



Otimização de Funções com Algoritmo Genético

Function Optimization with Genetic Algorithm

Natalia Argenta Santin¹, Bruno Adriano Menegotto², Mario Henrique Bigai³, Hugo Valadares Siqueira⁴

RESUMO

Este estudo aplicou Algoritmos Genéticos (AGs) para otimizar funções computacionais, incluindo as funções Rastrigin e Schwefel. Para tal foram utilizados AGs com variações nos métodos de seleção (torneio e roleta) e tipos de crossover (aritmético e uniforme) em diversas configurações de população. Os resultados demonstram que os AGs são eficazes em convergir para soluções ótimas ou aproximadas em diferentes cenários. A escolha das configurações depende do problema específico, mas os AGs são uma valiosa ferramenta de otimização de dados.

PALAVRAS-CHAVE: Algoritmos Genéticos. Funções Computacionais. Otimização de Dados.

ABSTRACT

This study applied Genetic Algorithms (AGs) to optimize computational functions, including the Rastrigin and Schwefel functions. AGs with variations in selection methods (tournament and roulette) and types of crossovers (arithmetic and uniform) were used in various population configurations. The results demonstrate that AGs are effective in converging towards optimal or approximate solutions in different scenarios. The choice of configurations depends on the specific problem, but AGs are a valuable data optimization tool.

KEYWORDS: Genetic Algorithms. Computational Functions. Data Optimization.

INTRODUÇÃO

A otimização de dados no mundo atual tem uma ampla variação de aplicações e é um campo de pesquisa em constante evolução. Pode ser utilizada em campus de estudo como física, geometria segundo Braga (2020), melhoria de aprendizados de uma máquina, até o planejamento de uma melhor rota, como é o caso do caixeiro viajante. Nessas situações os Algoritmos Genéticos (AG) são uma ferramenta importante para resolver exercícios computacionais que envolvem otimização.

O AG é inspirado em comportamentos da natureza, com o objetivo de encontrar a melhor solução para uma determinada tarefa como é o estudo de Cunha (2019) para solucionar o caso do caixeiro viajante. AG são métodos de otimização que se baseiam na ideia da evolução biológica e seleção natural de Charles Darwin, em que sobrevivem os indivíduos mais aptos do ambiente segundo Goldberg (1989). Os AG's foram desenvolvidos

¹ Voluntária. Universidade Tecnológica Federal do Paraná, Ponta Grossa, Brasil. E-mail: natsan@alunos.utfpr.edu.br. ID Lattes: 1740452643980245.

² Aluno do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE). Universidade Tecnológica Federal do Paraná, Ponta Grossa, Brasil. E-mail: brunomenegotto@alunos.utfpr.edu.br. ID Lattes: 0493049818753728.

³ Aluno do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE). Universidade Tecnológica Federal do Paraná, Ponta Grossa, Brasil. E-mail: mariobigai@alunos.utfpr.edu.br. ID Lattes: 4018254378620606.

⁴ Docente no Departamento de Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Ponta Grossa, Brasil. E-mail: hugosiqueira@utfpr.edu.br. ID Lattes: 6904980376005290.



por John Holland na década de 1960 e são aplicados em uma variedade de problemas até os dias atuais, que é o caso do estudo de Zini (2009).

Dentro esses exemplos, os AG's podem ser empregados com sucesso na otimização de funções procurando encontrar ótimos globais e evitar cair em ótimos locais segundo Souza (2014). Neste relatório mostrará como é a estrutura de um algoritmo genético e algumas aplicações.

METODOLOGIA

Nesse artigo o AG foi aplicado nas funções rastrigin, schwefel e uma função de ótimo único. O código foi elaborado no modelo do esquema abaixo.

POPULAÇÃO INICIAL

Inicia-se com uma população de soluções candidatas geradas aleatoriamente. Cada solução é representada como um cromossomo, que é uma sequência de genes, cada cromossomo tem dois genes, sendo os genes valores contínuos. Para o código foram utilizados 150 indivíduos.

AVALIAÇÃO DA APITIDÃO

Cada solução na população é avaliada quanto à sua qualidade por meio de uma função de aptidão. Essa função atribui um valor numérico à solução, representando o quão boa ela é em relação ao objetivo de otimização. Este valor leva o nome de fitness.

SELEÇÃO

Soluções com melhor aptidão têm uma maior probabilidade de serem selecionadas para a próxima geração, seguindo o princípio de "sobrevivência dos mais aptos". Neste trabalho foram utilizados os métodos da roleta e do torneio.

A roleta simula uma roleta de cassino embora seja viciada, de modo que soluções com uma aptidão maior têm também uma chance maior de serem selecionadas. Entretanto, existe a probabilidade de indivíduos com menos aptidão sejam escolhidos, mesmo que com uma porcentagem menor.

Já o método do torneio seleciona um subconjunto aleatório de soluções da população atual para determinar quais serão selecionadas para formar a próxima geração. Após a escolha de tal subconjunto, aquele indivíduo de maior fitness é selecionado. Note que a pressão seletiva tende a ser menor com tal escolha.

CROSSOVER

Os pares escolhidos no processo de seleção são combinados para criar novas soluções por meio de técnicas de recombinação, como a troca de partes dos cromossomos (crossover). Isso simula a recombinação genética na reprodução biológica. Para a confecção do código foram utilizados dois tipos de crossover, o aritmético e o uniforme.

O crossover aritmético seleciona dois indivíduos, denominados pais, que tem seus genes ponderados por um valor de acordo com a equação 1: passa por um valor de ponderação que determina com o que irá para cada filho, no projeto para calcular os filhos foi utilizada a equação (1) para o filho 1 e a equação (2) para o filho 2.



$$f_1 = (1 - \alpha)p_1 + \alpha p_2 \quad (1)$$

$$f_2 = \alpha p_1 + (1 - \alpha)p_2 \quad (2)$$

O α é um valor inteiro aleatório no intervalo $[0,1]$.

Já o crossover uniforme, como o caso anterior, é projetado para criar novos indivíduos trocando aleatoriamente informações entre dois pais. Porém aqui a probabilidade de selecionar os genes de cada pai é de 50%.

MUTAÇÃO

Ocorre ocasionalmente uma mutação em soluções selecionadas, introduzindo variação no código genético. Isso ajuda a explorar regiões do espaço de busca que podem não ser acessíveis apenas com recombinação. Para as execuções foi utilizada uma probabilidade de mutação de 10%.

SUBSTITUIÇÃO

Os indivíduos são substituídos pelas novas soluções criadas na etapa de recombinação e mutação, ou seja, os pais morrem e ficam os filhos. Isto ocorre até atingir o critério de parada.

CRITÉRIO DE PARADA

O algoritmo continua iterando por um número definido de gerações, sendo 200 o máximo utilizado, ou até que uma solução satisfatória seja encontrada com base no fitness e nos números de interações sem melhoria de fitness.


Ao longo das gerações, as soluções evoluem e convergem para uma solução que normalmente é de melhor qualidade em relação à solução inicial.

RESULTADOS E DISCUSSÕES

As análises para cada função, rastrigin, schwefel e de ótimo único. Foram analisadas em quatro populações com métodos diferentes, sendo elas, seleção de torneio com o crossover aritmético (TA), seleção de torneio com o crossover uniforme (TU), seleção de roleta com o crossover aritmético (RA) e seleção de roleta com o crossover uniforme (RU).


Na função rastrigin e schwefel, tinham como objetivo encontrar o ponto de mínimo das funções. Os AGs foram simulados como mostram nas figuras 1 e 2. Porém nem todas as populações chegam ao objetivo. A principal razão é a elevada probabilidade das soluções ficarem presas em mínimos locais.

Figura 1 – Gráfico da função rastrigin



Fonte: Autoria própria (2023).

Figura 2 – Gráfico da função schwefel

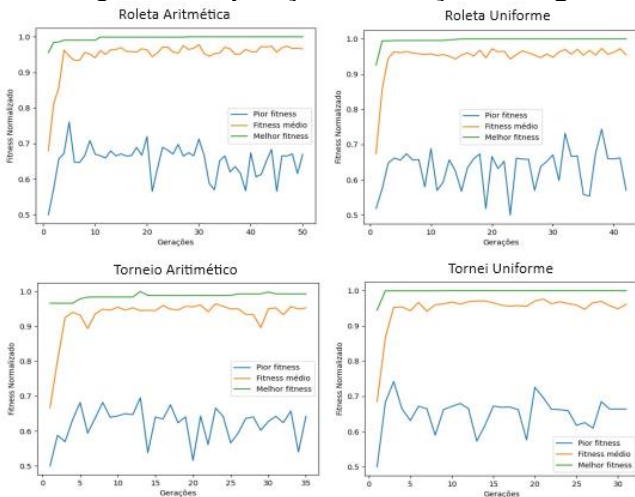


Fonte: Autoria própria (2023).




Nas figuras 3 e 4 temos quatro gráficos que mostram a evolução temporal do fitness de cada variação, e que cada uma foi composta por uma combinação de seleção e crossover. Como o objetivo é minimizar (encontrar o ponto mais baixo) quanto mais próximo de 1 o fitness normalizado é melhor.

Figura 3 – Populações da função rastrigin



Fonte: *Autoria própria* (2023).

Figura 4 – Populações da função schwefel



Fonte: *Autoria própria* (2023).

Analisando as tabelas 1 e 2 tem-se primeiro a localização do indivíduo nas posições XY e em seguida a solução que seria o fitness. Pode-se ver que na tabela 1 do caso rastrigin, a situação RU foi a melhor para esse gráfico com um fitness de 0,00234, pois o esperado dessa função seria as coordenadas de X e Y em 0 e o fitness 0 também. Já na tabela 2 do caso schwefel o esperado seria as coordenadas X e Y ambas em 421 e um fitness de 0, é possível observar que a situação RA chegou mais perto do resultado com um fitness de 0,002671.

Tabela 1 – Resultados obtidos da função rastrigin

	Coordenadas X;Y	solução
TA	-8,0611e-7;0,0576	0,651668
TU	-0,0079;-0,0030	0,014474
RA	0,0058;0,0099	0,026546
RU	-0,003;-0,0004	0,00234

Fonte: *Autoria própria* (2023).

Tabela 2 – Resultados obtidos da função schwefel

	Coordenadas X;Y	solução
TA	421,0910;420,9687	0,005018
TU	420,9394;421,4104	0,02475
RA	420,8239;420,9687	0,002671
RU	421,7900;421,3753	0,1060

Fonte: *Autoria própria* (2023).

No último caso, o objetivo foi maximizar a função de ótimo único, representada pela equação (3), mostrada na imagem 5. É possível observar que todas as populações chegaram no ponto mais alto.




$$Xe^{-(X^2+Y^2)}$$

(3)

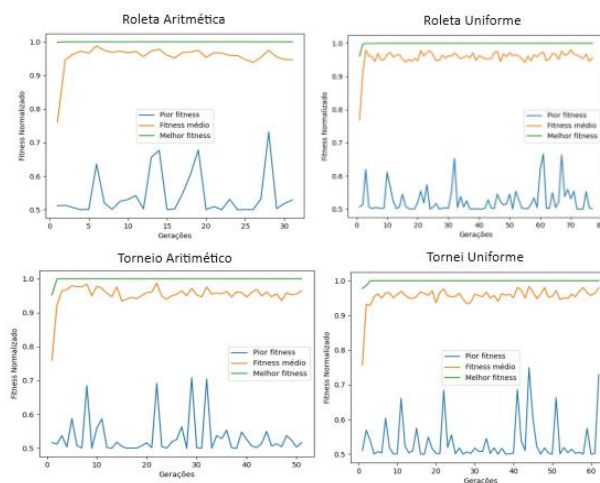
Como o objetivo é maximizar quanto mais próximo de 1 o fitness normalizado, melhor é o ponto no gráfico, por isso na ilustração 6 pode-se ver que em todos os casos ele tende a 1.

Figura 5 – Gráfico da função de ótimo único



Fonte: *Autoria própria* (2023).

Figura 6 – Gráfico da função de ótimo único



Fonte: *Autoria própria* (2023).

Aqui pode-se ver que todos conseguiram otimizar, porém alguns um pouco melhor que outros, sabendo que o resultado esperado dessa função seria as coordenadas de X e Y em 0,707 e 0 respectivamente e o fitness 0,43, na tabela 3 se tem os resultados com a melhor solução sendo RA que teve um fitness igual a 0,428882 idêntico ao TA, porem o RA obteve coordenadas melhores.

Tabela 3 – Resultados obtidos da função schwefel

	Coordenadas X;Y	solução
TA	0,7069;0,0008	0,428882
TU	0,7091;-0,0002	0,428878
RA	0,7069;0,0002	0,428882
RU	0,7091;2,9494e-5	0,428878

Fonte: *Autoria própria* (2023).

CONCLUSÕES

Os Algoritmos Genéticos são uma ferramenta eficaz para a otimização de funções, permitindo explorar soluções em diferentes cenários e encontrar resultados próximos ao ótimo. A escolha da configuração específica, incluindo métodos de seleção e crossover, pode depender da natureza do problema, mas a abordagem geral dos AG se mostrou promissora em todos os casos estudados.

Trabalhos futuros podem ser desenvolvidos com aplicações em problemas reais.

Agradecimentos



A Universidade Tecnológica Federal do Paraná campus Ponta Grossa, amigos e familiares que me apoiaram.

Conflito de interesse

Não há conflito de interesse.

REFERÊNCIAS

BRAGA, Cynthia Guerra. O uso de algoritmos genéticos para aplicação em problemas de otimização de sistemas mecânicos. 1998. 73 f. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal de Uberlândia, Uberlândia, 2020. DOI <http://doi.org/10.14393/ufu.di.1998.10>

CUNHA, Hugo Gustavo Valin Oliveira da. Algoritmo Genético e Algoritmo de Vaga-lumes aplicados ao Problema do Caixeiro Viajante. 2019. 58 f. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade Federal de Uberlândia, Uberlândia, 2019.

GOLDBERG, David Edward. Genetic Algorithms in Search, Optimization and Machine Learning, AddisonWesley 1989.

SOUZA, Gustavo Pinho Kretzer. Otimização de funções reais multidimensionais utilizando algoritmo genético contínuo. 2014. Trabalho de Conclusão de Curso (Graduação em Ciências da Computação) – Universidade Federal de Santa Catarina. Centro Tecnológico, 2014.

ZINI, Érico de Oliveira Costa. Algoritmo genético especializado na resolução de problemas com variáveis contínuas e altamente restritos. 2009. 149 f. Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, 2009.