

Controle Adaptativo de Parâmetros de Metaheurísticas: Uma Estratégia Gulosa Baseada no *Simulated Annealing*

Ítalo F. Gonçalves¹

PUC, Goiânia, GO

Maria J. P. Dantas²

PUC-GO, Goiânia, GO

Edgar M. A. Júnior³

PUC-GO, Goiânia, GO

Metaheurísticas são otimizadores estocásticos que apresentam bons resultados para problemas de otimização combinatória e problemas contínuos multidimensionais. Elas são baseadas em diferentes princípios e estratégias, porém todas possuem algo em comum: a presença de parâmetros. A escolha adequada destes parâmetros significa o alcance de bons resultados. São eles que irão direcionar a qualidade da solução final [5]. Tal tarefa pode ser feita de duas formas [3]. A primeira delas é o controle *offline*, conhecido também como *parameter tuning*. Este tipo de controle consiste em encontrar uma boa configuração de parâmetros e então fixá-los durante a execução do algoritmo. A segunda técnica de controle de parâmetros é o controle *online*, conhecido também como *parameter control*. O controle é feito no decorrer da execução do algoritmo, tomando decisões inteligentes ou não. Isto é, com ou sem o *feedback* dos atuais parâmetros [1].

O foco deste projeto se baseia em estudar e propor formas de controle *online* de parâmetros. Inicialmente foi realizada uma revisão bibliográfica, na base de dados *Web of Science* (WoS), seguindo uma série de etapas de refinamento. Então, foram implementadas e estudadas diversas metaheurísticas e técnicas de controle, adquirindo o conhecimento necessário para propor um controle *online* adaptativo.

O método é baseado no *simulated annealing* (SA) [4] e na estratégia gulosa. No início do algoritmo, a probabilidade de variação dos parâmetros tende a ser maior, baseando-se no princípio de entropia do SA. Esta probabilidade de variação decai com o tempo, de acordo com um fator de redução da temperatura (α). Então é aplicado a estratégia gulosa, escolhendo a melhor modificação a feita de acordo com os parâmetros presentes. Sendo Δ a variação atual, podemos fazer todas permutações possíveis dentro do vetor: $[+\Delta, -\Delta, 0, +rand_1, -rand_2]$, selecionando n elementos, sendo n a quantidade de parâmetros, onde 0 é uma variação nula e *rand* uma variação randômica. É somado estes valores aos parâmetros. Para avaliar uma configuração, são executadas 10 iterações da metaheurística em questão e obtida a média do *fitness* da nova população. Este controle pode ser incorporado em diversas metaheurísticas.

Foram executados alguns testes em funções de *benchmark*, todas com 5 dimensões. O controle foi incorporado no *differential evolution* (DE) [4]. Foram executadas 1000 vezes cada função, com uma população fixada em 50 e 100 iterações para cada execução. O controle foi feito nos parâmetros *Fp* e *Pc*, assumindo $\alpha = 0.9$ e $\Delta_{inicial} = 0.5$. A Tabela 1 mostra os resultados do controle que está sendo proposto. A Tabela 2 apresenta os resultados do DE original sem controle dos parâmetros,

¹italofernandes.fg@gmail.com

²mjpdantas@gmail.com

³junior.ancioto@gmail.com

que foram fixados como: $Fp = 0.5$ e $Pc = 0.9$, valores encontrados na literatura [2]. Nas Tabelas 1 e 2 pode-se encontrar as respectivas colunas com o nome da função, os intervalos de busca, o ótimo global, o melhor resultado, a média e o desvio padrão dos resultados obtidos. Pode-se notar que, inicialmente, o controle proposto é tão bom ou comparável ao DE original.

Para trabalhos futuros pretende-se realizar mais testes e melhorias sobre o controle proposto e aplicá-lo ao *capacitated vehicle routing problem* (CVRP). Os códigos desenvolvidos estão disponibilizados em: <https://github.com/fernandesitalo/Metaheuristics>

Tabela 1: DE com controle proposto.

Função	Limites	Ótimo	Melhor	Média	Desvio Padrão
Rastrigin	$-5.12 \leq x_i \leq 5.12$	0	4.536886e-08	1.681753e+00	1.877430e-04
Rosenbrock	$-2.048 \leq x_i \leq 2.048$	0	9.023829e-07	3.944163e-01	3.335613e-01
Easom	$-100 \leq x_i \leq 100$	-1	-1.000000e+00	-1.000000e+00	3.090659e-17
Ackley	$-32 \leq x_i \leq 32$	0	2.739664e-07	2.105383e-05	1.235939e-04

Tabela 2: DE original.

Função	Limites	Ótimo	Melhor	Média	Desvio Padrão
Rastrigin	$-5.12 \leq x_i \leq 5.12$	0	8.170435e-05	3.132049e+00	1.360433e+00
Rosenbrock	$-2.048 \leq x_i \leq 2.048$	0	5.031683e-06	4.690084e-01	3.813687e-01
Easom	$-100 \leq x_i \leq 100$	-1	-1.000000e+00	-1.000000e+00	1.609632e-16
Ackley	$-32 \leq x_i \leq 32$	0	1.038717e-05	7.188141e-05	4.214432e-05

Agradecimentos

Agradecimento ao grupo de pesquisa do laboratório de Estatística e Modelagem Matemática (LEMM) da PUC Goiás e ao CNPQ pela bolsa PIBIC.

Referências

- [1] Aleti, A. and Moser, I. A Systematic Literature Review of Adaptive Parameter Control Methods for Evolutionary Algorithm, *ACM Comput*,49:56:1–56:35, 2016. DOI: 10.1145/2996355
- [2] Brest, J., Greiner, S., Boskovic, B., Mernik, M. and Zumer, V. Self-Adapting Control Parameters in Differential Evolution: A Comparative Study on Numerical Benchmark Problems, *IEEE Transactions on Evolutionary Computation*, 10:646–657, 2006. DOI: 10.1109/TEVC.2006.872133
- [3] Eiben, A. E., Hinterding, R. and Michalewicz, Z. Parameter control in evolutionary algorithms *IEEE Transactions on Evolutionary Computation*, 3:124–141, 1999. DOI: 10.1109/4235.771166
- [4] Goldberg, M. C., Goldberg, E. G. e Luna, H. P. L. *Otimização combinatória e meta-heurísticas: Algoritmos e Aplicações*. Elsevier, 2016.
- [5] Karafotias, G., Hoogendoorn, M. and Eiben, A. E. Parameter Control in Evolutionary Algorithms: Trends and Challenges *IEEE Transactions on Evolutionary Computation*, 19:167–187, 2015. DOI: 10.1109/TEVC.2014.2308294