

**Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**

---

# Estado da Arte de Medidas de Desempenho de Algoritmos de Otimização Multiobjetivo

Jefferson B. A. Silva<sup>1</sup>

Departamento de Matemática, UFOP, Ouro Preto, MG

Thiago Santos<sup>2</sup>

Departamento de Matemática, UFOP, Ouro Preto, MG

Sebastião Martins Xavier<sup>3</sup>

Departamento de Matemática, UFOP, Ouro Preto, MG

## 1 Introdução

Um problema de otimização multiobjetivo consiste de um conjunto de funções que se pretende maximizar ou minimizar, restrito a um dado domínio

$$\begin{aligned} \min f(x) &= (f_1(x), f_2(x), \dots, f_m(x)) \\ \text{restrito a } x &\in \Omega \end{aligned} \quad (1)$$

onde  $\Omega$  é a região na qual procuramos minimizar as funções. As funções  $f_i(x)$  chamamos de *objetivos*. Dado um problema de maximização, podemos considerá-lo um de minimização apenas tomando  $g(x) = -f(x)$ .

Para representar o conjunto de soluções aceitáveis, utilizamos o conceito de Pareto-Dominância [1]. Um ponto  $x^*$  é dito *dominar*  $x$  se for tão bom quanto  $x$  em todos os objetivos e for estritamente melhor que  $x$  em pelo menos um dos objetivos, ou seja,  $f_i(x^*) \leq f_i(x) \quad \forall i = 1, \dots, m$  e  $f_j(x^*) < f_j(x) \quad \forall j = 1, \dots, m$ . O conjunto de todos os pontos  $x$  não dominados é chamado *Conjunto Pareto*, denotado por  $P$ . O conjunto das imagens dos elementos de  $P$  é chamado *Fronteira Pareto* e é denotado por  $PF$  [1].

Em problemas reais, como na construção de pontes, desenvolvimento de produtos, projetar um sistema de controle, deseja-se minimizar o gasto mas sem perder em qualidade do produto além de outros fatores [1]. Desta forma, não há um único valor que minimize todas os objetivos simultaneamente. Desta forma, procura-se um conjunto de soluções não dominadas,  $PF$ , soluções estas que podem não ser facilmente obtidas devido a quantidade e complexidade das funções em questão. Diversos algoritmos foram elaborados para se obter uma boa aproximação desta solução ideal em um tempo razoável [1]. Denotamos

---

<sup>1</sup>jeffauh@gmail.com

<sup>2</sup>santostf@iceb.ufop.br

<sup>3</sup>semarx@iceb.ufop.br

esta aproximação de  $PK$  e suas imagens por  $F$  de  $PFK$ . Com o advento de tais algoritmos como MO-PSO, NSGA, NSGA-II, NSGA-III dentre outros, comparar seus resultados se tornou algo necessário [3]. As principais características a serem observadas são: a *cardinalidade* de  $PFK$ , a *convergência* de  $PFK$  para  $PFT$ , ou seja, o quão próximo os dois conjuntos estão, e a *dispersão*, que mede o quão uniformemente os pontos de  $PFK$  estão distribuídos e como eles se aproximam aos extremos do  $PFT$  [2, 4]

## 2 Objetivo

Os objetivos deste trabalho são fazer um levantamento de 22 das medidas de desempenho citadas por Jiang, Ong, Zhang e Feng [2], estudá-las, implementá-las em MATLAB e posteriormente disponibilizá-las gratuitamente para a comunidade. Para o estudo das métricas, fomos em busca de onde as métricas foram definidas e outros artigos para obter o máximo de informação possível sobre cada métrica como em [1, 3–5]. Este estudo se resume à dividi-las em quatro grupos, a saber: Métricas de Capacidade, que medem a quantidade de elementos em um dado conjunto; Métricas de Convergência, que medem a distância entre o conjunto solução ( $PFK$ ) e um dado conjunto referência; Métricas de Dispersão que medem o quão uniformemente os pontos do conjunto solução estão distribuídos e como eles se aproximam aos extremos de  $PFK$ ; Métricas de Capacidade-Divergência, que medem tanto a capacidade quanto a divergência e capacidade do conjunto solução.

Hoje o trabalho se encontra em fase de implementação das métricas com previsão para conclusão para Agosto de 2017.

## Referências

- [1] D. Simon, *Evolutionary Optimization Algorithms*, John Wiley & Sons, 2013. ISSN:978-1-118-65950-2.
- [2] S. Jiang, Y. Ong, J. Zhang, and L. Feng, Consistencies and contradictions of performance metrics in multiobjective optimization, *IEEE Transactions on Cybernetics*, 44(12):2391–2404, 2014. DOI: 10.1109/tyb.2014.2307319.
- [3] D. A. Van Veldhuizen, Multiobjective evolutionary algorithms: classifications, analyses, and new innovations, Tese de Doutorado US Air Force Institute of Technology, 1999.
- [4] A. Zhou, B. Qu, H. Li, S. Zhao, P. N. Suganthan, and Q. Zhang, Multiobjective evolutionary algorithms: A survey of the state of the art, *Swarm and Evolutionary Computation*, 1(1):32–49, 2011. DOI: 10.1016/j.swevo.2011.03.001.
- [5] E. Zitzler, L. Thiele, M. Laumanns, C. M. Fonseca, and V. G da Fonseca, Performance assessment of multiobjective optimizers: An analysis and review, *IEEE Transactions on Evolutionary Computation*, 44(12):117–132, 2003. DOI: 10.3929/ethz-a-004363410.