

EVOLUÇÃO DIFERENCIAL COM PARAMETRIZAÇÃO ADAPTATIVA APLICADA A PROBLEMAS CONTÍNUOS SEM RESTRIÇÕES

Christopher Renkavieski ¹, Rafael Stubs Parpinelli ²

¹ Acadêmico(a) do Curso de Bacharelado em Ciência da Computação, CCT, bolsista PIBIC/CNPq.

² Orientador, Departamento de Ciência da Computação – rafael.parpinelli@udesc.br.

Palavras-chave: Computação Evolutiva. Evolução Diferencial. Parametrização Adaptativa.

A Computação Evolutiva é uma área da Computação Natural que busca inspiração para seus algoritmos na teoria da evolução Neodarwinista. Estes algoritmos têm a sua disposição os operadores evolutivos de mutação, recombinação e seleção que são utilizados para, a partir de uma população de possíveis soluções para um problema, “evoluir” uma solução melhor. Um desses algoritmos é a Evolução Diferencial (DE – *Differential Evolution*), concebida para a otimização de problemas com domínio contínuo.

Assim como toda técnica de otimização baseada em heurísticas, o DE apresenta parâmetros que devem ser definidos anteriormente à sua execução. Estes parâmetros são: o tamanho da população NP, o fator de mutação F, a taxa de recombinação CR e a estratégia de mutação. Além de serem específicos para o problema em mãos, esses parâmetros afetam diretamente a eficácia do algoritmo para a sua solução. Desta forma, a configuração correta dos parâmetros é imprescindível para o bom funcionamento do algoritmo.

Para lidar com este problema, múltiplas técnicas já foram propostas na literatura para realizar a autoadaptação dos parâmetros do DE. A ideia por trás destas técnicas é permitir que os parâmetros do DE possam ser ajustados de forma automática ao longo da sua execução, eliminando assim a necessidade da configuração manual destes parâmetros.

Tendo isto em mente, o objetivo deste trabalho foi o estudo de diferentes técnicas de DE com parametrização adaptativa, além da proposta de novas técnicas com o objetivo de aprimorar os resultados da literatura. Foi realizado um levantamento dos diferentes algoritmos de DE adaptativos propostos na literatura, e foram selecionados três para um estudo mais detalhado, sendo eles: SHADE, L-SHADE e EB-L-SHADE.

O SHADE foi selecionado devido à sua versatilidade, servindo de base para múltiplos outros algoritmos, incluindo os outros dois escolhidos. Os parâmetros adaptados por ele são o F e o CR. Já a escolha do L-SHADE foi motivada devido ao seu status como estado da arte e por ser um algoritmo já bem estabelecido na literatura. Ele acrescenta a adaptação de NP ao SHADE, que é realizada de forma linear. O EB-L-SHADE, por sua vez, é uma modificação do L-SHADE que apresenta resultados equivalentes ou superiores a este, porém é um algoritmo ainda recente e não tão bem estabelecido na literatura. Além dos parâmetros adaptados pelo L-SHADE, o EB-L-

SHADE também utiliza um mecanismo para adaptar a sua estratégia de mutação, sendo então um algoritmo que adapta os quatro parâmetros do DE.

Tendo como base as técnicas citadas, foram propostos os algoritmos A-SHADE, EB-A-SHADE e EB-A-SHADE-M. No A-SHADE, o mecanismo de redução linear de NP do L-SHADE foi substituído por um mecanismo alternativo, com forma exponencial, com o objetivo de aumentar o número de gerações disponíveis para o algoritmo convergir. Já o EB-A-SHADE foi o uso conjunto desta nova fórmula para redução de NP e do mecanismo do EB-L-SHADE para adaptar a estratégia de mutação. O EB-A-SHADE-M, por sua vez, acrescentou ao EB-A-SHADE uma estratégia para explorar a vizinhança dos indivíduos produzidos pela evolução.

Os três algoritmos selecionados da literatura, em conjunto com os três propostos e o DE canônico, foram aplicados ao conjunto de *benchmark* de otimização global do evento CEC-2013. Este conjunto é composto por 28 funções de domínio real, sendo que cada função apresenta somente um ponto ótimo global, porém 23 delas apresentam também múltiplos pontos ótimos locais, o que dificulta a otimização. Os experimentos foram realizados em 100 dimensões, e o número de avaliações de função disponíveis foi igual a 1.0×10^6 para todos os algoritmos. Foram feitas 30 execuções independentes de cada algoritmo em cada função, e as comparações foram realizadas com base na média e desvio padrão do erro obtido por eles. O erro é definido como a diferença entre o valor da função objetivo do melhor ponto encontrado pelo algoritmo e o valor da função no seu ponto ótimo global. As comparações entre os algoritmos foram auxiliadas pelos testes estatísticos de Kruskal-Wallis e de Dunn.

Os resultados obtidos mostraram que as modificações propostas foram positivas nos experimentos realizados. Os resultados obtidos pelo EB-A-SHADE foram os melhores ou equivalentes aos melhores em 19 das 28 funções. Já para o A-SHADE e para o EB-A-SHADE-M, este número foi de 16 funções. Para o DE, SHADE, L-SHADE e EB-L-SHADE, os números de funções em que eles se destacaram foram 4, 7, 14 e 15, respectivamente, valores estes menores que os dos algoritmos propostos.

Com estes resultados, pôde-se observar que a redução alternativa para o valor de NP teve um impacto positivo significativo na eficácia do L-SHADE, permitindo ao algoritmo convergir para resultados melhores. Já o uso de duas estratégias de mutação teve um impacto menor, porém ainda positivo, com o EB-A-SHADE se mostrando o melhor dos algoritmos avaliados. A estratégia para a exploração da vizinhança dos indivíduos, por sua vez, teve um impacto negativo na eficácia, com o EB-A-SHADE-M apresentando resultados inferiores aos do EB-A-SHADE. Análises da diversidade genética populacional, no entanto, mostraram que o EB-A-SHADE-M é efetivo em manter uma população mais diversificada, indicando que esta estratégia de exploração tem potencial para ser aplicada a algoritmos que apresentem perda rápida de diversidade.

Para o futuro, têm-se como objetivo a comparação destes algoritmos em funções com outros valores de dimensão, para observar se o comportamento observado se mantém. Outra possibilidade futura é a aplicação do EB-A-SHADE a um problema real, permitindo que este trabalho traga contribuições científicas para além da área de otimização numérica.

Este projeto foi desenvolvido em conjunto com Trabalho de Conclusão de Curso (TCC). Todos os códigos desenvolvidos, assim como os resultados e a dissertação completa, estão disponíveis *online* em <https://github.com/ChrisRenka/TCC>.