

Estudo comparativo de algoritmos meta-heurísticos na solução de posicionamento de UAV-BS

1st Davi Moraes

Instituto de Tecnologia (ITEC)
Universidade Federal do Pará (UFPA)
Belém-PA, Brasil
davi.moraes@itec.ufpa.br

2nd Wilson Silva

Instituto de Tecnologia (ITEC)
Universidade Federal do Pará (UFPA)
Belém-PA, Brasil
wrss10@gmail.com

3rd Diego Cardoso

Departamento de Engenharia Elétrica
Universidade Federal do Pará (UFPA)
Belém-PA, Brasil
diego@ufpa.br

Abstract—Veículos Aéreos Não Tripulados servindo como Estações Base UAV-BS (*Unmanned Aerial Vehicle Base Stations*) são capazes de restabelecer a conectividade dos usuários em cenários de desastres naturais. O posicionamento de UAV-BS apresenta desafios significativos. É necessário adaptar-se dinamicamente à densidade de usuários e aos requisitos de qualidade de serviço. Propõe-se neste trabalho a avaliação de cinco algoritmos meta-heurísticos (ABC, ACO, AG, PSO e TLBO) para otimizar o posicionamento de UAV-BS, considerando a cobertura dos usuários, qualidade do sinal e custo computacional. Para avaliação do desempenho foram utilizados modelos comparativos que indicaram vantagens do TLBO e PSO.

Index Terms—UAV, Estação base, Algoritmos Meta-heurísticos.

Abstract—Unmanned Aerial Vehicles as Base Stations (UAV-BS) are capable of reestablishing user connectivity in natural disaster scenarios. Optimizing the positioning of UAV-BS presents significant challenges, including identifying the most suitable metaheuristic for implementation. This study proposes the evaluation of five metaheuristic algorithms (ABC, ACO, GA, PSO, and TLBO) to optimize UAV-BS positioning considering user coverage, signal quality and computational cost. Comparative models were used to evaluate the performance of the algorithms indicating superior advantages of TLBO and PSO.

Index Terms—UAV, Base stations, metaheuristic algorithms.

I. INTRODUÇÃO

Veículos Aéreos Não Tripulados UAV (do inglês, *Unmanned Aerial Vehicle*) têm emergido como uma solução promissora devido à sua flexibilidade e capacidade de implantação rápida, atuando como Estações Base BS (do inglês, *Base Station*) para restabelecer a conectividade em cenários de desastres naturais. A otimização do posicionamento de UAV-BS, no entanto, apresenta desafios significativos. É necessário adaptar-se dinamicamente às mudanças nos cenários, à densidade de usuários e aos requisitos de qualidade de serviço (QoS), contribuindo de forma relevante para redes móveis modernas e futuras.

Algoritmos meta-heurísticos são propostos na literatura para abordar o posicionamento de UAV-BS, incluindo a otimização por Colônia de Abelhas ABC (do inglês *Artificial Bee Colony Algorithm*), a Otimização por Colônia de Formigas ACO (do inglês *Ant Colony Optimization Algorithm*), o Algoritmo Genético AG, a Otimização por Enxame de Partículas PSO (do inglês *Particle Swarm Optimization*) e

a Otimização Baseada em Ensino-Aprendizagem TLBO (do inglês *Teaching-Learning Based Optimization*).

Apesar dos avanços significativos no uso de algoritmos meta-heurísticos para otimização do posicionamento do UAV-BS, ainda há lacunas na literatura quanto à escolha da meta-heurística mais adequada. Esta pesquisa visa preencher essa lacuna, comparando o desempenho de diferentes meta-heurísticas para identificar a mais eficiente.

Nesse sentido, este estudo se propõe a implementar e avaliar métodos de otimização para o posicionamento de UAV-BS. Especificamente, visa: (1) Comparar e avaliar diferentes algoritmos meta-heurísticos (AG, PSO, ACO, ABC e TLBO) para determinar a posição ótima ou sub-ótima dos UAV-BS; (2) Analisar a correlação entre diferentes métricas de desempenho, como quantidade de usuários conectados, vazão e tempo de execução; (3) Identificar a meta-heurística mais eficiente em termos de qualidade de serviço e custo computacional, fornecendo recomendações práticas para a implementação.

A principal contribuição deste artigo é fornecer uma análise comparativa do desempenho de cinco meta-heurísticas na otimização do posicionamento de UAV-BS. Este estudo amplia o conhecimento teórico sobre algoritmos de otimização, destacando a importância de selecionar o algoritmo adequado para maximizar a cobertura de usuários e a qualidade do sinal, minimizando o tempo de resposta e o custo computacional.

O restante do documento está organizado da seguinte forma: a Seção II apresenta os trabalhos correlatos. A Seção III descreve metodologia utilizada. A Seção IV discute os resultados. Finalmente, a Seção V conclui o trabalho.

II. TRABALHOS CORRELATOS

O posicionamento eficaz dos UAVs para maximizar a cobertura de usuários é um desafio complexo abordado por diversos estudos. Em [1], foi proposto um algoritmo híbrido para a colocação de UAVs em cidades inteligentes, destacando a eficácia das abordagens meta-heurísticas. Já [2] introduziu um algoritmo baseado em meta-heurística para maximizar a cobertura com o número mínimo de UAVs.

Em [3] os autores demonstraram a relevância no uso do PSO propondo um algoritmo para otimizar a cobertura de estações base em UAVs, enquanto [4] focou na maximização da cobertura do usuário através da otimização conjunta do

posicionamento do UAV e do fator de compensação de perda de percurso.

Para a seleção de locais dos UAV-BS, [5] propuseram um método baseado no algoritmo espiral, integrando ACO para o planejamento ideal. Adicionalmente, [6] demonstraram a aplicabilidade do ACO em domínios contínuos para problemas de otimização.

Em [7], foi apresentada a utilização do ACO para otimizar o caminho em computação de borda móvel, enquanto [8] empregaram o ACO para minimizar o custo do caminho dos UAVs em Redes de Sensores sem Fio WSN (do inglês, *Wireless Sensor Networks*).

A eficiência dos algoritmos genéticos foi destacada em [9], que otimizaram parâmetros para um controlador adaptativo direto no controle de atitude de UAV-BS. Em [10], foi apresentado um método para maximizar a satisfação do usuário através de algoritmos genéticos e PSO para posicionar múltiplos UAV-BS.

O algoritmo ABC foi utilizado no posicionamento de UAVs como estações base em [12], propondo um método híbrido de otimização multiobjetivo para redes 5G. Em [13], foi apresentado um método eficiente para reconfigurar formações de UAVs com ABC, considerando restrições como prevenção de colisões e estabilidade da formação.

O TLBO foi aplicado no posicionamento de UAVs em [14], otimizando tarefas de emergência de múltiplos UAVs, melhorando a eficiência da convergência e garantindo a conclusão eficiente das missões.

III. METODOLOGIA

Esta seção fornece uma descrição detalhada do ambiente simulado no qual as soluções de meta-heurísticas foram avaliadas, bem como as métricas utilizadas e a forma de coleta.

A. Ambiente de Simulação

A pesquisa é conduzida em um ambiente de simulação que modela a propagação do sinal e a interferência em uma área de 1000m x 1000m, considerando uma frequência de 2.4GHz. Para a construção do cenário, foi utilizado Python, na versão 3.2.12. Para análise e visualização dos dados, foram utilizadas as versões mais atualizadas das bibliotecas NumPy (1.26.0) e Matplotlib (3.9).

No cenário construído os usuários são distribuídos de forma aleatória. Entretanto para uma análise comparativa entre os diferentes tipos de algoritmos meta-heurísticos, é atribuído uma semente na aleatoriedade da posição dos usuários, utilizando o módulo Random do Python, com o objetivo de criar cenários de busca idênticos para todos os algoritmos.

B. Planejamento de posicionamento

Ao planejar o posicionamento de UAV-BS, a propagação eletromagnética apresenta vários desafios, que deve considerar a comunicação entre UAV-BS e os usuários terrestres levando em conta alguns conceitos e fatores que afetam essa comunicação.

Para calcular a distância dos usuários até os UAV-BS é utilizada a equação da distância euclidiana em um plano bidimensional, amplamente compreendida, que calcula a distância entre dois pontos (x, y) e (x_i, y_i) [15].

C. Modelo de Propagação

Foi utilizado o modelo de perdas no caminho *Air-To-Ground* (A2G) [16], que leva em consideração L_{LoS} como a linha de visão (LoS) e η_{LoS} como a não linha de visão (NLoS) entre o UAV-BS e o usuário no solo. Onde LoS e NLoS são perdas de propagação no espaço livre e dependem do ambiente, conforme [17]. O modelo é expresso como:

$$PL_{LoS}(dB) = 20 \log_{10} \left(\frac{4\pi f_c d_{ij}}{c} \right) + \eta_{LoS} \quad (1)$$

onde: f_c é uma variável que representa a frequência portadora, d_{ij} é a distância em metros, e c é uma constante que representa a velocidade da luz [16].

D. Relação Sinal-Interferência mais Ruído

Assumimos que a Relação Sinal-Interferência mais Ruído (SINR, do inglês *Signal-to-Interference-Plus-Noise Ratio*) é utilizada para fornecer limites superiores teóricos para a capacidade do canal em sistemas de comunicação sem fio. A SINR representa o cenário onde o ruído de fundo e a intensidade da interferência de outras transmissões simultâneas também são consideradas.

Neste experimento consideramos que, durante o período de tempo em que o UAV-BS está transmitindo dados aos usuários terrestres, o UAV-BS mantém uma altitude e velocidade constante. Assumimos que possui menos obstáculos para que o UAV-BS opere eficientemente em alturas menores, 50 metros, aproveitando melhor a visibilidade direta [18]. Estimamos que cada nó transmite com a mesma potência, para permitir comparações diretas entre os diferentes algoritmos, que é o foco do trabalho. A fórmula para o cálculo do SINR [19]

$$SINR = \frac{P}{I + N} \quad (2)$$

onde:

- P é a potência do sinal de interesse.
- I é a potência de interferência de outros sinais na rede.
- N é a potência do ruído.

E. Cálculo de Shannon

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 [20]. A taxa de usuário alcançável é expressa como:

$$C = B \log_2 \left(1 + \frac{P_u G}{L N_0 B} \right) \quad (3)$$

onde B é a largura de banda alocada por usuário, P_u é a potência transmitida pelo UAV-BS, G é o ganho da antena direcional, L representa a perda de percurso definida em (1) e N_0 é a densidade espectral de potência do ruído [21].

F. 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 e uma placa de vídeo Intel (R) UHD Graphics 620.

Foram testadas variações de 2 a 6 UAV-BS 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.

1) *Teste de Significância Estatística*: Para avaliar o desempenho de diferentes algoritmos foi utilizado o teste de significância estatística, especificamente a Análise de Variância [22] que tem como objetivo verificar a existência de diferenças significativas entre os algoritmos para cada métrica avaliada: quantidade de Usuários Conectados UC, SINR, Vazão e Tempo de Execução TE.

2) *Cálculo de superioridade*: A fórmula utilizada para calcular a superioridade percentual de uma meta-heurística sobre a outra, é dada por:

$$S(\%) = \left(\frac{\theta - \iota}{\iota} \right) \times 100 \quad (4)$$

onde: $S(\%)$ é a superioridade de um algoritmo em relação ao outro, medida em percentual, θ é o Valor da métrica de uma Meta-Heurística; ι é Valor da métrica de uma Meta-Heurística Comparada.

G. Algoritmos de Meta-Heurísticos

Neste estudo, buscou-se algoritmos inspirados em diferentes fenômenos naturais (abelhas, formigas, evolução genética, comportamento social de partículas, e processos de ensino-aprendizagem), garantindo uma diversidade de estratégias e mecanismos de solução que cobrem amplamente o espectro de possíveis soluções. Ao final de cada meta-heurística busca-se otimizar o posicionamento dos UAV-BS de forma a maximizar a cobertura e a qualidade do sinal para os usuários.

Os algoritmos meta-heurísticos utilizados foram: O ABC que simula o comportamento forrageiro das abelhas para encontrar soluções ótimas, possuindo uma estrutura simples, com poucos parâmetros para ajuste, o que facilita sua implementação e reduz a carga computacional [23]. O ACO que baseia-se no comportamento de procura de caminho das formigas que utilizam o feromônio para otimização de planejamento de caminho, excelente para resolver problemas combinatórios e possui adaptabilidade a mudanças no ambiente, crucial para cenários onde a topologia e a demanda de rede podem variar [24]. O AG que utiliza conceitos de seleção natural e genética para evoluir soluções ao longo de várias gerações, atuando com flexibilidade e robustez em explorar grandes espaços de busca, sendo eficaz em evitar mínimos locais através de operações genéticas [25]. O PSO que inspira-se no comportamento social de enxames como os pássaros e peixes para encontrar soluções ótimas, explorando o espaço de busca globalmente, usando uma população de partículas que ajustam suas posições com base em suas próprias experiências

e nas dos vizinhos [26]. O TLBO que é um algoritmo baseado no processo de ensino e aprendizagem em sala de aula onde os "alunos" (soluções) aprendem do "professor" (melhor solução) e entre si, balanceando a exploração sem necessidade de muitos parâmetros ajustáveis, o que facilita sua implementação e uso [27].

A Tabela I apresenta os parâmetros da aplicação dos algoritmos para resolver o problema.

TABLE I
PARÂMETROS DOS ALGORITMOS DE META-HEURÍSTICA

Algoritmo	Parâmetro	Valor
ABC	Máximo de iterações	100
	Limite	200
ACO	Taxa de evaporação	0.1
	Feromônios (α)	1
	Informação heurística (β)	1
	Depósito de feromônio	1
	Feromônio inicial	0.5
	Máximo de iterações	100
AG	Número de gerações	250
	Tamanho da população	250
	Taxa de mutação	0.1
PSO	Número de partículas	200
	Máximo de iterações	10
	Peso da Inércia	0.5
	Peso Cognitivo	0.5
	Peso Social	0.8
TLBO	Máximo de iterações	400
	Taxa de aprendizado	1.0

Os parâmetros gerais do cenário são apresentados na Tabela II.

TABLE II
TABELA DE PARÂMETROS DA SIMULAÇÃO.

Parâmetro	Valor
Número de Usuários	100
Número de Pontos UAV-BS	2 - 6
Tamanho do espaço de busca	1000m x 1000m
Potência do Sinal	-80dBm
Potência de Ruído	38dBm
Frequência	2.4GHz
SINR Desejado	25dB
Altura do UAV-BS	50m
Altura antena receptora	1,2m

H. Função Fitness

A função de fitness deste problema avalia quão bem os pontos de acesso (UAV-BS) estão distribuídos para maximizar o número de usuários conectados com um SINR desejado. É definida como:

$$\text{Fitness} = \sum_i \begin{cases} 1 & \text{se } \text{SINR}_i \geq \text{SINR Objetivo} \\ 0 & \text{caso contrario} \end{cases} \quad (5)$$

onde i é o usuário avaliado.

Esta formulação contabiliza o número de usuários cujo SINR do usuário avaliado é maior que o SINR objetivo.

I. Procedimento de Coleta de Dados

1. Inicialização das posições aleatórias dos UAV-BS e usuários no espaço de busca;
2. Cálculo da SINR para cada par UAV-BS/usuário;
3. Execução dos algoritmos de meta-heurísticas para otimizar as posições dos UAV-BS;
4. Registro das posições ótimas ou subótimas encontradas, percentual de usuários conectados, SINR alcançado, vazão (Mbps) e custo computacional (tempo de execução do algoritmo).

IV. RESULTADOS

Na Tabela III são apresentados os resultados das estatísticas F e valor P estabelecidos no teste de significância estatística:

TABLE III
RESULTADOS DA SIGNIFICÂNCIA ESTATÍSTICA

Métrica	Estatística F	Valor P
Usuários Conectados	14,41	$2,46 \times 10^{-11}$
SINR	1585,89	0,0
Vazão	159,11	$2,21 \times 10^{-98}$
Tempo de execução	85,13	$1,49 \times 10^{-59}$

Os testes de significância estatística demonstraram que o Valor P, iguais ou próximos a zero, confirmam a hipótese de que a escolha do algoritmo impacta diretamente nos resultados, pois quanto mais próximo de zero, maior é a significância estatística da avaliação.

Na análise dos dados, o desempenho dos diferentes algoritmos de otimização é representado na Figura 1, demonstrando o desempenho quanto à conexão dos usuários para as diferentes quantidades de UAV-BS.




Fig. 1. Desempenho dos Algoritmos para Usuários Conectados por UAV-BS

Revelou-se que a quantidade de usuários conectados, obtidos por meio da métrica fitness, varia significativamente entre os algoritmos, com o TLBO e o PSO frequentemente conectando mais usuários em comparação aos outros algoritmos.

Percebe-se que o algoritmo PSO apresenta melhores resultados na busca por soluções ótimas quando se trata de usuários conectados, pois com 4 UAV-BS atinge a conexão máxima de 100% dos usuários e mantendo-se estável. Os algoritmos AG, ABC e TLBO mostram uma melhoria consistente no número de usuários conectados à medida que a quantidade de UAV-BS aumenta, porém alcançam a conexão total somente com 6 UAV-BS, apesar de que com 5 UAV-BS já indicam um alto nível de eficiência. Todavia o algoritmo ACO não converge

muito bem na cobertura dos usuários, apresentando o menor desempenho dentre os algoritmos analisados.

A análise comparativa de superioridade de um algoritmo em relação aos outros algoritmos, considerando 4 UAV-BS, está apresentada na matriz comparativa da Figura 2:




Fig. 2. Matriz comparativa de superioridade dos algoritmos com 4 UAV-BS.

O eixo X e Y representam respectivamente θ e ι no cálculo de S(%), onde o PSO apresenta uma superioridade de 10,22% frente o algoritmo ACO.

No gráfico da Figura 3 a vazão foi consistentemente alta para todos os algoritmos, com valores em torno de 97 a 100 Mbps. O AG e o ABC, destacaram-se com vazões ligeiramente superiores, especialmente com 6 UAV-BS. Percebe-se que o PSO, no momento que tem 4 UAV-BS, onde consegue atingir a cobertura de todos os usuários, seus resultados possuem uma menor variância com relação a média, ou seja, os resultados estão quase na mesma vazão e buscando um percentil menos ampliado. Entretanto, quando se analisa com 5 UAV-BS, a variância dos resultados da vazão do PSO aumenta, levando a identificar que o aumento de UAV-BS no ambiente gera uma maior interferência de sinal, sem gerar melhoria significativa nas métricas analisadas. Enquanto que o TLBO atinge seu melhor desempenho na vazão quando consegue cobrir todos os seus usuários com 5 UAV-BS, diminuindo sua variância na vazão, assumindo o mesmo comportamento do PSO.




Fig. 3. Desempenho de cada algoritmo em termos de vazão

O tempo de execução aumentou conforme estava aumentando a quantidade de UAV-BS, entretanto a partir do momento em que os algoritmos PSO, TLBO e ABC começaram a atingir o ponto de parada na cobertura de todos os usuários, conforme apresentado na Figura 1, ocorreu a diminuição do tempo de execução. Os algoritmos AG e ACO não conseguiram ter a mesma convergência e continuaram a aumentar o tempo de execução com o aumento da quantidade de UAV-BS. O TLBO e o PSO mostraram tempos de execução relativamente baixos em comparação com os outros algoritmos, sugerindo uma eficiência computacional superior.




Fig. 4. Desempenho dos algoritmos em razão do tempo por UAV-BS

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 (SINR) e vazão, com boas médias de usuários conectados.

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

PSO: Bom desempenho geral, mas com maior variabilidade e tempos de execução mais altos.

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

V. CONCLUSÕES

Neste artigo, foram comparados cinco algoritmos meta-heurísticos para otimizar o posicionamento de UAV-BS, comparando seus desempenhos na cobertura de usuários distribuídos no espaço de busca. Os resultados experimentais indicaram que o TLBO e o PSO superaram os demais algoritmos nas principais métricas de velocidade de convergência e cobertura dos usuários, com TLBO demonstrando uma velocidade de convergência de 0,64s enquanto que o PSO tem velocidade média de 2,36s. Entretanto o PSO alcança uma cobertura completa dos usuários com 4 UAV-BS, com superioridade de 2% em relação ao TLBO e 8% em relação ao ACO. As análises mostraram que TLBO e PSO competem de forma próxima em termos de qualidade de serviço e custo computacional. Estes achados contribuem para a generalização das abordagens de posicionamento de UAV-BS garantindo uma diversidade de estratégias e mecanismos de soluções, bem como abrem caminho para futuras pesquisas, incluindo a aplicação de TLBO e PSO em problemas otimização multiobjetivo.

REFERENCES

- [1] Saadi, Amylia Ait, et al. "A hybrid improved manta ray foraging optimization with Tabu search algorithm for solving the UAV placement problem in smart cities." *IEEE Access*, vol. 11, pp. 24315–24342, 2023.
- [2] T. Kimura and M. Ogura, "Distributed collaborative 3D-deployment of UAV base stations for on-demand coverage," *IEEE INFOCOM 2020-IEEE conference on computer communications*, pp. 1748–1757, 2020.
- [3] X. Chen, W. Chen, X. Tang, L. Yang, and L. Zhou, "PSO-VFA: A hybrid intelligent algorithm for coverage optimization of UAV-mounted base stations," *Internet Technology Journal*, vol. 23, no. 3, pp. 487–495, 2022.
- [4] N. Safwat, I. Hafez, and F. Newagy, "3D placement of a new tethered UAV to UAV relay system for coverage maximization," *Electronics*, vol. 11, no. 3, pp. 385, 2022.
- [5] Bian, Q., Xu, D., Kang, K., & Liu, J. Uav base station site selection based on spiral algorithm in complex environment. *Journal of Physics Conference Series*, vol. 2185, no. 1, pp. 12080, 2022.
- [6] K. Socha and M. Dorigo, "Ant colony optimization for continuous domains," *European Journal of Operational Research*, vol. 185, no. 3, pp. 1155–1173, 2008.
- [7] M. Mousa and M. Hussein, "Efficient UAV-based mobile edge computing using differential evolution and ant colony optimization," *PeerJ Computer Science*, vol. 8, e870, 2022.
- [8] Li, Y.; Meng, X.; Ye, F.; Jiang, T.; Li, Y. "Path Planning Based on Clustering and Improved ACO in UAV-assisted Wireless Sensor Network". *IEEE USNC-CNC-URSI North American Radio Science Meeting (Joint with AP-S Symposium)*, pp.57–58, 2020.
- [9] Carvalho, L. J. C., Prates, M. d. O., & Campos, V. C. d. S. "Utilização de algoritmo genético para estimação e otimização de parâmetros de um controlador adaptativo direto usado no controle da atitude de um drone quadrotor." *Congresso Brasileiro De Inteligência Computacional*, 2021.
- [10] Haghighi, Hassan, , Sadati, SH, Dehghan, SM e Karimi, J. "Hybrid form of particle swarm optimization and genetic algorithm for optimal path planning in coverage mission by cooperated unmanned aerial vehicles." *Journal of Aerospace Technology and Management*, vol. 12, pp. e4320, 2020
- [11] Shahin, H., Shaaban, M. F., Ismail, M. H., Mourad, H. A. M., & Khattab, A. "A Multi-Objective Situational Awareness Approach for Distribution Networks Using Drones." *IEEE Access*, 2023.
- [12] Zeng, Qingwen. "Optimization of Millimeter-Wave Base Station Deployment in 5G Networks." *Thirteenth International Conference on Ubiquitous and Future Networks (ICUFN)*. IEEE, 2022.
- [13] Yang, Zipeng, et al. "Reconfiguration for UAV Formation: A Novel Method Based on Modified Artificial Bee Colony Algorithm." *Drones*, vol. 7, no. 10, pp.595, 2023.
- [14] F. Oliveira, M. Luis, and S. Sargento, "Machine learning for the dynamic positioning of UAVs for extended connectivity," *Sensors*, vol. 21, no. 13, pp. 4618, 2021.
- [15] KHAN, Shah Khalid. "Mathematical framework for 5G-UAV relay." *Transactions on Emerging Telecommunications Technologies*, vol. 32, no. 3, pp. e4194, 2021.
- [16] Yan, Chaoxing, et al. "A comprehensive survey on UAV communication channel modeling." *IEEE Access*, vol. 7, pp. 107769–107792, 2019.
- [17] Zhao, K.; Razaq, M.M.; Li, K.; Peng, L.; Ho, P.-H. "3D Deployment of UAVs for Communications under Multiple Eavesdroppers." *In Proceedings of the 2022 International Conference on Networking and Network Applications (NaNA)*, IEEE pp. 437–441, 2022.
- [18] Shoer, I., Gunturk, B. K., Ates, H. F., & Baykas, T. "Altitude Optimization of UAV Base Stations from Satellite Images Using Deep Neural Network." *arXiv preprint arXiv:2112.14551*, 2021.
- [19] Jiang, Feng, and A. Lee Swindlehurst. "Optimization of UAV heading for the ground-to-air uplink." *IEEE Journal on Selected Areas in Communications*, vol. 30, no. 5, pp. 993–1005, 2012.
- [20] C. E. Shannon, "A mathematical theory of communication," *ACM SIGMOBILE Mobile Comput. Commun. Rev.*, vol. 5, no. 1, pp. 3–55, 2001.
- [21] GUO, Zinan; HU, Bo; CHEN, Shanzhi. "A Decision for Throughput Optimization in UAV-Enabled Emergency Outdoor-Indoor Fairness Communication." *Drones*, vol. 7, no. 7, pp. 460, 2023.
- [22] Terenciani, Marcelo Figueiredo, et al. "Desenvolvimento de uma plataforma web para sensoriamento remoto com VANT.", 2023.
- [23] Tan, Li, et al. "Multi-UAV path planning based on IB-ABC with restricted planned arrival sequence." *Robotica*, vol. 41 no. 4, pp. 1244–1257, 2023.
- [24] Konatowski, Stanisław, and Piotr Pawłowski. "Ant colony optimization algorithm for UAV path planning." *14th international conference on advanced trends in radioelectronics, telecommunications and computer engineering (TCSET)*. IEEE, pp. 177–182, 2018.
- [25] Anosri, Siwakorn, et al. "A comparative study of state-of-the-art meta-heuristics for solving many-objective optimization problems of fixed wing unmanned aerial vehicle conceptual design." *Archives of Computational Methods in Engineering*, vol. 30, no. 6, pp. 3657–3671, 2023.
- [26] Sánchez-García, Jesús, Daniel Gutierrez Reina, and S. L. Toral. "A distributed PSO-based exploration algorithm for a UAV network assisting a disaster scenario." *Future Generation Computer Systems*, vol. 90, pp. 129–148, 2019.
- [27] Ghambari, Soheila, et al. "A comparative study of meta-heuristic algorithms for solving UAV path planning." *IEEE Symposium Series on Computational Intelligence (SSCI)*, pp. 174–181, 2018.