



FEPEG

FÓRUM DE ENSINO,
PESQUISA, EXTENSÃO
E GESTÃO

TRABALHOS CIENTÍFICOS APRESENTAÇÕES ARTÍSTICAS E CULTURAIS DEBATES MINICURSOS E PALESTRAS

23 A 26 SETEMBRO DE 2015
Campus Universitário Professor Darcy Ribeiro

ISSN 1806-549X

A HUMANIZAÇÃO NA CIÊNCIA, TECNOLOGIA E INOVAÇÃO



Proposta de um algoritmo evolutivo para solução de problemas de otimização com muitos objetivos

Walmir Alexandre Gonçalves Lima, Allysson Steve Mota Lacerda

Introdução

A utilização de algoritmos evolucionários em tarefas de busca e otimização se tornou bastante popular nos últimos anos, com desenvolvimento contínuo de novos algoritmos, teorias e aplicações[1]. Tais métodos são baseados na teoria da seleção natural e se caracterizam pela presença de mecanismos inspirados na biologia, como reprodução, mutação e recombinação.

Em problemas de otimização multiobjetivo, há duas ou mais funções objetivo, geralmente conflitantes, a serem consideradas simultaneamente. Por consequência, não há apenas uma solução ótima, mas um conjunto de soluções denominadas eficientes, incomparáveis ou não-dominadas. O conceito de eficiência foi introduzido por Pareto[2] e consiste em dizer que uma solução é ótima se não há outra solução factível que melhore um critério (objetivo) sem causar uma piora simultânea em pelo menos um outro. Tal definição modifica o conceito de ótimo, já que agora não há apenas uma solução ótima, mas um conjunto de soluções conhecido como conjunto Pareto-ótimo ou, simplesmente, conjunto Pareto.

A primeira implementação de um algoritmo evolucionário multiobjetivo data da década de 1980 e, desde então, o interesse pela área tem crescido enormemente. A importância desse campo de pesquisa pode ser percebida pelo grande número de publicações realizadas, especialmente nos últimos vinte anos[1]. Vários algoritmos evolucionários multiobjetivo foram propostos nessa época, com especial destaque para o SPEA2[3] e o NSGA-II[4], que se tornou a principal referência para o desenvolvimento de novos métodos.

Nos últimos anos, no entanto, muitos trabalhos apontaram que vários métodos propostos não apresentam bons resultados em problemas com quatro ou mais objetivos[5]. Em geral, isso se deve ao fato de que, com o aumento no número de objetivos, a proporção de soluções não-dominadas cresce, dificultando a classificação das soluções utilizando apenas relações de dominância. Tal característica deu origem a uma nova classe de problemas, denominada otimização com muitos objetivos.

O presente trabalho apresenta o ManO-DE, um algoritmo baseado em Evolução Diferencial para solução de problemas de otimização com muitos objetivos. Testes preliminares mostram que o algoritmo proposto apresentou bons resultados quando comparado ao MOEA/D[6].

Materiais e métodos

A. Métodos existentes

O NSGA-II é um algoritmo genético que realiza o procedimento de classificar as soluções de um conjunto em diversas fronteiras (ranking), conforme o grau de dominância das soluções. O grau de dominância de uma solução é obtido através do número de soluções que a dominam, desse modo, as soluções não dominadas estão contidas na primeira fronteira, as soluções que são dominadas por apenas uma solução estão na segunda fronteira, e assim por diante. Além disso, para a retirada de soluções semelhantes é definido o conceito de distância de multidão, que nada mais é que a média da distância das duas soluções adjacentes a cada indivíduo.

O SPEA2 é um algoritmo que se baseia no uso da atribuição de fitness para o desempenho de suas atividades. O fitness é calculado a partir de um valor de dominância sobre uma determinada solução e a diversidade da mesma. Dessa forma, é característico dessa atribuição de fitness que, quanto menor o valor de fitness, melhor é a solução.

Já o MOEA/D faz uso da decomposição do problema multiobjetivo em vários subproblemas, resolvidos em paralelo. Cada subproblema busca encontrar uma região específica da fronteira Pareto e, por isso, o MOEA/D, em geral, alcança uma aproximação mais uniforme da mesma. Essa abordagem tem se mostrado bastante eficaz e o algoritmo tem se destacado também em problemas com muitos objetivos.



B. O algoritmo proposto

O ManO-DE utiliza conceitos herdados do algoritmo de Evolução Diferencial[7] para a geração e seleção de novos indivíduos. Além disso, utiliza um modelo de subpopulações, além de uma população externa composta pelos indivíduos eficientes de todas as sub-populações. O seu pseudocódigo está representado a seguir.

```
inicie as subpopulações aleatoriamente
enquanto não atingir um critério de parada
  atualize a população externa
  para cada subpopulação
    para cada indivíduo  $p$ 
      selecione  $r_1, r_2$  e  $r_3$  da população externa
      faça  $p' = r_1 + \mu(r_2 - r_3)$ 
      se  $p' < p$ 
        substitua  $p$  por  $p'$ 
    fim
  fim
fim
```

Para avaliar o desempenho do Mano-DE, foram utilizados os problemas de teste LZ09. Eles foram escolhidos por serem escaláveis quanto ao número de variáveis, embora possuam apenas dois objetivos. Nos testes realizados, foram utilizadas 30 variáveis de decisão e os resultados comparados à implementação oficial do MOEA/D disponibilizada pelos autores. Como indicador de qualidade das soluções, foi utilizado o Inverted Generational Distance (IGD), que avalia tanto a distância quanto a uniformidade das soluções obtidas em relação à fronteira Pareto real. Além disso, foi analisado também o tempo de execução médio de cada algoritmo, apenas para ilustração.

Resultados

Foram realizadas 30 execuções independentes de cada algoritmo, apresentadas na Figura 1. Os resultados foram ordenados pelo IGD, com o intuito de facilitar a visualização dos mesmos. Como pode ser observado, o ManO-DE apresentou resultados superiores ao MOEA/D em todos os problemas abordados. Outro aspecto relevante é o tempo médio de execução, apresentado na Figura 2, que foi inferior em todos os casos.

Embora os resultados ainda sejam preliminares, o ManO-DE se apresenta bastante promissor. Para analisar a sua robustez, serão realizados testes utilizando outros problemas, bem como outros algoritmos para comparação. Além disso, pretende-se ainda desenvolver uma nova versão do algoritmo capaz de ser executada em ambientes distribuídos, como clusters ou computadores multicore.

Agradecimentos

Os autores agradecem o apoio financeiro concedido pela Fundação de Amparo à Pesquisa do Estado de Minas Gerais.

Referências

- [1] Coello-Coello, CA. (2009). **Evolutionary multi-objective optimization: some current research trends and topics that remain to be explored**. Frontiers of Computer Science in China 3.
- [2] Pareto, V (1896). **Cours D'Economie Politique**. F. Rouge, Lausanne, Switzerland.
- [3] Zitzler, E; Laumanns, M; Thiele, L (2001). **SPEA2: Improving the Strength Pareto Evolutionary Algorithm for Multiobjective Optimization**.
- [4] Deb, K; Pratap, A; Agarwal, S; Meyarivan, T (2002). **A fast and elitist multiobjective genetic algorithm: NSGA-II**. IEEE Transactions on Evolutionary Computation.
- [5] von Lücken, C; Barán, B; Brizuela, C. (2014). **A survey on multi-objective evolutionary algorithms for many-objective problems**. Computational Optimization and Applications 58.
- [6] Zhang, Q; Li, H (2007). **MOEA/D: A multiobjective evolutionary algorithm based on decomposition**.
- [7] Storn, R; Price, K (1995). **Differential Evolution - A simple and efficient adaptive scheme for global optimization over continuous spaces**.




Figura 1. IGD (ordenado de forma crescente) obtido após 30 execuções.




Figura 2. Tempo médio de execução obtido após 30 execuções.