

Proceeding Series of the Brazilian Society of Computational and Applied Mathematics

Estratégias de Otimização Baseadas em Algoritmos Genéticos com Operadores Migração, Epidemia e Relaxamento Local

Vinicius S. Monego¹

Centro de Tecnologia, UFSM, Santa Maria, RS

Alex A. Schmidt²

Departamento de Matemática, CCNE, UFSM, Santa Maria, RS

Alice de Jesus Kozakevicius³

Departamento de Matemática, CCNE, UFSM, Santa Maria, RS

1 Introdução

Conhecidos como algoritmos genéticos (AG), uma classe de métodos de otimização inspirados na lei de evolução de Darwin vem sendo desenvolvidos desde a década de 1970 e empregados com sucesso em uma ampla gama de problemas científicos e tecnológicos [2,3]. Em tais algoritmos, operadores “genéticos” tais como seleção, recombinação (*crossover*) e mutação são aplicados a uma população (*i.e.*, a um conjunto de soluções aproximadas de um problema qualquer) com o intuito de promover a evolução de membros dessa população na direção da solução do problema.

Introduzido recentemente (2013), o BSA (*Backtracking Search optimization Algorithm*) [1] é um algoritmo genético do tipo evolucionário de fácil implementação, tendo sido concebido para resolver problemas de otimização numérica com variáveis reais. O BSA caracteriza-se por usar a memória de populações anteriores para definir a direção da evolução e de depender somente de um único parâmetro livre (*mixrate*) de controle do número de elementos que sofrem mutação. Quando comparado com outros algoritmos evolucionários conhecidos (PSO, CMAES, ABC, JDE, CLPSO, SADE), o BSA apresenta um desempenho semelhante ou melhor [1]. Neste trabalho apresentamos o desenvolvimento de uma nova estratégia de otimização (BSA+LREM) baseada no aprimoramento do BSA através da incorporação de três outros operadores ao algoritmo original: migração, epidemia e relaxamento local.

2 Metodologia e Resultados

A motivação para incorporar novos operadores genéticos ao BSA é a de melhorar a eficiência do algoritmo ao mesmo tempo em que são abordados aspectos considerados como

¹monego@mail.ufsm.br

²aas@ufsm.br

³alicek@ufsm.br

“pontos fracos” dos AG. Operador migração: a fim de aumentar a diversidade genética da população – ponto fundamental para o sucesso dos AG – ao invés de evoluir uma única população com um grande número de indivíduos, evolui-se, de forma independente, um conjunto de sub-populações menores permitindo-se que, ao final de cada ciclo evolutivo, os indivíduos mais adaptados de cada sub-população migrem (sejam distribuídos) entre as demais sub-populações. Essa estratégia minimiza a influência de possíveis maus resultados advindos de uma sub-população qualquer e aumenta a possibilidade de que a evolução, como um todo, ocorra na direção da solução. Operador epidemia: aplicado quando se detecta ausência de evolução em alguma sub-população, esse operador executa a substituição da maioria dos indivíduos por novos, gerados aleatoriamente (aniquilando a sub-população corrente), preservando apenas os de melhor adequação (mais adaptados). Operador relaxamento local: em geral, os principais operadores do AG, recombinação e mutação, são insensíveis à topografia do espaço de soluções (*fitness landscape*), sendo essa informação incorporada ao processo evolutivo de forma indireta via cálculo da adequação (*fitness*). O operador relaxamento local modifica a carga genética de cada indivíduo realizando uma busca rápida por um mínimo local via aplicação de um método tradicional de minimização. Essa operação promove um acomodamento (equilíbrio local) entre os gens de cada indivíduo e acelera significativamente o processo de convergência da evolução. A implementação desses operadores junto ao BSA é feita em Python (v3.5) com ferramentas do pacote NumPy na plataforma Anaconda [6].

Uma bateria de testes usando funções padrão para problemas de otimização [5] é realizada para determinar a eficiência do algoritmo proposto. Finalmente, como exemplo de aplicação, mostra-se que a carência de bons valores iniciais para se aplicar adequadamente o Método de Levenberg-Marquardt [4] no caso do ajuste não linear de um número arbitrário de gaussianas a um conjunto de dados, pode ser satisfatoriamente suprida com resultados obtidos com o BSA+LREM.

Referências

- [1] P. Civicioglu, Backtracking Search Optimization Algorithm for numerical optimization problems, *Appl. Math. Comput.*, 219:8121–8144, 2013. DOI: 10.1016/j.amc.2013.02.017.
- [2] D. E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Reading, MA: Addison-Wesley, 1989.
- [3] J. H. Holland, *Adaptation in Natural and Artificial Systems*, University of Michigan Press, 1975. (second edition: MIT Press, 1992.)
- [4] D. Marquardt, An Algorithm for Least-Squares Estimation of Nonlinear Parameters, *SIAM J. Soc. Ind. Appl. Math.*, 11:431–441. 1963. DOI:10.1137/0111030.
- [5] https://en.wikipedia.org/wiki/Test_functions_for_optimization
- [6] <https://www.continuum.io>