por outro lado, os UAVs de asa rotativa, que incluem tricópteros, quadricópteros, hexacópteros e octocópteros, são altamente valorizados por sua manobrabilidade e capacidade de pairar, facilitando tarefas que requerem precisão, como inspeções e filmagens aéreas (ATA; GENCAL, 2024). Essas características tornam os multirrotores ideais para inspeção de infraestrutura, entregas urbanas, segurança e aplicações em telecomunicações, onde a necessidade de “hover” (voo estacionário) e precisão são fundamentais, inclusive em cenários que demandam rápida adaptação, como operações de busca e resgate (KHAN; GUPTA; GUPTA, 2022). A Figura 2 demonstra alguns modelos de UAVs classificados por suas configurações de asas e funções operacionais.

Figura 2 – Classificação de UAVs baseado na configuração de asas e funções operacionais.



Fonte: Adaptada de (ZHOU, 2025).

Além da categorização básica com base em design, os UAVs também podem ser classificados de acordo com seu porte e finalidade, cada um atendendo a diferentes necessidades operacionais. Por exemplo, UAVs de menor porte são frequentemente utilizados em aplicações militares para reconhecimento ou em ambientes urbanos para monitoramento de multidões, enquanto UAVs de maior porte são mais utilizados para tarefas logísticas, como entrega de suprimentos em áreas de difícil acesso (RABIU; AHMAD; GOHARI, 2024).

Os UAVs de asa fixa são mais eficientes em termos de consumo energético e autonomia, sendo indicados para missões que envolvem grandes distâncias, como mapeamentos e levantamentos topográficos. Já os UAVs híbridos, que combinam asas fixas com decolagem e pouso vertical, vêm ganhando espaço por aliar a autonomia dos modelos de asa fixa com a versatilidade dos multirrotores, tornando-se soluções possíveis para operações em cidades inteligentes.

No cenário contemporâneo das chamadas smart cities, os Veículos Aéreos Não Tripulados (UAVs) têm ocupado uma posição de destaque, desempenhando funções estratégicas que transcendem o apoio à conectividade digital. Sua presença se estende por diversas esferas da dinâmica urbana, com impactos relevantes sobre a gestão territorial, a mobilidade, a segurança pública e os objetivos de sustentabilidade. A versatilidade desses dispositivos tem impulsionado sua adoção em iniciativas que buscam tornar as cidades mais inteligentes, eficientes e responsivas às necessidades da população.

Entre os campos em que os UAVs têm demonstrado elevado potencial de contribuição, destaca-se o geoprocessamento e o sensoriamento remoto. Por meio da captura de imagens aéreas de alta resolução, os drones possibilitam a geração de ortofotos, modelos digitais de

elevação e registros atualizados de áreas urbanas, subsidiando atividades como o planejamento urbano, o monitoramento ambiental e o acompanhamento de obras de infraestrutura (COLOMINA; MOLINA, 2014). Trata-se de uma ferramenta que amplia a capacidade de diagnóstico e intervenção dos gestores públicos, ao oferecer dados precisos em tempo real.

Outra frente promissora diz respeito à logística urbana e aos sistemas de entrega rápida, em especial no transporte de pequenas cargas em ambientes metropolitanos congestionados. A utilização de drones nesse contexto tem permitido encurtar prazos de entrega e reduzir os impactos ambientais associados ao transporte convencional. Empresas do setor tecnológico e varejista têm investido em soluções autônomas que utilizam UAVs para o despacho de mercadorias, em iniciativas que visam não apenas a eficiência operacional, mas também a mitigação de emissões de gases poluentes (GOODCHILD; TOY, 2018).

Na área da segurança pública e do monitoramento urbano, os UAVs têm sido empregados de maneira crescente em atividades de vigilância e fiscalização. Sua utilização em operações policiais, no acompanhamento de grandes eventos e na supervisão de áreas de risco tem se mostrado uma estratégia eficaz para ampliar a cobertura e a velocidade de resposta das forças de segurança, contribuindo para a prevenção de incidentes e a melhoria da qualidade dos serviços prestados à população (FERNANDEZ; CARVALHO; SILVA, 2020).

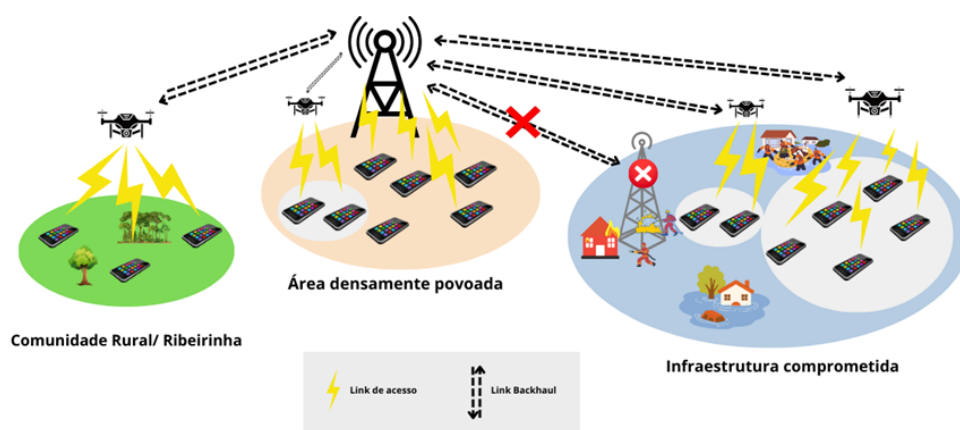
Um campo emergente, ainda em fase de pesquisa e testes, é o da mobilidade aérea urbana (Urban Air Mobility – UAM). Este conceito propõe a integração de veículos aéreos de maior porte e autonomia no sistema de transporte de pessoas e cargas em áreas metropolitanas. Embora os projetos estejam em estágio inicial, trata-se de uma proposta com potencial disruptivo, capaz de alterar significativamente a lógica tradicional do deslocamento urbano, conforme apontado por organismos reguladores internacionais (TRUXAL; SCOTT, 2024).

Por fim, apoio à gestão de emergências e defesa civil quando os UAVs desempenham papel fundamental em situações críticas, como desastres naturais, incêndios florestais, deslizamentos ou acidentes industriais. Nessas situações, eles são utilizados para o reconhecimento aéreo de áreas afetadas, identificação de rotas seguras para equipes de resgate, monitoramento da evolução de cenários de risco e, de forma particularmente estratégica, para o provimento emergencial de serviços de comunicação quando a infraestrutura terrestre se encontra comprometida. Em regiões atingidas por terremotos, enchentes ou colapsos de rede, UAVs equipados como estações base móveis (UAV-BSs) garantem conectividade temporária, facilitando a coordenação das ações de resposta (PALADIN et al., 2023).

2.2 Veículos Aéreos Não Tripulados servindo como Estações Base (UAV-BSs)

A utilização de Veículos Aéreos Não Tripulados (UAVs) como Estações Base (UAV-BSs) tem emergido como uma solução promissora para a expansão da conectividade em cenários diversos, incluindo desastres naturais, áreas rurais e zonas urbanas densas. UAV-BSs são dispositivos aéreos equipados com tecnologias de comunicação que atuam como pontos de acesso temporários, provendo serviços de conectividade de forma rápida e eficiente, conforme apresentado na Figura 3. Com os avanços recentes em tecnologias de redes sem fio e sistemas UAVs, as UAV-BSs tornaram-se um tópico central na pesquisa e desenvolvimento de redes de comunicação modernas.

Figura 3 – Ambiente de uso dos UAV-BSs.



Fonte: Elaborada pelo autor.

Um dos principais benefícios das UAV-BSs é sua flexibilidade e mobilidade. Esses dispositivos podem ser rapidamente posicionados para otimizar a cobertura de usuários e a capacidade da rede em áreas críticas, onde a infraestrutura terrestre pode ser insuficiente ou inexistente. Além disso, sua mobilidade permite a reconfiguração dinâmica da rede para atender a mudanças no padrão de demanda dos usuários ou para responder a situações de emergência. Isso é especialmente relevante em cenários pós-desastres, onde as redes de comunicação convencionais frequentemente sofrem colapsos, e o uso de UAV-BSs pode ser crucial para restabelecer serviços de comunicação.

A integração das UAV-BSs em redes heterogêneas, como redes 5G e futuras arquiteturas 6G, tem ganhado grande relevância, pois possuem a capacidade de operar em diferentes altitudes e ajustar sua posição em tempo real, o que os tornam adequados para lidar com os desafios de propagação e interferência inerentes às comunicações sem fio. As UAV-BSs podem melhorar significativamente métricas como a taxa de dados, a relação sinal-interferência mais ruído (*SINR* - *Signal-to-Interference-plus-Noise-Ratio*) e a eficiência espectral, especialmente em ambientes onde a linha de visada (*LoS* - *Line-of-Sight*) é difícil de alcançar com estações base terrestres.

Outro aspecto importante do uso de UAV-BSs é sua eficiência energética, que tem sido continuamente aprimorada com o desenvolvimento de tecnologias avançadas de baterias e métodos inovadores de reabastecimento em voo. Essas inovações permitem estender a duração das operações e expandir as aplicações das UAV-BSs em diversos cenários. Além disso, estratégias de otimização, como controle adaptativo de potência e posicionamento dinâmico, aumentam ainda mais a eficiência operacional, maximizando o potencial desses dispositivos em redes de comunicação modernas.

No contexto de cenários urbanos, as UAV-BSs apresentam uma grande versatilidade ao lidar com ambientes densamente povoados, aproveitando sua mobilidade para oferecer cobertura em áreas de difícil acesso. Modelos de propagação específicos para ambientes urbanos estão sendo desenvolvidos para aproveitar ao máximo as características únicas das UAV-BSs, garantindo um planejamento de rede mais preciso e eficiente. O uso de algoritmos avançados, incluindo meta-heurísticas, permite otimizar o posicionamento e a cobertura dessas unidades em tempo real, assegurando uma conectividade robusta e confiável.

As UAV-BSs também oferecem recursos avançados de segurança e privacidade, com tecnologias de criptografia robusta e autenticação segura que protegem as comunicações. Protocolos de comunicação resilientes e mecanismos de proteção integrados tornam as UAV-BSs uma solução confiável para cenários críticos, reforçando sua capacidade de operar em redes sensíveis com alto grau de confiança. A mobilidade e a capacidade de operar em altitudes variadas proporcionam vantagens adicionais em ambientes com requisitos elevados de segurança.

Essas qualidades tornam as UAV-BSs uma solução altamente adaptável e promissora, destacando sua eficiência energética, versatilidade em cenários urbanos e recursos de segurança avançados. Combinando mobilidade, inovação tecnológica e estratégias inteligentes de otimização, as UAV-BSs oferecem uma abordagem de ponta para a expansão da conectividade e suporte a redes resilientes e adaptativas.

Estudos recentes têm explorado o uso de UAV-BSs em aplicações emergentes, como o suporte a dispositivos da Internet das Coisas (IoT) e a conectividade em eventos de grande escala. Nesses contextos, a densidade de dispositivos conectados pode sobrecarregar as redes terrestres e o suporte aéreo fornecido pelas UAV-BSs pode ajudar a aliviar essa pressão. Além disso, a possibilidade de integração com outras tecnologias, como redes definidas por software (*SDN - Software Defined Networking*) e redes de computação de borda com múltiplos acessos (*MEC - Multi-Access Edge Computing*), tem ampliado o escopo de aplicação das UAV-BSs.

Portanto, as UAV-BSs representam uma fronteira emergente na área de comunicações sem fio, com implicações significativas para a expansão da conectividade global e o suporte a redes resilientes e adaptativas. Apesar dos avanços consideráveis, desafios relacionados à autonomia energética, segurança e integração com infraestruturas terrestres permanecem e continuam a motivar pesquisas intensivas. O estudo, desenvolvimento e avaliação de desempenho de algoritmos de otimização do posicionamento para um mesmo cenário são fundamentais para

o avanço desta tecnologia, que promete transformar as redes de comunicação em cenários cada vez mais complexos e dinâmicos.

2.3 Meta-heurísticas

Nas últimas décadas, tornou-se comum o uso de algoritmos de aproximação que se caracterizam por combinar heurísticas básicas dentro de uma estrutura de controle em nível superior, com o objetivo de aumentar a eficiência no processo de busca por soluções. Inicialmente denominadas “heurísticas modernas” (GLOVER; KOCHENBERGER, 2003), essas abordagens foram concebidas para tratar problemas em que o espaço de soluções é vasto ou indefinido, impossibilitando sua avaliação exaustiva em tempo computacionalmente viável. Em geral, tais técnicas são construídas a partir de procedimentos sistemáticos que buscam soluções aceitáveis, ainda que não necessariamente ótimas no sentido absoluto, especialmente em problemas cuja natureza impede a obtenção de soluções exatas em tempo hábil.

Nesse contexto, além do conceito clássico de heurística, destaca-se a noção de meta-heurística. As meta-heurísticas são *frameworks* genéricos destinados à construção de algoritmos aproximativos, com o propósito de encontrar boas soluções para problemas complexos de otimização. Embora muitas vezes se associe o termo meta-heurística a uma generalização de heurísticas específicas para diferentes tipos de problemas, sua aplicação efetiva exige uma análise criteriosa das características do problema em questão. Essa análise busca identificar qual estratégia tem maior potencial de conduzir a soluções satisfatórias, ainda que não haja garantias de sucesso absoluto.

As meta-heurísticas podem ser classificadas conforme a abordagem conceitual adotada por cada algoritmo. Em (MANDOUR et al., 2024) a primeira categoria compreende as meta-heurísticas evolutivas, como os Algoritmos Genéticos (AG) e a Evolução Diferencial (DE), que se baseiam em mecanismos biológicos de seleção natural, como mutação, cruzamento e seleção de indivíduos mais aptos. Segundo (LI et al., 2019), essas técnicas apresentam desempenho robusto tanto em problemas práticos quanto teóricos, especialmente quando aplicadas a espaços de busca altamente complexos, onde métodos convencionais são menos eficazes. Em seguida, destacam-se as meta-heurísticas baseadas em humanos, que buscam inspiração em processos sociais de aprendizado coletivo. Um exemplo notório é o Teaching-Learning-Based Optimization (TLBO), cuja dinâmica simula a interação entre professores e alunos no ambiente de aprendizagem, aprimorando gradualmente as soluções a partir da troca de conhecimento entre os agentes.

Outras categorias amplamente utilizadas são as meta-heurísticas baseadas em enxame, como o Particle Swarm Optimization (PSO) e a Otimização por Colônia de Formigas (ACO), que modelam o comportamento cooperativo de grupos naturais, como bandos de aves ou colônias de insetos, sendo frequentemente aplicadas em problemas como roteamento, planejamento e alocação de recursos. Também se destacam as meta-heurísticas físicas, que utilizam princípios da

física, como gravidade e equilíbrio, para guiar o processo de busca por soluções. O Equilibrium Optimizer (EO), por exemplo, adota o conceito de estado de equilíbrio para propor uma nova estratégia de otimização voltada a problemas matemáticos complexos (FARAMARZI et al., 2020). Por fim, as meta-heurísticas matemáticas, como o Angle Optimizer Algorithm (AOA) e o Sine Cosine Algorithm (SCA), baseiam-se em transformações e fórmulas matemáticas que exploram propriedades geométricas e trigonométricas para gerar soluções de forma inovadora. Essas classificações são apresentadas na Figura 4 e contribuem para uma apresentação resumida das diferentes abordagens existentes (MANDOUR et al., 2024).

Figura 4 – Classificação dos algoritmos meta-heurísticos.



Fonte: Adaptada de (MANDOUR et al., 2024).

No que se refere à sua arquitetura, as meta-heurísticas podem ser classificadas em naturais ou não naturais. As naturais são inspiradas em fenômenos do mundo real, como o comportamento de insetos sociais, exemplificado pelos algoritmos PSO e ACO. As não baseadas na natureza incluem abordagens como os métodos de busca local e algoritmos gananciosos, que se valem de princípios matemáticos puros. Outra forma de categorização distingue as técnicas com ou sem uso de memória: algoritmos como a Busca Tabu mantêm histórico de soluções visitadas, enquanto outros, como os genéticos, não armazenam esse tipo de informação (ALANCAY; VILLAGRA; VILLAGRA, 2016). A simplicidade e a versatilidade dos algoritmos meta-heurísticos são fatores que contribuem para sua ampla aplicação em diversas áreas, demonstrando sua relevância em problemas reais. Essas técnicas cobrem áreas como redes de comunicação, onde são utilizadas para otimizar recursos em redes 5G (PALADIN et al., 2023), engenharia mecânica, logística e roteirização, e finanças, com a seleção de portfólios, além de serem aplicadas no design de sistemas de engenharia e em áreas como aprendizado de máquina e bioinformática.

Os algoritmos meta-heurísticos são métodos amplamente utilizados para resolver proble-

mas de otimização complexos, possuindo uma abordagem eficiente em diversos cenários. Alguns desses algoritmos simulam processos naturais, biológicos ou sociais para explorar o espaço de busca, procurando soluções próximas ao ótimo global. Eles são particularmente eficazes em problemas onde o espaço de busca é vasto, não linear, multimodal ou apresenta restrições complexas. Ao contrário dos métodos exatos, os modelos meta-heurísticos podem até não garantir a solução ótima, mas oferecem uma abordagem eficiente para encontrar soluções de alta qualidade em um tempo computacional viável.

Uma característica distintiva dos algoritmos meta-heurísticos é a sua capacidade de equilibrar a exploração global e a exploração local. A exploração global visa descobrir novas regiões promissoras no espaço de busca, enquanto a exploração local foca no refinamento de soluções já conhecidas. Esse equilíbrio é alcançado por meio de estratégias adaptativas ou iterativas, que ajustam dinamicamente os parâmetros do algoritmo conforme o processo de otimização avança. Exemplos notáveis incluem o fator de inércia no Particle Swarm Optimization (PSO) e a taxa de evaporação do feromônio no Ant Colony Optimization (ACO).

Em síntese, os algoritmos meta-heurísticos são ferramentas poderosas e flexíveis para a resolução de problemas de otimização complexos. Sua inspiração em processos naturais, combinada com a capacidade de adaptar estratégias de busca, torna-os ideais para enfrentar desafios computacionais modernos. Com a evolução da tecnologia e o aumento da complexidade dos problemas, espera-se que os algoritmos meta-heurísticos continuem desempenhando um papel central na pesquisa para serem aplicados na prática laboral, sendo continuamente aprimorados e integrados a novos paradigmas computacionais. Cada algoritmo oferece abordagens distintas. A seguir é apresentada uma análise detalhada dos algoritmos usados nesta dissertação, apresentando seus fundamentos teóricos.

2.3.1 Meta-heurística Artificial Bee Colony (ABC)

O algoritmo Artificial Bee Colony (ABC), inspirado no comportamento coletivo das abelhas em busca de alimentos, é uma técnica de otimização proposta por (KARABOGA et al., 2005). O ABC é classificado como um algoritmo de inteligência de enxame, utilizando interações entre agentes (abelhas) para resolver problemas de otimização, seja em funções contínuas ou discretas. Ele simula as interações de três grupos principais de abelhas: empregadas, observadoras e exploradoras, que juntas formam uma estratégia robusta de busca e otimização.

O ABC é inspirado no sistema natural de forrageamento das abelhas, que consiste em:

- Identificar fontes de alimento (soluções potenciais);
- Compartilhar informações sobre as fontes com as abelhas na colmeia;
- Explorar novas áreas para identificar fontes de alimento ainda desconhecidas.

No grupo das abelhas empregadas, cada abelha está associada a uma fonte de alimento e realiza uma exploração local para melhorar a solução atribuída. No grupo das abelhas observadoras elas avaliam as fontes de alimento disponíveis com base em uma probabilidade proporcional à qualidade da fonte. Enquanto o grupo das abelhas exploradoras substituem as abelhas empregadas associadas a fontes esgotadas, buscando novas soluções em regiões inexploradas.

No contexto de otimização, as "fontes de alimento", representam soluções potenciais, e a "quantidade de néctar", reflete a qualidade da solução, medida por uma função objetivo.

O algoritmo é eficiente na exploração global e local do espaço de busca devido à interação entre esses agentes. Ele se mostrou competitivo em problemas de otimização multimodal devido à sua capacidade adaptativa. O algoritmo ABC é iterativo e pode ser descrito pelas seguintes etapas:

1. Inicialização:

- Uma população inicial de soluções (fontes de alimento) é gerada aleatoriamente dentro dos limites do problema.
- A função objetivo é avaliada para cada solução.

2. Fase das Abelhas Empregadas:

- Cada abelha empregada seleciona uma fonte de alimento e gera uma nova solução na vizinhança da atual, utilizando a Equação 2.1:

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad , \quad (2.1)$$

sendo:

- v_{ij} é a nova solução.
- x_{ij} é a solução atual.
- x_{kj} é uma solução aleatória da vizinhança.
- ϕ_{ij} é um número aleatório uniformemente distribuído em $[-1, 1]$.
- A nova solução é avaliada, e a melhor entre a nova e a atual é mantida.

3. Fase das Abelhas Observadoras:

- As abelhas observadoras escolhem fontes de alimento com base em uma probabilidade proporcional à qualidade das soluções, calculada pela Equação 2.2:

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad , \quad (2.2)$$

sendo:

- p_i é a probabilidade de seleção da solução i .

- f_i é o valor da função objetivo da solução i .
- N é o número total de soluções.
- Novas soluções são geradas e avaliadas utilizando o mesmo método das abelhas empregadas.

4. Fase das Abelhas Exploradoras:

- Um contador é incrementado sempre que uma solução não melhora. Quando o contador atinge um limite, a solução é substituída. Por exemplo, se uma solução não melhorar após um número pré-determinado de iterações, ela é abandonada e substituída por uma nova solução gerada aleatoriamente.

5. Atualização e Terminação:

- As etapas anteriores são repetidas até que um critério de parada seja atendido, como um número máximo de iterações ou uma melhoria mínima entre as soluções.

A Tabela 2 apresenta as principais vantagens, limitações e relevância do Algoritmo Artificial Bee Colony (ABC), conforme destacado na literatura.

Tabela 2 – Vantagens, Limitações e Relevância do Algoritmo ABC

Vantagens	Limitações	Relevância
Simplicidade de implementação	Convergência lenta em problemas complexos	Inspiração natural eficaz
Eficiência na otimização global	Exploração excessiva em detrimento da busca local	Ampla aplicabilidade em diversas áreas
Equilíbrio entre exploração global e exploração local	Dependência de parâmetros fixos	Foco em problemas dinâmicos
Adaptação a problemas não lineares	Baixo desempenho em superfícies de busca complexas	Base para extensões e melhorias
Poucos parâmetros ajustáveis	Competitividade inferior em algumas aplicações	Contribuição para problemas com restrições
Capacidade de resolver problemas multidimensionais	Dificuldade em escapar de ótimos locais	Aplicações em redes de sensores sem fio e sistemas de energia
Flexibilidade em diversas áreas	Sensibilidade à inicialização da população	Utilizado em engenharia, bioinformática e logística

Fonte: Elaborado com base em (KARABOGA et al., 2005), (DINH; NGOC; VASANT, 2013) e (XIAO et al., 2023).

O ABC combina eficientemente a exploração global (abelhas exploradoras) e a exploração local (abelhas empregadas e observadoras), permitindo uma busca abrangente no espaço de soluções. A estrutura do algoritmo é simples, o que facilita sua implementação e aplicação em uma ampla gama de problemas, podendo lidar com funções objetivo não lineares, com múltiplos picos e com descontinuidades, sendo particularmente eficaz em problemas de alta dimensionalidade.

Os principais parâmetros do ABC são: tamanho da população, número máximo de iterações, limite de abandono para soluções não promissoras.

2.3.2 Meta-heurística Ant Colony Optimization (ACO)

O algoritmo Ant Colony Optimization (ACO), inspirado no comportamento coletivo das formigas na busca por caminhos otimizados para fontes de alimento, foi introduzido por (DORIGO; MANIEZZO; COLORNI, 1996). É classificado como um algoritmo de inteligência de enxame que utiliza interações indiretas, mediadas por trilhas de feromônio, para resolver problemas de otimização combinatória. Este algoritmo é particularmente eficaz para problemas como o caixeiro-viajante, roteamento de veículos e escalonamento de tarefas.

No ACO, as formigas (agentes artificiais) simulam o processo natural de busca de caminho das formigas reais, que consiste em:

- Explorar caminhos alternativos entre a colônia e uma fonte de alimento.
- Marcar os caminhos com feromônio, reforçando os mais curtos e eficientes.
- Seguir caminhos com maior concentração de feromônio, favorecendo a convergência para soluções otimizadas.

Cada formiga constrói uma solução de forma probabilística, baseando-se na concentração de feromônio e em uma função heurística local, que reflete a atratividade ou custo de uma decisão específica. A interação indireta entre as formigas, mediada pelo feromônio, permite a convergência coletiva para soluções de alta qualidade.

No contexto de otimização, os caminhos representam soluções potenciais, enquanto a concentração de feromônio reflete a qualidade da solução, com base em uma função objetivo específica.

O ACO pode ser descrito por etapas iterativas:

1. Inicialização:

- Um número inicial de formigas é distribuído no grafo do problema, onde cada nó ou aresta representa uma decisão.

- As trilhas de feromônio são inicializadas com valores baixos e uniformes, promovendo a exploração inicial.

2. Construção de Soluções:

- Cada formiga constrói uma solução movendo-se no grafo, decisão a decisão, com base em uma probabilidade p_{ij} , apresentado na Equação 2.3:

$$p_{ij} = \frac{[\tau_{ij}]^\alpha [\eta_{ij}]^\beta}{\sum_{k \in \mathcal{N}_i} [\tau_{ik}]^\alpha [\eta_{ik}]^\beta} \quad , \quad (2.3)$$

sendo:

- τ_{ij} é a intensidade do feromônio na aresta (i, j) .
- η_{ij} é a heurística local, como a inversa da distância ou custo.
- α e β controlam a importância relativa do feromônio e da heurística.
- \mathcal{N}_i é o conjunto de nós disponíveis para a formiga na posição i .

3. Atualização do Feromônio:

- Após todas as formigas completarem suas soluções, as trilhas de feromônio são atualizadas. O feromônio é evaporado para evitar a convergência prematura e reforçado nas melhores soluções, conforme Equação 2.4:

$$\tau_{ij} \leftarrow (1 - \rho)\tau_{ij} + \sum_{k=1}^m \Delta\tau_{ij}^k \quad , \quad (2.4)$$

sendo:

- ρ é a taxa de evaporação do feromônio.
- $\Delta\tau_{ij}^k$ é o incremento de feromônio depositado pela k -ésima formiga, proporcional à qualidade da solução encontrada.

O incremento $\Delta\tau_{ij}^k$ é calculado como:

$$\Delta\tau_{ij}^k = \begin{cases} \frac{Q}{L_k}, & \text{se a aresta } (i, j) \text{ foi percorrida pela formiga } k, \\ 0, & \text{caso contrário,} \end{cases}$$

sendo:

- Q : Constante relacionada à quantidade total de feromônio depositado.
- L_k : Comprimento total da solução encontrada pela formiga k .

4. Função de Decaimento:

- A Função de Decaimento do Feromônio, apresentado na Equação 2.5, é o processo de evaporação, que é modelado pela multiplicação do feromônio atual por $(1 - \rho)$, evitando a estagnação e promovendo a exploração:

$$\tau_{ij} \leftarrow (1 - \rho)\tau_{ij}. \quad (2.5)$$

5. Critérios de Parada:

- O processo é repetido por um número máximo de iterações ou até que a solução encontrada atenda a critérios de qualidade previamente estabelecidos.

A Tabela 3 apresenta as principais vantagens, limitações e relevância do Algoritmo de Otimização por Colônia de Formigas (ACO), conforme destacado na literatura.

Tabela 3 – Vantagens, Limitações e Relevância do Algoritmo ACO

Vantagens	Limitações	Relevância
Capacidade de encontrar soluções próximas do ótimo global	Convergência lenta em problemas muito grandes	Amplamente utilizado em otimização combinatória
Flexibilidade para diferentes problemas	Sensibilidade a parâmetros	Base para algoritmos híbridos
Uso colaborativo da inteligência coletiva	Tendência à estagnação prematura	Eficiente em problemas dinâmicos
Robustez em ambientes dinâmicos	Dependência de uma função heurística bem definida	Aplicável a problemas NP-difíceis
Eficiência em grafos densos	Necessidade de balancear exploração global e exploração local	Popular em redes de comunicação e logística

Fonte: Elaborada com base em (DORIGO; MANIEZZO; COLORNI, 1996), (DORIGO; BLUM, 2005), (MAVROVOUNIOTIS; ANASTASIADOU; HADJIMITSIS, 2023) e (WU; LI; WEI, 2023).

O ACO destaca-se por sua capacidade de equilibrar a exploração global e a exploração local devido à interação entre o feromônio (memória coletiva) e a heurística (informação local). É amplamente utilizado em problemas complexos, como roteamento de redes, bioinformática e planejamento logístico, sendo também uma base sólida para extensões e combinações com outros algoritmos.

Os principais parâmetros do ACO incluem: taxa de evaporação do feromônio (ρ), peso relativo do feromônio (α), peso da heurística (β), e número de formigas por iteração. A escolha cuidadosa desses parâmetros é crucial para obter desempenho ideal em aplicações práticas.

2.3.3 Meta-heurística Algoritmo Genético (AG)

O Algoritmo Genético (AG), inspirado nos princípios de seleção natural e evolução das espécies propostos por Darwin, foi introduzido por (HOLLAND, 1975). É classificado como um método de otimização baseado em população que utiliza operadores genéticos, como seleção, cruzamento e mutação, para iterativamente refinar soluções candidatas. Este algoritmo é

amplamente aplicado em problemas de otimização complexos, como planejamento, roteamento e design de sistemas.

No AG, uma população de indivíduos (soluções potenciais) evolui ao longo de várias gerações, guiada por uma função de aptidão (*fitness*), que mede a qualidade de cada solução. O processo de evolução no AG pode ser resumido em três principais etapas:

- Selecionar indivíduos com base em sua aptidão para gerar a próxima geração.
- Combinar características de indivíduos selecionados por meio do cruzamento.
- Introduzir variações na população através da mutação para explorar novas regiões do espaço de busca.

Cada indivíduo na população é representado por um cromossomo, que é uma codificação do problema em forma binária, numérica ou outra representação adequada. O AG utiliza operadores inspirados na genética natural para garantir um equilíbrio entre exploração global e refinamento local.

No contexto de otimização, os indivíduos representam soluções potenciais, enquanto a função de aptidão avalia a qualidade de cada solução com base em critérios específicos do problema.

O AG pode ser descrito por etapas iterativas:

1. Inicialização:

- Uma população inicial de indivíduos é gerada aleatoriamente ou com base em heurísticas, respeitando os limites do problema.
- Cada indivíduo é avaliado por uma função de aptidão (*fitness*), que mede sua qualidade em relação ao objetivo do problema.

2. Seleção:

- Os indivíduos mais aptos são selecionados para reprodução com base em métodos como:
 - **Roleta:** A probabilidade de seleção é proporcional à aptidão do indivíduo.
 - **Torneio:** Um grupo aleatório de indivíduos compete, e o mais apto é selecionado.

3. Cruzamento:

- Pares de indivíduos selecionados trocam partes de seus cromossomos para gerar novos indivíduos (*offspring*):

$$\text{offspring} = \text{crossover}(\text{parent1}, \text{parent2}) \quad ,$$

sendo que, o ponto ou os pontos de cruzamento são definidos aleatoriamente ou de forma controlada.

4. Mutação:

- Pequenas alterações são introduzidas nos cromossomos para garantir a exploração do espaço de busca:

$$\text{mutated_gene} = \text{flip}(\text{original_gene}) \quad ,$$

sendo que, o *flip* altera o valor do gene (e.g., 0 para 1 ou 1 para 0 em representação binária).

5. Substituição e Terminação:

- A nova geração substitui a antiga com base em estratégias como substituição total ou elitismo (manutenção dos melhores indivíduos).
- O processo é repetido até que um critério de parada seja atingido, como número máximo de gerações ou convergência das soluções.

A Tabela 4 apresenta as principais vantagens, limitações e relevância do Algoritmo Genético (AG), conforme identificado na literatura relevante especializada.

Tabela 4 – Vantagens, Limitações e Relevância do Algoritmo Genético

Vantagens	Limitações	Relevância
Capacidade de encontrar soluções próximas ao ótimo global	Grande variedade de parametrização (e.g., taxas de mutação e cruzamento)	Amplamente utilizado em otimização global
Flexibilidade na representação de soluções	Alto custo computacional em populações grandes	Base para algoritmos híbridos
Exploração eficiente de espaços de busca complexos	Convergência lenta em alguns cenários	Aplicável a problemas multiobjetivos
Capacidade de escapar de mínimos locais	Requer mais iterações por conta de sua estrutura de otimização	Popular em áreas como bioinformática e engenharia
Equilíbrio entre exploração e exploração local		Eficaz em problemas com grandes espaços de busca

Fonte: Elaborada com base em (HOLLAND, 1975), (GOLDBERG, 1989) e (VIE; KLEINNIJENHUIS; FARMER, 2020).

Os principais parâmetros do AG incluem: tamanho da população, taxa de cruzamento, taxa de mutação e número máximo de gerações. A escolha cuidadosa desses parâmetros é essencial para obter um desempenho eficiente e alcançar soluções de alta qualidade.

O AG é amplamente utilizado em problemas onde o espaço de busca é grande e apresenta várias soluções locais. Sua flexibilidade e eficiência o tornam uma ferramenta poderosa para resolver problemas complexos e dinâmicos em diversas áreas, incluindo otimização combinatória, aprendizado de máquina e sistemas inteligentes.

2.3.4 Meta-heurística Particle Swarm Optimization (PSO)

O algoritmo Particle Swarm Optimization (PSO), inspirado no comportamento social de grupos, como cardumes de peixes e bandos de pássaros, foi proposto por (KENNEDY; EBERHART, 1995). É classificado como um algoritmo de inteligência de enxame que utiliza a colaboração entre partículas para explorar o espaço de busca, buscando soluções ótimas para problemas de otimização contínua e discreta. Sua simplicidade e eficiência o tornam uma escolha popular em diversas áreas de pesquisa e aplicação..

No PSO, um conjunto de partículas (soluções potenciais) se movimenta em um espaço de busca multidimensional guiado por sua experiência individual e pela experiência coletiva do grupo. Cada partícula possui uma posição e uma velocidade, ajustadas iterativamente com base em duas principais influências:

- A melhor posição já encontrada pela própria partícula (p_{best}).
- A melhor posição já encontrada pelo grupo (g_{best}).

A dinâmica do algoritmo permite o equilíbrio entre a exploração global e a exploração local, garantindo a convergência para soluções de alta qualidade.

No contexto de otimização, as partículas representam soluções potenciais, enquanto uma função objetivo avalia a qualidade de cada solução. O PSO pode ser descrito pelas seguintes etapas iterativas:

1. Inicialização:

- Um conjunto inicial de partículas é gerado aleatoriamente no espaço de busca, respeitando os limites do problema.
- Cada partícula é inicializada com uma posição x_i e uma velocidade v_i .
- A função objetivo é avaliada para determinar p_{best} e g_{best} , as melhores soluções individuais e globais, respectivamente.

2. Atualização da Velocidade:

- A velocidade de cada partícula é atualizada com base em sua experiência e na experiência coletiva, apresentado na Equação 2.6:

$$v_i(t + 1) = w \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_{best,i} - x_i(t)) + c_2 \cdot r_2 \cdot (g_{best} - x_i(t)) \quad , \quad (2.6)$$

sendo:

- w : Fator de inércia, que controla a influência da velocidade anterior.
- c_1, c_2 : Coeficientes de aprendizado (pesos de aceleração) que controlam a influência de p_{best} e g_{best} , respectivamente.
- r_1, r_2 : Números aleatórios uniformemente distribuídos em $[0, 1]$, que introduzem diversidade no movimento.

3. Atualização da Posição:

- A posição de cada partícula é atualizada com base em sua nova velocidade, conforme demonstrado na Equação 2.7:

$$x_i(t + 1) = x_i(t) + v_i(t + 1). \quad (2.7)$$

4. Avaliação e Atualização das Melhores Soluções:

- A função objetivo é avaliada na nova posição de cada partícula.
- Os valores de p_{best} e g_{best} são atualizados se as novas posições apresentarem soluções melhores.

5. Critérios de Parada:

- O processo é repetido até que um critério de parada seja atingido, como número máximo de iterações ou convergência para uma solução satisfatória.

A Tabela 5 apresenta as principais vantagens, limitações e relevância do algoritmo PSO, com base na literatura acadêmica especializada.

Tabela 5 – Vantagens, Limitações e Relevância do Algoritmo PSO

Vantagens	Limitações	Relevância
Simplicidade de implementação	Pode convergir para mínimos locais em problemas complexos	Amplo uso em problemas de otimização contínua
Baixo custo computacional	Sensível à escolha de parâmetros como w , c_1 , c_2	Aplicável em aprendizado de máquina e robótica
Adaptação a problemas não lineares	Exploração limitada em espaços de alta dimensionalidade	Base para variantes híbridas
Equilíbrio entre exploração e exploração local	Desempenho pode ser impactado por populações pequenas	Eficaz em problemas multimodais
Eficiência em espaços de busca grandes	Dependência de uma função objetivo bem definida	Popular em engenharia e modelagem

Fonte: Elaborada com base em (KENNEDY; EBERHART, 1995), (POLI; KENNEDY; BLACKWELL, 2007) e (CLERC, 2010).

Os principais parâmetros do PSO incluem:

- w (fator de inércia): Controla a influência da velocidade anterior, balanceando exploração e exploração local.
- c_1, c_2 (coeficientes de aprendizado): Determinam a importância de p_{best} e g_{best} .
- Tamanho da população: Influencia a diversidade e a cobertura do espaço de busca.
- Número máximo de iterações: Define o limite para o processo iterativo.

O PSO é amplamente utilizado em aplicações que vão desde a otimização de funções contínuas até a modelagem de sistemas complexos. Sua estrutura simples, combinada com a capacidade de convergir rapidamente para soluções de alta qualidade, faz dele uma ferramenta poderosa em áreas como engenharia, redes de comunicação, aprendizado de máquina e bioinformática.

2.3.5 Meta-heurística Teaching-Learning-Based Optimization (TLBO)

O algoritmo Teaching-Learning-Based Optimization (TLBO), inspirado no processo de ensino-aprendizagem em ambientes educacionais, foi proposto por (RAO; SAVSANI; VAKHARIA, 2011). É um algoritmo meta-heurístico baseado em população, que utiliza a interação entre alunos e professor para buscar soluções ótimas em problemas de otimização contínua e discreta.

Este algoritmo destaca-se por sua simplicidade, não necessitando de parâmetros específicos como fatores de mutação ou cruzamento.

No TLBO, cada indivíduo na população é considerado um "aluno", e o melhor indivíduo da população atua como "professor". O processo de ensino-aprendizagem é modelado em duas fases principais:

- **Fase do Professor:** O professor tenta elevar o nível médio da turma, modificando o desempenho dos alunos.
- **Fase do Aluno:** Os alunos interagem entre si para melhorar suas habilidades, compartilhando conhecimentos de forma colaborativa.

No contexto de otimização, os alunos representam soluções potenciais, enquanto a função objetivo avalia a qualidade de cada solução. A interação entre professor e alunos promove um equilíbrio entre exploração e exploração local no espaço de busca.

O TLBO pode ser descrito pelas seguintes etapas:

1. Inicialização:

- Uma população inicial de soluções (alunos) é gerada aleatoriamente dentro dos limites do problema.
- Cada solução é avaliada por uma função objetivo para determinar a qualidade do desempenho de cada aluno.

2. Fase do Professor:

- O melhor aluno (solução com melhor valor de função objetivo) é identificado como o "professor"(T).
- O professor tenta melhorar o desempenho médio (M) da turma, ajustando as soluções individuais, apresentado na Equação 2.8:

$$X_i^{new} = X_i + r \cdot (T - F \cdot M) \quad , \quad (2.8)$$

sendo:

- X_i : Solução atual do aluno i .
- r : Número aleatório uniformemente distribuído em $[0, 1]$.
- F : Fator de ensino, que assume valores 1 ou 2 para controlar a influência do professor.
- M : Média da população atual.
- A nova solução (X_i^{new}) é aceita se apresentar melhor valor de função objetivo.

3. Fase do Aluno:

- Cada aluno interage com outro aluno (X_j) selecionado aleatoriamente, aprendendo com ele e ajustando sua solução, conforme Equação 2.9:

$$X_i^{new} = \begin{cases} X_i + r \cdot (X_j - X_i), & \text{se } f(X_j) < f(X_i) \quad , \\ X_i + r \cdot (X_i - X_j), & \text{se } f(X_i) \leq f(X_j) \quad , \end{cases} \quad (2.9)$$

sendo:

- X_j : Solução de outro aluno escolhido aleatoriamente.
- $f(X_i)$: Valor da função objetivo para o aluno i .
- A nova solução (X_i^{new}) é aceita se for melhor do que a solução atual.

4. Critérios de Parada:

- O processo é repetido até que um critério de parada seja atingido, como número máximo de iterações ou convergência para uma solução satisfatória.

Os principais parâmetros do TLBO incluem:

- Tamanho da população: Define o número de alunos (soluções) no espaço de busca.
- Número máximo de iterações: Controla o limite do processo iterativo.
- Fator de ensino (F): Determina a influência do professor na fase de ensino.

A ausência de parâmetros adicionais torna o TLBO menos dependente de ajustes finos, simplificando sua aplicação em diversos problemas. A Tabela 6 apresenta as principais vantagens, limitações e relevância do algoritmo TLBO, conforme a literatura especializada.

Tabela 6 – Vantagens, Limitações e Relevância do Algoritmo TLBO

Vantagens	Limitações	Relevância
Não depende de parâmetros específicos	Pode convergir para mínimos locais em problemas complexos	Simplicidade de implementação
Alta eficiência em problemas contínuos	Sensível à escolha inicial da população	Ampla aplicabilidade em problemas de engenharia
Equilíbrio entre exploração global e local	Pouca flexibilidade em problemas discretos	Base para variantes híbridas
Sem necessidade de ajustes finos de parâmetros	Desempenho pode ser inferior a algoritmos com maior diversidade	Popular em problemas de otimização contínua
Robusto em diferentes condições iniciais	Pode requerer mais iterações em problemas multimodais	Aplicável em modelagem de sistemas e aprendizado de máquina

Fonte: Elaborada com base em (RAO; SAVSANI; VAKHARIA, 2011), (RAO, 2015) e (CHEN; YANG, 2020).

O TLBO é amplamente utilizado em problemas de otimização contínua e é especialmente eficaz em aplicações que requerem algoritmos simples e robustos. Sua abordagem baseada em interações sociais permite explorar o espaço de busca de forma eficiente, tornando-o uma ferramenta poderosa em engenharia, modelagem matemática e sistemas inteligentes.

3 ASPECTOS METODOLÓGICOS

3.1 Considerações Iniciais

Este capítulo apresenta uma metodologia para a análise comparativa de algoritmos meta-heurísticos para a tomada de decisão sobre o posicionamento de UAV-BSs em redes móveis. No capítulo 1.1 deste trabalho, encontram-se várias técnicas e métodos que foram desenvolvidos para resolver o desafio do posicionamento eficiente de UAV-BSs em redes móveis sem fio. No entanto, ainda há uma escassez de soluções voltadas para a comparação de meta-heurísticas, especificamente para o contexto do ambiente de desastre e urgência no provimento do restabelecimento do serviço, utilizando métricas de QoS, que afetam diretamente a qualidade do sinal nos momentos de necessidade. Para lidar com esses problemas, é importante o investimento em infraestrutura e tecnologia para aumentar a capacidade e garantir que os usuários tenham acesso consistente à rede, mesmo durante horários de picos. Isso inclui a instalação de novas infraestruturas, utilização de tecnologias de rede 5G que ofereçam velocidades mais rápidas e capacidade de banda larga e o uso de infraestruturas temporárias (MASROOR et al., 2023).

3.2 Metodologia

Nesta seção, apresenta-se uma descrição detalhada da abordagem utilizada para implementar e avaliar os algoritmos meta-heurísticos na otimização do posicionamento de UAV-BSs. A metodologia foi concebida para garantir reprodutibilidade, rigor científico e precisão na análise dos resultados. Para tanto, foram definidos o ambiente de simulação, as métricas de avaliação, os modelos matemáticos aplicados e a configuração dos algoritmos utilizados.

3.2.1 Ambiente de Simulação

O ambiente de simulação modela uma área plana de 1000m x 1000m, representativa de um cenário urbano ou semiurbano típico, onde desastres naturais poderiam comprometer a infraestrutura de comunicação. Para a propagação do sinal, foi adotada uma frequência de 2,4 GHz, que representa condições de banda amplamente utilizadas e é significativamente relevante na análise de redes sem fio. A literatura indica que a faixa de frequência de 2,4 GHz é comumente utilizada (SAFWAT; NEWAGY; HAFEZ, 2020) devido sua capacidade de atender a requisitos de comunicação em ambientes urbanos densamente povoados, onde interferências de outros dispositivos (como Bluetooth e Zigbee) podem impactar o desempenho do sinal (SHIN et al., 2007). Além disso, estudos sugerem que as características de propagação nessa faixa são críticas, especialmente em condições climáticas variadas, afetando diretamente a qualidade e a

confiabilidade da comunicação apresentada em ambientes desafiadores como os urbanos (ZHOU et al., 2018). Assim, a escolha dessa frequência não apenas reflete práticas comuns, mas também leva em conta as complexidades que os ambientes urbanos impõem sobre as comunicações sem fio.

O Python foi utilizado como linguagem principal devido à sua robustez para modelagem matemática e capacidade de integração com bibliotecas avançadas como NumPy (para operações matemáticas e estatísticas) e Matplotlib (para visualização de dados). Para garantir a consistência na avaliação dos algoritmos, atribuiu-se uma semente fixa para o gerador de números aleatórios, facilitando a reprodução dos experimentos.

No cenário construído, os usuários foram adicionados no espaço de busca, utilizando a distribuição normal aleatória. Entretanto, para uma análise comparativa entre os diferentes tipos de algoritmos meta-heurísticos, foi atribuída uma semente na aleatoriedade da posição dos usuários, por meio do módulo Random do Python, com o objetivo de criar cenários de busca idênticos para todos os algoritmos.

3.2.2 Planejamento de posicionamento dos Veículos Aéreos não Tripulados, servindo com Estação Base (UAV-BSs).


O planejamento do posicionamento de UAV-BSs apresenta desafios relacionados à propagação eletromagnética, especialmente no que se refere à comunicação entre os UAV-BSs e os usuários terrestres. Para realizar uma comunicação eficiente, foi fundamental levar em consideração diversos fatores que influenciam a qualidade e o alcance do sinal. Um dos aspectos essenciais nesse contexto é o cálculo preciso da distância entre os usuários e os UAV-BSs. Para isso, empregou-se a equação da distância euclidiana, que é amplamente utilizada em um plano tridimensional para determinar a distância entre dois pontos definidos por suas coordenadas (x, y, z) e (x_i, y_i, z_i) , conforme apresentado na Equação 3.1, (LI et al., 2019).

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2} \quad , \quad (3.1)$$

sendo z_j a altitude do UAV-BS j em relação à terra e z_i a altitude do EU i em relação ao solo.

A Figura 5 ilustra a área de cobertura de um UAV-BS localizado a uma altura de h_{bs} e um EU no raio de R a partir de um ponto correspondente à projeção acima do solo h_{ra} .

Figura 5 – Área de cobertura de um UAV-BS



Fonte: Elaborado pelo autor.

O ângulo de elevação (em graus) formado entre o EU i e o UAV-BS j é expressado pela Equação 3.2

$$\theta = \tan^{-1} \left(\frac{h}{R} \right) , \quad (3.2)$$

sendo:

- θ : ângulo de elevação entre o usuário e o UAV-BS (em graus);
- h : altura do UAV-BS em relação ao EU (em metros);
- R : distância horizontal entre o UAV-BS e o usuário no solo (em metros);
- $\tan^{-1}(\cdot)$: função arco-tangente, também conhecida como inversa da tangente ou *atan*.

3.2.3 Distribuição de Usuários e Configuração iniciais dos Veículos Aéreos não Tripulados, servindo com Estação Base (UAV-BSs).

A distribuição dos usuários no espaço de simulação foi realizada de maneira aleatória a cada rodada da busca pelo ótimo, adotando-se uma distribuição uniforme contínua dentro dos limites definidos para o ambiente de operação. Para assegurar a reprodutibilidade dos experimentos e permitir uma comparação justa entre os diferentes algoritmos meta-heurísticos aplicados, foi definida uma semente de aleatoriedade fixa. Essa configuração foi executada em trinta repetições independentes, com o propósito de garantir robustez estatística às análises e, simultaneamente, representar um cenário dinâmico e não determinístico, como é comum em contextos de desastres, nos quais a posição dos usuários tende a variar de forma imprevisível. O posicionamento inicial dos UAV-BSs respeitou as particularidades operacionais de cada

algoritmo considerado, sendo posteriormente refinado iterativamente conforme as regras de aprendizado e atualização definidas por cada meta-heurística, com base na avaliação da função objetivo em cada etapa do processo de otimização.

3.2.4 Modelos Matemáticos Utilizados

A análise do sinal baseou-se em modelos padrão de comunicação, incluindo perda de caminho (Path Loss), relação sinal-interferência mais ruído (SINR) e capacidade teórica de Shannon. A Tabela 7 apresenta os principais parâmetros utilizados no cenário de simulação.

Tabela 7 – Parâmetros do cenário de simulação

Largura de banda	20 MHz
Potência de transmissão	20 dBm
Altura dos UAV-BSs	50 m
Fator de ajuste de perda de caminho	3

Fonte: Elaborada com base em (CARDOSO et al., 2020), (FERNANDEZ; CARVALHO; SILVA, 2020), (GUPTA; VARMA, 2021) e (ALFAIA et al., 2022).

3.2.4.1 Modelo de Propagação

Foi utilizado para determinar as perdas no caminho do UAV-BS para o EU, o modelo *Air-To-Ground* (A2G) (AL-HOURANI; KANDEEPAN; JAMALIPOUR, 2014), pois é possível considerar tanto ocorrências de linha de visada direta (*LOS - Line of Sight*) quanto ocorrências de perdas de caminho com obstruções parciais ou totais (*NLOS - Non-Line of Sight*). Diante da possibilidade do canal A2G seguir múltiplos caminhos de propagação, resultante de desvanecimento e interferências ao longo da trajetória, a probabilidade da ocorrência de *LoS* e *NLoS* pôde ser modelada e quantificada por meio das Equações 3.3 e 3.4 (LAGUM; BOR-YALINIZ; YANIKOMEROGLU, 2017) e (CARDOSO et al., 2020) respectivamente:

$$PL_{LoS}(dB) = 20 \log_{10} \left(\frac{4\pi f_c d_{ij}}{c} \right) + \eta_{LoS} \quad , \quad (3.3)$$

$$PL_{NLoS}(dB) = 20 \log_{10} \left(\frac{4\pi f_c d_{ij}}{c} \right) + \eta_{NLoS} \quad , \quad (3.4)$$

sendo f_c uma variável que representa a frequência portadora, d_{ij} é a distância Euclidiana entre um EU e um UAV-BS, c é uma constante que representa a velocidade da luz, enquanto η_{LoS} , η_{NLoS} são as perdas médias adicionais graças à perda de propagação no espaço livre, que depende do ambiente e assumimos neste estudo valores típicos para o ambiente urbano ($\eta_{LoS} = 1\text{dB}$; $\eta_{NLoS} = 20\text{dB}$), assim como realizado em (LAGUM; BOR-YALINIZ; YANIKOMEROGLU, 2017), fundamentado em valores que representam perdas adicionais médias observadas em ambientes urbanos, conforme descrito por (AL-HOURANI; KANDEEPAN; JAMALIPOUR, 2014).

Além das perdas médias adicionais, o modelo também estabelece a probabilidade de ocorrência de um link com linha de visada (*LoS*), em função da variação angular θ entre o UAV-BS e o EU, bem como a probabilidade complementar de um link sem linha de visada *NLoS*. Essas probabilidades são fundamentais para caracterizar o canal de comunicação ar-terra e são determinadas pelas Equações 3.5 e 3.6,

$$P_{LoS}(\theta_{ij}) = [1 + \varphi \cdot \exp(-\beta(\theta_{ij} - \varphi))]^{-1} \quad ; \quad (3.5)$$

$$P_{NLoS}(\theta_{ij}) = 1 - P_{LoS}(\theta_{ij}) \quad , \quad (3.6)$$

sendo:

- φ e β constantes atribuídas a partir do ambiente (urbano, sub-urbano, rural, etc.);
- θ_{ij} representa o ângulo de elevação (em graus) entre o usuário i e o UAV-BS j .

Por conseguinte, a perda de percurso probabilística resultante pode ser expressa conforme apresentado na Equação 3.7:

$$PL = PL_{LoS} \cdot P_{LoS}(\theta_{ij}) + PL_{NLoS} \cdot P_{NLoS}(\theta_{ij}). \quad (3.7)$$

3.2.4.2 Relação Sinal-Interferência mais Ruído

A relação sinal-interferência mais ruído (*SINR - Signal-to-Interference-plus-Noise-Ratio*) é uma métrica bastante usual na literatura para avaliar o desempenho do enlace de comunicação, pois considera o nível do sinal útil, o ruído térmico do sistema e a interferência causada por outras estações base ativas. Quanto maior a SINR, melhor a qualidade do enlace e, conseqüentemente, maior a capacidade de transmissão de dados para aquele usuário.

Assume-se que a SINR representa um cenário no qual tanto o ruído de fundo quanto a interferência proveniente de outras transmissões simultâneas são considerados no sistema de comunicação da rede (JUN; PEDDABACHAGARI; SICHITIU, 2003). Nesta dissertação, considera-se que, durante a transmissão de dados aos usuários em solo, os UAV-BSs operam com altitude e velocidade constantes. Adota-se ainda a hipótese de que há uma quantidade reduzida de obstáculos, o que permite que os UAV-BSs operem de forma mais eficiente em altitudes mais baixas, beneficiando-se de maior probabilidade de linha de visada direta, conforme indicado em (ZHAO et al., 2019). Além disso, pressupõe-se que todos os nós transmissores operam com a mesma potência, de modo a possibilitar uma comparação justa entre os diferentes algoritmos analisados, que é o objetivo central desta dissertação.

Considerando que U é um conjunto de usuários, $U = \{1, 2, \dots, N_u\}$, onde N_u é o n ésimo usuário que necessita de serviço de comunicação e B um conjunto de todos os UAV-BSs,

$B = \{1, 2, \dots, N_b\}$, sendo N_b , o enésimo UAV-BS no cenário considerado. A potência de sinal recebida em (dB) pelo usuário $i \in U$, provida pelo UAV-BS $j \in B$ é denotada por $Pr_{i,j}$ (dB), conforme é demonstrado na Equação 3.8 (GOLDSMITH, 2005)

$$Pr_{i,j} = P_t - PL \quad , \quad (3.8)$$

sendo:

- Pr_{ij} a potência recebida entre o par EU e o UAV-BS;
- P_t a potência transmitida pelo UAV-BS;
- PL a perda de percurso resultante, expresso na Equação 3.7.

De acordo com (GOLDSMITH, 2005) em sistemas com interferência, frequentemente usa-se a SINR recebida para calcular a probabilidade de erro. Esta é uma aproximação razoável devido às estatísticas de interferência se aproximarem das do ruído gaussiano. A SINR recebida é dada pela Equação 3.9 (CARDOSO et al., 2020) e (ALFAIA et al., 2022)

$$SINR_{i,j} = \frac{Pr_{i,j}}{\sigma + \sum_{k=1, k \neq j}^{N_b} Pr_{i,k}} \quad , \quad (3.9)$$

sendo:

- $SINR_{i,j}$ o valor da SINR entre o usuário i e a estação base j ;
- σ a potência do ruído;
- A soma no denominador representa a potência dos sinais recebidos por i dos demais UAV-BSs $k \neq j$, ou seja, a interferência.

3.2.4.3 Capacidade do canal

Para medir a capacidade do canal com ruído aditivo branco gaussiano (AWGN - *Additive White Gaussian Noise*), é comumente utilizado na literatura a fórmula proposta por Shannon-Hartley. Sua fórmula representa o limite máximo teórico da quantidade de informações que podem ser transmitidas sem erro, considerando um nível de ruído e largura de banda específicos. Diferenciando-se por pouco da vazão, pois esta se refere à taxa real de transferência de dados alcançada em um canal de comunicação, levando em conta fatores como sobrecarga de protocolos, condições do canal e eficiência do sistema. Neste estudo, consideramos que a vazão se aproxima do limite teórico máximo, assumindo condições ideais de operação, com eficiência máxima e ausência de sobrecarga significativa. Esse princípio é o mesmo adotado por (GOLDSMITH, 2005), (LI et al., 2019) e (ALFAIA et al., 2022).

Para calcular a taxa de transmissão ou rendimento da rede, que indica a taxa de bits transmitidos em um intervalo de tempo, é utilizada a fórmula de Shannon. A taxa de usuário alcançável é expressa na Equação 3.10

$$C_{i,j} = B \log_2(1 + SINR_{i,j}) \quad , \quad (3.10)$$

sendo $C_{i,j}$ a capacidade do canal do EU i para a UAV-BS j e B é a largura de banda do canal.

3.2.4.4 Parâmetros de simulação

Os parâmetros gerais do cenário são apresentados na Tabela 8. A utilização destes parâmetros proporciona a criação de um cenário adequado para a implementação dos cinco algoritmos meta-heurísticos (ABC, ACO, AG, PSO e TLBO) estudados em um ambiente simulado para atendimento de casos emergenciais, similar aos parâmetros utilizados em (ALAMMOURI; ANDREWS; BACCELLI, 2017) e (ALFAIA et al., 2022).

Tabela 8 – Tabela de parâmetros da simulação.

Parâmetro	Valor
Número de Usuários	100
Número de UAV-BS	2 - 6
Tamanho do espaço de busca	1000m x 1000m
SINR_Desejado	10dB
P_t	20dBm
σ	-101dBm
f	2.4GHz
h_{bs}	50m
h_{ra}	1.2m
B	20MHz
Perda de propagação LoS	1dB
Perda de propagação $NLoS$	20dB
Tipo do ambiente	Urbano
α	9.6
β	0.28

Número de Usuários (100): Escolheu-se uma quantidade significativa de usuários para garantir a relevância prática da simulação, representando adequadamente um cenário típico de emergência em áreas urbanas ou semiurbanas, onde é necessário fornecer comunicação temporária a um grupo numeroso de indivíduos afetados distribuídos pelo espaço de busca.

Número de UAV-BSs (de 2 a 6): Essa faixa permite analisar o impacto incremental na capacidade de cobertura à medida que mais UAV-BSs são adicionados. A faixa mínima de 2 UAV-BSs é escolhida para verificar a efetividade inicial da solução com múltiplos UAV-BSs,

enquanto a quantidade máxima de 6 UAV-BSs possibilita identificar um limite ou saturação do ganho na cobertura proporcionada pelos dispositivos.

Tamanho do espaço de busca (1000m × 1000m): Este tamanho é representativo para uma situação de emergência, abrangendo uma área suficientemente ampla para testar a eficácia e alcance da cobertura fornecida pelos UAV-BSs. Esse espaço é realista para aplicação em áreas críticas atingidas por eventos como enchentes, terremotos ou incêndios.

SINR desejado (10dB): Um SINR acima de 10dB garante níveis suficientes e adequados para garantir a qualidade e estabilidade de serviços críticos, como voz, vídeo e transmissão de dados essenciais, fundamentais durante cenários de emergência, onde a qualidade do serviço (QoS) é crucial.

Potência de transmissão ($P_t = 20\text{dBm}$): A potência de 20dBm é apropriada para dispositivos UAV-BSs, garantindo um equilíbrio entre alcance suficiente para cobrir a área designada e o baixo consumo energético, essencial devido à limitação da bateria dos UAV-BSs.

Potência do Ruído ($\sigma = -101\text{dBm}$): Esse valor típico representa condições reais de potência do ruído em canais sem fio com largura de banda de 20MHz, garantindo uma simulação realista das condições operacionais.

Frequência ($f = 2,4\text{GHz}$): A escolha dessa frequência é justificada pela disponibilidade, ampla utilização e facilidade de implementação de equipamentos existentes, permitindo simular de forma realista os sistemas de comunicação temporária utilizados em emergências.

Altura das estações UAV-BSs ($h_{bs} = 50\text{m}$): A altura escolhida é adequada para obter um equilíbrio ótimo entre cobertura ampla, qualidade do sinal e viabilidade operacional das aeronaves não tripuladas, reduzindo interferências e garantindo linha de visada com os usuários terrestres.

Altura dos usuários ($h_{ra} = 1,2\text{m}$): Corresponde a uma altura média representativa dos usuários segurando dispositivos móveis, garantindo realismo na simulação e precisão na análise da propagação eletromagnética.

Largura de Banda ($B = 20\text{MHz}$): Representa uma faixa espectral amplamente utilizada em aplicações de comunicação móvel, proporcionando taxas de transmissão compatíveis com serviços de emergência e necessidades de usuários temporariamente conectados.

3.2.5 Metodologia aplicada aos algoritmos Meta-Heurísticos

Para a análise comparativa, implementou-se cinco algoritmos meta-heurísticos (ABC, ACO, AG, PSO e TLBO), cada qual com características únicas, como inspiração biológica, comportamental ou social. Abaixo, destacam-se os ajustes realizados em cada algoritmo.

3.2.5.1 Implementação do algoritmo Artificial Bee Colony (ABC)

A implementação do ABC no presente estudo adapta o algoritmo para trabalhar em um espaço de busca contínuo, sendo a posição das "abelhas" a representação das posições dos UAV-BSs, realizando a busca por meio de “Abelhas Empregadas” (Employed Bees), as “Abelhas Observadoras” (Onlooker Bees) e as “Abelhas Exploradoras” (Scout Bees), cujo objetivo é encontrar e melhorar as localizações dos UAV-BSs para maximizar a cobertura dos usuários, podendo assumir qualquer posição dentro dos limites pré-definidos da área de cobertura.

Em cada iteração do processo de otimização, uma solução é formada por um conjunto de coordenadas que define a posição dos UAV-BSs na região de cobertura. Para avaliar o desempenho dessas configurações, utiliza-se a função objetivo, demonstrada na Equação 3.12, que associa a qualidade da solução à quantidade de usuários conectados (uma analogia à busca pelo néctar mais valioso). Quando uma nova disposição espacial dos UAVs resulta em melhor cobertura ou maior qualidade de sinal, ela é considerada superior à anterior e passa a ser armazenada como a melhor solução identificada até aquele ponto da busca, representando, de forma figurada, uma fonte mais rica de néctar (LI et al., 2019), conforme apresentado no Algoritmo 1.

Algoritmo 1: U-ABC: Algoritmo da Colônia Artificial de Abelhas para Posicionamento de UAV-BSs

Entrada: Número de UAVs m , número de usuários u , tamanho da população $n_{abelhas}$, número máximo de iterações $max_iteracao$, área de cobertura $espaco_busca$

Saída: Solução ótima $S_{otima} = [S_1, S_2, \dots, S_m]$

início

Selecionar aleatoriamente a posição de u usuários e m UAV-BSs, com coordenadas no $espaco_busca \in \mathbb{R}^2$, para inicializar U soluções;

Calcular os valores de aptidão das U soluções e registrar a melhor solução S_{otima} ;

Definir $iteracao \leftarrow 0$;

while $iteracao < max_iteracao$ **do**

para cada abelha empregada $i = 1$ até $|U|$ **faça**

 Gerar uma nova solução candidata, conforme Equação 2.1;

se $aptidao(n_i) > aptidao(s_i)$ **então**

 Substituir s_i por n_i ;

fim

fim

 Calcular as probabilidades de seleção para abelhas observadoras, conforme Equação 2.2;

para cada abelha observadora **faça**

 Gerar número aleatório $rand \in [0, 1]$;

se $rand < p_i$ **então**

 Selecionar s_i e aplicar mesma equação da abelha empregada para gerar nova solução;

se $aptidao(n_i) > aptidao(s_i)$ **então**

 Substituir s_i por n_i ;

fim

fim

fim

para cada solução que não melhorou após número limite de iterações **faça**

 Substituir por nova solução aleatória;

fim

 Recalcular os valores de aptidão das U soluções e atualizar S_{otima} ;

se $aptidao == u$ **então**

break;

fim

 Atualizar $iteracao \leftarrow iteracao + 1$;

end

fim

3.2.5.2 Implementação do algoritmo Ant Colony Optimization (ACO)

A implementação do ACO no presente estudo adapta o algoritmo para trabalhar em um espaço de busca contínuo, onde cada solução é representada por um conjunto de coordenadas que define a posição dos UAV-BSs dentro da área de cobertura. As "formigas" no algoritmo correspondem a agentes exploradores que percorrem o espaço de busca, construindo soluções candidatas para o posicionamento dos UAV-BSs.

Cada formiga inicia seu percurso a partir de uma posição inicial e, baseada em uma função de transição probabilística, decide sua próxima movimentação no espaço de busca, considerando a influência do feromônio acumulado e a qualidade da cobertura que cada posição proporciona. Ao final de cada iteração, o conjunto de posições dos UAV-BSs formado pela colônia de formigas é avaliado por uma função fitness, que mede a cobertura de usuários e a qualidade do sinal. As melhores soluções encontradas recebem uma maior deposição de feromônio, incentivando que futuras iterações do algoritmo explorem essas regiões promissoras do espaço de busca. Dessa forma, o ACO ajusta dinamicamente o posicionamento dos UAV-BSs, maximizando a eficiência do provimento dos serviços de comunicação, conforme apresentado no Algoritmo 2.

Algoritmo 2: ACO: Otimização por Colônia de Formigas para Posicionamento de UAV-BSs

Entrada: Número de UAVs m , número de usuários u , tamanho da população $n_{formigas}$, número máximo de iterações $max_iteracao$, área de cobertura $espaco_busca$

Saída: Solução ótima $S_{otima} = [S_1, S_2, \dots, S_m]$

início

Inicializar a posição aleatória dos u usuários em $espaco_busca$;

Inicializar a matriz de feromônio τ ;

Definir $iteracao \leftarrow 0$;

while $iteracao < max_iteracao$ **do**

para cada $formiga\ k = 1$ **até** $n_{formigas}$ **faça**

 Inicializar a posição inicial dos UAV-BSs para a formiga k ;

para cada UAV $j = 1$ **até** m **faça**

 Escolher próxima posição S_j para o UAV-BS j com base na função de transição probabilística considerando τ e a função heurística de cobertura;

fim

 Armazenar solução construída pela formiga k ;

fim

 Avaliar todas as soluções construídas utilizando a função de aptidão;

 Atualizar a melhor solução S_{otima} , se necessário;

 Evaporar parcialmente o feromônio em todas as posições da matriz τ ;

 Depositar feromônio adicional nas posições dos UAV-BSs das melhores soluções;

se $aptidao == u$ **então**

break;

fim

 Atualizar $iteracao \leftarrow iteracao + 1$;

end

fim

3.2.5.3 Implementação do Algoritmo Genético (AG)

A implementação do AG no presente estudo adapta o algoritmo para otimizar o posicionamento dos UAV-BSs em um espaço de busca contínuo. Nesse contexto, cada indivíduo da população representa uma possível solução, ou seja, um conjunto de coordenadas espaciais que define as posições dos UAV-BSs na área de cobertura. A evolução da população ocorre por meio de operadores genéticos que simulam o processo de seleção natural, buscando continuamente aprimorar a cobertura dos usuários e a qualidade do sinal.

Inicialmente, uma população de soluções candidatas é gerada aleatoriamente, onde cada cromossomo é um vetor contendo as coordenadas dos UAV-BSs. A função fitness avalia a

qualidade de cada solução com base no número de usuários atendidos e na intensidade do sinal. Para a seleção dos pares de indivíduos que participarão da reprodução, foi adotada a seleção por torneio, em detrimento da roleta proporcional. Essa escolha se justifica pela maior robustez do torneio frente a variações na escala dos valores de fitness, além de proporcionar maior controle sobre a pressão seletiva ao ajustar o tamanho do torneio. Tais características são especialmente desejáveis em problemas contínuos com grande espaço de busca, como o posicionamento de UAV-BSs, onde se busca evitar a convergência prematura e manter a diversidade da população.

O processo de crossover permite a troca de informações entre soluções bem-sucedidas, combinando diferentes configurações de posicionamento dos UAV-BSs para criar novas soluções promissoras. Já a mutação introduz pequenas variações nas posições dos UAV-BSs, permitindo que o algoritmo explore novas regiões do espaço de busca e evite o estagnamento em ótimos locais.

Para a atualização da população ao final de cada geração, optou-se por aplicar a seleção elitista, que garante a preservação das melhores soluções já encontradas ao longo das gerações. Essa abordagem é preferível à seleção truncada simples, pois assegura que os indivíduos de maior aptidão não sejam descartados, promovendo uma evolução mais eficiente e segura do ponto de vista da qualidade global da população.

Ao longo das gerações, a população evolui de forma adaptativa, refinando as posições dos UAV-BSs até alcançar uma configuração que maximize a cobertura e otimize a eficiência do sistema de comunicação.

Algoritmo 3: AG: Algoritmo Genético para Posicionamento de UAV-BSs

Entrada: Número de UAVs m , número de usuários u , tamanho da população N , número de gerações $max_geracao$, taxa de crossover p_c , taxa de mutação p_m , área de cobertura $espaço_busca$

Saída: Solução ótima $S_{ótima} = [S_1, S_2, \dots, S_m]$

início

Inicializar aleatoriamente uma população de N indivíduos, onde cada indivíduo é um vetor com m coordenadas de UAV-BSs dentro do $espaço_busca$;

Avaliar a aptidão de cada indivíduo com base na cobertura de usuários e qualidade do sinal;

Registrar a melhor solução $S_{ótima}$;

para geração = 1 até $max_geracao$ **faça**

Seleção: Selecionar os pares de indivíduos pelo método de torneio com base na aptidão;

Crossover com probabilidade p_c :

para cada par de indivíduos selecionados **faça**

 Realizar recombinação de genes (coordenadas de UAVs) para gerar novos filhos;

fim

Mutação com probabilidade p_m :

para cada filho gerado **faça**

 Perturbar aleatoriamente uma ou mais coordenadas com ruído dentro de $espaço_busca$;

fim

 Avaliar a aptidão da nova população (pais + filhos);

 Selecionar os N melhores indivíduos, pelo método elitista, para a próxima geração;

 Atualizar $S_{ótima}$ se uma nova solução melhor for encontrada;

se aptidão == u **então**

break;

fim

fim

fim

3.2.5.4 Implementação do Particle Swarm Optimization (PSO)

A implementação do PSO no presente estudo adapta o algoritmo para trabalhar em um espaço de busca contínuo, onde cada partícula da população representa uma possível solução, ou seja, um conjunto de coordenadas espaciais que define as posições dos UAV-BSs na área de cobertura. As partículas movem-se no espaço de busca ajustando suas posições com base em

suas experiências individuais e na experiência coletiva do enxame.

Inicialmente, um conjunto de partículas é distribuído aleatoriamente dentro dos limites da área de cobertura. Cada partícula possui uma posição e uma velocidade associadas, sendo a posição correspondente às coordenadas dos UAV-BSs e a velocidade determinando a taxa de mudança dessas coordenadas. A qualidade de cada solução é avaliada por uma função fitness, que mede a cobertura dos usuários e a qualidade do sinal.

Durante cada iteração, as partículas ajustam suas posições com base em dois fatores principais: Melhor posição individual (pbest), onde cada partícula armazena a melhor posição que encontrou até o momento, ou seja, a configuração que proporcionou maior cobertura e melhor qualidade de sinal, e melhor posição global (gbest), que, dentre todas as partículas, identifica a melhor solução encontrada pelo enxame, que é utilizada para guiar as demais partículas em direção a regiões mais promissoras do espaço de busca.

A atualização da posição de cada partícula é feita por meio de uma equação de movimentação que equilibra a exploração global e a exploração local. Esse processo iterativo permite que as partículas convirjam para uma configuração otimizada, garantindo um posicionamento eficiente dos UAV-BS, conforme apresentado no Algoritmo 4.

Algoritmo 4: PSO: Otimização por Enxame de Partículas para Posicionamento de UAV-BSs

Entrada: Número de UAVs m , número de partículas N , número máximo de iterações max_iter , área de cobertura $espaco_busca$, conjunto de usuários U

Saída: Solução ótima $S_{ótima} = [S_1, S_2, \dots, S_m]$

início

Inicializar aleatoriamente as posições $P[i]$ e velocidades $V[i]$ das N partículas dentro de $espaco_busca$;

Avaliar a aptidão de cada partícula com base na cobertura de usuários e na qualidade do sinal;

Armazenar a melhor posição individual $pbest[i]$ e identificar a melhor posição global $gbest$;

para $iter = 1$ até max_iter **faça**

para cada partícula i **faça**

 Atualizar a velocidade $V[i]$ com base na Equação 2.6;

 Atualizar a posição $P[i] \leftarrow P[i] + V[i]$;

 Aplicar limites ao espaço de busca se necessário;

 Avaliar nova aptidão de $P[i]$;

se $nova_aptidao > aptidao_de_pbest[i]$ **então**

 Atualizar $pbest[i] \leftarrow P[i]$;

fim

se $aptidao_de_pbest[i] > aptidao_de_gbest$ **então**

 Atualizar $gbest \leftarrow pbest[i]$;

fim

fim

se $aptidao(gbest) == u$ **então**

break;

fim

fim

Definir $S_{ótima} \leftarrow gbest$;

fim

3.2.5.5 Implementação do Teaching-Learning-Based Optimization (TLBO)

A implementação do TLBO no presente estudo adapta o algoritmo para otimizar o posicionamento dos UAV-BSs em um espaço de busca contínuo. Nesse contexto, cada solução candidata é representada por um aluno, que corresponde a um conjunto de coordenadas espaciais definindo as posições dos UAV-BSs dentro da área de cobertura. O algoritmo baseia-se no processo de ensino-aprendizagem, no qual as soluções são refinadas iterativamente por meio da influência de um professor e da troca de conhecimento entre os alunos, buscando maximizar a

cobertura dos usuários e a qualidade do sinal.

Inicialmente, um conjunto de soluções é gerado de forma aleatória, representando diferentes configurações possíveis para os UAV-BSs. Durante o processo de otimização, o melhor aluno da população, que corresponde à melhor configuração encontrada até o momento, assume o papel de professor. Sua influência sobre os demais alunos leva à atualização das posições dos UAV-BSs, na tentativa de aproximar as demais soluções daquela que apresenta o melhor desempenho. Esse aprendizado induz um ajuste progressivo das soluções em direção a regiões do espaço de busca que oferecem maior cobertura e melhor qualidade de sinal.

Além da influência do professor, os alunos também interagem entre si, comparando suas soluções e buscando melhorias a partir do conhecimento compartilhado. Caso uma solução encontrada por um aluno apresente um desempenho superior ao de outro, a posição do UAV-BSs correspondente pode ser ajustada para refletir essa melhoria.

A função fitness avalia cada configuração de UAV-BSs com base no número de usuários atendidos e na intensidade do sinal, garantindo que apenas as melhores soluções sejam mantidas ao longo das iterações. Com isso, a população evolui de forma contínua, refinando as posições dos UAV-BSs até atingir uma configuração otimizada que maximize a eficiência do sistema de comunicação, conforme apresentado no Algoritmo 5.

Algoritmo 5: TLBO: Ensino-Aprendizagem para Posicionamento de UAV-BSs

Entrada: Número de UAVs m , tamanho da população N , número de usuários u , número máximo de iterações max_iter , área de cobertura $espaco_busca$

Saída: Solução ótima $S_{ótima} = [S_1, S_2, \dots, S_m]$

início

Inicializar aleatoriamente uma população de N alunos, onde cada aluno representa uma configuração de coordenadas dos UAV-BSs dentro do $espaco_busca$;

Avaliar a aptidão de cada aluno com base na cobertura de usuários e na qualidade do sinal;

iter \leftarrow 1;

while iter \leq max_iter **do**

Fase de Ensino::

 Identificar o melhor aluno T (professor), com maior aptidão;

 Calcular o vetor médio \bar{X} da população;

para cada aluno X_i **faça**

 Gerar novo aluno X'_i com base na influência do professor, conforme descrito na Equação 2.8;

 Avaliar a aptidão de X'_i ;

se $aptidao(X'_i) > aptidao(X_i)$ **então**

 Atualizar $X_i \leftarrow X'_i$;

fim

fim

Fase de Aprendizagem::

para cada par de alunos (X_i, X_j) com $i \neq j$ **faça**

 Realizar ajuste da solução, conforme Equação 2.9;

 Avaliar a aptidão de X'_i ;

se $aptidao(X'_i) > aptidao(X_i)$ **então**

 Atualizar $X_i \leftarrow X'_i$;

fim

fim

se $aptidao == u$ **então**

break;

fim

 iter \leftarrow iter + 1;

end

Retornar a melhor solução $S_{ótima}$ encontrada na população;

fim

3.2.6 Justificativa para escolha dos Algoritmos

A seleção dos algoritmos baseou-se em suas aplicabilidades a problemas de otimização contínua e sua capacidade de adaptação a cenários dinâmicos. Buscou-se comparar os algoritmos de otimização meta-heurísticos que mais são aplicados, na literatura, para solução de posicionamento de UAV-BSs - não se resumindo somente a esses mais comuns, para dar uma maior abrangência no estudo. Os algoritmos de otimização bio-inspirados foram escolhidos por serem classificados com base nos fenômenos biológicos que emulam. Suas categorias comuns incluem algoritmos evolutivos, inteligência de enxame e outros métodos inspirados na natureza e comportamento social. Os algoritmos evolutivos, como Algoritmos Genéticos (AG) e Colônia de Abelhas Artificial (ABC), simulam a seleção natural e os comportamentos de forrageamento, respectivamente. Os algoritmos de inteligência de enxame, como Otimização por Enxame de Partículas (PSO) e Otimização por Colônia de Formigas (ACO), imitam o comportamento coletivo de organismos sociais (WU; LI; WEI, 2023).

Cada algoritmo deste estudo oferece vantagens específicas, como simplicidade (ABC), forte capacidade de exploração (ACO) e convergência rápida (AG, PSO e TLBO), tornando-os adequados para a análise comparativa.

3.2.7 Metodologia para escolha dos parâmetros

A definição dos parâmetros de controle de algoritmos meta-heurísticos representa um fator decisivo para o desempenho obtido na resolução de problemas de otimização, sendo reconhecida como uma das etapas mais sensíveis tanto na fase de desenvolvimento quanto na de comparação entre diferentes métodos. Conforme destacado por (HUANG; LI; YAO, 2020), o ajuste adequado de parâmetros pode ser realizado por meio de diferentes estratégias, com destaque para os métodos de *parameter tuning* (ou ajuste *off-line*), os quais consistem em identificar, antes da execução do algoritmo, as melhores combinações de valores que maximizem o desempenho esperado. Esses métodos diferem do *parameter control* (ajuste *on-line*), que atua dinamicamente durante a execução do algoritmo, mas cuja aplicação exige um maior conhecimento sobre o comportamento interno da técnica e do problema abordado.

No contexto do *parameter tuning*, os autores classificam as estratégias em três categorias principais: métodos simples de gerar-e-avaliar (como *brute-force* e *F-Race*), métodos iterativos (como *ParamILS*, *CALIBRA* e *irace*) e métodos de alto nível, que utilizam modelos sofisticados para explorar regiões promissoras do espaço de configurações. Ainda que este trabalho não tenha empregado um autotuner automatizado, as decisões de configuração dos parâmetros seguiram uma lógica inspirada nessas abordagens iterativas, baseando-se na análise progressiva de desempenho a partir de diferentes combinações e na adaptação do conjunto de valores segundo a resposta observada do algoritmo.

Paralelamente, (KAZIKOVA; PLUHACEK; SENKERIK, 2020) reforçam que compara-

ções justas entre algoritmos requerem o uso criterioso de configurações de parâmetros. O uso de valores padrão, muitas vezes extraídos diretamente de propostas originais ou bibliotecas de referência, pode comprometer a validade das conclusões, sobretudo quando tais parâmetros não foram calibrados para a dimensão ou natureza do problema considerado. Os autores demonstram empiricamente que diferentes configurações resultam em desempenhos estatisticamente distintos, sendo fundamental adequar os parâmetros ao perfil específico da tarefa, como a dimensionalidade do espaço de busca e o tipo de função objetivo.

Considerando tais recomendações, o processo de escolha dos parâmetros adotado nesta pesquisa seguiu um roteiro sistemático. Em um primeiro momento, foram adotados valores comumente utilizados na literatura especializada para cada um dos algoritmos analisados, com base em publicações consolidadas e bibliotecas reconhecidas (como EvoloPy) (FARIS; ALJARA; MIRJALILI, 2016). Em seguida, procedeu-se a um refinamento desses valores por meio de uma abordagem empírica iterativa, similar à filosofia dos métodos de *tuning* baseados em busca heurística. Foram realizadas diversas execuções preliminares variando os parâmetros dentro de faixas plausíveis, com análise estatística dos resultados quanto ao desempenho médio e variância. A cada rodada, os valores com melhor desempenho foram mantidos como referência para novos ajustes incrementais, até que se atingisse um ponto de estabilidade nos resultados, associado a uma configuração de parâmetros eficaz para a dimensionalidade e complexidade do problema tratado.

Assim, a seleção final dos parâmetros não se deu de forma arbitrária, mas seguiu uma estratégia orientada pelas boas práticas recomendadas nos estudos de (HUANG; LI; YAO, 2020) e (KAZIKOVA; PLUHACEK; SENKERIK, 2020). Essa abordagem assegura não apenas a reprodutibilidade dos experimentos, mas também a confiabilidade dos resultados comparativos entre os algoritmos testados, fortalecendo as conclusões obtidas ao longo deste trabalho. A Tabela 9 apresenta os parâmetros utilizados para cada algoritmo na simulação:

Tabela 9 – Parâmetros utilizados nos algoritmos de otimização

Algoritmo	Parâmetro	Valor	Algoritmo	Parâmetro	Valor
ABC	Máximo de iterações	200	AG	Número de gerações	250
	População	20		População	100
	Limite	10		Taxa de mutação	0.1
				Taxa de cruzamento	0.9
			Operador cruzamento	Aritmético	
			Operador seleção	Torneio	
			Operador mutação	Gaussiana	
ACO	Taxa de evaporação	0.1	PSO	Número de partículas	200
	Feromônios (α)	1		Máximo de iterações	10
	Informação heurística (β)	2		Peso da inércia	0.5
	Depósito de feromônio	1		Peso cognitivo	0.5
	Feromônio inicial	0.5		Peso social	0.8
	Máximo de iterações	100			
	Número de formigas	100			
TLBO	Máximo de iterações	400			
	Taxa de aprendizado	1.0			
	Número de alunos	100			

3.2.8 Avaliação Comparativa dos Algoritmos

Para o cenário de avaliação, foi utilizado um computador equipado com um processador Intel(R) Core (TM) i5-8350U CPU 1.70GHz - 1.90GHz, com 8GB de memória RAM. Foram testadas variações de 2 a 6 UAV-BSs nos experimentos, executando cada algoritmo 30 vezes para cada configuração. Essa abordagem permitiu avaliar a convergência e a capacidade de resiliência dos algoritmos em diferentes condições.

3.2.8.1 Cálculo de superioridade

A fórmula utilizada para calcular a superioridade percentual de uma meta-heurística sobre a outra é dada por:

$$S(\%) = \left(\frac{\theta - \iota}{\iota} \right) \times 100 \quad , \quad (3.11)$$

sendo: $S(\%)$ a superioridade de um algoritmo em relação ao outro, medida em percentual, onde θ é o valor de uma métrica da meta-heurística avaliada e ι é o valor de uma métrica da meta-heurística comparada.

3.2.9 Função Fitness

O objetivo do problema é maximizar a cobertura dos usuários dentro da área de comunicação sem fio, garantindo que cada usuário possua um nível mínimo de SINR aceitável e otimizando a capacidade da rede. A função fitness é apresentada na Equação 3.12.

$$\max_X f(X) = w_1 \cdot U(X) + w_2 \cdot C(X) + w_3 \cdot \text{SINR}_{\text{avg}}(X) \quad , \quad (3.12)$$

sendo que:

- $X = \{(x_i, y_i)\}_{i=1}^m$ representa o conjunto de posições dos m UAV-BSs na área de cobertura;
- $U(X)$ é o número de usuários cobertos pelos UAV-BSs;
- $C(X)$ é a capacidade média (vazão média) da rede, em bits por segundo (bps);
- $\text{SINR}_{\text{avg}}(X)$ é o SINR médio recebido pelos usuários conectados;
- w_1, w_2, w_3 são pesos ajustáveis que controlam a importância de cada termo na função de otimização.

Os componentes da função fitness usuários conectados $U(X)$, capacidade média (vazão média) da rede e SINR médio recebido pelo usuário conectado são definidos pelas Equações 3.13, 3.14 e 3.15, respectivamente:

$$U(X) = \sum_{j=1}^u \mathbf{1}(\text{SINR}_j(X) \geq \text{SINR}_{\text{min}}) \quad , \quad (3.13)$$

sendo:

- u o número total de usuários;
- $\text{SINR}_j(X)$ o SINR recebido pelo usuário j na posição (x_i, y_i) ;
- SINR_{min} o limiar mínimo necessário para considerar um usuário conectado;
- $\mathbf{1}(\cdot)$ uma função indicadora que vale 1 se a condição for verdadeira (ou seja, o usuário está conectado) e 0 caso contrário.

$$C(X) = \frac{1}{U(X)} \sum_{j \in \mathcal{U}(X)} B \cdot \log_2(1 + \text{SINR}_j(X)) \quad , \quad (3.14)$$

sendo que:

- $\mathcal{U}(X)$ é o conjunto de usuários conectados;
- B é a largura de banda disponível (Hz);

- $SINR_j(X)$ é o valor do SINR do usuário j ,

$$SINR_{avg}(X) = \frac{1}{U(X)} \sum_{j \in \mathcal{U}(X)} SINR_j(X) \quad , \quad (3.15)$$

sendo:

- $SINR_{avg}(X)$: valor médio do SINR para os usuários conectados;
- $U(X)$: número de usuários conectados,

esse termo busca garantir que os usuários conectados possuam boa qualidade de sinal.

Para este problema, foram elaboradas as restrições de conjunto factível de soluções no espaço de busca contínuo (que representa os UAV-BSs dentro da área de cobertura) e SINR mínimo para conexão, com o objetivo de garantir que a solução seja viável, conforme Equações 3.16 e 3.17:

$$X \in \Omega \subset \mathbb{R}^{2N}, \quad \text{com} \quad 0 \leq x_i \leq G_r, \quad 0 \leq y_i \leq G_r, \quad \forall i = 1, \dots, N, \quad (3.16)$$

sendo:

- X : vetor de decisão que agrupa as coordenadas (x_i, y_i) de todos os UAV-BSs;
- Ω : conjunto factível de soluções dentro do espaço de busca contínuo;
- \mathbb{R}^{2N} : espaço vetorial real de dimensão $2N$, correspondente às coordenadas (x_i, y_i) de N UAV-BSs;
- G_r : dimensão máxima da área de cobertura (limite superior das coordenadas);
- x_i, y_i : coordenadas do UAV-BS i , com $i = 1, \dots, N$.

$$SINR_j(X) \geq SINR_{min}, \quad \forall j \in \mathcal{U}(X) \quad , \quad (3.17)$$

sendo que a distância máxima de cobertura não tem uma fórmula explícita fechada, mas é obtida numericamente pela função, que busca o menor valor de d tal que o SINR fique maior do que o limite do $SINR_{min}$.

Considerou-se metodologicamente mais vantajoso simplificar a função objetivo para um único critério dominante. Ao definir $w1=1$ (usuários conectados), $w2=0$ (capacidade média da rede) e $w3=0$ (SINR médio recebido), conseguimos isolar a capacidade intrínseca de cada

meta-heurística em explorar o espaço de busca para alcançar a máxima cobertura de usuários. Se múltiplos objetivos fossem ponderados, a análise se tornaria um problema multi-objetivo mais complexo, com trade-offs que poderiam mascarar o desempenho puro de cada algoritmo na tarefa de cobrir usuários de forma abrangente. Esta abordagem permite uma avaliação mais clara e direta de qual algoritmo é mais eficaz em posicionar os UAV-BSs para atingir esse objetivo primário, onde o objetivo mais crítico e imediato é restabelecer a comunicação básica para o maior número possível de usuários.

4 RESULTADOS

Este capítulo tem como propósito principal apresentar os dados e as análises obtidas a partir das simulações realizadas. Este capítulo foi cuidadosamente desenvolvido para ilustrar e fundamentar as conclusões da pesquisa, organizando e discutindo os dados com base nas métricas de desempenho avaliadas, como eficiência de cobertura, qualidade de serviço e tempo médio de execução dos algoritmos analisados.


Em sua estrutura, o capítulo inicia com Considerações Iniciais, onde são detalhados os aspectos do ambiente computacional utilizado para a avaliação. Esta seção também explica o cenário de simulação, incluindo a distribuição da posição dos usuários e a variância na quantidade de UAV-BSs testadas (de 2 a 6). Para garantir a confiabilidade estatística e a reprodutibilidade dos resultados. Após essa introdução, prossegue com a apresentação detalhada dos Resultados do posicionamento para cada meta-heurística individualmente, como ABC, ACO, AG, PSO e TLBO, culminando em uma Análise Comparativa entre todos os algoritmos avaliados.

4.1 Considerações Iniciais

Para o cenário de avaliação, foi utilizado um computador equipado com um processador Intel(R) Core (TM) i5-8350U CPU 1.70GHz - 1.90GHz, com 8GB de memória RAM.

A Figura 6 demonstra a distribuição da posição dos usuários no espaço de busca. Por se tratar de um cenário envolvendo múltiplos UAVs, em que vários dispositivos são necessários para solucionar um problema de restrição não linear, foram realizadas simulações variando a quantidade de UAV-BS de 2 a 6 nos experimentos.

Figura 6 – Distribuição dos usuários no espaço de busca.



Fonte: Elaborado pelo autor.

Para cada algoritmo, foram realizadas 30 (trinta) execuções com variação do posicionamento dos usuários, permitindo uma análise abrangente do desempenho. Essa abordagem é considerada suficiente para garantir a confiabilidade estatística dos resultados obtidos. Esse valor é amplamente aceito na literatura científica como um padrão que permite reduzir erros aleatórios, pois quanto maior o número de repetições, mais os erros ocasionais ou aleatórios são minimizados, oferecendo resultados mais precisos e estáveis, além de garantir robustez estatística, pois a distribuição das médias tende para uma normal, permitindo análises mais confiáveis (teorema central do limite). Com essa quantidade de repetições, torna-se possível avaliar a variabilidade e o desvio padrão, fornecendo uma visão clara sobre a consistência dos resultados.

A dinamicidade da distribuição da posição dos usuários, devido à repetição da simulação, promoveu adicionalmente o entendimento de como o algoritmo se comporta quando os usuários mudam seu posicionamento, caso comum quando ocorre a mobilidade dos usuários durante um período de tempo, porque a cada repetição a posição dos usuários é atualizada e alterada para outro ponto, fazendo com que o algoritmo atue novamente para a busca de um novo posicionamento ótimo.

4.2 Resultados do posicionamento

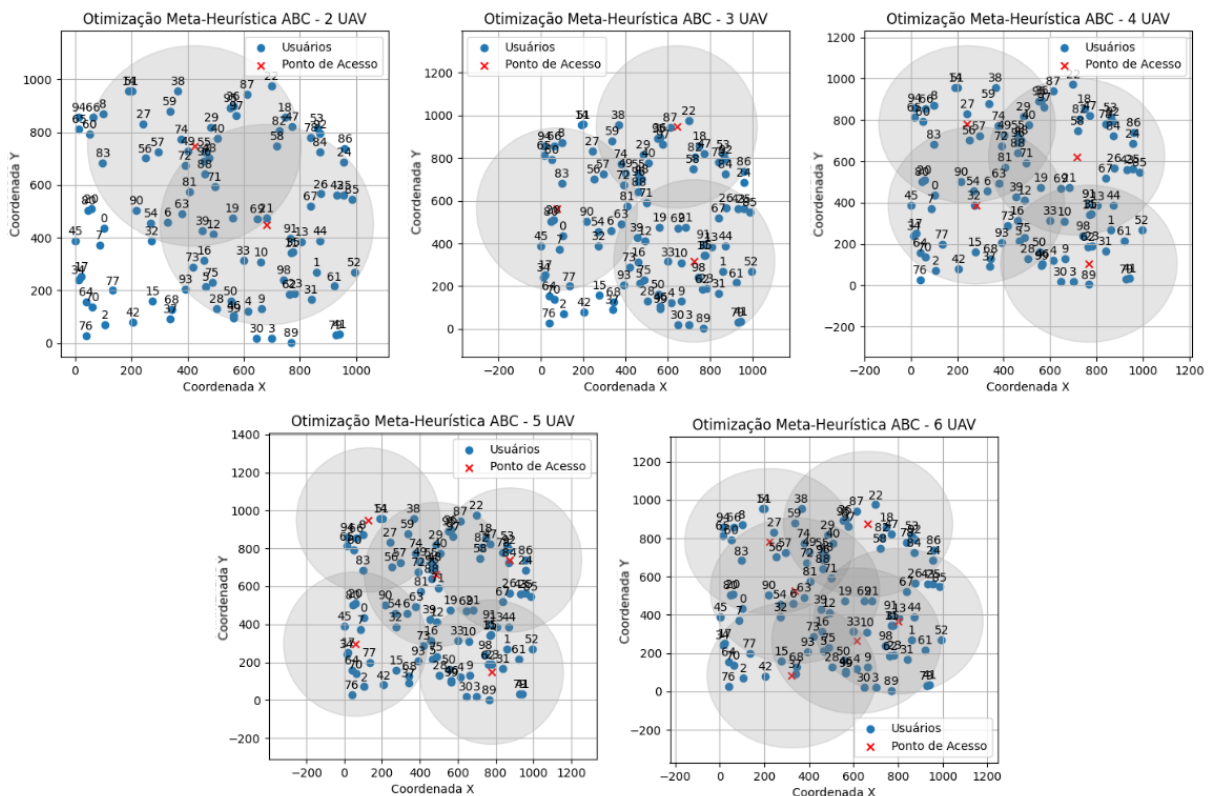
As meta-heurísticas estudadas para prover o posicionamento de UAV-BSs demonstraram ser ferramentas eficazes na resolução de problemas complexos de otimização em cenários de

comunicação. Algoritmos como ABC, ACO, AG, PSO e TLBO foram capazes de identificar posições estratégicas para os UAV-BSs, maximizando a cobertura de usuários em terra e otimizando recursos, como potência de transmissão e tempo de resposta. Cada meta-heurística, com suas características específicas, contribuiu para superar desafios como interferência, sobreposição de coberturas e conexão em áreas densamente povoadas, remotas ou em uma situação de emergência.

4.2.1 Resultado do posicionamento - Meta-heurística ABC

Por meio de um processo iterativo, o algoritmo ABC equilibrou eficazmente a exploração local e global do espaço de busca, proporcionando uma cobertura eficiente dos usuários. Essa abordagem demonstrou robustez ao ajustar dinamicamente o posicionamento dos UAV-BSs para maximizar o número de usuários conectados, reduzindo interferências e perdas de sinal. Os resultados obtidos com o algoritmo ABC utilizando entre 2 e 6 UAV-BSs são apresentados na Figura 7, ressaltando sua eficiência em cenários de alta complexidade.

Figura 7 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística ABC.



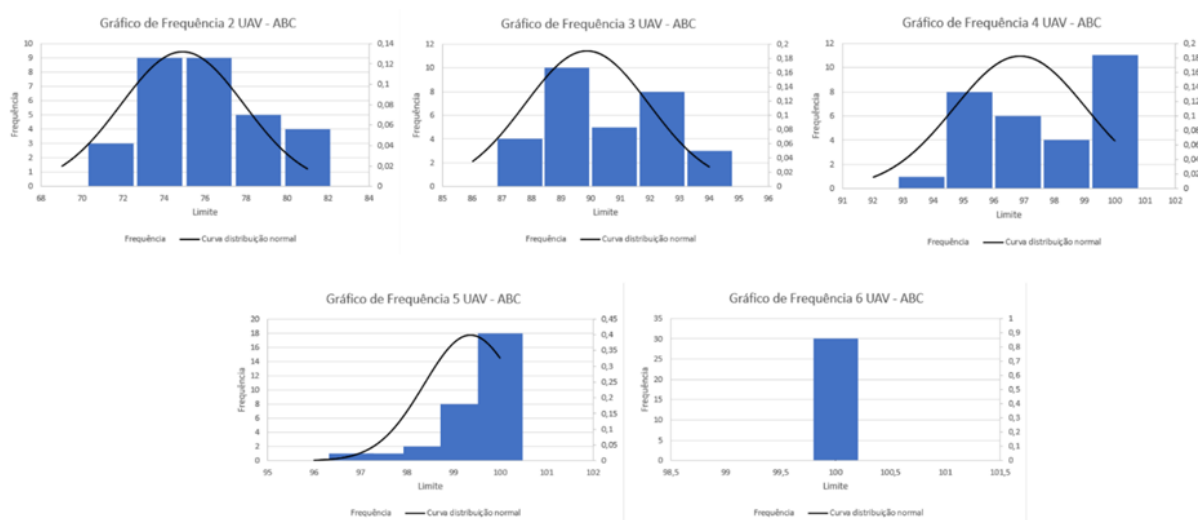
Fonte: Elaborado pelo autor.

Ao aumentar o número de UAV-BSs, é possível observar visualmente padrões que indicam uma melhora progressiva na quantidade de usuários cobertos. Contudo, percebe-se que há um limite de eficiência alcançado quando o algoritmo ABC utiliza 5 UAV-BSs, a partir do qual, pode-se estabelecer que incrementos adicionais oferecem ganhos mínimos ou desprezíveis na cobertura de usuários no espaço de busca.

4.2.1.1 Dados Estatísticos - Meta-heurística ABC

Os resultados estatísticos para a quantidade de usuários conectados pelo número de UAV-BSs da meta-heurística ABC são apresentados na Figura 8 por meio de gráficos de frequência que servem para compreender a variabilidade e consistência dos resultados, evidenciando a dispersão dos resultados, com o objetivo de mostrar se o algoritmo apresenta resultados consistentes ou se há muita variação entre as repetições do experimento.

Figura 8 – Histograma de Frequência com curva de distribuição normal – Algoritmo ABC.



Fonte: Elaborado pelo autor.

A Tabela 10 apresenta os valores mínimo, máximo, médio e desvio padrão correspondentes a cada quantidade de UAV-BSs. A partir desses dados, observa-se uma tendência de melhora na cobertura de usuários à medida que o número de UAV-BSs aumenta. Esse comportamento era esperado, pois um maior número de UAV-BSs reduz zonas sem cobertura e melhora a distribuição do sinal.

Tabela 10 – Dados estatísticos de usuários conectados por quantidade de UAV-BS para a meta-heurística ABC.

Quantidade de UAV-BS (unid.)	Mínimo (unid.)	Máximo (unid.)	Média (unid.)	Desvio Padrão (unid.)
2	69	81	74,900	3,021
3	86	94	89,867	2,097
4	92	100	96,867	2,193
5	96	100	99,367	0,999
6	100	100	100,000	0,000

Fonte: Elaborado pelo autor.

Além disso, verifica-se uma redução significativa da variabilidade conforme o número de UAV-BSs aumenta. O desvio padrão diminui progressivamente, indicando que o algoritmo convergiu para soluções mais estáveis e previsíveis. Por exemplo, a diferença entre o desvio padrão com 2 UAV-BSs (3,021) e com 5 UAV-BSs (0,999) é de 2,022, o que sugere que o aumento na quantidade de UAV-BSs reduz a dispersão dos resultados entre diferentes execuções.

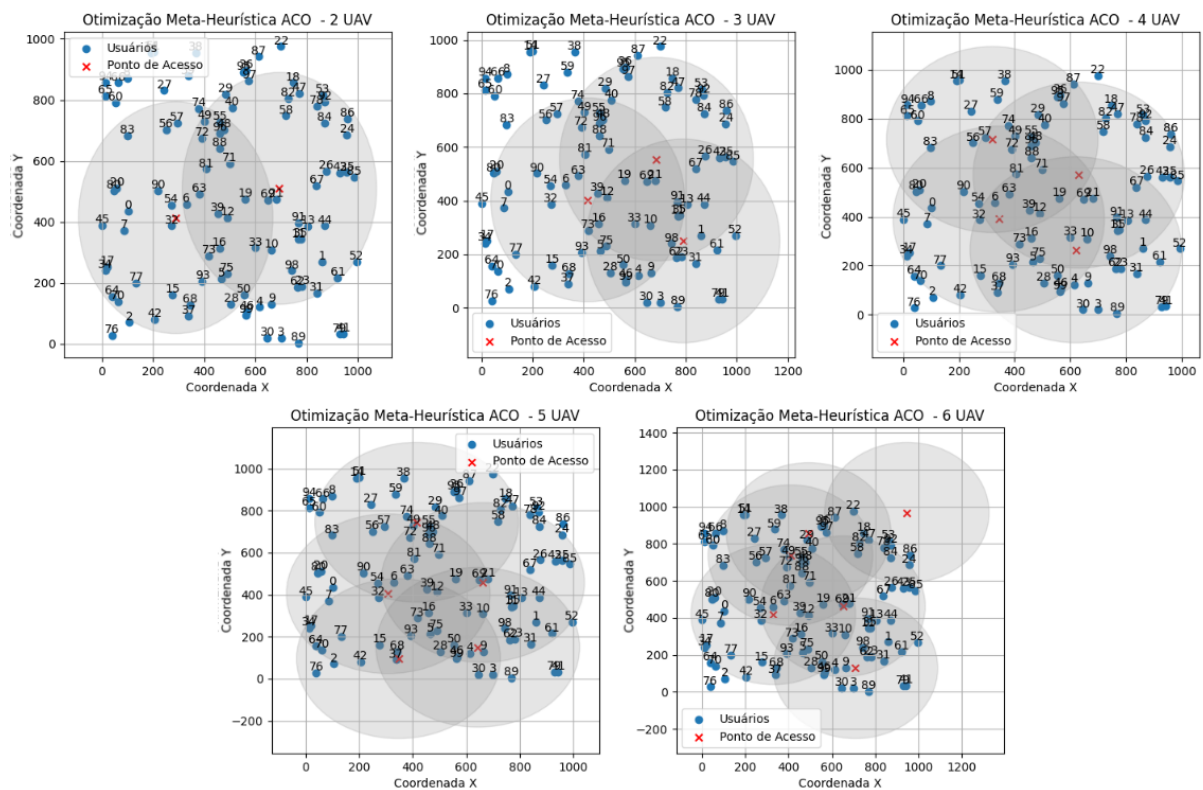
A análise dos resultados demonstra que o algoritmo ABC foi eficiente na otimização do posicionamento dos UAV-BSs. Com 4 UAV-BSs, a cobertura média já ultrapassa 96% (96,867 usuários). Com 5 UAV-BSs, a cobertura atinge 99,367%, apresentando um desvio padrão reduzido (0,999). Já com 6 UAV-BSs, a cobertura chega a 100% em todas as execuções, sem variação.

Esse comportamento sugere que o ponto de saturação pode ser determinado com maior precisão, ocorrendo a partir de 6 UAV-BSs, pois a cobertura se estabiliza em 100% sem qualquer oscilação. Dessa forma, adicionar mais UAV-BSs não traria benefícios adicionais à cobertura de usuários e poderia gerar custos desnecessários ou complexidades operacionais. Assim, os resultados indicam um possível número ótimo de UAV-BSs para alocação eficiente.

4.2.2 Resultado do posicionamento - Meta-heurística ACO

Baseando-se no comportamento cooperativo das formigas em busca de rotas ótimas. Através da atualização iterativa de feromônios e da seleção probabilística de soluções, o ACO apresentou um desempenho eficaz na determinação de posições que maximizam a conectividade dos usuários. O método demonstrou alta capacidade de convergência, reduzindo a probabilidade de sobreposições de cobertura. A Figura 9 ilustra os resultados alcançados pelo ACO, evidenciando sua eficiência no posicionamento estratégico com 2 a 6 UAV-BSs.

Figura 9 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística ACO.

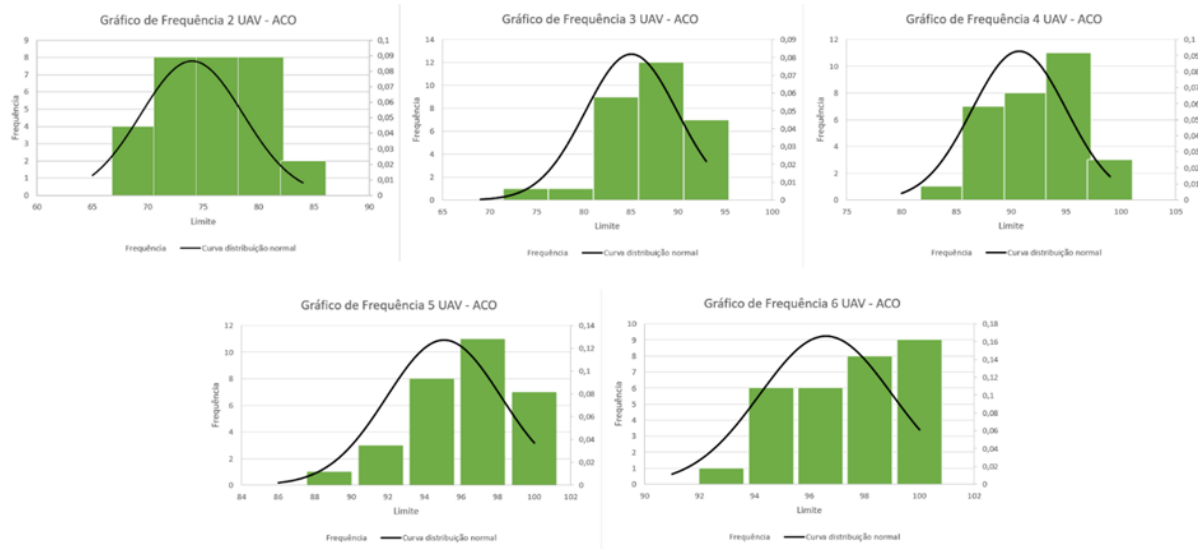


Fonte: Elaborado pelo autor.

4.2.2.1 Dados Estatísticos - Meta-heurística ACO

Para demonstrar os resultados estatísticos para a quantidade de usuários pelo número de UAV-BSs da meta-heurística ACO, a Figura 10 apresenta o histograma de frequência, enquanto a Tabela 11 mostra os valores mínimo, máximo, médio e o desvio padrão correspondentes a cada quantidade de UAV-BSs.

Figura 10 – Histograma de Frequência com curva de distribuição normal – Algoritmo ACO.



Fonte: Elaborado pelo autor.

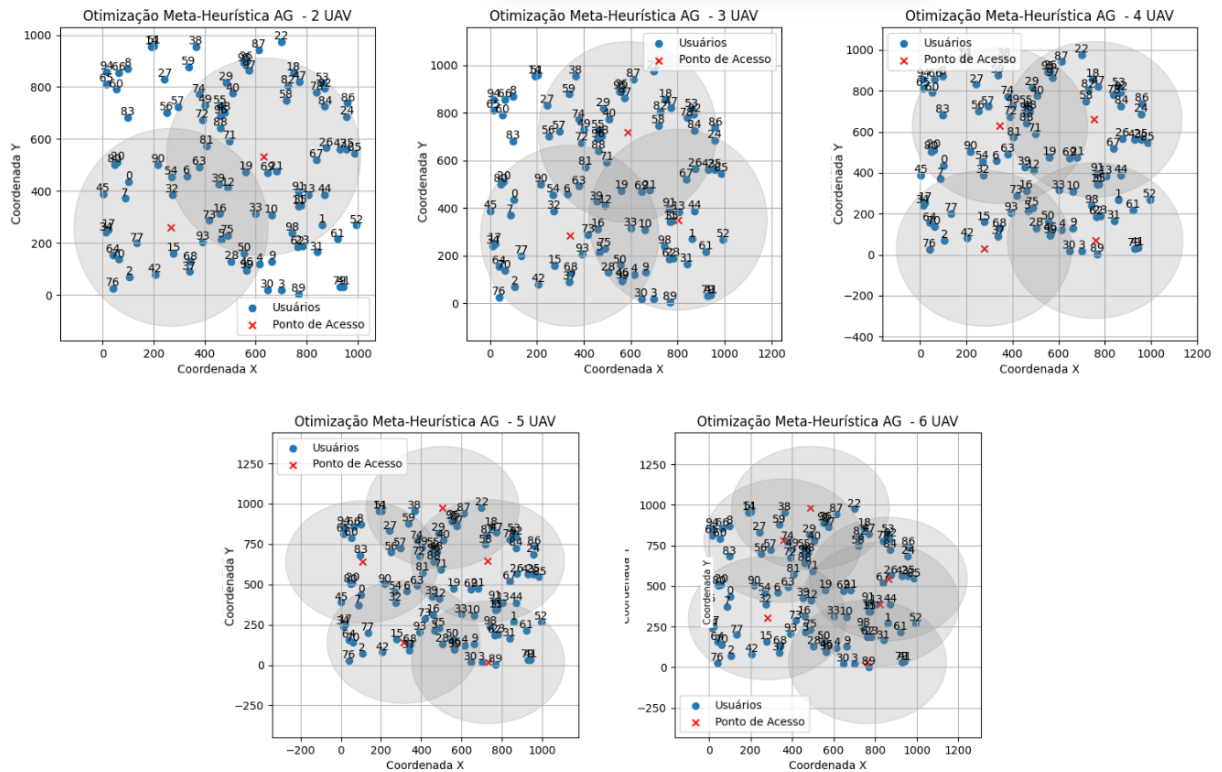
Tabela 11 – Dados estatísticos de usuários conectados por Quantidade de UAV para a meta-heurística ACO.

Quantidade de UAV-BS (unid.)	Mínimo (unid.)	Máximo (unid.)	Média (unid.)	Desvio Padrão (unid.)
2	65	84	74.000	4.609
3	69	93	85.033	4.888
4	80	99	90.733	4.307
5	86	100	95.067	3.140
6	91	100	96.600	2.401

4.2.3 Resultado do posicionamento - Meta-heurística AG

Por meio da aplicação de operadores genéticos, como seleção, cruzamento e mutação, o AG demonstrou ser capaz de explorar o espaço de busca de maneira equilibrada, reduzindo a probabilidade de convergência para mínimos locais. Essa abordagem permitiu a identificação de posições ideais para os UAV-BSs, maximizando a cobertura de usuários e otimizando os recursos disponíveis. Os resultados obtidos por meio dessa meta-heurística com 2 a 6 UAV-BSs são apresentados na Figura 11, ilustrando a eficácia do AG no ambiente simulado.

Figura 11 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística AG.

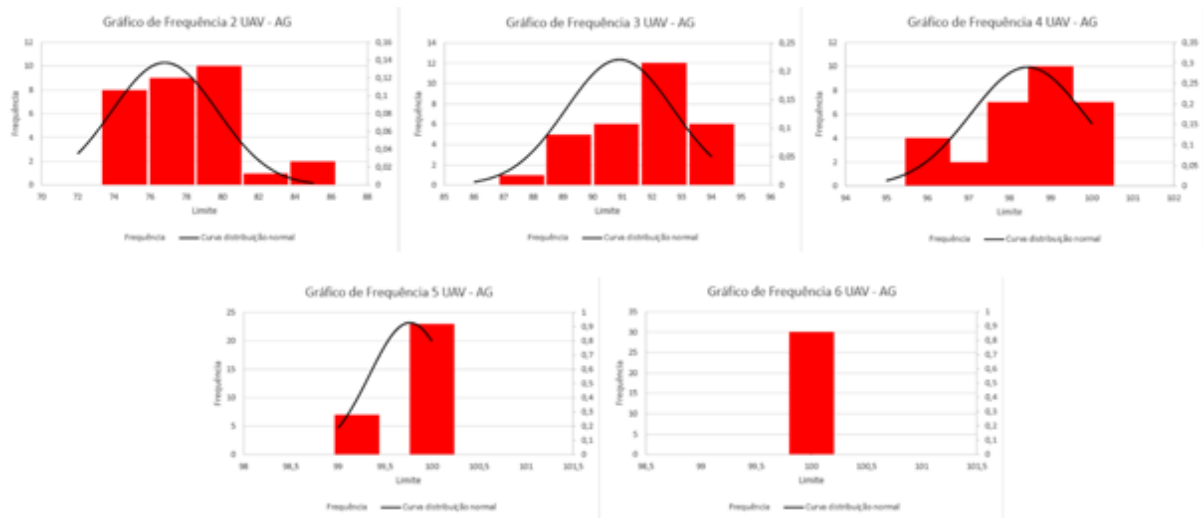


Fonte: Elaborado pelo autor.

4.2.3.1 Dados Estatísticos - Meta-heurística AG

Para demonstrar os resultados estatísticos para a quantidade de usuários pelo número de UAV-BSs da meta-heurística AG, a Figura 12 apresenta os gráficos de frequência, enquanto a Tabela 12 mostra os valores mínimo, máximo, médio e o desvio padrão correspondentes a cada quantidade de UAV-BSs.

Figura 12 – Histograma de Frequência com curva de distribuição normal – AG.



Fonte: Elaborado pelo autor.

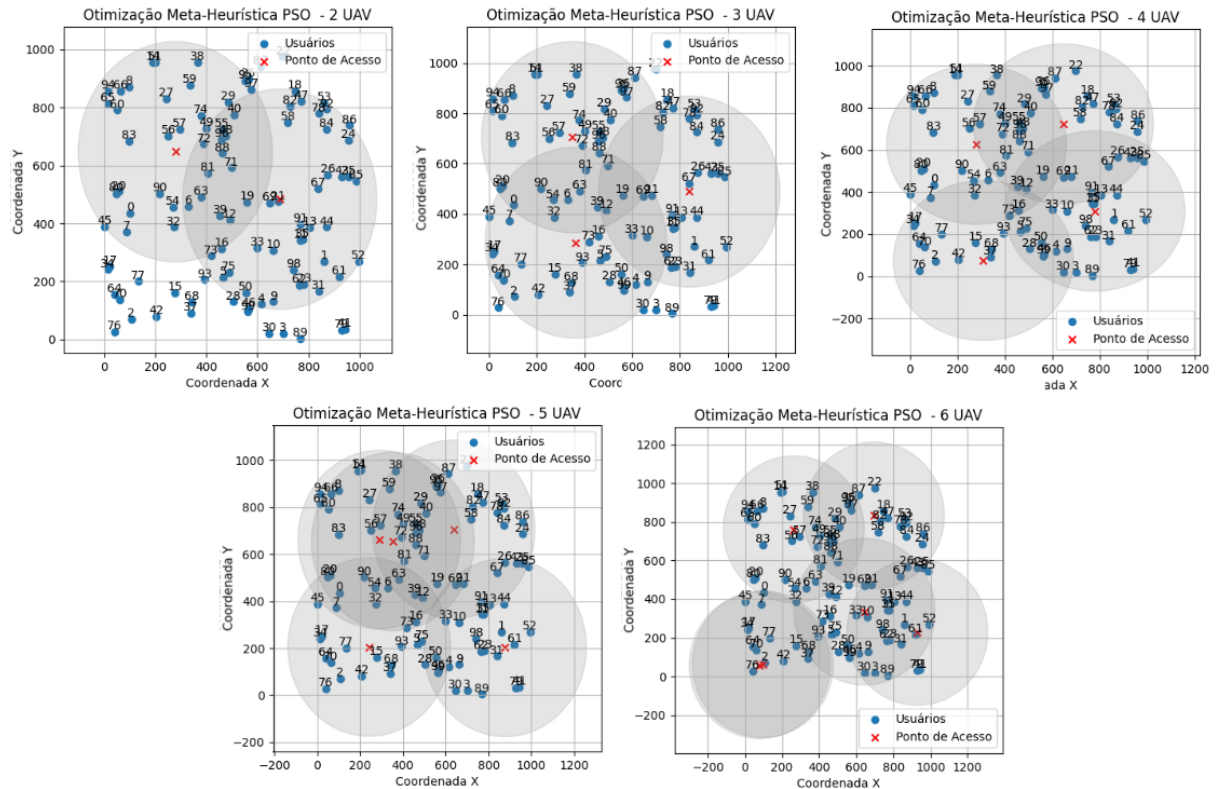
Tabela 12 – Dados estatísticos de usuários conectados por Quantidade de UAV-BS para a meta-heurística AG.

Quantidade de UAV-BS (unid.)	Mínimo (unid.)	Máximo (unid.)	Média (unid.)	Desvio Padrão (unid.)
2	72	85	76.800	2.917
3	86	94	90.900	1.807
4	95	100	98.433	1.382
5	99	100	99.767	0.430
6	100	100	100.000	0.000

4.2.4 Resultado do posicionamento - Meta-heurística PSO

Ao iterar sobre uma população de partículas, inspirado no comportamento coletivo de enxames, o PSO explorou o espaço de busca para identificar posições que otimizassem a cobertura dos usuários. A capacidade do algoritmo de ajustar dinamicamente as trajetórias das partículas, com base nas melhores soluções individuais e globais, foi essencial para alcançar resultados otimizados. A Figura 13 apresenta os resultados do posicionamento obtido pelo PSO com 2 a 6 UAV-BSs, demonstrando sua eficácia em cenários com necessidade de conectividade, demandada por usuários em terra.

Figura 13 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística PSO.

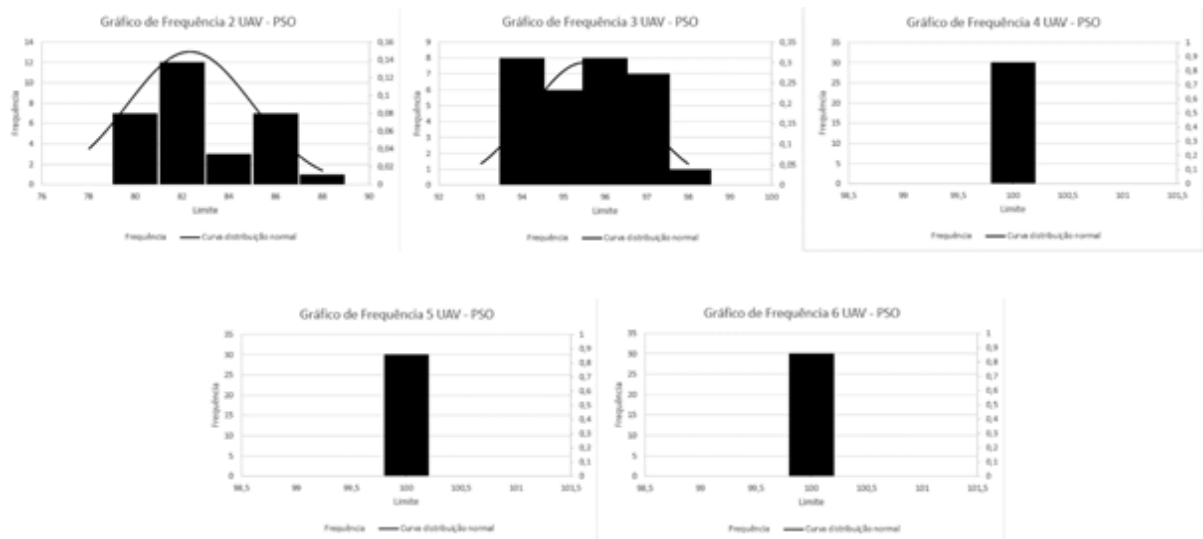


Fonte: Elaborado pelo autor.

4.2.4.1 Dados Estatísticos - Meta-heurística PSO

Para demonstrar os resultados estatísticos para a quantidade de usuários pelo número de UAV-BSs da meta-heurística PSO, a Figura 14 apresenta os gráficos de frequência, enquanto a Tabela 13 mostra os valores mínimo, máximo, médio e o desvio padrão correspondentes a cada quantidade de UAV-BSs.

Figura 14 – Histograma de Frequência com curva de distribuição normal - PSO.



Fonte: Elaborado pelo autor.

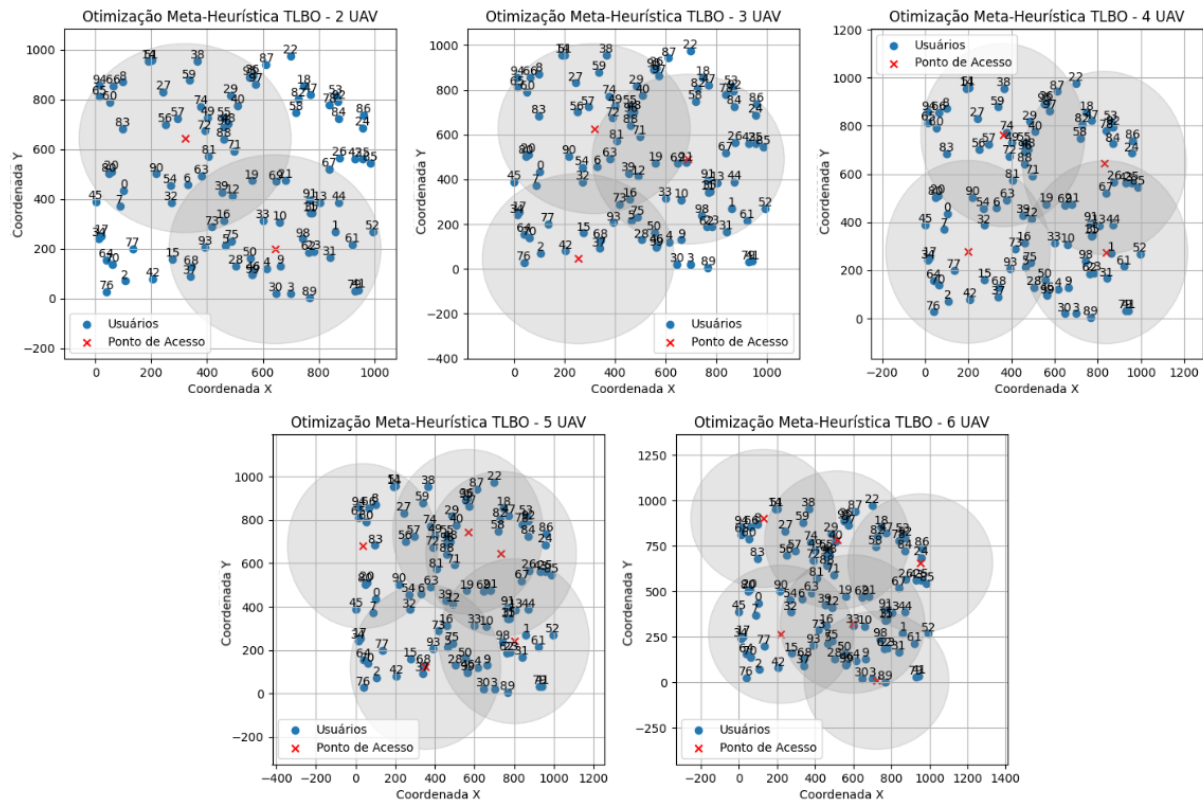
Tabela 13 – Dados estatísticos de usuários conectados por Quantidade de UAV-BS para a meta-heurística PSO.

Quantidade de UAV-BS (unid.)	Mínimo (unid.)	Máximo (unid.)	Média (unid.)	Desvio Padrão (unid.)
2	78	88	82.333	2.670
3	93	98	95.500	1.333
4	100	100	100.000	0.000
5	100	100	100.000	0.000
6	100	100	100.000	0.000

4.2.5 Resultado do posicionamento - Meta-heurística TLBO

Durante o processo de otimização, o TLBO ajustou iterativamente as posições dos UAV-BSs, explorando o espaço de busca inspirado na interação entre professores e alunos no processo de aprendizado para maximizar a conectividade dos usuários enquanto mantinha os custos computacionais reduzidos. A ausência de muitos parâmetros específicos de controle tornou o TLBO uma escolha eficiente, com rápida convergência e robustez em diferentes cenários. A Figura 15 apresenta os resultados do TLBO, evidenciando sua capacidade de encontrar soluções eficazes, utilizando de 2 a 6 UAV-BSs para o problema proposto.

Figura 15 – Cobertura de usuários alcançada com a utilização de 2 a 6 UAV-BSs, aplicando-se a meta-heurística TLBO.

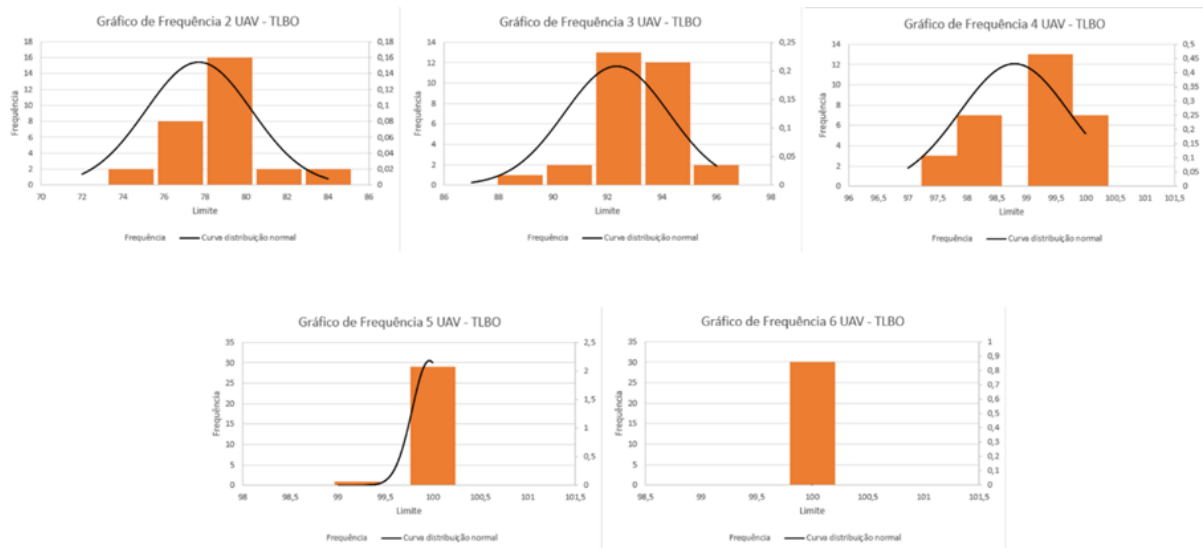


Fonte: Elaborado pelo autor.

4.2.5.1 Dados Estatísticos - Meta-heurística TLBO

Para demonstrar os resultados estatísticos para a quantidade de usuários pelo número de UAV-BSs da meta-heurística TLBO, a Figura 16 apresenta os gráficos de frequência, enquanto a Tabela 14 mostra os valores mínimo, máximo, médio e o desvio padrão correspondentes a cada quantidade de UAV-BSs.

Figura 16 – Histograma de Frequência com curva de distribuição normal – TLBO.



Fonte: Elaborado pelo autor.

Tabela 14 – Dados estatísticos de usuários conectados por Quantidade de UAV-BS para a meta-heurística TLBO.

Quantidade de UAV-BS (unid.)	Mínimo (unid.)	Máximo (unid.)	Média (unid.)	Desvio Padrão (unid.)
2	72	84	77.700	2.588
3	87	96	92.333	1.918
4	97	100	98.800	0.925
5	99	100	99.967	0.183
6	100	100	100.000	0.000


4.2.5.2 Considerações Finais

Os resultados obtidos nas simulações demonstraram alta consistência e confiabilidade, evidenciada por diversos indicadores estatísticos analisados. O baixo desvio padrão registrado em relação às médias dos resultados confirmou a baixa variabilidade entre as 30 (trinta) repetições do experimento. Além disso, a distribuição concentrada dos dados, observada claramente nos gráficos de frequência, reforçou a estabilidade dos valores obtidos. A análise estatística revelou também intervalos de confiança estreitos, destacando ainda mais a precisão dos resultados. A ausência significativa de valores discrepantes (outliers), somada à identificação clara de tendências previsíveis, fortaleceu a confiança na robustez do método empregado. Dessa forma, os resultados apresentaram excelente reprodutibilidade, ratificando a eficácia da abordagem adotada no experimento, comprovando a ideia de que essas técnicas não apenas oferecem soluções robustas e adaptáveis, mas também resolvem o problema de posicionamento de forma inteligente a fim de garantir conectividade satisfatória em situações de desastres, reafirmando sua importância na evolução das redes de comunicação modernas.

4.3 Análise comparativa

Na análise comparativa dos dados, foi avaliado o desempenho das diferentes meta-heurísticas aplicadas ao problema de otimização. A Figura 17 ilustra o comportamento de cada algoritmo em relação à quantidade de usuários conectados, considerando diferentes unidades de UAV-BSs. Essa análise permite observar a eficácia de cada abordagem no atendimento aos usuários, destacando as variações de desempenho em cenários com múltiplos UAV-BSs.

Figura 17 – Desempenho dos Algoritmos para Usuários Conectados por UAV-BSs.



Fonte: Elaborado pelo autor.

A análise revelou que a quantidade média de usuários conectados, avaliada por meio da função fitness, apresenta variações importantes entre os algoritmos. Em particular, o PSO e o TLBO destacaram-se por conectar, de forma consistente, um maior número de usuários em comparação às demais meta-heurísticas avaliadas, evidenciando sua superioridade neste cenário de otimização para prover conectividade.

Percebe-se ainda que, dentre todos, o algoritmo PSO apresenta os melhores resultados na busca por soluções ótimas, para a métrica de usuários conectados, pois com 4 (quatro) UAV-BSs atinge uma cobertura de 100% (cem por cento) dos usuários, com desvio padrão zero, sugerindo uma opção estável para esta quantidade de UAV-BSs. Os algoritmos AG, ABC e TLBO mostraram ser uma opção secundária pois, apesar de demonstrarem uma melhoria consistente no número de usuários conectados à medida que a quantidade de UAV-BSs aumenta, alcançam a conexão total somente com 6 (seis) UAV-BSs, mesmo que com 5 (cinco) UAV-BSs já indicam um alto nível de eficiência. É importante notar que o algoritmo ACO não consegue convergir muito bem na cobertura dos usuários, apresentando o menor desempenho dentre os algoritmos analisados. Realizando uma análise comparativa por quantidade de UAV-BSs é possível identificar na Tabela 15 os pontos mais importantes.

Tabela 15 – Análise descritiva dos resultados por quantidade de UAV-BSs

2 UAV-BSs	3 UAV-BSs
O ABC apresentou um desempenho intermediário (74,900) com um desvio padrão de 3,021, sugerindo uma dispersão relativamente alta.	O desvio padrão reduzido em TLBO, AG e PSO sugere que esses métodos são mais estáveis do que ABC e ACO para esta quantidade de UAV-BSs.
O ACO teve o pior desempenho (74,000) e apresentou a maior variabilidade (desvio padrão de 4,609), indicando menor estabilidade na solução.	ABC e ACO tiveram coberturas menores (89,867 e 85,033, respectivamente), com ACO mantendo um desvio padrão elevado (4,888).
O PSO obteve o melhor desempenho médio (82,333 usuários), seguido por TLBO (77,700) e AG (76,800).	O PSO continua com a melhor cobertura média (95,500 usuários), seguido por TLBO (92,333) e AG (90,900).
4 UAV-BSs	5 UAV-BSs
PSO e TLBO atingiram 100% de cobertura, com PSO apresentando zero variação (desvio padrão 0,000) e TLBO com um leve desvio (0,925).	PSO, TLBO e AG atingiram praticamente 100% de cobertura, com variações mínimas.
AG também apresentou um resultado próximo ao ótimo (98,433 usuários), com um desvio padrão relativamente baixo (1,382).	ABC e ACO ainda apresentaram valores menores (99,367 e 95,067, respectivamente), indicando que precisaram de mais iterações para se aproximar do ótimo.
ABC e ACO tiveram coberturas menores (96,867 e 90,733, respectivamente), com ACO novamente apresentando maior variabilidade (4,307 de desvio padrão).	ACO manteve um desvio padrão alto (3,140), sugerindo que a solução encontrada ainda tem variação significativa entre execuções.
6 UAV-BSs	
Todas as meta-heurísticas alcançaram 100% de cobertura.	
PSO, AG, ABC e TLBO apresentaram desvio padrão zero, indicando convergência total.	
ACO foi a única meta-heurística que ainda apresentou variação (mínimo 91, máximo 100, média 96,600 e desvio padrão 2,401), evidenciando menor eficiência.	


Fonte: Elaborado pelo autor.

Diante do exposto, considera-se que PSO se destaca como a melhor meta-heurística nesta métrica, atingindo rapidamente 100% de cobertura com estabilidade absoluta (desvio padrão zero a partir de 4 UAV-BSs). O TLBO e AG também demonstraram excelente desempenho, com TLBO alcançando ótimos resultados com um pequeno desvio padrão e AG convergindo rapidamente para soluções quase ótimas. O ABC apresentou um desempenho intermediário, conseguindo boas médias, mas com maior variação na fase inicial. O algoritmo ACO foi identificado como

o que obteve a menor eficiência, dentre as meta-heurísticas avaliadas, pois obteve menores valores médios de cobertura e maior desvio padrão, sugerindo que essa abordagem pode não ser viável para quando se deseja uma minimização de recursos para atendimento de uma demanda emergencial no provimento de serviços de rede.

Na análise comparativa da métrica de vazão, o gráfico mostrado na Figura 18 confirma que os resultados foram consistentemente altos para todos os algoritmos, com valores em torno de 97Mbps a 100Mbps. O AG, ABC e TLBO destacaram-se com vazões ligeiramente superiores, especialmente com 6 (seis) UAV-BSs. Percebe-se que quando o PSO consegue atingir a cobertura de todos os usuários, quando tem 4 (quatro) UAV-BSs, seus resultados possuem uma menor variância com relação à média, ou seja, os resultados estão quase na mesma vazão e buscando um percentil menos ampliado. Entretanto, quando se analisa com 5 (cinco) UAV-BSs, a variância dos resultados da vazão do PSO aumenta, levando a identificar que o aumento de UAV-BSs no ambiente gera uma maior interferência de sinal, sem gerar melhora significativa nas métricas analisadas. Comportamento também notado quando o TLBO atinge seu melhor desempenho na vazão, no instante de 5 (cinco) UAV-BSs, pois quando consegue cobrir todos os seus usuários, a vazão diminui sua variância.

Figura 18 – Desempenho de cada algoritmo em termos de vazão.




Fonte: Elaborado pelo autor.

Na análise comparativa foi identificado que o número de UAV-BSs é inversamente proporcional ao tempo de execução para a resolução do problema de otimização. À medida que a quantidade de UAV-BSs aumenta, o tempo de processamento também cresce. No entanto, observou-se que, a partir do momento em que o algoritmo PSO atingiu o ponto ótimo de convergência, com variância zero na cobertura de todos os usuários, no instante de 4 UAV-BS, houve uma redução significativa no tempo de execução, conforme ilustrado na Figura 19, pois

atingiu um nível de aptidão igual ao número de usuários conectados, fazendo o PSO parar antes de obter taxas melhores em vazão. Percebe-se que esta pequena perda na possível melhora em vazão pode ser superada pelos ganhos significativos em tempo de execução, oriundos da parada por causa da convergência ao alcançar a completude da cobertura dos usuários e também graças às características de enxame na distribuição pelo espaço de busca, que contribuiu para a rápida identificação dos pontos ótimos, mesmo com o aumento do número de UAV-BSs a serem posicionados.

Figura 19 – Desempenho dos algoritmos em razão do tempo por UAV-BSs.



Fonte: Elaborado pelo autor.

Os algoritmos ABC, ACO e TLBO apresentaram um melhor desempenho em termos de tempo de execução quando havia poucos UAV-BSs disponíveis para cobrir uma área extensa. Nesses cenários, eles mantiveram tempos de processamento abaixo de 1 segundo, destacando-se positivamente em relação ao PSO, que apresentou o maior tempo de execução quando os recursos de UAV-BSs eram limitados (com dois ou três). No entanto, ao contrário do PSO, nenhum outro algoritmo demonstrou uma redução significativa no tempo de execução à medida que o número de UAV-BSs aumentou, pelo contrário, o tempo de processamento continuou a crescer conforme a quantidade de UAV-BSs ficava maior.

De forma geral, o TLBO se destacou tanto em cenários com poucos quanto com muitos UAV-BSs, enquanto o PSO obteve melhor desempenho quando havia um número maior de UAV-BSs disponíveis. Ambos apresentaram tempos de execução relativamente baixos em comparação com os demais algoritmos, sugerindo uma eficiência computacional superior.

Os resultados apontam para as seguintes características:

AG: Desempenho sólido em vazão, com perda no desempenho na métrica de tempo de execução;

ABC: Melhor escolha para qualidade de sinal, proporcionando uma melhor vazão, com médias de usuários conectados aceitáveis;

ACO: Desempenho equilibrado, mas com maior variabilidade e tempos de execução mais altos;

PSO: Ótimo desempenho geral, mas com maior variabilidade e tempos de execução mais altos para cenários de poucos recursos de UAV-BSs disponíveis;

TLBO: Boa escolha para um desempenho geral consistente, com excelente média em todas as métricas e tempos de execução rápidos;

Diante da análise comparativa realizada entre os algoritmos meta-heurísticos aplicados ao problema de posicionamento de UAV-BSs em cenários emergenciais, observa-se que os resultados obtidos nesta pesquisa estão, em sua maioria, alinhados com as evidências e tendências reportadas na literatura especializada. A performance destacada do PSO, com sua alta taxa de cobertura e rápida convergência, bem como a robustez e estabilidade do TLBO, são características amplamente reconhecidas em estudos prévios voltados à otimização em espaços contínuos. A adequação dessas técnicas a problemas de posicionamento é reforçada por sua capacidade intrínseca de realizar exploração eficiente do espaço de busca sem necessidade de parametrizações excessivamente complexas, como é o caso do TLBO.

Adicionalmente, os resultados intermediários do Algoritmo Genético (AG), apesar de satisfatórios em termos de cobertura, refletiram seu comportamento típico de convergência global com custo computacional elevado, um aspecto também reportado em múltiplos estudos comparativos, devido muito à seus vários parâmetros e ajustes para refinamento da melhor posição. O desempenho do ABC, embora não tenha superado PSO e TLBO, demonstrou potencial competitivo, sobretudo em cenários com maior número de UAV-BSs, o que se coaduna com a literatura que reconhece sua eficácia em funções objetivo complexas e multidimensionais.

A principal divergência em relação à literatura reside nos resultados do ACO, cujo desempenho inferior, especialmente na cobertura e tempo de execução, contrasta com aplicações bem-sucedidas do algoritmo em domínios combinatórios. Essa disparidade pode ser explicada pela natureza contínua do problema de posicionamento de UAV-BSs, que difere substancialmente das estruturas discretas (como grafos e caminhos) para as quais o ACO foi originalmente concebido. Tal constatação reforça o entendimento de que a eficácia de uma meta-heurística está intimamente relacionada à adequação de sua lógica de busca à estrutura do espaço de solução.

Com essas informações, a análise comparativa fornece um panorama claro sobre o desempenho relativo das meta-heurísticas estudadas e auxilia na escolha do método mais adequado para otimizar o posicionamento de UAV-BSs em cenários de cobertura de rede.

5 CONCLUSÃO

5.1 Considerações finais

Esta dissertação teve como propósito central investigar o desempenho de diferentes algoritmos meta-heurísticos aplicados à tarefa de otimizar o posicionamento de Estações Rádio Base embarcadas em Veículos Aéreos Não Tripulados (UAV-BSs) em contextos emergenciais, caracterizados pela indisponibilidade das infraestruturas convencionais de comunicação. Diante da crescente demanda por conectividade móvel e da necessidade de soluções eficientes em cenários de crise, evidenciou-se a relevância dos UAVs como plataformas alternativas e dinâmicas para o suporte à comunicação em redes móveis de última geração.

Ao longo da pesquisa, foram explorados os fundamentos técnicos e operacionais dos UAV-BSs, sua taxonomia, aplicações potenciais e os desafios inerentes ao seu uso em ambientes reais. Definiu-se que o problema de alocação espacial desses dispositivos configura-se como uma tarefa de otimização não trivial, que ainda é um desafio a ser superado na literatura, cuja resolução exige estratégias inteligentes. Com base nisso, selecionou-se os algoritmos AG, PSO, ACO, TLBO e ABC, considerando suas distintas origens computacionais e ampla utilização em problemas semelhantes na literatura.

5.1.1 Contribuições

Os experimentos realizados em ambiente simulado permitiram avaliar o desempenho de cada técnica por meio de métricas relevantes, como número de usuários atendidos, relação sinal-interferência mais ruído (SINR), vazão de dados e tempo de execução. Os resultados obtidos indicaram comportamentos diferenciados de cada algoritmo, principalmente à medida que se aumentava a quantidade de UAV-BSs. Em termos de cobertura de usuários conectados, observou-se que o algoritmo PSO apresentou desempenho notavelmente elevado, alcançando a cobertura total (100%) a partir de 4 UAV-BSs, de forma mais precoce que os demais. Foi identificado que esse desempenho está relacionado à sua capacidade de balancear exploração e convergência, favorecendo a rápida identificação de regiões promissoras no espaço de busca. Assim, em cenários que exigem ampla cobertura com poucos recursos, o PSO mostrou-se uma alternativa bastante eficaz.

Já o algoritmo TLBO alcançou uma cobertura total de conectividade dos usuários com 5 UAV-BSs, mas manteve desempenho consistentemente alto mesmo em configurações com menos UAV-BSs. Na análise realizada, tal característica indica que o TLBO pode ser particularmente vantajoso em situações em que a confiabilidade e a consistência da solução são críticas, ainda que com maior custo computacional.

O AG obteve resultados intermediários, com desempenho crescente conforme o número de UAVs aumentava, o que evidencia sua boa capacidade adaptativa. Já o ABC demonstrou potencial competitivo, sobretudo em configurações com 5 e 6 UAVs, sugerindo que seu mecanismo de busca baseado em colaboração de agentes pode ser mais eficaz em cenários mais complexos ou com maior liberdade de posicionamento. O ACO, por sua vez, manteve-se competitivo em algumas métricas, especialmente aquelas relacionadas à qualidade do sinal (como sugerido pela literatura), embora tenha apresentado variação de desempenho que demanda ajustes finos em sua parametrização para diferentes contextos.

Esses resultados sustentam a proposta de que a escolha do algoritmo mais adequado deve ser orientada pelos critérios que cada aplicação considera prioritários, sejam eles cobertura, estabilidade, rapidez de execução ou robustez frente a variações do cenário. A pesquisa oferece, assim, um panorama comparativo que serve de base para decisões técnicas fundamentadas em ambientes com requisitos diversos, seja na área acadêmica ou em aplicações práticas.

A temática abordada nesta dissertação foi apresentada na Conferência Nacional em Comunicações, Redes e Segurança da Informação (ENCOM 2024), realizado na cidade de Natal, Rio Grande do Norte. Durante o evento, foram discutidos os principais aspectos relacionados à análise comparativa de algoritmos meta-heurísticos para o posicionamento de UAV-BS, visando ao provimento eficiente de serviços de comunicação em cenários diversos. A apresentação contou com a participação de uma banca, contendo professores especialistas/pesquisadores da área, promovendo um rico debate científico.

O trabalho foi selecionado para publicação nos Anais da Conferência Nacional em Comunicações, Redes e Segurança da Informação (ENCOM)¹, consolidando a relevância e o rigor técnico da pesquisa realizada. Esse reconhecimento acadêmico demonstra a importância da pesquisa realizada e contribuições necessárias no campo das telecomunicações para o avanço das soluções tecnológicas envolvendo UAV-BSs em ambientes de comunicação.

5.2 Trabalhos Futuros

As contribuições deste trabalho abrem caminho para novas pesquisas no campo da otimização aplicada ao provimento de serviços de comunicação por UAV-BSs. Especificamente, futuras investigações podem explorar algoritmos híbridos que combinem as vantagens observadas individualmente, como a agilidade do PSO com a consistência do TLBO, bem como realizar simulações com cenários mais dinâmicos, considerando variações topográficas e fatores climáticos. Ademais, a integração com plataformas baseadas em inteligência artificial e sensores ambientais poderá ampliar ainda mais o grau de automação e adaptabilidade dos UAV-BSs, tornando-os ainda mais úteis em operações de emergência e suporte a redes resilientes, incluindo

¹ Título: Análise comparativa de algoritmos meta-heurísticos na solução de posicionamento de UAV-BS(AN532 - IFRN - CDD - 370 - ISSN: 2237-5112 (<https://www.even3.com.br/anais/encom2024/>))

a possibilidade de usar os insights obtidos para guiar soluções inovadoras no futuro.

Além disso, considerando que este trabalho se concentrou na análise comparativa de algoritmos meta-heurísticos para a solução do problema de posicionamento de UAV-BSs, futuras pesquisas poderiam expandir essa abordagem para o planejamento de rotas dos UAV-BSs. Ao realizar uma análise comparativa das meta-heurísticas no contexto de planejamento de trajetórias, seria possível identificar os melhores caminhos para o deslocamento dos UAV-BSs, otimizando não apenas o posicionamento, mas também o plano de missão como um todo.

Essa integração entre a otimização do posicionamento e o planejamento de rota completaria o plano de missão para o provimento eficiente de serviços de comunicação, contribuindo para uma melhor utilização dos recursos e maior qualidade de serviço em cenários desafiadores.

Por fim, destaca-se a oportunidade de desenvolvimento de sistemas integrados que unam UAV-BSs, sensores ambientais e plataformas baseadas em inteligência artificial, com vistas à tomada de decisão autônoma e em tempo real. Além disso, sugere-se a incorporação de variáveis mais complexas, como condições atmosféricas, de modo a ampliar a aplicabilidade e robustez dos modelos propostos.

Referências

- AL-HOURANI, A.; KANDEEPAN, S.; JAMALIPOUR, A. Modeling air-to-ground path loss for low altitude platforms in urban environments. In: IEEE. *2014 IEEE global communications conference*. 2014. p. 2898–2904. ISSN 1930-529X. Disponível em: <<https://doi.org/10.1109/GLOCOM.2014.7037248>>. Citado na página 37.
- ALAMMOURI, A.; ANDREWS, J. G.; BACCELLI, F. Sinr and throughput of dense cellular networks with stretched exponential path loss. *IEEE Transactions on Wireless Communications*, IEEE, v. 17, n. 2, p. 1147–1160, 2017. Disponível em: <<https://doi.org/10.48550/arXiv.1703.08246>>. Citado na página 40.
- ALANCAI, N.; VILLAGRA, S. M.; VILLAGRA, N. A. Metaheurísticas de trayectoria y poblacional aplicadas a problemas de optimización combinatoria. *Informes Científicos Técnicos-UNPA*, v. 8, n. 1, p. 202–220, 2016. ISSN 1852-4516. Citado na página 19.
- ALFAIA, R. D. et al. Resource management in 5g networks assisted by uav base stations: Machine learning for overloaded macrocell prediction based on users' temporal and spatial flow. *Drones*, MDPI, v. 6, n. 6, p. 145, 2022. Disponível em: <<https://doi.org/10.3390/drones6060145>>. Citado 4 vezes nas páginas 7, 37, 39 e 40.
- ALWIS, C. D. et al. Survey on 6g frontiers: Trends, applications, requirements, technologies and future research. *IEEE Open Journal of the Communications Society*, IEEE, v. 2, p. 836–886, 2021. Disponível em: <<https://doi.org/10.1109/OJCOMS.2021.3071496>>. Citado na página 1.
- ANOSRI S., P. N. C. P. B. S. T. C. K. S. . . Y. A. R. A comparative study of state-of-the-art metaheuristics for solving many-objective optimization problems of fixed wing unmanned aerial vehicle conceptual design. *Archives of Computational Methods in Engineering*, Springer, v. 30, n. 6, p. 3657–3671, 2023. Disponível em: <<http://dx.doi.org/10.1007/s11831-023-09914-z>>. Citado na página 7.
- ATA, B.; GENCAL, M. C. Comparison of optimization approaches on linear quadratic regulator design for trajectory tracking of a quadrotor. *Evolutionary Intelligence*, Springer, v. 17, n. 5, p. 3225–3240, 2024. Disponível em: <<https://doi.org/10.1007/s12065-024-00928-5>>. Citado na página 13.
- CARDOSO, E. H. S. et al. Novel multilayered cellular automata for flying cells positioning on 5g cellular self-organising networks. *IEEE Access*, IEEE, v. 8, p. 227076–227099, 2020. ISSN 2169-3536. Disponível em: <<https://doi.org/10.1109/ACCESS.2020.3045663>>. Citado 2 vezes nas páginas 37 e 39.
- CHEN, Y.-C.; YANG, C.-C. Teaching–learning based optimization (tlbo) with variable neighborhood search for shelf-space allocation problems. *Mathematics*, v. 8, n. 8, p. 1296, 2020. ISSN 2227-7390. Disponível em: <<https://doi.org/10.3390/math8081296>>. Citado na página 33.
- CLERC, M. *Particle swarm optimization*. [S.l.]: John Wiley & Sons, 2010. v. 93. Citado na página 30.

- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of photogrammetry and remote sensing*, Elsevier, v. 92, p. 79–97, 2014. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2014.02.013>>. Citado na página 15.
- DINH, L. L.; NGOC, D. V.; VASANT, P. Artificial bee colony algorithm for solving optimal power flow problem. *The Scientific World Journal*, Wiley Online Library, v. 2013, n. 1, p. 159040, 2013. Disponível em: <<https://doi.org/10.1155/2013/159040>>. Citado na página 22.
- DORIGO, M.; BLUM, C. Ant colony optimization theory: A survey. *Theoretical Computer Science*, v. 344, n. 2-3, p. 243–278, 2005. Disponível em: <<https://doi.org/10.1016/j.tcs.2005.05.020>>. Citado na página 25.
- DORIGO, M.; MANIEZZO, V.; COLORNI, A. Ant system: optimization by a colony of cooperating agents. *IEEE transactions on systems, man, and cybernetics, part b (cybernetics)*, Ieee, v. 26, n. 1, p. 29–41, 1996. ISSN 1083-4419. Disponível em: <<https://doi.org/10.1109/3477.484436>>. Citado 2 vezes nas páginas 23 e 25.
- FARAMARZI, A. et al. Equilibrium optimizer: A novel optimization algorithm. *Knowledge-based systems*, Elsevier, v. 191, p. 105190, 2020. Disponível em: <<https://doi.org/10.1016/j.knosys.2019.105190>>. Citado na página 19.
- FARIS, H.; ALJARAH, I.; MIRJALILI, S. *EvoPy: An open-source nature-inspired optimization framework in Python*. 2016. <<https://github.com/7ossam81/EvoPy>>. Accessed 22 de Maio de 2024. Citado na página 53.
- FERNANDEZ, S. A.; CARVALHO, M. M.; SILVA, D. G. A hybrid metaheuristic algorithm for the efficient placement of uavs. *Multidisciplinary Digital Publishing Institute*, v. 13, n. 323, 2020. ISSN 1999-4893. Disponível em: <<https://doi.org/10.3390/a13120323>>. Citado 3 vezes nas páginas 7, 15 e 37.
- GHAMBARI, S. et al. A comparative study of meta-heuristic algorithms for solving uav path planning. In: IEEE. *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*. 2018. p. 174–181. Disponível em: <<https://doi.org/10.1109/SSCI.2018.8628807>>. Citado na página 6.
- GLOVER, F. W.; KOCHENBERGER, G. A. *Handbook of metaheuristics*. [S.l.]: Springer Science & Business Media, 2003. v. 57. Citado na página 18.
- GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, 1989. Disponível em: <<https://dl.acm.org/doi/book/10.5555/534133>>. Citado na página 27.
- GOLDSMITH, A. *Wireless Communications*. 2005. Disponível em: <<https://doi.org/10.1017/cbo9780511841224>>. Citado na página 39.
- GOODCHILD, A.; TOY, J. Delivery by drone: An evaluation of unmanned aerial vehicle technology in reducing co2 emissions in the delivery service industry. *Transportation Research Part D: Transport and Environment*, Elsevier, v. 61, p. 58–67, 2018. Disponível em: <<https://doi.org/10.1016/j.trd.2017.02.017>>. Citado na página 15.
- GUPTA, M.; VARMA, S. Metaheuristic-based optimal 3d positioning of uavs forming aerial mesh network to provide emergency communication services. *Institution of Engineering and Technology (IET)*, v. 15, n. 1297-1314, 2021. ISSN 1751-8636. Disponível em: <<https://doi.org/10.1049/cmu2.12112>>. Citado 2 vezes nas páginas 6 e 37.

HAQUE, A.; CHOWDHURY, M. N.-U.-R.; HASSANALIAN, M. A comprehensive review of classification and application of machine learning in drone technology. *Preprints*, Preprints, June 2023. Disponível em: <<https://doi.org/10.20944/preprints202306.1901.v1>>. Citado na página 2.

HENTATI, A. I. et al. Multi-uavs-based sdn, iot, and cloud architecture for hostile areas supervision. In: IEEE. *2023 15th International Conference on Developments in eSystems Engineering (DeSE)*. 2023. p. 274–279. Disponível em: <<https://doi.org/10.1109/DeSE58274.2023.10099609>>. Citado na página 4.

HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. University of Michigan Press, 1975. Disponível em: <<https://doi.org/10.7551/mitpress/1090.001.0001>>. Citado 3 vezes nas páginas 5, 25 e 27.

HUANG, C.; LI, Y.; YAO, X. A survey of automatic parameter tuning methods for metaheuristics. *IEEE Transactions on Evolutionary Computation*, v. 24, n. 2, p. 201–216, 2020. Disponível em: <<https://doi.org/10.1109/TEVC.2019.2921598>>. Citado 2 vezes nas páginas 52 e 53.

JUN, J.; PEDDABACHAGARI, P.; SICHITIU, M. Theoretical maximum throughput of ieee 802.11 and its applications. In: IEEE. *Second IEEE International Symposium on Network Computing and Applications, 2003. NCA 2003*. 2003. p. 249–256. Disponível em: <<https://doi.org/10.1109/NCA.2003.1201163>>. Citado na página 38.

KARABOGA, D. et al. An idea based on honey bee swarm for numerical optimization. Technical report-tr06, Erciyes university, engineering faculty, computer . . . , 2005. Citado 2 vezes nas páginas 20 e 22.

KAZIKOVA, A.; PLUHACEK, M.; SENKERIK, R. Why tuning the control parameters of metaheuristic algorithms is so important for fair comparison? *MENDEL – Soft Computing Journal*, v. 26, n. 2, p. 9–13, 2020. Disponível em: <<https://doi.org/10.13164/mendel.2020.2.009>>. Citado 2 vezes nas páginas 52 e 53.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, v. 4, n. None, 1995. ISSN 1098-7576. Disponível em: <<https://doi.org/10.1109/ICNN.1995.488968>>. Citado 3 vezes nas páginas 5, 28 e 30.

KHAN, A.; GUPTA, S.; GUPTA, S. K. Emerging uav technology for disaster detection, mitigation, response, and preparedness. *Journal of Field Robotics*, Wiley Online Library, v. 39, n. 6, p. 905–955, 2022. Disponível em: <<https://doi.org/10.1002/rob.22075>>. Citado na página 13.

LAGUM, F.; BOR-YALINIZ, I.; YANIKOMEROGLU, H. Strategic densification with uav-bss in cellular networks. *IEEE Wireless Communications Letters*, IEEE, v. 7, n. 3, p. 384–387, 2017. Disponível em: <<https://www.sce.carleton.ca/faculty/yanikomeroглу/Pub/WCL-June2018-flibyhy.pdf>>. Citado na página 37.

LI, J. et al. Post-disaster unmanned aerial vehicle base station deployment method based on artificial bee colony algorithm. *IEEE Access*, IEEE, v. 7, p. 168327–168336, 2019. ISSN 2169-3536. Disponível em: <<https://doi.org/10.1109/ACCESS.2019.2954332>>. Citado 3 vezes nas páginas 18, 35 e 39.

MANDOUR, S. et al. Data mining problems optimization by using metaheuristic algorithms: A survey. *Multicriteria Algorithms with Applications*, v. 4, p. 28–52, 2024. Disponível em: <<https://doi.org/10.61356/j.mawa.2024.4301>>. Citado 2 vezes nas páginas 18 e 19.

MASROOR, R. et al. Optimal stratified placement of balloons and uavs to support users' coverage. *Internet of Things*, Elsevier, v. 23, p. 100865, 2023. Citado na página 34.

MAVROVOUNIOTIS, M.; ANASTASIADOU, M. N.; HADJIMITSIS, D. Measuring the performance of ant colony optimization algorithms for the dynamic traveling salesman problem. *Algorithms*, v. 16, n. 12, p. 545, 2023. Disponível em: <<https://doi.org/10.3390/a16120545>>. Citado na página 25.

MOHSAN, S. A. H. et al. Unmanned aerial vehicles (uavs): Practical aspects, applications, open challenges, security issues, and future trends. *Intelligent service robotics*, Springer, v. 16, n. 1, p. 109–137, 2023. Disponível em: <<https://doi.org/10.1007/s11370-022-00452-4>>. Citado 3 vezes nas páginas 2, 4 e 13.

NORAZMAN, F. D. et al. Investigation of empennage location effect to the unmanned aerial vehicle (uav) structure characteristic. *Journal of Advanced Research in Applied Mechanics*, semarak ilmu, v. 113, n. 1, p. 1–12, 2024. Disponível em: <<https://doi.org/10.37934/aram.113.1.112>>. Citado na página 13.

OZDAG, R.; YANIKÖMEROĞLU, H. *A New Meta-heuristic Approach for 3D Placement of Multiple Unmanned Aerial Vehicle Base Stations In Wireless Networks*. 2019. Citado na página 7.

PALADIN, Z. et al. The 5g-supported unmanned aerial vehicles for emergency cases response. *MIPRO ICT and Electronics Convention (MIPRO)*, v. 46, n. 1376-1381, 2023. ISSN 2623-8764. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/10159711>>. Citado 3 vezes nas páginas 5, 15 e 19.

PASANDIDEH, F. et al. An improved particle swarm optimization algorithm for uav base station placement. *Wireless Personal Communications*, v. 130, n. 1343-1370, 2023. Disponível em: <<https://doi.org/10.1007/s11277-023-10334-2>>. Citado na página 2.

PENKOV, I.; ALEKSANDROV, D. Propeller shrouding influence on lift force of mini unmanned quadcopter. *International Journal of Automotive and Mechanical Engineering*, v. 14, n. 3, p. 4486–4495, 2017. Disponível em: <<https://doi.org/10.15282/ijame.14.3.2017.7.0354>>. Citado na página 13.

POLI, R.; KENNEDY, J.; BLACKWELL, T. Particle swarm optimization: An overview. *Swarm intelligence*, Springer, v. 1, p. 33–57, 2007. Citado na página 30.

RABIU, L.; AHMAD, A.; GOHARI, A. Advancements of unmanned aerial vehicle technology in the realm of applied sciences and engineering: A review. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, v. 40, n. 2, p. 74–95, 2024. Disponível em: <<https://doi.org/10.37934/araset.40.2.7495>>. Citado na página 14.

RAHMAN, M. H. et al. A comprehensive survey of unmanned aerial vehicles detection and classification using machine learning approach: Challenges, solutions, and future directions. *Remote Sensing*, MDPI, v. 16, n. 5, p. 879, 2024. Disponível em: <<https://doi.org/10.3390/rs16050879>>. Citado 2 vezes nas páginas 3 e 6.

RAO, R. V. Teaching-learning-based optimization and its engineering applications. *Springer*, 2015. Disponível em: <<https://doi.org/10.1007/978-3-319-22732-0>>. Citado na página 33.

- RAO, R. V.; SAVSANI, V. J.; VAKHARIA, D. P. Teaching–learning-based optimization: A novel method for constrained mechanical design optimization problems. *Computer-Aided Design*, v. 43, n. 3, p. 303–315, 2011. ISSN 0010-4485. Disponível em: <<https://doi.org/10.1016/j.cad.2010.12.015>>. Citado 3 vezes nas páginas 5, 30 e 33.
- RUKAIYA, R. et al. Communication architecture and operations for sdr-enabled uavs network in disaster-stressed areas. *Ad Hoc Networks*, Elsevier, v. 160, p. 103506, 2024. Disponível em: <<https://doi.org/10.1016/j.adhoc.2024.103506>>. Citado na página 5.
- SAFWAT, N. E.-D.; NEWAGY, F.; HAFEZ, I. M. Air-to-ground channel model for uavs in dense urban environments. *IET Communications*, Wiley Online Library, v. 14, n. 6, p. 1016–1021, 2020. Disponível em: <<https://doi.org/10.1049/iet-com.2019.0964>>. Citado na página 34.
- SÁNCHEZ-GARCÍA, J.; REINA, D. G.; TORAL, S. A distributed pso-based exploration algorithm for a uav network assisting a disaster scenario. *Future Generation Computer Systems*, Elsevier, v. 90, p. 129–148, 2019. Disponível em: <<https://doi.org/10.1016/j.future.2018.07.048>>. Citado na página 2.
- SHARMA, A. et al. Communication and networking technologies for uavs: A survey. *Journal of Network and Computer Applications*, Elsevier, v. 168, p. 102739, 2020. Disponível em: <<https://doi.org/10.1016/j.jnca.2020.102739>>. Citado na página 3.
- SHIN, S. Y. et al. Packet error rate analysis of zigbee under wlan and bluetooth interferences. *IEEE Transactions on Wireless communications*, IEEE, v. 6, n. 8, p. 2825–2830, 2007. ISSN 1536-1276. Disponível em: <<https://doi.org/10.1109/TWC.2007.06112>>. Citado na página 34.
- SIVALINGAM, T. et al. Positioning of multiple unmanned aerial vehicle base stations in future wireless network. *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*, v. 1, n. 1-6, 2020. Disponível em: <<https://doi.org/10.48550/arXiv.1911.03929>>. Citado na página 6.
- TRUXAL, S.; SCOTT, B. I. The regulation of unmanned aircraft systems in the european union. In: *Civil Regulation Of Autonomous Unmanned Aircraft Systems In Europe*. Edward Elgar Publishing, 2024. p. 31–63. Disponível em: <<https://doi.org/10.4337/9781035312344.00008>>. Citado na página 15.
- VIE, A.; KLEINNIJENHUIS, A. M.; FARMER, D. J. Qualities, challenges and future of genetic algorithms: a literature review. *arXiv preprint arXiv:2011.05277*, 2020. Disponível em: <<https://arxiv.org/abs/2011.05277>>. Citado na página 27.
- WU, S.; LI, Q.; WEI, W. Application of ant colony optimization algorithm based on triangle inequality principle and partition method strategy in robot path planning. *Axioms*, v. 12, n. 6, p. 525, 2023. Disponível em: <<https://doi.org/10.3390/axioms12060525>>. Citado 2 vezes nas páginas 25 e 52.
- XIAO, W.-s. et al. A novel chaotic and neighborhood search-based artificial bee colony algorithm for solving optimization problems. *Scientific Reports*, Nature Publishing Group UK London, v. 13, n. 1, p. 20496, 2023. ISSN 2045-2322. Disponível em: <<https://doi.org/10.1038/s41598-023-44770-8>>. Citado na página 22.
- ZHAO, N. et al. Uav-assisted emergency networks in disasters. *IEEE Wireless Communications*, IEEE, v. 26, n. 1, p. 45–51, 2019. ISSN 1536-1284. Disponível em: <<https://doi.org/10.1109/MWC.2018.1800160>>. Citado na página 38.

ZHOU, L. et al. Propagation characteristics of air-to-air channels in urban environments. In: IEEE. *2018 IEEE Global Communications Conference (GLOBECOM)*. 2018. p. 1–6. ISSN 2576-6813. Disponível em: <<https://doi.org/10.1109/GLOCOM.2018.8647360>>. Citado na página 35.

ZHOU, Y. Unmanned aerial vehicles based low-altitude economy with lifecycle techno-economic-environmental analysis for sustainable and smart cities. *Journal of Cleaner Production*, Elsevier, p. 145050, 2025. Disponível em: <<https://doi.org/10.1016/j.jclepro.2025.145050>>. Citado na página 14.