

Algoritmo Genético Aplicado em Identificação de Sistemas de Múltiplas Entradas e Múltiplas Saídas



Mariane Gavioli Bergamini¹ ; Gideon Villar Leandro¹

¹ UFPR – Universidade Federal do Paraná

RESUMO

A computação evolucionária tem como base princípios da evolução biológica pois tomam os métodos da natureza, ou seja, a rotina da vida social de colônias ou enxames. Desta maneira se torna cada vez mais próxima em direção à biologia, sendo aplicada em diversos problemas complexos. Um fator interessante é a facilidade de se implementar estes algoritmos baseados na seleção natural de forma paralela em vários sistemas. Os sistemas de identificação com múltiplas entradas e múltiplas saídas (MIMO) requerem algoritmos capazes de solucionar seus problemas em espaços de busca por serem sistemas críticos. Este artigo propõe um método heurístico que utilizará o algoritmo genético para obter soluções de ótimos locais em um determinado espaço de busca pois é considerado um método convencional de otimização e o seu tempo de processamento é fundamental uma vez que encontra as melhores soluções rapidamente. Os resultados a serem apresentados são significativos em relação a cada tipo de função objetivo apresentada.

Palavras chave: Identificação de sistemas, método heurístico, algoritmo genético

ABSTRACT

The evolutionary computer is based in the principles of biological evolution because they take methods of nature, that is, the routine of social life of colonies or swarms. Thus, it becomes closer to the biology and being applied in several complex problems. An interesting factor is the easily way of implementing these algorithms based on natural selection in parallel in several systems. Multiple-input and multiple-output identification systems (MIMO) require efficient algorithms to solve their problems in search space because they are critical systems. This paper proposes a heuristic method using the genetic algorithm in order to obtain solutions of optimal locations in a particular search space once it is considered a conventional method of optimization and its processing time is fundamental to find best solutions quickly. The following results are significant in each objective function exhibit.

Key Words: Systems identification, heuristic method, genetic algorithm

1. INTRODUÇÃO

Atualmente, modelos de sistemas reais vem demonstrando sua importância em diversas áreas. Eles possibilitam prever ou simular o comportamento do sistema. Na engenharia, é importante o uso de modelos para desenvolver novos processos e para analisar esses processos.

Em identificação de sistemas, a modelagem matemática estuda as diversas maneiras de implementar e desenvolver modelos matemáticos de sistemas reais (AGUIRRE, 2003).

Em (HAGGBLOM, 2015), o desempenho do experimento é importante para se obter dados com boa representação do sistema a ser identificado. Os sistemas de múltiplas entradas e múltiplas saídas (MIMO) são considerados mais complexos do que os sistemas de única entrada e única saída (SISO). Os problemas de otimização (ISERMANN; MÜNCHHOF, 2011) e (SINHA et al.), são resolvidos por uma superposição que tal problema é definido e não contém quaisquer incertezas. Porém, a maioria dos problemas de otimização em ciência, engenharia e negócios nunca são identificados com precisão e envolvem diversas aproximações, ruídos, erros de medição, etc. Há diferentes tipos de abordagens de otimização que são baseadas em incerteza, otimização estocástica e otimização robusta como exemplo. É como se um algoritmo de otimização resolve se as soluções ruins encontradas durante o processo de busca e, enquanto outro algoritmo busca apenas as melhores soluções em um espaço com tempo de processamento menor.

Um problema inverso é geralmente incondicionado, sua solução não é única, enquanto que um problema ótimo tem múltiplas soluções. As soluções finais de um problema multiobjectivo são geralmente um conjunto de compromissos de diferentes objetivos chamados de Pareto ótimo. Ele ajuda o tomador de decisão a fazer o julgamento de acordo com as condições operacionais e ambientes do sistema. O otimizador de objetivo múltiplo aceitável terá que ter a capacidade de encontrar soluções ideais de Pareto e, o designer irá minimizar a distância entre as soluções encontradas do Pareto verdadeiro e maximizar a diversidade entre as soluções de Pareto obtidas em ambos espaços objetivos e de parâmetros (HO et al., 2013) e (COELLO, 2011).

Conforme (ARROYO, 2002), a escolha do método de resolução, que depende da razão entre a qualidade da solução gerada por tal método e tempo que ela gasta para encontrar essas soluções. Quando se trata do tempo de processamento, muitos métodos se tornam intratáveis, mas, os métodos heurísticos conseguem obter soluções para os problemas intratáveis.

Os algoritmos metaheurísticos (BLUM; ROLI, 2003), considerados algoritmos que aproximam a combinação de métodos heurísticos básicos em estruturas de alto nível, com o objetivo de explorar eficientemente um espaço de busca. Além disso, é definida como um processo de geração iterativa a que orienta uma heurística, combinando diferentes conceitos para explorar e suas estratégias de aprendizagem são utilizadas para estruturas informações, encontrando soluções eficientemente ou seja, ótimas.

Em (YAZDANI; JOLAI, 2015) e (MIRJALILI, 2015), diz a respeito dos algoritmos metaheurísticos que são baseados na natureza e usados com frequência para encontrar soluções ótimas de problemas reais de otimização. Esses algoritmos se beneficiam de operadores estocásticos e sua principal característica é a aleatoriedade. Pois, operam de forma aleatória dando maior confiabilidade ao algoritmo na obtenção de solução a cada execução, por ser um algoritmo que utiliza a formulação do problema para avaliar o conjunto de soluções, o processo é realizado independentemente do problema e com base nas entradas dadas e saídas recebidas. Conceitos evolutivos naturais ou comportamentos coletivos são inspirações para boa parte dos algoritmos deste campo. Além disso, seguem uma estrutura geral e comum, na qual um conjunto de soluções é criada aleatoriamente aprimorando ou evoluindo iterativamente.

Recentemente problemas de identificação de sistemas são pesquisados frequentemente por serem muito utilizados no cotidiano de várias áreas de pesquisas. O projeto desenvolve o algoritmo genético sendo aplicado com duas funções objetivos diferentes. Com isso, através de gráficos e tabelas dos resultados, uma análise do tempo de processamento desse algoritmo com cada função objetivo será importante. Pois, os dados adquiridos, futuramente serão trabalhados de forma online dentro de problemas de identificação de sistemas. Com isso, seu objetivo é de solucionar os erros gerados durante seu tempo de processamento e visando o melhor tempo presente para encontrar a solução mais próxima do real.

2. METODOLOGIA

Por volta de 1900 (SRINIVAS; PATNAIK, 1994) e (KONAK et al., 2006), o trabalho de Gregor Mendel, desenvolvido em 1865, sobre os princípios básicos de herança genética, foi redescoberto pelos cientistas e teve grande influência sobre os futuros trabalhos relacionados à evolução. A moderna teoria da evolução combina a genética e as ideias de Darwin e Wallace sobre a seleção natural, criando o princípio básico de Genética Populacional: a variabilidade entre indivíduos em uma população de organismos que se reproduzem sexualmente é produzida pela mutação e pela recombinação genética.

Desenvolvido durante os anos 30 e 40, por biólogos e matemáticos de importantes centros de pesquisa. Nos anos 50 e 60, vários biólogos começaram a desenvolver simulações computacionais de sistemas genéticos. Entretanto, foi John Holland começou a desenvolver as primeiras pesquisas no tema da evolução. Holland foi refinando suas ideias e em 1975 publicou o seu livro “Adaptation in Natural and Artificial Systems”, hoje considerado a Bíblia de Algoritmos Genéticos. Desde então, estes algoritmos vêm sendo

aplicados com sucesso nos mais diversos problemas de otimização e aprendizado de máquina.

Estes algoritmos são considerados de otimização global, baseados nos mecanismos de seleção natural e da genética. Empregam uma estratégia de busca paralela e estruturadas, mas aleatória, voltada em direção da busca de pontos de "alta aptidão", ou seja, pontos nos quais a função a ser minimizada (ou maximizada) tem valores relativamente baixos (ou altos). Os Algoritmos Genéticos exploram informações históricas para encontrar novos pontos de busca onde são esperados melhores desempenhos. Isto é realizado através de processos iterativos, onde cada iteração é chamada de geração.

O princípio básico de seu funcionamento é que um critério de seleção irá fazer depois de muitas gerações o conjunto inicial de indivíduos gerar indivíduos mais aptos. Os indivíduos são representados fenotipicamente por vetores binários. Um método de seleção muito usado é o Método de Roleta, onde indivíduos são escolhidos para fazer parte da próxima geração, através de um sorteio de roleta. Os indivíduos são representados na roleta proporcionalmente ao seu índice de aptidão. Assim, a roleta é girada um determinado número de vezes, depende do tamanho da população, e são escolhidos os indivíduos que irão participar da próxima geração. Um conjunto de operadores é necessário para que consiga gerar populações sucessivas de melhor aptidão. Esses operadores são: cruzamento e mutação. Eles são usados para criar uma nova geração com as características dos pais.

3. METÓDO PROPOSTO

Os algoritmos genéticos (COELHO, 2003), possuem procedimentos probabilísticos de busca, baseados nos princípios decorrentes da dinâmica das populações naturais. Com isso, por ser um algoritmo robusto e de fácil implementação, será utilizado de forma on-line, pois o seu tempo de processamento será importante ao encontrar os ótimos locais aplicando em qualquer problema de identificação de sistemas MIMO. No procedimento de busca, a população corrente é gerada aleatoriamente dentro do espaço de busca com limites superior e limite inferior, e evoluem através da aplicação de operadores genéticos. Sendo esses operadores: seleção cruzamento (crossover) e mutação. Ao gerar a população corrente, tem parâmetro gerados aleatoriamente que consiste em vetores apresentados a seguir:

- Representação canônica (bit) $x_i \in \{0,1\}$
- Representação real $x_i \in \mathcal{R}$.

Assim, cada solução classificada em $x_i, i=1,2,\dots,N_p$, com relação a função objetivo ou função de aptidão, avaliando cada indivíduo da população em relação ao problema. A população gerada estará dentro de determinado intervalo de busca definido a partir da função objetivo a ser aplicada. Após isto, selecionar os indivíduos de melhor aptidão de acordo com o operador seleção. O operador seleção é resolvido por meio "Roulette-wheel", maior for a aptidão do indivíduo maior a chance de ser selecionado pela roleta. O pseudocódigo é mostrado pela figura 1 a seguir:

<p>Início</p> <p>$T = \sum f(x);$</p> <p>Para N vezes selecionar n – indivíduos</p> <p>$r = [0, T];$</p> <p>Percorra sequencialmente os indivíduos acumulando</p> <p>Em S o valor de aptidão dos indivíduos percorridos já;</p> <p>Se $S \geq r$ então</p> <p style="padding-left: 40px;">Selecionar individuo</p> <p>fim Se;</p> <p>fim Para;</p> <p>fim;</p>

FIGURA 1 – ILUSTRA O PSEUDOCÓDIGO DE SELEÇÃO POR ROLETA. FONTE: AUTOR,2017.

Depois disso, é aplicado o operador cruzamento ou recombinação (quando se trata de representação por ponto flutuante) é o operador principal porque é onde ocorre a troca das partes dos cromossomos entre os indivíduos e possui uma taxa de cruzamento $Cr = [0,8 1]$ que se encontra dentro deste intervalo. Por fim, é aplicado o operador mutação e gera a nova população e sua taxa de mutação é $F = [0,5 1]$, se não satisfizer o critério de parada voltará para o fator seleção e iniciará novamente todo o processo. Os parâmetros definidos para inicializa o processo são:

Parâmetros = {

- Cromossomo (Np)*
- Limite inferior (Bl)*
- Limite superior (Bu)*
- População (M)*
- Operador Mutação (F)*
- Operador Cruzamento (Cr)*

A figura 2, mostra todo o caminho percorrido pelo algoritmo durante seu processamento.

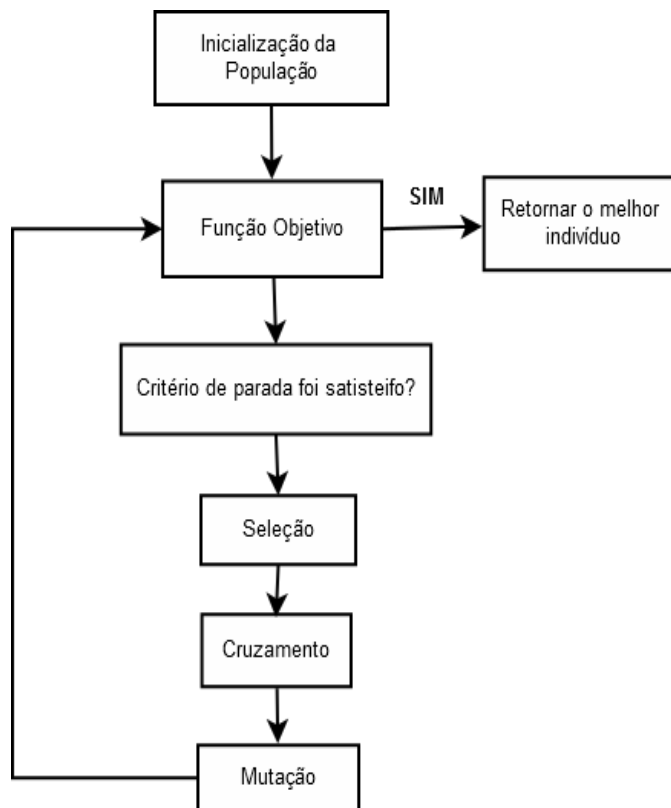


FIGURA 2– FLUXOGRAMA DO ALGORITMO GENÉTICO. FONTE: AUTOR,2017.

Este fluxograma, considerado padrão para o desenvolvimento deste algoritmo, facilitando compreender melhor seu funcionamento e demonstra a sequência de cada passo da rotina do algoritmo.

3.1 FUNÇÃO OBJETIVO

A funções objetivo a serem apresentadas, são conhecidas como funções de teste e úteis para avaliar algoritmos de otimização, em questão da velocidade de convergência, precisão, robustez e desempenho geral (SURJANOVIC et al., 2013).

- Função Objetivo Ackely: É considerada função de teste multimodal e amplamente usada para testar algoritmos de otimização. Limitando seu espaço de busca baseados em seus limites inferior e superior no intervalo e apresenta vários mínimos locais. Representada matematicamente pela equação a seguir:

$$f(x) = -a \exp\left(\sqrt{\frac{1}{d} \sum_{i=1}^d x_i^2}\right) - \exp\left(\sqrt{\frac{1}{d} \sum_{i=1}^d \cos(cx_i)}\right) + a + \exp(1) \quad (1)$$

$$\text{Dados} = \begin{cases} a = 20 \\ b = 0,2 \\ c = 2\pi \end{cases}$$

• Função Objetivo Sphere: uma função simples que testa a velocidade de otimização local de determinado método de pesquisa e, é contínuo, convexo e uni-modal. Limitando seu espaço de busca baseados em seus limites inferior e superior no intervalo para encontrar as melhores soluções. Representada matematicamente pela equação a seguir:

$$f(x) = \sum_{i=1}^d x_i^2 \quad (2)$$

Dados={*d é a dimensão dos mínimos locais*}

• Função Objetivo Matyas: Esta função não tem mínimos locais, só o global. Limitando seu espaço de busca baseados em seus limites inferior e superior no intervalo. Representada matematicamente pela equação a seguir:

$$f(x) = 0,26(x_1^2 + x_2^2) - 0,48x_1x_2 \quad (3)$$

4. RESULTADOS

A partir das equações e do diagrama de fluxo, foi possível realizar testes, visando analisar o desenvolvimento a cada iteração do algoritmo aplicado. As funções objetivos são aplicadas de modo multiobjectivos, pois são três funções sendo testadas dentro de um problema. As figuras a serem apresentadas mostram dois gráficos gerados a partir de vinte simulações de cada função objetivo a cima, percorrendo 501 iterações de uma população de 40 indivíduos gerada aleatoriamente e mostra a curva de convergência a partir da dimensão do problema, que neste caso sua dimensão foi $N_p=2$ ou seja, quantidade de cromossomo utilizado no problema, a taxa de $CR=0,80$ e a taxa de $F=0,50$. A partir disto, cada função limita seu espaço de busca dentro dos intervalos de:

- Ackley: [-32 32]
- Matyas: [-10 10]
- Sphere: [-5,12 5,12]

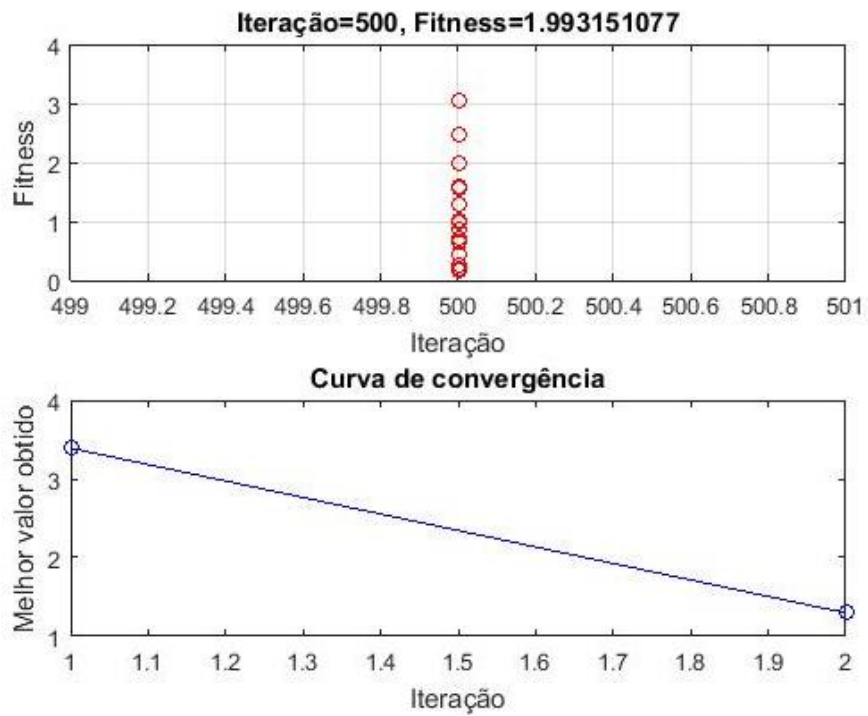


FIGURA 3 – GRÁFICO DA FUNÇÃO OBJETIVO ACKELY. FONTE: AUTOR,2017.

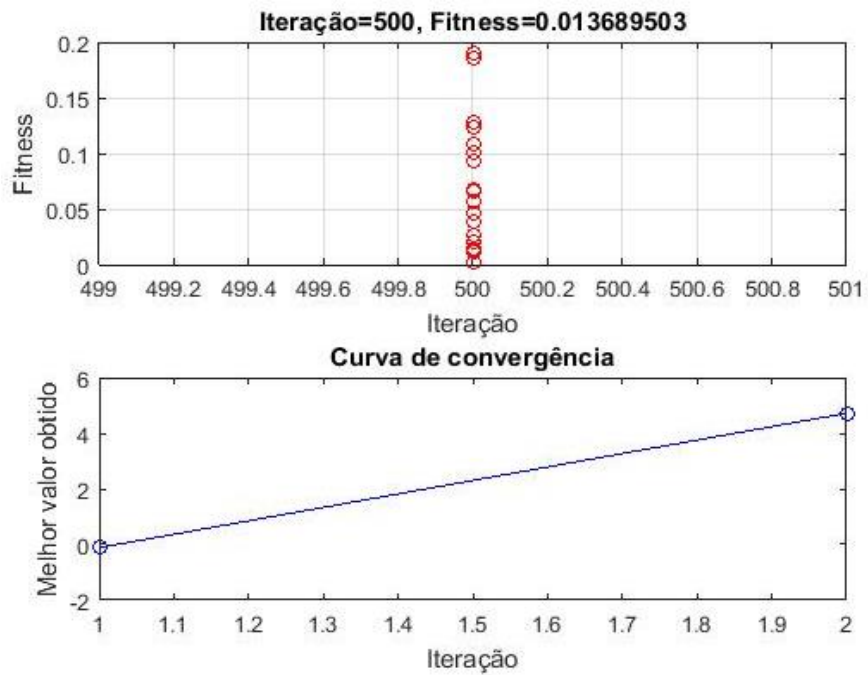


FIGURA 4– GRÁFICO DA FUNÇÃO OBJETIVO SPHERE. FONTE: AUTOR,2017.

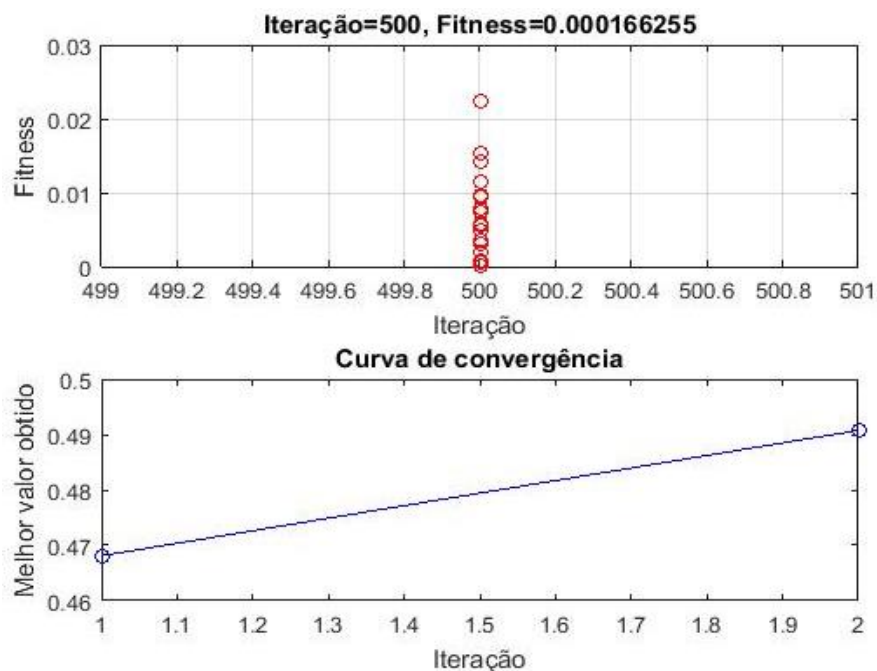


FIGURA 5– GRÁFICO DA FUNÇÃO OBJETIVO MATYAS. FONTE: AUTOR,2017.

5. CONCLUSÃO

Os resultados apresentados neste trabalho mostram que o desempenho do algoritmo genético tem um bom funcionamento quando aplicado em identificação de sistemas de múltiplas entradas e múltiplas saídas. É um problema que funciona como uma caixa cinza, onde não preciso ter o conhecimento nenhum para achar suas soluções e ajuda a obter os melhores parâmetros para o sistema.

É visível o comportamento de cada curva de convergência gerado a partir das funções objetivos. A função Ackely obteve ótimos locais melhores do que as outras duas funções, por começar com uma taxa de 3,3915 que vai convergindo para uma taxa menor de 1,296 que é um resultado qualitativo pois teve queda de valor e quanto menor for a taxa ou ótimos locais, mais próximo ele ficará da solução ideal que é zero.

REFERÊNCIAS

AGUIRRE, L. A. Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares ... - Luis Antonio Aguirre - Google Livros. .

ARROYO, J. E. C. Heurísticas E Metaheurísticas Para Multiobjetivo. **Tese de Doutorado UNICAMP**, 2002.

BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: overview and conceptual comparison. **ACM Computing Surveys**, v. 35, n. 3, p. 189–213, 2003.

COELHO, L. Fundamentos, potencialidades e aplicações de algoritmos evolutivos. **Notas em Matemática Aplicada**, 2003.

COELLO, C. A. C. Evolutionary multiobjective optimization. **Wiley**

Interdisciplinary Reviews: Data Mining and Knowledge Discovery, v. 1, n. 5, p. 444–447, 2011.

HAGGBLOM, K. E. Evaluation of experiment designs for MIMO system identification by model predictive control. **2015 IEEE Conference on Control and Applications, CCA 2015 - Proceedings**, p. 169–174, 2015.

HO, S. L.; YANG, S.; NI, P.; HUANG, J. A quantum-inspired evolutionary algorithm for multi-objective design. **IEEE Transactions on Magnetics**, v. 49, n. 5, p. 1609–1612, 2013.

ISERMANN, R.; MÜNCHHOF, M. **Identification of Dynamic Systems: An Introduction with Applications**. 2011.

KONAK, A.; COIT, D. W.; SMITH, A. E. Multi-objective optimization using genetic algorithms: A tutorial. **Reliability Engineering and System Safety**, v. 91, n. 9, p. 992–1007, 2006.

MIRJALILI, S. The ant lion optimizer. **Advances in Engineering Software**, v. 83, p. 80–98, 2015. Elsevier Ltd.

SINHA, A.; POROKKA, A.; MALO, P.; DEB, K. 2015 Unconstrained robust optimization using a descent-based crossover operator. , p. 85–92.

SRINIVAS, M.; PATNAIK, L. M. Genetic Algorithms: A Survey. **Computer**, v. 27, n. 6, p. 17–26, 1994.

SURJANOVIC, S.; BINGHAM, D.; SIMON FRASER UNIVERSITY. Optimization Test Functions. .

YAZDANI, M.; JOLAI, F. Lion Optimization Algorithm (LOA): A Nature-Inspired Metaheuristic Algorithm. **Journal of Computational Design and Engineering**, v. 3, n. 1, p. 1–14, 2015. Elsevier.