

Algoritmo Genético na minimização da função de Rosenbrock

Garcia, Leticia Caroline¹; Borges da Silva, Fabiano²

Resumo: Inspirados no princípio darwiniano da evolução das espécies e na genética, os Algoritmos Genéticos são procedimentos probabilísticos que oferecem um mecanismo de busca adaptativo, fundamentado na seleção natural dos mais adaptados e na reprodução. A função de Rosenbrock é utilizada como uma métrica robusta para avaliar o desempenho de algoritmos de otimização. Neste trabalho se concentra na aplicação de um Algoritmo Genético para a resolução de um problema de otimização não linear, cuja função objetivo é a de Rosenbrock. Para obter os resultados numéricos, o algoritmo foi implementado em Python.

Palavras-chave: Algoritmo Genético, Função de Rosenbrock, Otimização.

1. Introdução

Os problemas de otimização são onipresentes em diversos setores da vida real, como logística, finanças, engenharia, ciência de dados, aprendizado de máquina, entre outros. A eficiente resolução desses problemas é crucial para aprimorar a tomada de decisões e aperfeiçoar processos em várias áreas. Diversas técnicas são empregadas para abordar problemas de otimização, incluindo Algoritmos Genéticos, Algoritmos Evolutivos, Programação Linear e Programação Dinâmica. O Algoritmo Genético convencional (AG) é uma técnica de otimização bioinspirada que, segundo PACHECO (1999), é inspirada no princípio darwiniano de seleção natural e reprodução genética, onde os indivíduos mais aptos ao meio tendem a sobreviver e passar suas características adiante. No AG, cada indivíduo da população representa uma solução candidata para o problema de otimização a ser resolvido e a ideia é criar gerações de indivíduos, de tal forma que o mais apto (melhor solução) sobreviva. A função de Rosenbrock é amplamente reconhecida e empregada como uma métrica fundamental para avaliar o desempenho de algoritmos de otimização, dada a sua complexidade e a sua característica multimodal, dificultando sua resolução. Este trabalho se concentra na aplicação do AG para a resolução de um problema de otimização não linear, cuja função objetivo é a função de Rosenbrock. Inicialmente estudou-se as características do AG e sua abordagem na otimização dessa função. O algoritmo foi implementado em Python e os resultados obtidos são apresentados mais adiante. Como o comportamento do melhor indivíduo de cada população pode ser interpretado como um processo estocástico discreto, esta teoria pode proporcionar uma análise mais aprofundada do comportamento do algoritmo e sua trajetória de convergência em direção à solução ótima do problema. A compreensão dessa dinâmica pode possibilitar extrair insights cruciais para o aprimoramento da eficiência e eficácia do Algoritmo Genético convencional na resolução da função de Rosenbrock. Assim, este trabalho trata de um estudo inicial que, em etapas posteriores, ainda ganhará uma abordagem dentro de sistemas dinâmicos estocásticos.

2. Resultados obtidos

O fluxograma do AG é mostrado na Figura 1 e seus operadores são detalhados a seguir:

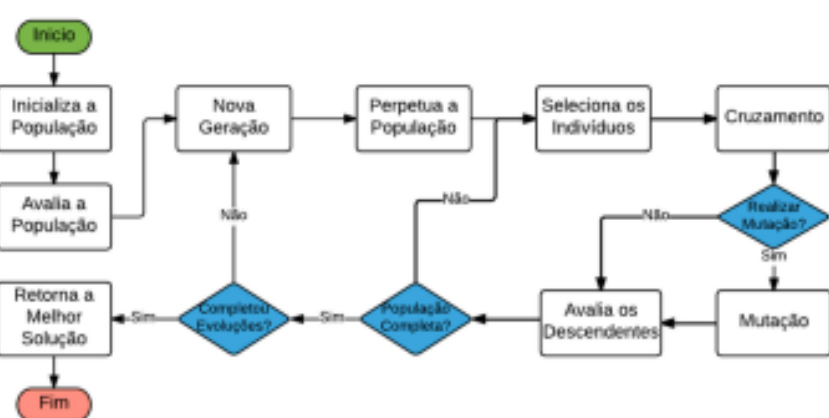


Fig. 1: Fluxograma do Algoritmo Genético Implementado por [2]

O processo de evolução começa com a criação aleatória de indivíduos que formarão a população inicial. Em seguida, todos os indivíduos da população são avaliados através da função fitness (mede a aptidão), capaz de representar os requisitos necessários a que uma população deve se adaptar a fim de avançar para a próxima geração. No caso da função de Rosenbrock, como é um problema de minimização, a fitness será inversamente proporcional à função objetivo.

A partir de um processo com base na aptidão de cada indivíduo, são escolhidos indivíduos pais que sofrerão um cruzamento (crossover) e que gerarão os indivíduos filhos. Uma vez criados os filhos, cada um deles pode sofrer uma mutação, um operador genético que soma um valor aleatório em cada uma das entradas. A taxa de mutação garante a diversidade das características dos indivíduos da população e permite que sejam introduzidas informações que não estavam presentes em nenhum dos indivíduos. Deste modo, a aptidão do indivíduo determina seu grau de sobrevivência. O critério de parada pode ser o número de iterações, a ausência de melhora nas gerações ou algum outro critério escolhido. No final do processo, o melhor indivíduo é retornado como melhor solução encontrada para o problema:

$$f(x, y) = (a - x)^2 + b(y - x^2)^2$$

A função acima é a de Rosenbrock, cuja função é bastante utilizada como um problema teste de desempenho para algoritmos de otimização. Neste trabalho iremos restringir em um caso particular com duas variáveis. Nos testes numéricos foram utilizados os parâmetros $a = 1$, $b = 100$, os limites das variáveis são $X_{min} = -10$, $X_{max} = 10$, $Y_{min} = -10$, $Y_{max} = 10$ e taxa de mutação de 10%. Para essas entradas, o mínimo global é $f(1,1) = 0$. O tamanho da população é de 100 indivíduos e o número de gerações (interações) foram de 500. A melhor solução obtida pelo AG foi o ponto (0.5578930498097652, 0.6899432453487506), com valor igual a 14.536720786647244 e tempo de execução igual a 3.8823654651641846 segundos. A Figura 2, mostra a trajetória do melhor indivíduo de cada geração, sendo o ponto inicial indicado pela cor verde e o ponto final, pela cor vermelha.

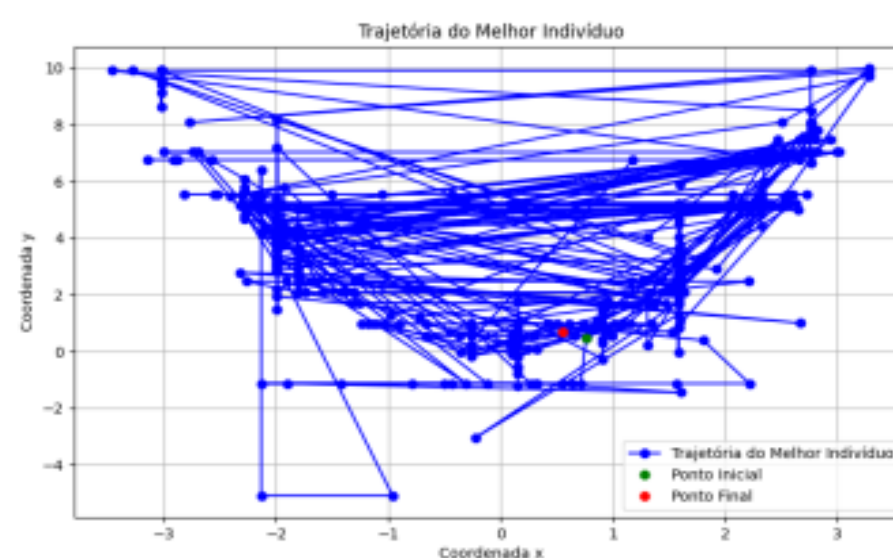


Fig. 2: Autoria própria

3. Conclusão

Através das simulações realizadas foi possível observar o comportamento do método e seu processo de busca na minimização da função de Rosenbrock. Além disso, no gráfico é possível notar a dinâmica estocástica realizada pelo melhor indivíduo da população em direção ao ótimo global da região factível escolhida no problema. Uma análise de convergência estocástica é um assunto interessante e desafiador em vários trabalhos recentes, e serve de inspiração para os autores deste trabalho seguirem com a pesquisa nesta direção. Por fim, vale destacar que este mesmo método pode ser utilizado para resolver diversos problemas de otimização.

Referências

- ALLEN, Linda JS. **An introduction to stochastic processes with applications to biology**. CRC press, 2010.
- DE OLIVEIRA GRESSLER, Henrique; CERA, Márcia Cristina. **O Impacto da paralelização com OpenMP no desempenho e na qualidade das soluções de um algoritmo genético**. Revista Brasileira de Computação Aplicada, v. 6, n. 2, p. 35-47, 2014..
- HE, Jun; KANG, Lishan. **On the convergence rates of genetic algorithms**. Theoretical Computer Science, v. 229, n. 1-2, p. 23-39, 1999.
- HE, Jun; YAO, Xin. **Towards an analytic framework for analysing the computation time of evolutionary algorithms**. Artificial Intelligence, v. 145, n. 1-2, p. 59-97, 2003.
- PACHECO, Marco Aurélio Cavalcanti et al. **Algoritmos genéticos: princípios e aplicações**. ICA: Laboratório de Inteligência Computacional Aplicada. Departamento de Engenharia Elétrica. Pontifícia Universidade Católica do Rio de Janeiro. Fonte desconhecida, v. 28, 1999.
- RUFFINO, P. R. C. **Uma iniciação aos sistemas dinâmicos estocásticos**. 2. ed. Rio de Janeiro: IMPA, 2009.

¹ Universidade Estadual Paulista- Unesp, Faculdade de Ciências, Licenciatura em Matemática, lc.garcia@unesp.br

² Universidade Estadual Paulista- Unesp, Faculdade de Ciências, Departamento de Matemática, fabiano.borges@unesp.br