

Planejamento da Mobilização de Pessoal para a Missão EXCON TÁPIO utilizando Pesquisa Operacional

Resumo – O Exercício Conjunto Tápio (EXCON TÁPIO) é uma atividade operacional fundamental para o desenvolvimento doutrinário e o treinamento técnico das Unidades Militares do Comando de Preparo (COMPREP), da Marinha do Brasil, do Exército Brasileiro e de países parceiros. Organizado pela Base Aérea de Campo Grande (BACG) e coordenado pelo COMPREP, o exercício exige o planejamento e a execução da rota mais eficiente para a mobilização e desmobilização de militares da Força Aérea, além do planejamento de carga de diversas localidades do Brasil até a cidade de Campo Grande, MS. A logística deste exercício é crucial para o sucesso da operação, representando um desafio significativo para a coordenação e otimização das rotas. Este estudo objetiva desenvolver um modelo matemático para otimizar o planejamento da rota de transporte aéreo, considerando variáveis como distância, quantidade de passageiros por localidade e capacidade máxima de passageiros da aeronave. O trabalho apresenta formulações matemáticas em Programação Meta-heurística e propõe o Algoritmo Simulated Annealing (SA) para otimizar uma variação do Problema do Caixeiro Viajante (Traveling Salesman Problem, TSP). Os resultados obtidos confirmaram que a formulação adotada e o Algoritmo Simulated Annealing são eficazes em encontrar a melhor rota e soluções ótimas, ao incorporar heurísticas.

Palavras-Chave – Logística, Pesquisa Operacional, Recozimento Simulado.

I. INTRODUÇÃO

O Exercício Conjunto Tápio (EXCON TÁPIO) representa uma das principais atividades operacionais voltadas ao desenvolvimento doutrinário e ao treinamento técnico das Unidades Militares do Comando de Preparo (COMPREP). Este exercício envolve a Marinha do Brasil, o Exército Brasileiro e forças armadas de países parceiros, sendo organizado pela Base Aérea de Campo Grande (BACG) e coordenado pelo COMPREP.

A EXCON TÁPIO é uma atividade operacional fundamental para o desenvolvimento doutrinário e o adestramento técnico das Unidades Militares do Comando de Preparo (COMPREP), da Marinha do Brasil, do Exército Brasileiro e de países parceiros. Com base em uma situação hipotética de Guerra Irregular, Assimétrica, Regional e Limitada, conforme definido pelo MD 51-M-04, o exercício visa principalmente o cumprimento de Ações de Força Aérea em consonância com a DCA 11-45.

A complexidade logística do EXCON TÁPIO é notável, especialmente devido à necessidade de planejar e executar a rota mais eficiente para o deslocamento de militares da Força Aérea de diversas localidades do Brasil até Campo Grande, MS. Com a participação de 24 unidades operacionais, 12 unidades administrativas, uma unidade operacional da Marinha do Brasil e uma do Exército Brasileiro, distribuídas

em 13 estados diferentes, o exercício apresenta desafios significativos em termos de mobilização, desmobilização e planejamento de carga. A BACG desempenha um papel central na coordenação dessas operações, exigindo um cuidadoso planejamento logístico para garantir o transporte eficiente de pessoal e material.

O planejamento logístico do EXCON TÁPIO exige a consideração de várias variáveis, como a distância entre as localidades, a quantidade de passageiros por localidade e a capacidade máxima de passageiros da aeronave. Este estudo visa desenvolver um modelo matemático que permita a otimização do planejamento da rota de transporte aéreo, focando na minimização de custos e tempo de voo, enquanto atende às necessidades das unidades operacionais envolvidas.

Para abordar a complexidade desse problema, são exploradas técnicas avançadas de otimização, como o algoritmo genético e o algoritmo de recozimento simulado (Simulated Annealing). Estes métodos são escolhidos pela sua capacidade de encontrar soluções aproximadas em um tempo razoável, mesmo para instâncias grandes e complexas do problema.

Este artigo está organizado da seguinte forma: na seção de Metodologia, detalhamos os métodos e algoritmos utilizados para resolver o problema de otimização logística. Em seguida, apresentamos os Resultados e a Discussão, onde analisamos os achados da pesquisa e suas implicações práticas. Finalmente, concluímos com uma síntese dos principais pontos e sugestões para trabalhos futuros.

II. METODOLOGIA

O problema abordado neste estudo é a otimização da rota de transporte aéreo para o EXCON TÁPIO, visando minimizar os custos e o tempo de voo, ao mesmo tempo em que atende às necessidades das unidades operacionais envolvidas.

A. Formulação do Problema

O objetivo é minimizar a distância total percorrida pelas aeronaves, garantindo que todas as restrições de capacidade e demanda sejam atendidas.

A formulação da sua função objetivo pode ser expressa por:

$$Z = \left(\sum_{i=0}^{n-1} d(x_i, x_{i+1}) \right) + \sum_{j=0}^k P_j + d(x_n, x_0)$$

onde $d(x_i, x_j)$ é a distância entre pontos i e j e P_j é a penalidade paga por querer ir a uma localidade e não ter capacidade para alocar todos os PAX.

Além disso, a modelagem se sujeita às restrições de visitar cada localidade do conjunto V uma única vez, ou seja,

$x_i \neq x_j, \forall (i, j) \in V$, além de que o ponto inicial x_0 deverá ser sempre a BACG e a aeronave retornará a ele no final.

O grafo da rota é composto por doze pontos. A matriz de distâncias pode ser observada na Tab. I, onde cada célula representa a distância para ir de um ponto a outro do grafo.

TABELA I. MATRIZ DE DISTÂNCIAS ENTRE PONTOS DO GRAFO PARA A ROTA DO EXCON

	SBCG	SBBR	SBGL	SBPV	SBSM	SBAN	SBNT	SBMN	SBSJ	SBCO	SBCT	SBBV	SBGR
SBCG		876.48	1208.24	1641.10	1032.34	763.78	2647.98	2010.27	958.51	1110.48	780.79	2674.41	906.61
SBBR	876.48		914.53	1908.50	1647.95	118.40	1771.54	1934.93	845.44	1598.78	1068.55	2510.78	855.04
SBGL	1208.24	914.53		2703.83	1292.56	945.51	2066.79	2834.31	271.49	1116.78	672.49	3424.09	337.44
SBPV	1641.10	1908.50	2703.83		2565.92	1823.38	3174.78	754.36	2509.21	2707.75	2419.13	1332.82	2474.49
SBSM	1032.34	1647.95	1292.56	2565.92		1574.37	3278.16	3027.04	1061.66	246.09	650.03	3695.83	1000.36
SBAN	763.78	118.40	945.51	1823.38	1574.37		1884.92	1889.36	842.16	1540.34	1019.88	2482.50	842.38
SBNT	2647.98	1771.54	2066.79	3174.78	3278.16	1884.92		2759.31	2236.34	3149.55	2629.90	2988.96	2290.54
SBMN	2010.27	1934.93	2834.31	754.36	3027.04	1889.36	2759.31		2700.42	3120.73	2728.43	671.16	2683.55
SBSJ	958.51	845.44	271.49	2509.21	1061.66	842.16	2236.34	2700.42		913.54	419.09	3314.63	67.14
SBCO	1110.48	1598.78	1116.78	2707.75	246.09	1540.34	3149.55	3120.73	913.54		538.82	3783.88	859.28
SBCT	780.79	1068.55	672.49	2419.13	650.03	1019.88	2629.90	2728.43	419.09	538.82		3375.05	354.61
SBBV	2674.41	2510.78	3424.09	1332.82	3695.83	2482.50	2988.96	671.16	3314.63	3783.88	3375.05		3303.78
SBGR	906.61	855.04	337.44	2474.49	1000.36	842.38	2290.54	2683.55	67.14	859.28	354.61	3303.78	

TÁPIO

O número de militares em cada ponto do grafo pode ser visto na Tab. II.

TABELA II. QUANTITATIVO DE PASSAGEIROS EM CADA UM DOS PONTOS DO GRAFO

Aeroporto	SBCG	SBBR	SBGL	SBPV	SBSM	SBAN	SBNT	SBMN	SBSJ	SBCO	SBCT	SBBV	SBGR
PAX	0	79	142	27	122	52	38	75	4	33	8	26	1

A penalidade identificada em (1) ocorre quando uma aeronave está em um ponto, suponhamos SBGL, e planeja ir para SBSM mas não possui espaço o suficiente para alocar todos os militares de SBSM. Nesse caso, a aeronave deve retornar à SBCG, desembarcar os militares e ir para SBSM continuar sua mobilização.

B. Algoritmos Utilizados

1) *Algoritmo Genético (GA)*: O Algoritmo Genético (GA) é uma técnica de otimização inspirada nos processos de evolução natural. No GA, cada cromossomo representa uma possível solução para a rota de transporte aéreo. A configuração do GA acontece com os seguintes passos:

a) *Inicialização*: Gerar uma população inicial de soluções aleatórias.

b) *Avaliação*: Calcular a função de aptidão para cada cromossomo com base na minimização dos custos totais e do tempo de voo.

c) *Seleção*: Selecionar pares de cromossomos para reprodução com base em sua aptidão (seleção por torneio).

d) *Crossover*: Realizar o crossover de dois pontos nos pares selecionados para gerar novos cromossomos.

e) *Mutação*: Aplicar mutações nos novos cromossomos por troca de posição de genes.

f) *Substituição*: Substituir a população antiga pelos novos cromossomos.

g) *Iteração*: Repetir os passos 2 a 6 por um número fixo de gerações ou até atingir um critério de parada.

2) *Simulated Annealing (SA)*: Simulated Annealing (SA) é um método de busca estocástica baseado no processo de recozimento de metais. A configuração do SA acontece com os seguintes passos:

a) *Inicialização*: Definir uma solução inicial e uma temperatura inicial T .

b) *Perturbação*: Gerar uma nova solução x por uma pequena alteração (por exemplo, troca de posições).

c) *Avaliação*: Calcular a diferença de custo $\Delta E = E(x') - E(x)$.

d) *Crítério de Aceitação*: Aceitar sempre a nova solução se $e' < e$ ou, caso contrário, com uma probabilidade $P(e', T) = e^{-e'/T}$, onde e é a energia (valor da função de custo) da solução atual, e' é a energia da nova solução e T é a temperatura atual.

e) *Atualização da Temperatura*: Reduzir a temperatura de acordo com um esquema de resfriamento exponencial $T = \alpha T$, onde α é a taxa de resfriamento.

f) *Iteração*: Repetir os passos 2 a 5 até que a temperatura seja suficientemente baixa ou um critério de parada seja atingido.

3) *Enumeração Exaustiva*: O método de Enumeração Exaustiva, por percorrer e avaliar todas as soluções existentes, garante a obtenção da solução ótima, mas o tempo de execução pode ser proibitivo para problemas grandes. Sua finalidade é apresentar o valor da solução ótima e permitir avaliar cada um dos outros algoritmos com o valor encontrado.

Discussão sobre a seleção dos parâmetros (Simulated Annealing e Algoritmo Genético)

Seleção de Parâmetros: A escolha dos parâmetros tanto para o Simulated Annealing (SA) quanto para o Algoritmo Genético (GA) foi baseada em diretrizes da literatura, porém ajustes finos nesses parâmetros podem melhorar o desempenho dos algoritmos.

Para o SA, a temperatura inicial foi definida em 1000, permitindo uma ampla exploração inicial do espaço de soluções. A taxa de resfriamento de 0.95 foi escolhida para garantir uma convergência gradual, o que geralmente evita que o algoritmo fique preso em mínimos locais. Alterações nessa taxa, como um resfriamento mais rápido (valores menores), podem reduzir o tempo de execução, mas também podem limitar a busca, resultando em soluções de menor qualidade. No GA, a taxa de mutação de 7,5% foi selecionada para manter a diversidade entre as soluções, evitando a convergência prematura. Uma taxa mais alta pode aumentar a diversidade, porém com o risco de gerar muitas soluções subótimas, enquanto uma taxa mais baixa pode acelerar a convergência, mas pode levar o algoritmo a uma solução local de qualidade inferior. A população inicial de 100 cromossomos foi escolhida para garantir diversidade suficiente, mas estudos futuros podem explorar populações maiores, o que pode melhorar a qualidade das soluções ao custo de um tempo de execução mais longo.

C. Implementação

1) *Algoritmo Genético*: O algoritmo genético foi testado através da ferramenta *Solver* do software *Microsoft Excel*. Os parâmetros foram setados da seguinte maneira: *Max Time Unlimited, Iterations Unlimited, Precision 0.1, Convergence 0.0001, Population Size 100, Random Seed 0, Mutation Rate 0.075, Time w/o Improve 5 sec, Max Subproblems Unlimited, Max Integer Sols Unlimited, Integer Tolerance 1%, Assume NonNegative*.

2) *Simulated Annealing*: A implementação do algoritmo SA foi realizada utilizando a linguagem de programação Python, com o auxílio de bibliotecas para manipulação de dados e visualização dos resultados. Os parâmetros definidos foram a temperatura inicial igual a 1000, a taxa de resfriamento igual a 0.95 e o número máximo de iterações de 1000.

3) *Enumeração Exaustiva*: O algoritmo de Enumeração Exaustiva foi implementado utilizando a linguagem de programação Python, de forma a percorrer todas as rotas possíveis.

III. RESULTADOS

A. Enumeração Exaustiva

O algoritmo de Enumeração Exaustiva encontrou o melhor caminho num custo de 14338.57 km. O tempo total para o algoritmo percorrer todas as soluções foi de 1278.59 segundos.

B. Simulated Annealing

O algoritmo foi executado e programado para encontrar 10000 soluções. Seu resultado se encontra na Fig. 1, onde pode-se notar um histograma com as quantidades de soluções em cada um dos intervalos definidos no eixo x .

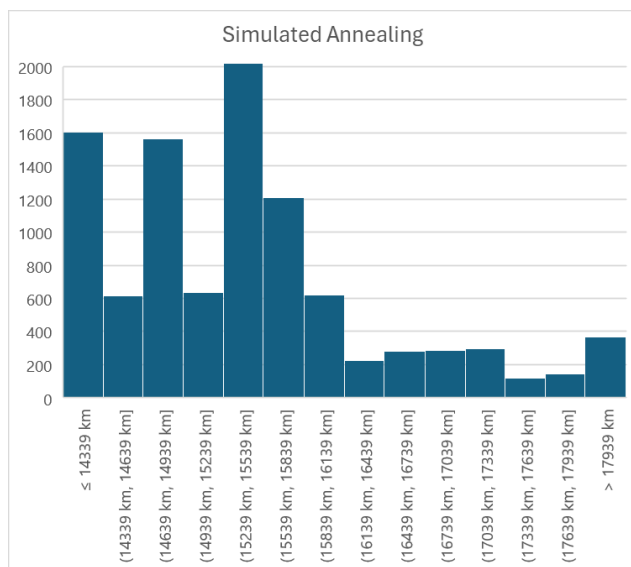


Fig. 1. Histograma das soluções para o algoritmo Simulated Annealing.

A melhor solução sub-ótima encontrada pelo algoritmo foi de 14338.57 km, em 1603 das 10000 soluções, enquanto que as outras foram maiores ou iguais a 14358.25 km.

O tempo de execução foi de 32.31 segundos para as 10000 soluções, portanto cada solução teve, em média, um custo de 0.032 segundos. Como apenas uma fração igual a 1603/10000 foram das melhores soluções, a média de tempo até encontrá-las foi de aproximadamente 0.2 segundos.

C. Algoritmo Genético

O algoritmo genético foi executado numa planilha do software *Microsoft Excel*, por 10 vezes. O resultado pode ser visualizado na Tab. III, onde todas as soluções apresentadas dizem respeito à solução sub-ótima de 14338.57 km.

TABELA III. RESULTADOS DO ALGORITMO GENÉTICO NO EXCEL

Número da solução	Tempo total (segundos)	Tempo corrigido (segundos)
1	11.00	6.00
2	9.52	4.52
3	10.72	5.72
4	9.45	4.45
5	10.78	5.78
6	10.39	5.39
7	10.02	5.02
8	10.03	5.03
9	11.00	6.00
10	11.11	6.11

O tempo corrigido, na Tab. 1, é entendido como o tempo total subtraído do critério de parada, que é o intervalo de tempo, definido em 5 segundos, em que não se encontra uma solução melhor. A média do tempo corrigido para as 10 soluções foi de 5.40 segundos.

IV. DISCUSSÃO

Ambos os métodos SA e GA encontraram a solução ótima apresentada pelo algoritmo de Enumeração Exaustiva. O método GA, entretanto, necessitou de um tempo médio consideravelmente maior (5.40 segundos) para apresentar essa solução, se comparado ao SA (0.2 segundos).

Essa diferença de tempo se destaca quando o grafo ganha novos pontos. Isso acontece pelo fato do problema ser de complexidade $\Theta(n!)$.

No caso, como o grafo possuía 12 pontos no caminho (que poderiam ser permutados), o número de soluções era de $12! \cong 479000000$ (quatrocentos e setenta e nove milhões) de soluções. Se houvessem, por exemplo, mais 6 pontos, o número de soluções seria $1! \cong 6400000000000000$ (seis quadrilhões e 400 trilhões) de soluções. Esse crescimento no número de pontos é factível e o incremento resultante no número de soluções faria um algoritmo de Enumeração Exaustiva demorar aproximadamente 542 anos.

A variação dos parâmetros do SA e GA também pode impactar o desempenho. Testes com taxas de resfriamento mais rápidas no SA ou maior taxa de mutação no GA podem reduzir o tempo de execução, mantendo soluções de qualidade similar. Experimentos futuros podem explorar essas variações para otimizar ainda mais os tempos de execução.

V. CONCLUSÃO

Com base nos resultados obtidos e na discussão realizada, podemos chegar a uma conclusão sobre os métodos propostos para a solução do problema do planejamento da rota.

Os métodos de GA e SA foram aplicados e avaliados em termos de tempo de execução e qualidade das soluções encontradas. Enquanto isso, o Método de Enumeração Exaustiva foi exclusivamente utilizado para efeitos comparativos, a fim de encontrar a solução ótima global de 14338.57 km. Embora não tenha sido uma solução viável em termos de tempo de execução, sua contribuição foi fundamental para garantir uma comparação precisa com as soluções encontradas pelos outros métodos.

Dito isso, o GA apresentou a solução ótima global consistente em 5.40 segundos, enquanto SA se destacou como o mais eficiente em termos de tempo de execução, encontrando a solução ótima global em apenas 0.2 segundos, o que o mostra como uma abordagem viável para resolver o problema da mobilização para o EXCON TÁPIO.

Da mesma maneira, como forma de nos aproximarmos mais ainda da realidade, podemos considerar um valor de \$30000 por hora de voo e uma velocidade de cruzeiro de 870 km/h para a aeronave responsável pela mobilização do pessoal. Nesse cenário, uma solução não otimizada, como por exemplo SBCG → SBBR → SBGL → SBPV → SBSM → SBAN → SBMN → SBBV → SBNT → SBSJ → SBCO → SBCT → SBGR → SBCG, que tem um custo de 20164.73 km, o potencial econômico seria de aproximadamente \$ 200902.

Nesse ponto, fica clara a diferença entre incorporar meta-heurísticas para a resolução de problemas de otimização de rotas. A redução no tempo para encontrar soluções pode ser significativa e o custo da operação substancialmente menor, fornecendo à FAB opções valiosas para otimizar suas operações aéreas de forma eficiente e eficaz.

REFERÊNCIAS

- [1] BRASIL. Comando da Aeronáutica. Estado-Maior da Aeronáutica, Portaria no 189/GC3, de 30 de janeiro de 2017. Aprova a 1ª modificação da Concepção Estratégica - Força Aérea 100. *Boletim do Comando da Aeronáutica*, Brasília, DF, n. 18, 1º fev. 2017b. DCA 11-45.
- [2] BRASIL. Ministério da Defesa. Portaria nº 113, de 1º de fevereiro de 2007. Dispõe sobre a “Doutrina Militar de Defesa - MD 51-M-04”. Brasília: Boletim nº 006/MD, 9 fev. 2007.
- [3] MITCHELL, M. An Introduction to Genetic Algorithms. Cambridge, MA: MIT Press, 1998.
- [4] REINELT, G. The Traveling Salesman: Computational Solutions for TSP Applications. Berlin: Springer-Verlag, 1994.
- [5] ABDOLHAMID, M. et al. Metaheuristic Approaches for Solving the Traveling Salesman Problem: A Comparative Study. *Journal of Optimization Theory and Applications*, 2022.
- [6] LEE, K. et al. Performance of Genetic Algorithms in TSP Solvers: Benchmarking Different Mutation and Crossover Techniques. *International Journal of Computational Intelligence and Applications*, 2021.