

Estudo Comparativo de Algoritmos Meta-Heurísticos Baseados em Comportamentos Humanos em Problemas de Otimização

Pedro Henrique Ton Pauletti,
Unesp - Universidade Estadual Paulista
Rio Claro, Brasil
pedro.pauletti@unesp.br

Fabricio Aparecido Breve
Unesp - Universidade Estadual Paulista
Rio Claro, Brasil
fabricio.breve@unesp.br

Resumo—Este estudo visa analisar algoritmos meta-heurísticos baseados em comportamentos humanos para otimização de modelos de Machine Learning, funções e no problema do caixeiro-viajante (TSP). Foram avaliados critérios como melhor ajuste, diversidade, tempo de execução e exploração. Os resultados mostram que esses algoritmos aprimoram a precisão e eficiência, com o *Queuing Search Algorithm (QSA)* exibindo o melhor desempenho geral em eficiência e estabilidade.

Área: Inteligência Computacional

I. INTRODUÇÃO

A otimização é uma área fundamental em diversas disciplinas, incluindo ciência da computação, engenharia e pesquisa operacional. Algoritmos meta-heurísticos (MH) têm se destacado como poderosas ferramentas para resolver problemas de otimização complexos devido à sua capacidade de escapar de mínimos locais e encontrar soluções próximas do ótimo global. Os algoritmos MH baseados em atividades humanas são introduzidos com base na modelagem matemática de várias atividades humanas que possuem um processo evolutivo [1].

O objetivo deste trabalho é comparar a eficiência e o desempenho de algoritmos meta-heurísticos (MH) baseados em comportamentos humanos em diferentes contextos de otimização, incluindo modelos de *Machine Learning*, funções matemáticas e o problema do caixeiro-viajante (TSP). Diferentemente de estudos como o de [1], que introduziu o DTBO inspirado em treinamento humano, ou o de [2], que explorou a otimização de redes neurais profundas com MH, nosso trabalho foca em uma análise comparativa de múltiplos algoritmos *human-inspired* para avaliar suas capacidades de exploração e exploração do espaço de busca, diversidade e tempo de execução. Essa abordagem permite uma avaliação abrangente, auxiliando na identificação de algoritmos que oferecem maior precisão e eficiência computacional para problemas complexos, ampliando o estado da arte na aplicação prática de MH em diferentes áreas de otimização.

XIII Workshop do Programa de Pós-Graduação em Ciência da Computação, Unesp, Rio Claro, 26 e 27 de novembro de 2024.

II. CONCEITOS E TÉCNICAS

Para o estudo comparativo de algoritmos meta-heurísticos (MH) inspirados em comportamentos humanos, foram utilizadas técnicas e modelos de otimização aplicados a diferentes contextos. A biblioteca MEALPY, amplamente reconhecida no campo dos MH, foi empregada para a implementação e comparação de onze algoritmos, incluindo o *Queuing Search Algorithm (QSA)* e o *Teaching Learning-based Optimization (TLO)*. A biblioteca OPFUNDU foi utilizada para definir funções de *benchmark*, oferecendo um conjunto diversificado de funções matemáticas complexas, que são referência para testes de desempenho e avaliação dos algoritmos em problemas de otimização. Além disso, o problema clássico do caixeiro-viajante (TSP) foi implementado para observar a capacidade dos algoritmos em resolver desafios de roteamento.

Os principais conceitos avaliados incluem exploração e exploração, essenciais para evitar mínimos locais e alcançar soluções globais eficientes. A diversidade da população, o melhor ajuste atual e global e o tempo de execução foram métricas analisadas para avaliar a eficácia e estabilidade dos algoritmos. Essas métricas fornecem uma visão detalhada da performance computacional e da capacidade dos algoritmos de otimizar soluções complexas em tempo hábil, além de facilitar comparações entre diferentes abordagens de MH.

III. METODOLOGIA DE DESENVOLVIMENTO

A metodologia do estudo envolveu a seleção e implementação dos algoritmos MH na biblioteca MEALPY, garantindo uma abordagem padronizada para os testes. Os algoritmos foram aplicados a três contextos distintos: otimização de hiperparâmetros em modelos de Machine Learning (usando um modelo de Máquina de Vetores de Suporte - SVM), funções matemáticas de *benchmark* e o problema do caixeiro-viajante (TSP). Para a otimização de funções, a biblioteca OPFUNDU, com funções da competição CEC2022, foi utilizada para avaliar o desempenho dos algoritmos em problemas numéricos complexos.

Os experimentos equilibraram precisão e tempo de execução, com 50 épocas para os testes de ML e até 10.000 épocas para TSP e funções matemáticas. Foram definidos

critérios de avaliação como ajuste atual e global, diversidade das soluções e tempo de execução, permitindo uma avaliação abrangente da capacidade de cada algoritmo em alcançar soluções ótimas, maximizando exploração e eficiência computacional.

IV. RESULTADOS

A. Desempenho Geral dos Algoritmos

Os resultados indicaram que o *Queuing Search Algorithm* (QSA) apresentou o melhor desempenho geral nos problemas de otimização, com elevada eficiência computacional, capacidade de exploração e estabilidade na convergência das soluções. O algoritmo *Life Choice-based Optimization* (LCO) também se destacou, especialmente na exploração do espaço de busca, embora em menor escala comparado ao QSA.




Figura 1. Melhor Ajuste Global ao longo das épocas para otimização do modelo de ML.

Fonte: Autoria Própria

B. Diversidade e Exploração

Durante os experimentos, o *Coronavirus Herd Immunity Optimization* (CHIO) demonstrou alta diversidade nas soluções e forte capacidade de exploração, essencial para evitar aprisionamento em mínimos locais. No entanto, essa característica resultou em um custo computacional mais elevado. Em contraste, algoritmos como o *Culture Algorithm* (CA) e o QSA apresentaram convergência mais rápida, o que pode levar ao aprisionamento em soluções locais, embora isso varie de acordo com o problema.




Figura 2. Diversidade ao longo das épocas para o problema do Caixeiro-Viajante (TSP).

Fonte: Autoria Própria

C. Eficiência Computacional

A análise do tempo de execução revelou variações significativas entre os algoritmos. O SSDO, QSA e LCO demonstraram maior eficiência computacional, sendo adequados para aplicações em tempo real. Em contrapartida, o FBIO e o

CHIO, apesar de eficazes na exploração do espaço de busca, apresentaram maior custo de tempo de execução, o que pode limitar sua aplicabilidade em cenários que exigem respostas rápidas.

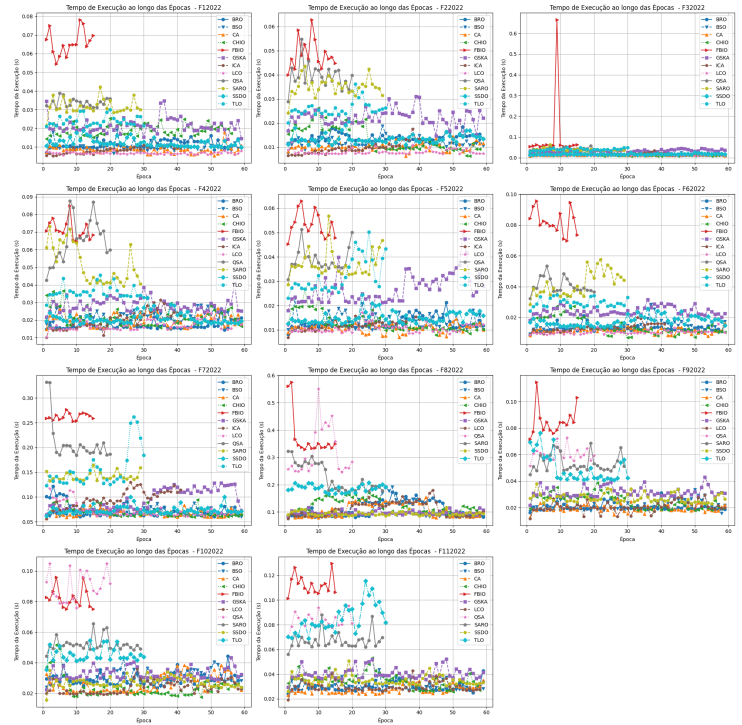


Figura 3. Tempo de Execução dos algoritmos para funções matemáticas de benchmark.

Fonte: Autoria Própria

V. CONSIDERAÇÕES FINAIS

Nos contextos de otimização estudados, os algoritmos QSA e LCO apresentaram desempenho superior, alcançando soluções ótimas rapidamente e mantendo estabilidade, além de equilibrar exploração e exploração com alta eficiência computacional, tornando-os adequados para diversos cenários de otimização. O CHIO destacou-se pela forte capacidade exploratória, essencial para evitar mínimos locais, apesar do maior custo computacional, sendo ideal para cenários que demandam diversidade nas soluções. Já os algoritmos CA e BSO mostraram boa habilidade em escapar de mínimos locais e adaptar-se, embora enfrentem desafios de estabilidade. No geral, o QSA emergiu como o algoritmo mais eficiente, combinando exploração, estabilidade e eficiência, consolidando-se como a melhor escolha para uma ampla gama de tarefas de otimização.

REFERÊNCIAS

- [1] M. Dehghani, E. Trojovská, and P. Trojovský, "A new human-based metaheuristic algorithm for solving optimization problems on the base of simulation of driving training process," *Scientific reports*, vol. 12, no. 1, p. 9924, 2022.
- [2] B. Akay, D. Karaboga, and R. Akay, "A comprehensive survey on optimizing deep learning models by metaheuristics," *Artificial Intelligence Review*, vol. 55, no. 2, pp. 829–894, 2022.