

OTIMIZAÇÃO DE *SCHEDULING* DE TAREFAS PARA UM SATÉLITE DE OBSERVAÇÃO DA TERRA

IMAGING SCHEDULING ON AN EARTH OBSERVATION SATELLITE

O Cap Av Jose Carlos de Melo Junior concluiu o Curso de Formação de Oficiais Aviadores pela AFA em 2007, e é Mestre em Ciências e Tecnologias Espaciais pelo Instituto Tecnológico de Aeronáutica (ITA). Vem desenvolvendo pesquisas com ênfase em Inteligência Artificial, Sensoriamento Remoto e Visão Computacional.

Contato: melojcmj@fab.mil.br



A Dra. Mischel Carmen Neyra Belderrain possui Doutorado em Engenharia Aero-náutica e Mecânica pelo ITA, Mestrado em Engenharia de Sistemas e Computação pela UFRJ, Graduação em Investigación Operativa pela Universidad Nacional Mayor de San Marcos, Peru. Atualmente é Professora Titular do ITA.

Contato: carmen@ita.br



A Dra. Mônica Maria De Marchi possui Doutorado em Computação Aplicada pelo Instituto Nacional de Pesquisas Espaciais (1999). Desde 2002 é pesquisador titular do Instituto de Estudos Avançados (IEAv) do Departamento de Ciência e Tecnologia Aeroespacial (DCTA) e exerce a função de chefe da Divisão de Geointeligência.

Contato: monica@ieav.cta.br



O Maj Av Diego Geraldo é pesquisador da Subdivisão de Sistemas de Apoio à Decisão (EGI-A) do IEAv e membro da equipe de desenvolvimento do AEROGRAF.

Contato: diegogeraldo@ieav.cta.br



RESUMO

Satélites de Observação da Terra são satélites que possuem a capacidade de imagear alvos na superfície. Entretanto, o que se observa na prática é que a demanda de requisições de imageamento normalmente excede a capacidade desse tipo de Sistema Espacial. Assim, a otimização do scheduling de tarefas de imageamento é de vital importância, pois permite que esses Sistemas possam ser operados eficientemente. Neste trabalho, o problema é modelado e implementado na plataforma AEROGRAF, e um Algoritmo Genético híbrido é proposto para resolver o problema. O método proposto permitiu otimizar um scheduling para até 300 alvos em poucos segundos, maximizando a função objetivo proposta no artigo.

Palavras-Chave: Satélites, Sensoriamento Remoto, Algoritmos Genéticos.

ABSTRACT

Earth Observation Satellites are remote sensing satellites used for imaging tasks on Earth. However, they are still scarce with respect to the increasing uses and requests for imaging. As a result, the optimization of the scheduling plays an important role in the management of satellites. Here, the problem is modeled and implemented in a computational platform named AEROGRAF, and a hybrid Genetic Algorithm is used to handle the problem. The proposed method was able to optimize the scheduling for 300 targets in a few seconds, maximizing the given objective function.

Keywords: Satellites, Remote Sensing, Genetic Algorithms.

I – INTRODUÇÃO

A Força Aérea Brasileira (FAB) possui a competência constitucional de Controlar, Defender e Integrar um cenário correspondente a uma área de 22 milhões de km² - conhecida como Dimensão 22. Considerando-se ainda a tridimensionalidade desse cenário, é indiscutível que a utilização de Sistemas Espaciais (SE) é imprescindível para atender às necessidades da Defesa Nacional.

Entre os SE contemplados pelo Programa Estratégico de Sistemas Espaciais (PESE), é prevista a implementação de um sistema de Sensoriamento Remoto Óptico (SRO), que permitirá que todo o território nacional possa ser imageado mediante a utilização de Satélites de Observação da Terra (*Earth Observation Satellites* - EOS).

A utilização de EOS contribuirá para que as informações possam ser coletadas, processadas e distribuídas mais rapidamente e com maior precisão.

Os EOS são satélites que possuem a capacidade de imagear alvos na superfície do planeta. Amplamente utilizados em apoio às Forças Armadas, esses SE são equipados com diversos tipos de sensores, e podem adquirir imagens de pontos ou áreas que estejam dentro de sua janela de visibilidade, armazenando-as em uma memória embarcada limitada, e descarregando-as (*downlink*) posteriormente para alguma estação de solo [1].

Entretanto, observa-se que na prática a demanda de requisições de imageamento realizada aos operadores normalmente ultrapassa a capacidade de oferta dos EOS. Não obstante, existem ainda as restrições técnicas e operacionais a serem consideradas durante a confecção de um *scheduling* [2].

A Fig. 1 exemplifica o problema de *scheduling* de tarefas para um EOS, onde o objetivo é identificar um subconjunto de alvos a serem imageados a fim de maximizar uma dada função objetivo.




Figura 1 - O problema de *scheduling* de tarefas consiste em identificar quais dos alvos candidatos em (a) devem ser imageados pelo EOS. Em (b) os alvos selecionados para comporem o *scheduling* são destacados.

A otimização do *scheduling* possibilitará que haja uma sensível redução nos custos de aquisição de imagens, maior capacidade operacional da Força, maior quantidade e qualidade nos insumos de Inteligência e maior velocidade no ciclo de tomada de decisão.

Neste trabalho, propõe-se um modelo de otimização baseado em Algoritmos Genéticos que permitirá ao decisor realizar o planejamento do *scheduling* de tarefas para um EOS por um sensor óptico embarcado. Também é apresentado o *plugin* desenvolvido pelo Instituto de Estudos Avançados (IEAv) para solucionar o problema, que permite a visualização do resultado na plataforma AEROGRAF.

II – FUNDAMENTAÇÃO TEÓRICA

Não é foco deste artigo entrar em detalhes técnicos específicos, ou promover uma revisão da literatura completa. O objetivo é apenas promover uma consciência situacional a respeito do problema proposto e do método de Inteligência Artificial conhecido como Algoritmo Genético.

A. Problema de Otimização de *Scheduling* para EOS

Observa-se que a maior parte dos trabalhos relacionados a este problema tem foco em plataformas satelitais específicas, como por exemplo o SPOT5, constelação PLEIADES, constelação COSMO-Skymed e ROCSAT-II [1]. Observa-se ainda que grande parte dos trabalhos relacionados ao problema de *scheduling* para EOS diz respeito a situações emergenciais, como desastres e calamidades públicas [3].

A literatura mostra que o problema considerado é complexo e classificado como pertencente à classe de complexidade NP-completo, e que as abordagens propostas para solucionar o problema podem ser divididas entre métodos exatos e métodos aproximados [4].

O presente trabalho optou pelo desenvolvimento de um Algoritmo Genético, pertencente aos métodos aproximados, devido à velocidade com a qual a solução é apresentada (fator relevante no contexto militar) e aos bons resultados atingidos na literatura.

B. Algoritmos Genéticos

Algoritmos Genéticos (*Genetic Algorithms* - GA) são métodos computacionais de busca global e otimização baseados nos princípios da Genética e na teoria da evolução das espécies proposta por Charles Darwin, no século XIX, na obra "*On the Origin of the Species*". Utilizando técnicas bio-inspiradas, esses algoritmos combinam as características de

possíveis soluções que tiveram um bom desempenho, a fim de construir soluções melhores ao longo de diversas gerações (processo evolutivo) [5].

De maneira geral, um GA trabalha o processo evolutivo mediante seleção, cruzamento (reprodução ou *crossover*) e mutação dos indivíduos de uma população (Fig. 2), replicando o comportamento das espécies do mundo real.




Figura 2 - Visão geral de um Algoritmo Genético [6].

Mediante esse processo, o GA é capaz de realizar um processo de seleção a fim de aproveitar os melhores indivíduos (cromossomos), atribuindo aos mais adaptados ao meio as maiores chances de reproduzirem e gerarem descendentes.

Para que as operações de *crossover* e mutação possam acontecer, as potenciais soluções do problema sofrem um processo de codificação, ou seja, são representadas geneticamente. Existem na literatura diferentes tipos de codificação, sendo as mais comuns as de ponto flutuante, inteira e forma binária [7]. Para exemplificar as operações básicas de um GA, será adotada a codificação binária.

A Fig. 3 ilustra uma operação de *crossover* de 1 ponto e 2 pontos. O objetivo dessa operação é recombinar cromossomos a fim de gerar descendentes melhores. Uma vez que a solução para o problema está codificada, este operador permite a exploração de novas regiões do espaço de busca.

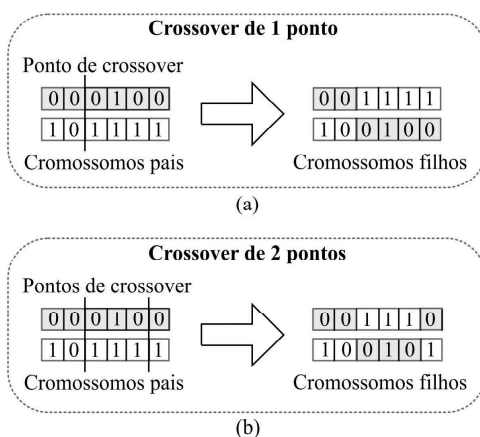


Figura 3 - Exemplo do operador de *crossover* de 1 ponto e dois pontos em cromossomos codificados binariamente [8].

Já a operação de mutação (Fig. 4) consiste, geralmente, em substituir um ou mais genes do cro-

mosso, e visa melhorar a diversidade de indivíduos da população mediante variabilidade genética.

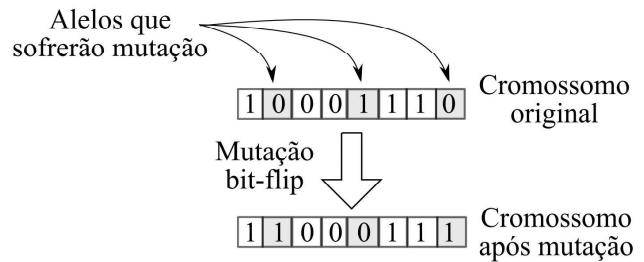


Figura 4 - Exemplo do operador de mutação aplicado a um cromossomo codificado binariamente [8].

Apesar de utilizado em diversas áreas de pesquisa, os GA têm se apresentado como um método de grande valor para tratar os mais diversos tipos de problemas complexos de otimização combinatória, como os problemas de *scheduling*, por exemplo [7].

III – MODELAGEM E MODULAÇÃO MATEMÁTICA

Visando resolver o problema de *scheduling* para EOS no contexto da FAB, implementou-se o modelo em linguagem C++, utilizando o ambiente de desenvolvimento *Borland C++ Builder Professional 6.0*, dentro da Plataforma AEROGRAF, um sistema de informações geográficas desenvolvido pela FAB [9].

A. Formulação Matemática

No modelo matemático proposto, os alvos são chamados de tarefas. Considere $T = \{t_1, t_2, \dots, t_N\}$, onde N é o número total de tarefas. Para cada tarefa t_1 pertencente a T existe uma prioridade (peso) p_1 e um tempo mínimo de execução d_1 .

Para cada tarefa t_i , também é associada uma janela de visibilidade $[ws_i, we_i]$ e um ângulo ideal de imageamento Θ_i . Como mostra a Fig. 5, para que um alvo seja imageado, ele deve estar dentro dessa janela de visibilidade.




Figura 5 - Janela de visibilidade $[ws_1, we_1]$ associada à tarefa t_1 .

Considere ainda que para um dado EOS s são associados os parâmetros $s = (\Delta\theta, sl, msg, duty)$. As definições dos parâmetros são:

$\Delta\theta$: Alcance do Sensor, que estabelece o alcance máximo do sensor óptico;

sl : Taxa de Varredura, ou seja, o tempo consumido no deslocamento angular do sensor;

msg : Campo de Visão, área quadrada em que o sensor é capaz de imagear uma tarefa; e

$duty$: Tempo máximo de abertura do sensor, restrição que limita o tempo de captura do sensor óptico por órbita.

No modelo proposto, o sensor óptico possui abertura de 5° (msg), e é capaz de deslocar lateralmente em até $\pm 30^\circ$ em relação à projeção vertical do EOS no solo ($\Delta\theta$). A Fig. 6 ilustra a atividade de imageamento proposto para este modelo matemático.

O problema de otimização do *scheduling* de tarefas do EOS compreende a maximização do lucro da atividade de imageamento, que no contexto do estabelecido neste trabalho é representado pelo somatório das prioridades dos alvos imageados (tarefas executadas).

A função objetivo para o modelo é definida como:

$$\max Z = \sum_{i=1}^N x_i p_i \quad (1)$$

Em que a variável de decisão x_i assume o valor 1 caso a tarefa i seja executada, ou valor 0 caso contrário.

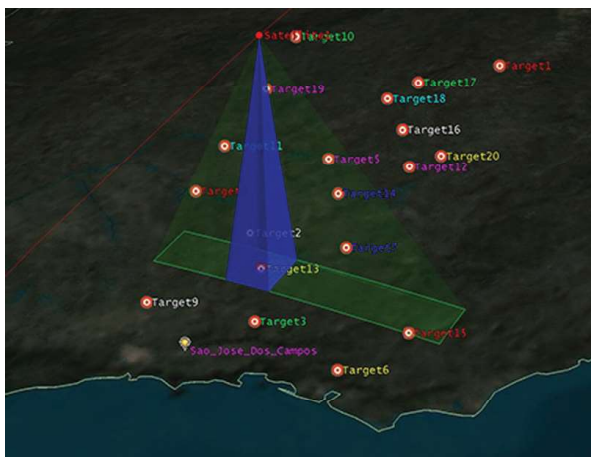


Figura 6 - Exemplo da atividade de imageamento com o EOS considerado no modelo proposto.

Já as restrições do modelo estão relacionadas aos limites técnicos do satélite e da observância e respeito às janelas de visibilidade das tarefas candidatas:

$$\text{s.a. } ts_u + d_u + tr_{u,v} \leq ts_v \quad (2)$$

$$x_i(ts_i - ws_i) \geq 0 \quad (3)$$

$$x_i(ts_i + d_i - we_i) \leq 0 \quad (4)$$

$$\sum_{i \in T} d_i \leq duty \quad (5)$$

$$x_i \in \{0, 1\} \quad (6)$$

Em (2), deve haver um tempo adequado de transição do sensor entre duas tarefas distintas tu e tv , com tSi representando o tempo de início da execução da tarefa ti e $tr_{u,v} = sl \times |\theta_v - \theta_u|$ representando o tempo que o sensor leva para mudar o alinhamento entre os alvos u e v .

As restrições (3) e (4) garantem que a execução das tarefas ocorra dentro da janela de visibilidade. Por fim, a restrição (5) impõe a limitação de abertura do sensor óptico por órbita.

Para solucionar o problema, foi proposto um GA híbrido que levou em consideração as restrições de precedência e janelas de visibilidade para cada tarefa.

Dessa maneira, a codificação utilizada consiste em um vetor contendo a sequência de alvos que devem ser imageados pelo EOS, sendo os genes de cada cromossomo o índice da tarefa a ser imageada. Devido às restrições do modelo, neste problema específico os cromossomos podem ter tamanhos variados.

Como exemplo, a Fig. 7 mostra uma população contendo n indivíduos de tamanhos diversos, e cada gene representa o índice da tarefa ti a ser executada, dispostos na sequência correta de execução.

CROMOSSOMO 1 =	7	9	11	18	14	5	21				
CROMOSSOMO 2 =	3	14	2	25	32	17	33	38	41	12	34
CROMOSSOMO 3 =	2	8	14	15	21	32					
.....											
CROMOSSOMO N =	3	23	17	11	1	9	8	21			

Figura 7 - Cada cromossomo da população representa uma potencial solução para o problema, com comprimentos variados.

Para conseguir lidar com cromossomos de tamanhos diferentes e restrições de precedência entre as tarefas, optou-se por uma hibridização do GA. Essa hibridização permitiu melhorar a eficiência do algoritmo e adaptá-lo ao problema de *scheduling* para EOS [7].

Especificamente, foi incorporada uma heurística construtivista para gerar a população inicial de cromossomos, em que se inverteu a ordem dos operadores de crossover e mutação, e se criou uma heurística para o operador de cruzamento.

Os detalhes específicos do modelo proposto, assim como os detalhes relativos aos operadores de seleção, *crossover* e mutação se encontram em [7].

IV- RESULTADOS

Como ilustrado na Fig. 8, o desenvolvimento e implementação de um módulo satelital na Plataforma AEROGRAF permitiu que os alvos inseridos aleatoriamente no mapa pudessem ser processados, e as informações necessárias, como janelas de visibilidade e ângulos ideais, extraídas.

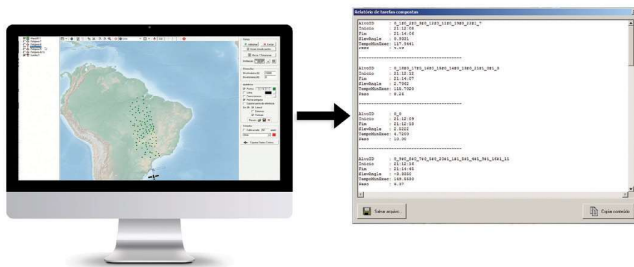


Figura 8 - Extração dos dados de entrada dos alvos candidatos pela plataforma AEROGRAF.

A fim de verificar o desempenho do algoritmo frente a instâncias de tamanhos variados, foram realizados experimentos com cenários envolvendo diferentes quantidades de alvos candidatos (QAC), todos viáveis e gerados dentro de um horizonte de planejamento de 9 minutos.

Escolheu-se arbitrariamente os valores de $QAC = \{25, 50, 100, 200, 300\}$, criando assim os cenários de teste C1, C2, C3, C4 e C5.

Em relação ao tempo de execução do algoritmo, a Fig. 9 fornece a representação gráfica dos resultados. As barras verticais representam os tempos médios de execução do GA e as barras de erro representam os intervalos de ± 1 desvio-padrão.




Figura 9 - Tempo de execução do algoritmo, em segundos, para os diferentes cenários de teste.

Outra análise importante para verificar o desempenho do algoritmo diz respeito à sua convergência. Assim, foi gerado um gráfico do melhor valor (média de 50 execuções) da função objetivo em relação ao número de observações da função objetivo (NFOB). A Fig. 10 mostra a convergência do algoritmo para todas os cenários de teste.

Como observado, para as instâncias de C1,

C2, C3 e C4 houve uma convergência rápida do algoritmo, com poucas oscilações até que o melhor resultado fosse encontrado. Mesmo na instância C5, com 300 alvos candidatos, a convergência é percebida com cerca de 5×10^4 NFOB.

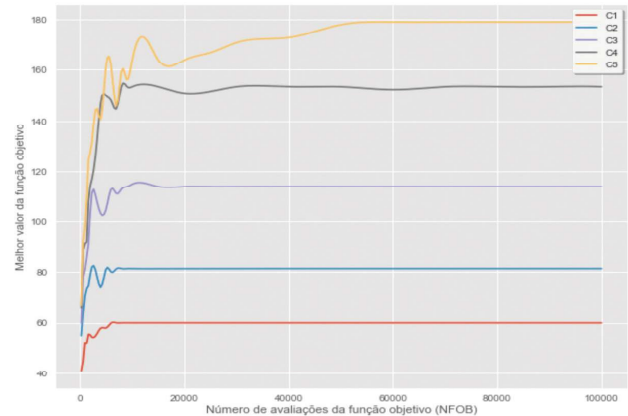


Figura 10 - Convergência do GA proposto para as cinco instâncias do problema.

Também foi feita uma análise entre a quantidade de alvos imageados e o somatório das prioridades dos mesmos, para as cinco instâncias (Tabela 1).

Como se observa, mesmo nas instâncias de maior complexidade, o desvio padrão se manteve baixo, indicando que o incremento no número de alvos não teve impacto significativo na qualidade do algoritmo.

Tabela 1 - Desempenho do algoritmo para as diferentes instâncias.

QAC	ALVOS IMAGEADOS				SOMA DAS PRIORIDADES			
	max	min	\bar{x}	s	max	min	\bar{x}	s
25	13	13	13	0	60	60	60	0
50	19	19	19	0	82	81	81,4	0,5
100	25	23	24,13	0,64	115	112	114	0,93
200	31	29	30,07	0,7	157	147	153,53	2,90
300	36	33	34,27	0,88	184	174	179,07	3,08

V- CONCLUSÕES

É inevitável a importância dos SE para a sociedade moderna, especialmente os satélites. Em relação aos SE de SRO, estes são instrumentos imprescindíveis de apoio ao processo de tomada de decisão, capazes de gerar informações de maneira mais eficiente, correta e rápida.

Os resultados obtidos pela otimização do *scheduling* se mostraram relevantes e robustos frente a um conjunto de cenários hipotéticos próximos à realidade que a FAB espera operar.

Especificamente, um algoritmo que seja capaz de apresentar resultados rapidamente, pode contribuir positivamente para acelerar o ciclo de tomada de decisões, representando uma vantagem estratégica para a Força.

De natureza aplicada, ou seja, visando uma aplicação prática, este trabalho contribui ainda com o *plugin* desenvolvido dentro da Plataforma AEROGRAF (Fig. 11), da própria FAB, o qual poderá ser utilizado para realizar análises preliminares sobre o ambiente a ser imageado e antecipar expectativas quanto aos resultados, desta forma contribuindo para que os decisores tenham informações mais eficazes.

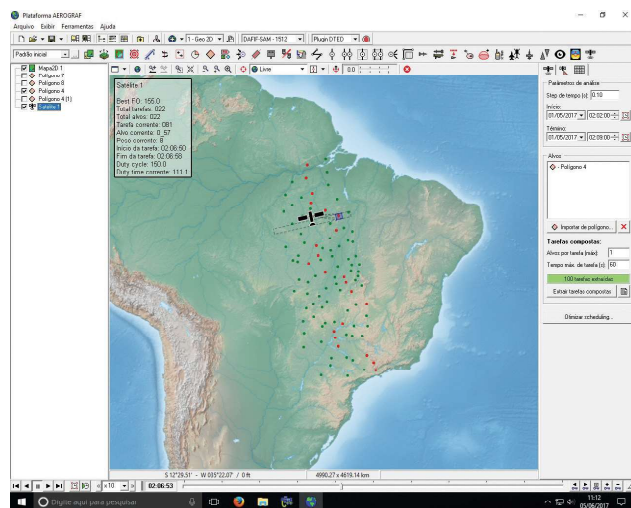


Figura 11 - *Plugin* para EOS desenvolvido dentro do ambiente AEROGRAF.

Além da contribuição acadêmica proporcionada pela relevância do tema aqui tratado, espera-se que este trabalho sirva ainda para incentivar pesquisas de natureza aplicada dentro do setor espacial.

REFERÊNCIAS

[1] XU, R. et al. **Priority-based constructive algorithms for scheduling agile earth observation satellites with total priority maximization.** Expert Systems with Applications, v. 51, p. 195–206, 2016.

[2] WANG, J.; DEMEULEMEESTER, E.; QIU, D. **A pure proactive scheduling algorithm for multiple earth observation satellites under uncertainties of clouds.** Computers and Operations Research, v. 74, p. 1–13, 2016.

[3] ZHAI, X. et al. **Robust Satellite Scheduling Approach for Dynamic Emergency Tasks.** Mathematical Problems in Engineering, p. 1–20, 2015.

[4] NIU, X. et al. **Imaging-Duration Embedded Dynamic Scheduling of Earth Observation Satellites for Emergent Events.** Mathematical Problems in Engineering, p. 1–31, 2015.

[5] MCCALL, J. **Genetic algorithms for modelling and optimisation.** Journal of Computational and Applied Mathematics, v. 184, n. 1, p. 205–222, 2005.

[6] NALDI, M. C. **Técnicas de combinação para agrupamento centralizado e distribuído de dados.** 245 f. Tese (Doutorado em Ciências da Computação e Matemática Computacional) - Universidade de São Paulo, São Carlos, 2011.

[7] MELO JÚNIOR, J. C. **Um Problema de Atribuição de Tarefas para um Satélite de Observação da Terra no Contexto do PESE.** 2018. 88f. Dissertação de Mestrado - Instituto Tecnológico de Aeronáutica, São José dos Campos.

[8] CERRI, R. **Redes neurais e algoritmos genéticos para problemas de classificação hierárquica multirrótulo.** 175 f. Tese (Doutorado em Ciências de Computação e Matemática Computacional) - Universidade de São Paulo, São Carlos, 2013.

[9] PETERSEN, F. J. **Plataforma AEROGRAF: um SIG voltado para a Força Aérea.** Revista Spectrum, v. 1, n. 11, p. 26–28, 2013.