

**UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA – ITEC  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**HEICTOR ALVES DE OLIVEIRA COSTA**

**Métodos de Auto Sintonização Bioinspirados para o Algoritmo Genético**

DM 12/2024

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil

2024

**UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA – ITEC  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**HEICTOR ALVES DE OLIVEIRA COSTA**

**Métodos de Auto Sintonização Bioinspirados para o Algoritmo Genético**

Dissertação apresentada ao Programa de Pós Graduação em Engenharia Elétrica, da Universidade Federal do Pará, como requisito parcial para a obtenção do título de Mestre.

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil

2024

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD  
Sistema de Bibliotecas da Universidade Federal do Pará  
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

---

C837m Costa, Heictor Alves de Oliveira.  
Métodos de Auto Sintonização Bioinspirados para o Algoritmo  
Genético / Heictor Alves de Oliveira Costa. — 2024.  
78 f. : il. color.

Orientador(a): Prof. Dr. Roberto Célio Limão de Oliveira  
Dissertação (Mestrado) - Universidade Federal do Pará,  
Instituto de Tecnologia, Programa de Pós-Graduação em  
Engenharia Elétrica, Belém, 2024.

1. Algoritmo Genético. 2. Radiação Adaptativa. 3. Auto  
Sintonização. 4. Modelos Multicritério. I. Título.

CDD 621.310285

---

UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

“MÉTODOS DE AUTO SINTONIZAÇÃO BIOINSPIRADOS PARA O ALGORITMO  
GENÉTICO”

AUTOR: **HEICTOR ALVES DE OLIVEIRA COSTA**

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA  
APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO  
GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO  
APLICADA.

APROVADA EM: 25/03/2024

**BANCA EXAMINADORA:**

Documento assinado digitalmente  
 **Roberto Célio Limão de Oliveira**  
Data: 25/03/2024 16:11:25-0300  
Verifique em <https://validar.iti.gov.br>

---

**Prof. Dr. Roberto Célio Limão de Oliveira**  
(Orientador – PPGEE/ITEC/UFPA)

Documento assinado digitalmente  
 **CLAUDOMIRO DE SOUZA DE SALES JUNIOR**  
Data: 27/03/2024 16:00:10-0300  
Verifique em <https://validar.iti.gov.br>

---

**Prof. Dr. Claudomiro de Souza de Sales Júnior**  
(Avaliador Interno – PPGEE/ITEC/UFPA)

Documento assinado digitalmente  
 **OTAVIO NOURA TEIXEIRA**  
Data: 25/03/2024 17:24:24-0300  
Verifique em <https://validar.iti.gov.br>

---

**Prof. Dr. Otávio Noura Teixeira**  
(Avaliador Externo ao Programa – CAMPUS TUCURUÍ/UFPA)

Documento assinado digitalmente  
 PEDRO BAPTISTA FERNANDES  
Data: 25/03/2024 17:39:34-0300  
Verifique em <https://validar.iti.gov.br>

---

**Prof. Dr. Pedro Baptista Fernandes**  
(Avaliador Externo – UFMA)

VISTO:

---

**Prof. Dr. Diego Lisboa Cardoso**  
(Coordenador do PPGEE/ITEC/UFPA)

## AGRADECIMENTOS

À Universidade Federal do Pará (UFPA), por sua estrutura e qualidade, ao Programa de Pós-Graduação em Engenharia Elétrica do Instituto Tecnológico (PPGEE - ITEC), por prover excelente docentes que inspiraram, influenciaram e motivaram o desenvolvimento dessa pesquisa, e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), por garantir o apoio necessário para me manter no caminho acadêmico.

Ao meu orientador, Roberto Limão, que desde os contatos iniciais, ainda que virtuais, aceitou a tarefa de me orientar, e apoiou minha proposta de pesquisa.

Aos meus amigos, que me acompanharam tanto dentro e fora dos ambientes acadêmicos, o que foi necessário para que eu pudesse me empenhar cientificamente, ao mesmo tempo que enriquecer pessoalmente.

Aos meus avós, Carlos Costa e Maria Costa, por sempre estenderem sua inteligência, educação e bondade, para que eu pudesse ser criado em um ambiente familiar saudável.

E principalmente, aos meus pais, Denis Costa e Jailsa Costa, por me apresentarem o caminho que hoje eu trilho, e no qual pretendo me aperfeiçoar ao longo próximos capítulos da minha história.

## SUMÁRIO

|        |  |    |
|--------|--|----|
| 1.     | Introdução .....                                     | 1  |
| 1.1.   | Objetivos da Dissertação .....                       | 4  |
| 2.     | Trabalhos Relacionados.....                          | 5  |
| 3.     | Estudos de Caso.....                                 | 8  |
| 3.1.   | Funções de <i>Benchmark</i> .....                    | 8  |
| 3.2.   | Problemas de Engenharia .....                        | 9  |
| 3.2.1. | Viga soldada: .....                                  | 9  |
| 3.2.2. | Vaso de Pressão .....                                | 10 |
| 3.2.3. | Viga Cantilever .....                                | 11 |
| 3.2.4. | Mola de Tensão.....                                  | 12 |
| 3.3.   | Problema Real .....                                  | 12 |
| 4.     | Metodologia.....                                     | 17 |
| 4.1.   | Inicialização da população .....                     | 17 |
| 4.2.   | Avaliação de Aptidão .....                           | 20 |
| 4.3.   | Processo de Escolha da Função de Seleção .....       | 20 |
| 4.4.   | Organização da Estratégia Comparativa .....          | 20 |
| 4.5.   | Escolha do método de <i>Crossover</i> .....          | 21 |
| 4.6.   | Método de Escolha da Função de Mutação.....          | 22 |
| 4.7.   | Radiação Adaptativa .....                            | 22 |
| 4.8.   | Formulação da Função de Radiação Adaptativa .....    | 23 |
| 4.9.   | Escolha de Parceiros.....                            | 26 |
| 4.10.  | Formulação da função de Escolha Multicritérios ..... | 27 |
| 4.11.  | Radiação Adaptativa + Multicritério .....            | 29 |
| 4.12.  | Comparação de Algoritmos .....                       | 30 |
| 5.     | Resultados.....                                      | 34 |
| 5.1.   | Funções CEC2019:.....                                | 35 |
| 5.1.1. | CEC 01:.....   | 39 |
| 5.1.2. | CEC 02:.....   | 41 |
| 5.1.3. | CEC 03:.....   | 43 |
| 5.1.4. | CEC 04:.....   | 44 |
| 5.1.5. | CEC 05:.....   | 45 |
| 5.1.6. | CEC 06:.....   | 46 |
| 5.1.7. | CEC 07:.....   | 47 |

|                                     |    |
|-------------------------------------|----|
| 5.1.8. CEC 08:.....                 | 47 |
| 5.1.9. CEC 09:.....                 | 48 |
| 5.1.10. CEC 10:.....                | 49 |
| 5.2. Problemas de Engenharia: ..... | 51 |
| 5.2.1. Viga soldada.....            | 53 |
| 5.2.2. Vaso de Pressão: .....       | 54 |
| 5.2.3. Viga Cantilever: .....       | 55 |
| 5.2.4. Mola de Tensão.....          | 55 |
| 5.3. Problema Real .....            | 56 |
| 6. Conclusão .....                  | 61 |
| Referências.....                    | 63 |

## **LISTA DE SIGLAS**

**GA** Algoritmo Genético (*Genetic Algorithm*)

**PSO** Otimização do Enxame de Partículas (*Particle Swarm Optimization*)

**APSO** Enxame de Partículas Adaptativo (*Adaptive Particle Swarm Optimization*)

**AR** Radiação Adaptativa (*Adaptive Radiation*)

**MDMC** Modelos de Decisão Multicritério

**ELIII** Electre III

**GAAR** Algoritmo Genético com Radiação Adaptativa

**MCGA** Algoritmo Genético Multicritério

**CNN** Rede Neural de Convolução (*Convolutional Neural Network*)

**ERT** Tempo de Execução Esperado (*Expected Running Time*)

**AUC** Área sob a Curva (*Area Under the Curve*)

## RESUMO

Esta pesquisa foi motivada pela necessidade de aprimorar a eficiência do algoritmo genético (*Genetic Algorithm* - GA) ao lidar com uma variedade de problemas complexos. O objetivo é desenvolver estratégias que permitam ao GA ajustar-se automaticamente aos desafios específicos de cada problema, sem necessidade de intervenção manual para reajustar os seus parâmetros operacionais, tornando este algoritmo em uma ferramenta mais dinâmica. Para atingir esse objetivo, a pesquisa propôs duas estratégias bioinspiradas para aprimorar a adaptabilidade e a eficiência do GA. A primeira foi a Radiação Adaptativa (*Adaptive Radiation* - AR), um fenômeno biológico que provoca altas taxas de mutação em populações, permitindo rápida adaptação às condições de sobrevivência. A segunda foi uma técnica de seleção inspirada em Modelos de Decisão Multicritério (MDMC) e no comportamento natural da escolha de parceiros de diversas espécies, que auxiliam na tomada de decisão, avaliando soluções com base em critérios múltiplos. A metodologia envolveu a implementação dessas estratégias no GA, criando dois novos algoritmos: GA com Radiação Adaptativa (GAAR) e GA Multicritério (MCGA). Esses algoritmos foram então testados em três categorias diferentes de problemas: dez funções de *benchmark*, que simulam uma variedade de ambientes complexos; quatro problemas de engenharia, que representam desafios da indústria; e um problema real, para testar a aplicabilidade prática dos algoritmos em um cenário de alta magnitude. Os resultados mostraram que os algoritmos GAAR e MCGA superaram o GA padrão e outros algoritmos de otimização na maioria dos problemas testados. Em particular, eles foram capazes de adaptar-se efetivamente a diferentes tipos de problemas e encontrar soluções eficientes sem a necessidade de reajuste manual dos seus parâmetros. Esses resultados sugerem que a introdução de estratégias bioinspiradas como AR e MDMC pode melhorar significativamente o desempenho do GA, tornando-os uma ferramenta poderosa para uma ampla gama de aplicações do mundo real.

**PALAVRAS-CHAVE:** Algoritmo Genético, Radiação Adaptativa, Auto Sintonização, Modelos Multicritério.

## ABSTRACT

This research was motivated by the need to improve the efficiency of the Genetic Algorithm (GA) when dealing with a variety of complex problems. The goal is to develop strategies that allow the GA to automatically adjust itself to the specific challenges of each problem, without the need for manual intervention to readjust its operational parameters, making this algorithm a more dynamic tool. To achieve this goal, this research proposed two bioinspired strategies to enhance the adaptability and efficiency of GA. The first strategy was Adaptive Radiation (AR), a biological phenomenon that causes high rates of mutation in populations, allowing rapid adaptation to survival conditions. The second strategy was a selection technique inspired by Multi-Criteria Decision Models (MCDM) and the natural behavior of choosing partners, observed on different species, which assist in decision making, evaluating solutions based on multiple criteria. The methodology consists of implementing these strategies in GA, creating two new algorithms: GA with Adaptive Radiation (GAAR) and Multicriteria GA (MCGA). These algorithms were then tested on three different categories of problems: ten *benchmark* functions, which simulate a variety of complex environments; four engineering problems, which represent industry challenges; and a real problem, to test the practical applicability of the algorithms in a high magnitude scenario. The results showed that the GAAR and MCGA algorithms outperformed the standard GA and other optimization algorithms on most of the tested problems. In particular, they were able to effectively adapt to different types of problems and find efficient solutions without the need to manually readjust their parameters. These results suggest that the introduction of bioinspired strategies such as AR and MCDM can significantly improve GA performance, making them a powerful tool for a wide range of real-world applications.

**KEYWORDS:** Genetic Algorithm, Adaptive Radiation, Autotuning, Multicriteria Models.

## 1. INTRODUÇÃO

Sistemas computacionais modernos, focados na otimização de problemas complexos, utilizam técnicas bioinspiradas por sua capacidade superior de trabalhar com funções matemáticas não-lineares-multidimensionais (DARWISH, 2018). Mais especificamente neste campo de estudo, um subgrupo de algoritmos implementa o comportamento observado em fenômenos evolutivos da natureza para otimizar diversos problemas, buscando uma solução aceitável (CAO et al., 2023): São os algoritmos evolutivos.

Os algoritmos evolutivos trabalham em torno do conceito de uma população, que progride ao longo das etapas de geração ao longo de seu tempo, gerando indivíduos melhores. Tais indivíduos são, então, interpretados como possíveis soluções para o problema otimizado (LI, J. e LI, L., 2019). Em processos de minimização, por exemplo, o indivíduo que apresentar o menor valor da função de aptidão, dentro do domínio da função, é a melhor solução disponível.

Dentre os pioneiros dos algoritmos evolutivos, destaca-se o Algoritmo Genético (*Genetic Algorithm* - GA), que imita os passos básicos do neo-evolucionismo darwinista (HOLLAND, 1992). Nesse modelo, a população seleciona seus melhores indivíduos para o cruzamento e, a partir daí, introduz um fator de mutação para simular o comportamento estocástico presente na observação da natureza.

Apesar de ter revolucionado o campo bioinspirado, a implementação clássica do GA tornou-se obsoleta, gerando a necessidade de modalidades específicas de GA, mais adaptadas a cada problema. O elitismo, por exemplo, estabelece uma porcentagem de indivíduos da população, que são preservados de uma geração para a seguinte, possibilitando que os melhores indivíduos estejam nas próximas gerações, e aumentando a probabilidade de encontrar a solução ótima, pois evita a destruição aleatória dos melhores cromossomos e evita a convergência prematura (NATESHA e GUDDI, 2021).

Apesar de apresentar melhora nos resultados do GA, esse tipo de adição de processo transforma esse algoritmo em uma estrutura de alta complexidade por causa da alta quantidade de parâmetros sintonizáveis, criando oportunidades para a introdução de algoritmos de otimização mais eficientes e bioinspirados. Existem outros algoritmos bioinspirados como o Otimização do Enxame de Partículas (*Particle Swarm Optimization* - PSO) que baseia-se no comportamento das aves em busca de alimento, e trabalha com poucos parâmetros (CORTEZ, GARRIDO e MEZURA-MONTES, 2022). Outro é a evolução diferencial que gera novos descendentes ao perturbar as soluções com vetores de diferença escalonados, além de

apresentar um pequeno número de componentes ajustáveis, sendo uma boa estratégia para encontrar uma solução aceitável para um problema de inversão de fontes na prática de gestão ambiental (MAO et al., 2022).

A configuração de um algoritmo para cada problema diferente, embora seja uma estratégia razoável, requer esforço para o ajuste de tentativa e erro dos parâmetros. Este processo torna-se cada vez mais complexo quando se aplica determinado algoritmo para trabalhar sobre múltiplos problemas de diferentes qualidades, em que as funções de aptidão são de natureza diferente.

Os algoritmos bioinspirados apresentam a capacidade de adaptação a situações dinâmicas, sendo o fator dinamismo caracterizado por alterar a função matemática sendo otimizado, substituindo, portanto, o problema em si. Isso é possível através do processo de auto sintonização que é o processo de ajuste automático dos parâmetros do algoritmo com base nas características do problema e medidas de desempenho (RAJANI, KUMAR e KASWAN, 2022). O ajuste automático permite que algoritmos de otimização bioinspirados alcancem o desempenho ideal em uma ampla gama de instâncias de problemas, permitindo que um algoritmo seja uma ferramenta poderosa para várias aplicações do mundo real.

Lembrando a referência do GA sobre processo evolutivo, existem múltiplas ações biológicas relacionadas a operações genéticas, ainda, a serem implementadas em ambiente computacional, podendo fundamentar o comportamento de auto sintonização no algoritmo, como a inércia adaptativa no PSO (NAYEEM, FAN e AKHTER, 2021). No entanto, vários subprocessos executados sob o mesmo algoritmo requerem maior esforço computacional. Assim, qualquer inovação bioinspirada exige uma troca razoável, trazendo mais traços positivos do que negativos para o algoritmo.

Esta dissertação buscou elaborar um método de auto sintonização que precisa alterar o valor de um único parâmetro, mas também contando com um elemento biológico coerente, diretamente relacionado ao comportamento do GA.

As referências RAPINI et al. (2020) e RICHARDS (2021) destacam a presença de biodiversidade e especialização de nicho na jornada de sobrevivência, fatores gerados por episódios de intensa adaptação genética, posteriormente observados como sendo o ponto de partida da diversificação de múltiplas espécies. Ambos os fatores são promovidos por um fenômeno denominado Radiação Adaptativa (*Adaptive Radiation* - AR), que provoca altas

taxas de mutação em populações endêmicas, permitindo que seus indivíduos passem rapidamente por adaptações em suas características para fins de sobrevivência.

A tomada de decisão no processo de seleção de soluções, nos algoritmos evolutivos, comumente considera apenas o valor de aptidão do indivíduo. O Darwinismo também deu origem aos estudos de escolha por parceiros, permitindo o estudo de estratégias evolutivas adotadas por diversas espécies, com o intuito de garantir sua perpetuação genética (HENSHAW, FROMHAGE e JONES, 2022). Essas estratégias consistem em intensificar características, relacionadas com certos genes, para garantir maior chance do indivíduo de ser escolhido para reprodução. Tais comportamentos se assemelham aos Modelos de Decisão Multicritério (MDMC), que auxiliam a tomada de decisão, trazendo processos lógicos que comparam soluções de maneira ponderada, baseada no que for preferível pelo especialista (ŻAK e KRUSZYŃSKI, 2015). Dessa forma, é possível assimilar o comportamento biológico por meio dos MDMC.

Lidando com a necessidade de otimizar múltiplas funções de naturezas distintas, visando alta eficiência e evitando a necessidade de reajuste dos parâmetros operacionais de maneira manual, esta pesquisa traz a proposta da introdução do AR como estratégia de auto sintonização, para apresentar um algoritmo evolutivo de maior adaptabilidade, e de uma técnica de seleção inspirada em MDMC e comportamentos naturais, considerando diferentes critérios, para diferentes entradas de medidas de aptidão. Tal proposta almeja melhorar o desempenho do GA nos resultados de otimização, e apresentar uma melhor pontuação geral em funções com diferentes características, devido aos métodos evolutivos de auto sintonização e seleção multicritério bioinspirados.

As demais seções deste artigo são apresentadas a seguir: A Seção II apresenta o contexto científico abordado, com o estado da arte dos trabalhos relacionados ao campo de estudo desta pesquisa. A seção III discute o Estudo de Caso adotado, como os tipos de funções utilizadas nos testes de desempenho. A seção IV explica a metodologia abordada, com cada etapa do algoritmo proposto, detalhando os métodos biológicos e suas implementações sistemáticas na modelagem das funções RA e MCGA. A seção V apresenta os resultados dos algoritmos propostos e de seus algoritmos rivais, além da explicação do desempenho sobre as funções de teste, com base em suas respectivas características. Por fim, a seção VI apresenta as conclusões deste estudo, destacando as inovações propostas por essa pesquisa, discutindo os resultados alcançados e seus significados, além de apresentar as propostas para trabalhos futuros.

### 1.1. Objetivos da Dissertação

Introduzir no Algoritmo Genético, componentes de auto sintonização, inspirados em comportamentos biológicos, vinculados ao processo de aperfeiçoamento genético evolutivo, para elaborar uma versão desse algoritmo clássico mais adaptável e eficiente. Esse objetivo geral será alcançado por meio das seguintes tarefas:

- a) Analisar e modelar matematicamente comportamentos biológicos coerentes com as capacidades do Algoritmo Genético.
- b) Implementar computacionalmente as diferentes componentes elaboradas em versões inéditas do Algoritmo Genético.
- c) Comparar a versão clássica e novas do Algoritmo Genético propostas nessa pesquisa, assim como demais algoritmos rivais, em problemas de diferentes características.
- d) Analisar o desempenho dos algoritmos para compreensão de suas dinâmicas.

### 1.2. Justificativa

Dentre os artigos consultados, não foram encontradas pesquisas que, assim como a proposta desta dissertação, trabalhem a modelagem e implementação dos fenômenos de Radiação Adaptativa e Escolha Multicritério de Parceiros, como componentes de auto sintonização para o Algoritmo Genético. Desta forma, justifica-se a realização deste trabalho, que seguindo a metodologia proposta, será capaz de introduzir essas novas componentes, para a elaboração de uma nova versão do Algoritmo Genético clássico, que tenha maior adaptabilidade para problemas de naturezas distintas, sem abdicar da qualidade de soluções otimizadas.

## 2. TRABALHOS RELACIONADOS

Ao observar algoritmos de Inteligência Artificial (IA) que estão sendo desenvolvidos, tem-se uma imagem interessante de como esses algoritmos funcionam. Há muito trabalho manual envolvido na automatização dos processos de decisão para que os algoritmos tenham um bom desempenho. Isso é conhecido como sintonização de IA (VICTORIA e MARAGATHAM, 2021). Este é um trabalho robusto, e explica o motivo de um algoritmo de IA funcionar muito bem para resolver uma tarefa, mas se a tarefa for trocada, o desempenho não será o mesmo. Em outras palavras, algoritmos de IA ajustados são bons para algumas tarefas, mas outras tarefas exigirão ajustes adicionais (KARN, KUDVA e ELFADEL, 2019). O ajuste de IA é um campo de estudo promissor.

Para técnicas de computação evolutiva e/ou inteligência de enxame, a auto sintonização também é importante (CHENG, FANG e WANG, 2021). Normalmente, a computação evolutiva/inteligência de enxame é usada para ajustar alguma técnica computacional que está resolvendo um problema (ACHARYA et al., 2014; CASTOLDI et al., 2014). Mas o desempenho desses algoritmos também depende de um bom ajuste de seus hiperparâmetros (LIN e GEN, 2009; UGOLOTTI e CAGNONI, 2015).

Dentre os algoritmos evolutivos, o GA é um dos mais antigos e complexos (CHAMBERS, 2019). Uma característica dessa complexidade é o número de parâmetros (PONGCHAROEN et al., 2002; Vlasov et al., 2021). Os parâmetros mais importantes da GA são o tamanho da população, a taxa de cruzamento, a taxa de mutação, entre outros. A taxa de mutação é responsável por explorar o espaço de busca e tentar manter a diversidade da população (WATSON e MESSER, 2001; MCGINLEY et al., 2011). Várias versões do GA variam a taxa de mutação (HASSANAT et al., 2019; CHITTY, 2022; JAVADI e AMINIAN, 2017) ou a mantêm alta (CROITORU, 2015; SPALEK e GREGOR, 2011), para melhorar o desempenho do algoritmo.

Mais recentemente, a estratégia de auto sintonização tem sido utilizada no GA. Em (FRANCO, KRASNOGOR e BACARDIT, 2020), os autores modelam o desempenho de algoritmos de aprendizado de máquina como uma função da estrutura inerente de conjuntos de dados muito grandes. Portanto, um mecanismo de parametrização é apresentado para um sistema de aprendizado de máquina baseado em regras evolutivas que pode encontrar o valor apropriado de um parâmetro para uma ampla variedade de problemas de classificação sintética com atributos binários com, ou sem, ruído adicionado.

Em (YE et al., 2022), é feita uma comparação entre quatro diferentes métodos de sintonia para hiperparâmetros de AG. Método não-automatizado ou *grid search* é usado. Os outros três métodos automatizados são competições iteradas, otimização global com eficiência paralela inteira mista (MIP-EGO) e estratégias evolutivas inteiras mistas. Os resultados sugerem que, mesmo quando interessado no desempenho do Tempo de Execução Esperado (*Estimated Runtime* - ERT), pode ser preferível usar medidas de desempenho a qualquer momento para a tarefa de configuração. Enquanto minimizar a ERT favorece o tempo médio de primeiro acerto de um único alvo fixo, maximizar a área sob a métrica empírica de função de Distribuição Cumulativa de Tempo de Execução (*Area Under the Curve* - AUC) visa otimizar o desempenho a qualquer momento, que é medido em todo um conjunto de pares de custo computacional e valor de referência da solução. Isso mostra que, em vários casos, o ajuste para AUC produz configurações que têm valores de ERT menores do que aqueles que foram obtidos ao sintonizar diretamente para ERT.

Em (HUYNH, HO e NGUYEN, 2023) é proposto um GA de auto sintonização com cromossomos bidimensionais para projetar um modelo de Rede Neural de Convolução ótima (*Convolutional Neural Network* - CNN) de forma eficiente, para detecção de defeitos com base nas imagens de superfície em fabricação. Um cromossomo bidimensional é desenvolvido para representar a estrutura e os parâmetros da CNN. Para melhorar o processo de busca, a taxa de cruzamento e a taxa de mutação são ajustadas automaticamente de acordo com a geração.

O MDMC trabalha com modelos para análise de múltiplas variáveis, fornecendo suporte ao processo de tomada de decisão por meio de ponderação de critérios e ordenação de soluções (TAHERDOOST e MADANCHIAN, 2023), apresentando métodos que produzem a solução mais adequada para um determinado conjunto de preferências, como a família Electre de modelos (ROY, 1958), que é um grupo de métodos de comparação para alcançar a melhor alternativa.

O Electre III (ELIII), por exemplo, permite um funcionamento confiável, baseado em séries de comparações de concordância e discordância, aumentando ou diminuindo a “pontuação” de uma solução, com relação aos atributos mais impactantes com base na sua credibilidade final (VASTO-TERRIENTES et al, 2015). Iniestra e Garcia-Gutierrez (2009), implementaram o ELIII para avaliação de múltiplas possibilidades de projetos de modelagem de infraestrutura de transporte. Os autores construíram sua abordagem com base em múltiplos critérios, como custo monetário e impacto social. Com base nas prioridades governamentais de cada critério,

estas foram ponderadas para realizar o processo de superação. Este trabalho também aplicou GA para otimização das soluções disponíveis.

Dadas as características do fenômeno AR, e sua coerente possível implementação em algoritmos de otimização, esta pesquisa o adotou como referência para um dos métodos de auto sintonização. Uma vez que o AR está diretamente relacionado com os passos evolutivos na natureza, ao agregar um novo comportamento mutacional à população, cria-se um novo modelo denominado Algoritmo Genético com Radiação Adaptativa, ou simplesmente, GAAR, que equilibra a biodiversidade e a especialização de nicho de acordo com a necessidade.

A estrutura de processos dos MDMC também foi adotada para compor uma vertente nova do AG, que incorpora análises baseadas em preferência por valores de parâmetros, influência das estratégias biológicas de escolhas de parceiro. O modelo do GA com incorporação dessa escolha multicritério foi denominada Algoritmo Genético Multicritério, ou simplesmente MCGA, visando aprimorar a fase de seleção de soluções, antes do cruzamento.

O GA apresenta-se como o algoritmo mais capaz de adotar estes novos componentes, pela abstração evolutiva presente nesta ferramenta, desta forma, este algoritmo será utilizada como a estrutura base das metodologias propostas.

### 3. ESTUDOS DE CASO

Para analisar o desempenho do algoritmo proposto, foram adotadas 3 categorias diferentes de problemas: dez funções de *benchmark*, quatro problemas de engenharia e um problema real.

#### 3.1. Funções de *Benchmark*

Para as funções de *benchmark*, foi adotado o pacote “*CEC-2019 Single Objective Optimization*”, composto de 10 funções confiáveis para testes de performance dos algoritmos. Tais funções foram herdadas do Desafio de 100 Dígitos (PRICE, 2018), e estas estão apresentadas na Tabela 1.

TABELA 1 - FUNÇÕES CEC-2019

| No. | Funções  | $f_{min}$ | D  | Intervalo de Busca |
|-----|--|-----------|----|--------------------|
| 1   | Problema de encaixe polinomial de Chebyshev de Storn | 1         | 9  | [-8192, 8192]      |
| 2   | Problema inverso da matriz de Hilbert                | 1         | 16 | [-16384, 16384]    |
| 3   | Cluster de Energia Mínima de Lennard-Jones           | 1         | 18 | [-4, 4]            |
| 4   | Função de Rastagin                                   | 1         | 10 | [-100, 100]        |
| 5   | Função de Griewangk                                  | 1         | 10 | [-100, 100]        |
| 6   | Função Weierstrass                                   | 1         | 10 | [-100, 100]        |
| 7   | Função de Schwefel modificada                        | 1         | 10 | [-100, 100]        |
| 8   | Função F6 de Schaffer expandida                      | 1         | 10 | [-100, 100]        |
| 9   | Função Happy Cat                                     | 1         | 10 | [-100, 100]        |
| 10  | Função Ackley  | 1         | 10 | [-100, 100]        |

Fonte: Autor (2024).

As funções CEC-2019 apresentam características matemáticas diferentes em seus próprios modelos, que realizam cenários distintos para o processo de otimização. Conforme apresentado na Tabela 1, cada função tem seu Número de Dimensões ( $D$ ), Intervalo de Busca e o valor de seu respectivo Mínimo Global ( $f_{min}$ ). Essas funções simulam muitos ambientes complexos para o algoritmo proposto trabalhar e são usadas para medir seu desempenho, e avaliar em quais oportunidades ele se torna a melhor ferramenta de otimização.

### 3.2. Problemas de Engenharia

Os problemas de engenharia apresentam quatro funções diferentes, apresentadas na Tabela 2.

TABELA 2 – PROBLEMAS DE ENGENHARIA

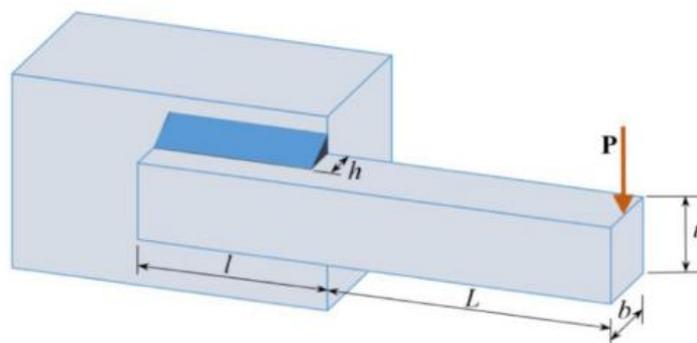
| No. | Funções                                    | D | Intervalo de Busca                                     |
|-----|--|---|--|
| 1   | Problema de otimização da viga soldada     | 4 | [(0.1 0.1 0.1 0.1), (2 10 10 2)]                       |
| 2   | Problema de otimização de vasos de pressão | 4 | [(0.0625 0.0625 10 10), (99×0.0625 99×0.0625 200 200)] |
| 3   | Problema de otimização de viga cantilever  | 5 | [(0.01 0.01 0.01 0.01 0.01), (100 100 100 100 100)]    |
| 4   | Problema de otimização de mola de tensão   | 3 | [(0.05 0.25 2), (2 1.3 15)]                            |

Fonte: Autor (2024).

#### 3.2.1. Viga soldada:

Neste problema, o objetivo é minimizar o custo de construção, este é composto por quatro variáveis ( $h(x_1)$ ,  $l(x_2)$ ,  $t(x_3)$ ,  $b(x_4)$ ), conforme mostrado na Figura 1.

Figura 1– Ilustração do problema Viga soldada



Fonte: Yang, Li e Huan (2023).

As restrições satisfeitas por essas variáveis são descritas em detalhes na Equação 1.

$$\begin{aligned} \min f(x) &= 1.1047x_1^2x_2 + 0.04811x_3x_4(14 + x_2) \\ \text{tal que} &\left\{ \begin{array}{l} g_1(x) = \tau(x) - \tau_{\max} \leq 0 \\ g_2(x) = \sigma(x) - \sigma_{\max} \leq 0 \\ g_3(x) = x_1 - x_4 \leq 0 \\ g_4(x) = 0.10471x_1^2 + 0.04811x_3x_4(14 + x_2) - 5 \leq 0 \\ g_5(x) = 0.125 - x_1 \leq 0 \\ g_6(x) = \delta(x) - \delta_{\max} \leq 0 \\ g_7(x) = P - P_c(x) \leq 0 \end{array} \right. \quad (1) \end{aligned}$$

Intervalo das variáveis:  $0.1 \leq x_i \leq 2 \text{ i} = 1 \vee 4$ ;  $0.1 \leq x_i \leq 10 \text{ i} = 2 \vee 3$

$$\text{em que } \tau(x) = \sqrt{(\tau')^2 + 2\tau'\tau''\frac{x_2}{2R} + (\tau'')^2},$$

$$\tau' = \frac{P}{\sqrt{2x_1x_2}}, \tau'' = \frac{MR}{J} M = P \left( L + \frac{x_2}{2} \right), R = \sqrt{\left(\frac{x_2}{2}\right)^2 + \left(\frac{x_1 + x_3}{2}\right)^2}$$

$$J = 2 \left( \sqrt{2x_1x_2} \left( \frac{x_2^2}{12} + \left(\frac{x_1 + x_3}{2}\right)^2 \right) \right), \sigma(x) = \frac{6PL}{x_4x_3^2}, \delta(x) = \frac{4PL^3}{Ex_3^3x_4}$$

$$P_c(x) = \frac{4.013E \sqrt{\frac{x_3^2x_4^6}{36}}}{L^2} \left( 1 - \frac{x_3}{2L} \sqrt{\frac{E}{4G}} \right)$$

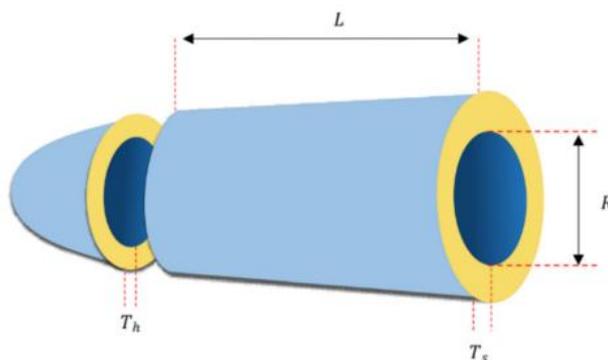
$$P = 6000lb, L = 14in, E = 30 \times 10^6psi, G = 12 \times 10^6psi$$

$$\tau_{\max} = 13600psi, \quad \sigma_{\max} = 30000psi, \quad \delta_{\max} = 0.25in$$

### 3.2.2. Vaso de Pressão

Neste problema, o objetivo é encontrar o menor custo, que inclui materiais, moldagem e soldagem (Cuong-Le et al., 2021). O custo de construção é composto por quatro variáveis ( $Ts(x_1), h(x_2), R(x_3), L(x_4)$ ), conforme mostrado na Figura 2.

Figura 2 – Ilustração do problema Vaso de Pressão



Fonte: Yang, Li e Huan (2023).

As restrições satisfeitas por estas variáveis são descritas em detalhes na Equação 2.

$$\min f(x) = 0,6224x_1x_3x_4 + 1,7781x_2x_3^2 + 3.1661x_1^2x_4 + 19.84x_1^2x_3$$

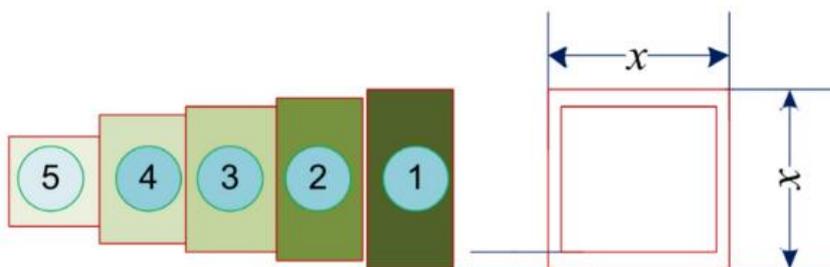
$$\text{tal que} \begin{cases} g_1(x) = -x_1 + 0,0193x_3 \leq 0 \\ g_2(x) = -x_3 + 0.00954x_3 \leq 0 \\ g_3(x) = -\pi x_3^2 x_4 - \frac{4}{3}\pi x_3^3 + 1296000 \leq 0 \\ g_4(x) = x_4 - 240 \leq 0 \end{cases} \quad (2)$$

Intervalo das Variáveis:  $0.1 \leq x_i \leq 100$   $i = 1, 2$ ;  $10 \leq x_i \leq 200$   $i = 3, 4$

### 3.2.3. Viga Cantilever

Neste problema, o objetivo é encontrar o peso mínimo (Yıldız e Erdaş, 2021; Yildiz et al., 2019), (Yıldız et al., 2021a). O peso da construção é composto por quatro variáveis ( $x_1$ ,  $x_2$ ,  $x_3$ ,  $x_4$ ), conforme mostrado na Figura 3.

Figura 3 – Ilustração do problema Viga Cantilever



Fonte: Yang, Li e Huan (2023).

As restrições satisfeitas por essas variáveis são descritas em detalhes na Equação 3.

$$\min f(x) = 0,06224(x_1 + x_2 + x_3 + x_4 + x_5)$$

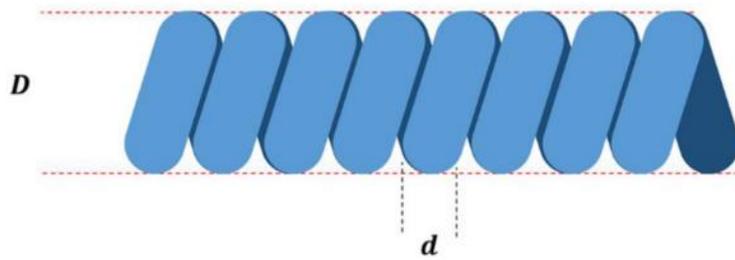
$$g(x) = \frac{61}{x_1^3} + \frac{37}{x_2^3} + \frac{19}{x_3^3} + \frac{7}{x_4^3} + \frac{1}{x_5^3} \leq 1 \quad (3)$$

$$0,01 \leq x_1, x_2, x_3, x_4, x_5 \leq 100$$

### 3.2.4. Mola de Tensão

Neste problema, o objetivo é encontrar o peso mínimo  $t$  (Cuong-Le et al.,2021). O peso da construção é composto por três variáveis ( $d(x_1)$ ,  $D(x_2)$ ,  $N(x_3)$ ), conforme mostrado na Figura 4.

Figura 4 – Ilustração do problema Mola de Tensão



Fonte: Yang, Li e Huan (2023).

As restrições satisfeitas por essas variáveis são descritas em detalhes na Equação 4.

$$\begin{aligned} \min f(x) &= (x_3 + 2)x_2x_1^2 \\ \text{tal que} &\left\{ \begin{aligned} g_1(x) &= 1 - \frac{x_2^3x_3}{71785x_1^4} \leq 0 \\ g_2(x) &= \frac{4x_2^2 - x_1x_2}{12566(x_2x_1^3 - x_1^4)} + \frac{1}{5108x_1^2} \leq 0 \\ g_3(x) &= 1 - \frac{140.45x_1}{x_2^2x_3} \leq 0 \\ g_4(x) &= \frac{x_1 + x_2}{1,5} - 1 \leq 0 \end{aligned} \right. \quad (4) \end{aligned}$$

Em que  $0,05 \leq x_1 \leq 2$ ;  $0,25 \leq x_2 \leq 1,30$ ;  $2,00 \leq x_3 \leq 15$

### 3.3. Problema Real

Para o problema real a ser otimizado, foi escolhida uma rede elétrica IEEE de 300 Barramentos (*300-Bus*) (ADIBI et al, 1993), que apresenta diversas variáveis de diferentes grandezas. A otimização desse problema se dá em torno da função custo dessa estrutura, que

busca minimizar os gastos, porém atendendo os valores de geração energética para alimentar a demanda dos barramentos. Os valores de limites operacionais das componentes da rede foram importados da ferramenta MATPOWER (ZIMMERMAN, MURILLO-SANCHEZ E THOMAS, 2011), que nessa estrutura opera com 300 barramentos e 69 geradores, cada um com seus respectivos valores de produção e demanda. A estrutura desta rede é apresentada na Figura 5.

A adoção da nomenclatura “Problema Real” nesta categoria, usada para o problema de 300 barramentos, representa a única das funções que foi modelada a partir de uma aplicação prática desta pesquisa, como demonstrado a seguir, contrário aos demais problemas utilizados, que se tratam de funções populares na literatura de otimização. Dessa forma, esse problema constitui o cenário real para o qual se desenvolve a metodologia desta dissertação, em sua aplicação no despacho ótimo de redes elétricas.

Figura 5 – Estrutura da IEEE 300-Bus

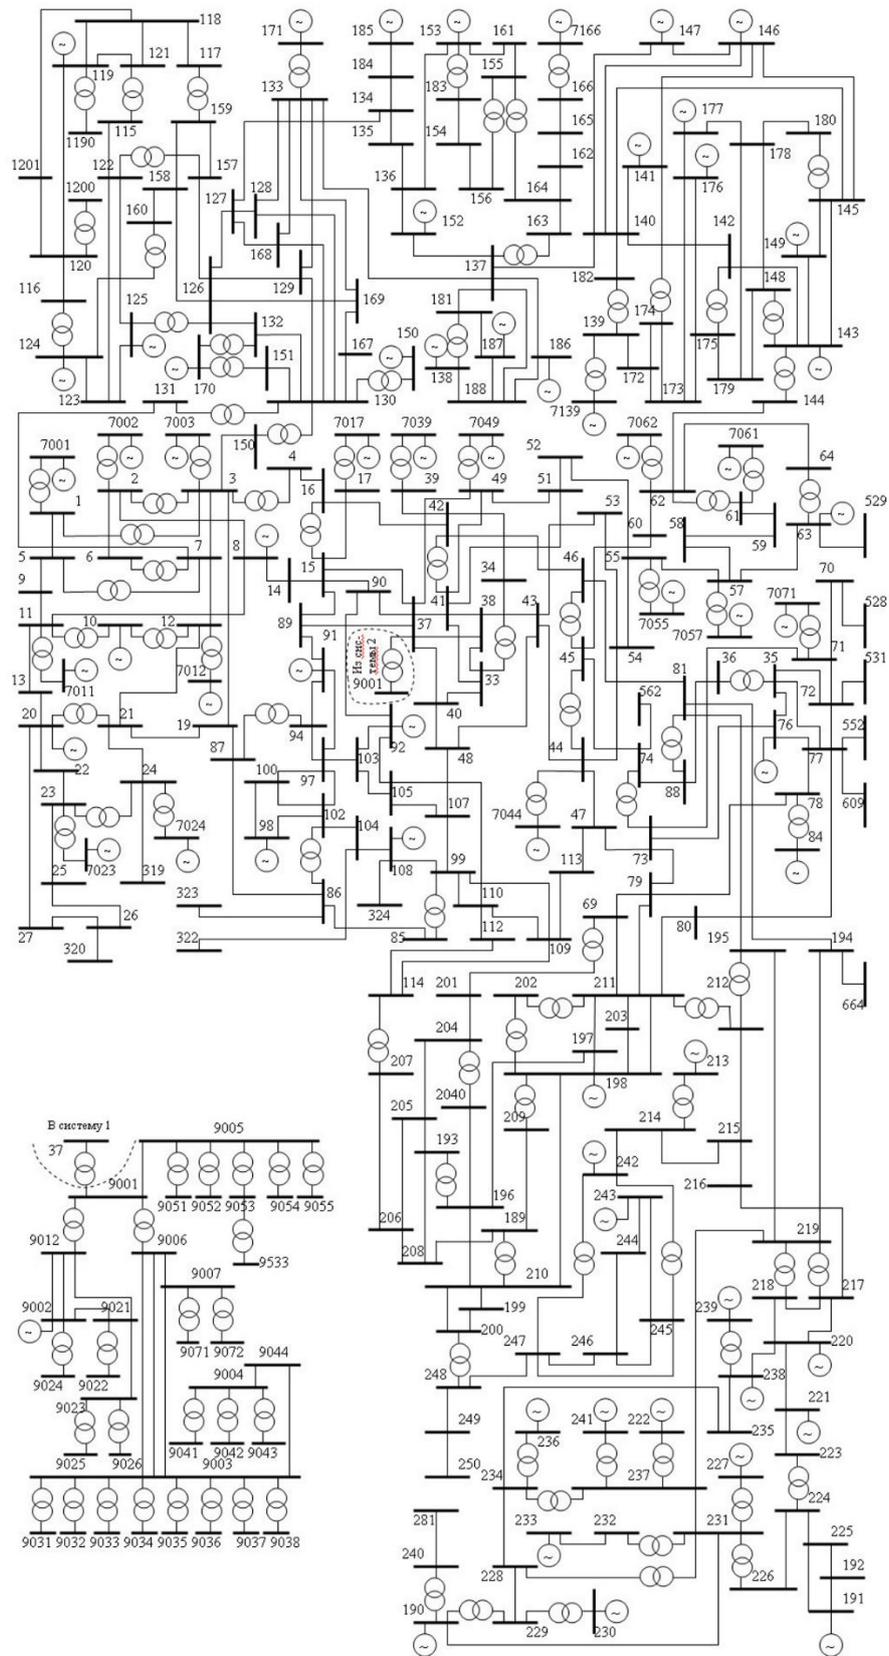


Рис.1. IEEE тестовая схема, состоящая из 300 узлов

Fonte: Ali R. Al-Roomi (2015).

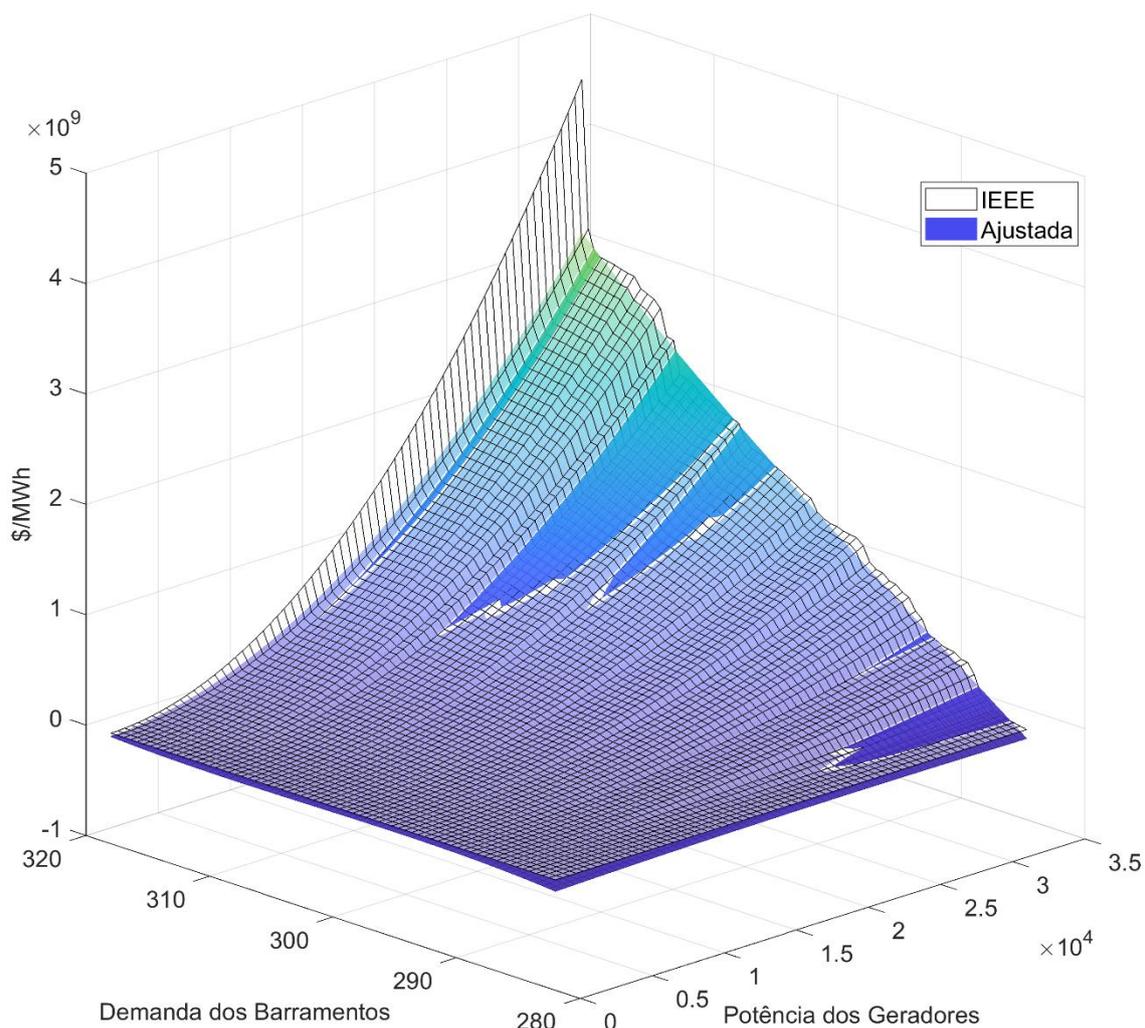
Devido ao grande número de valores para os intervalos de busca, torna-se mais prático apresentar as características da função aptidão por meio de um polinômio de ajuste, gerado com os dados da rede. Essa função trabalha a geração de energia e a demanda energética como variáveis independentes, sendo o valor de custo (\$/MWh) a variável dependente e o valor de aptidão das soluções. A função aptidão da *300-Bus* é apresentada na Equação 5.

*IEEE300\_Custo*

$$= -2.915e^{11} + 1.131e^6 \cdot x + 2.902e^9 \cdot y - 23.23 \cdot x^2 - 7558 \cdot x \cdot y - 9.627e^6 \cdot y^2 + 4.493e^{-7} \cdot x^3 + 0.082 \cdot x^2 \cdot y + 12.63 \cdot x \cdot y^2 + 1.064e^4 \cdot y^3 \quad (5)$$

Em que  $x$  é a potência ativa de saída dos geradores (MW), e  $y$  é a demanda de potência ativa dos barramentos (MW). Graças a esta função de ajuste, foi possível modelar um problema de 369 variáveis independentes para uma equação de 2 variáveis independentes. Essa simplificação permite, inclusive, apresentar o modelo da rede em um gráfico tridimensional, como apresentado na Figura 6.

Figura 6 – Superfície da função IEEE300



Fonte: Autor (2024).

A Figura 6 apresenta a função original, gerada a partir dos dados brutos oriundos do MATPOWER (superfície de malha), e a função ajustada para o polinômio apresentado na Equação 5 (superfície contínua). A partir da função ajustada, tem-se as características finais do modelo em questão, como apresentado na Tabela 3.

TABELA 3 – PROBLEMA REAL

| No. | Funções      | D | Intervalo de Busca            |
|-----|--------------|---|-------------------------------|
| 1   | IEEE 300-Bus | 2 | [(0 282),<br>(32678.435 318)] |

Fonte: Autor (2024).

#### 4. METODOLOGIA

Nesta seção, é apresentada a metodologia do processo de desenvolvimento do algoritmo proposto, descrevendo o seu passo a passo. Esta seção se baseia na estrutura do Algoritmo Genético Clássico, que é ilustrado na Figura 7.

Figura 7 – Estrutura do GA



Fonte: Autor (2024).

A partir desse fluxo de etapas, serão apresentadas as funções propostas neste trabalho, e como estas se encaixam na estrutura original do GA.

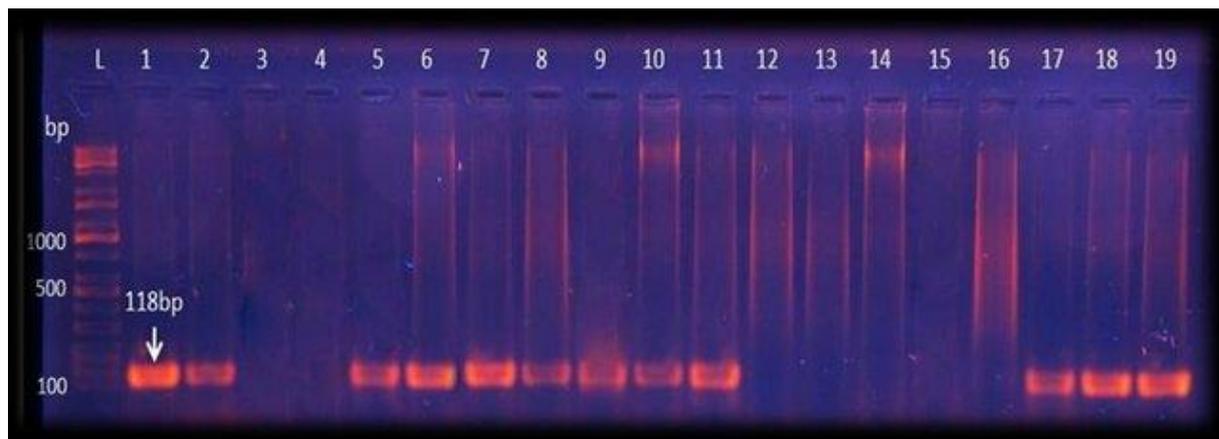
##### 4.1. Inicialização da população

A função responsável por gerar a população inicial demanda 2 entradas, o número de indivíduos ( $I_n$ ) e o número de dimensões para cada indivíduo ( $D$ ). Quando iniciada, essa etapa

gera uma população de soluções aleatórias, cada uma feita de D valores, uniformemente distribuídos entre os limites do Intervalo de Busca.

Este trabalho apresenta uma estratégia de ilustração lúdica para observar o progresso populacional baseada no método de eletroforese em gel de agarose com brometo de etídio (AL-MAYALI.et. al, 2019), para separar e observar padrões genéticos, conforme mostrado na Figura 8.

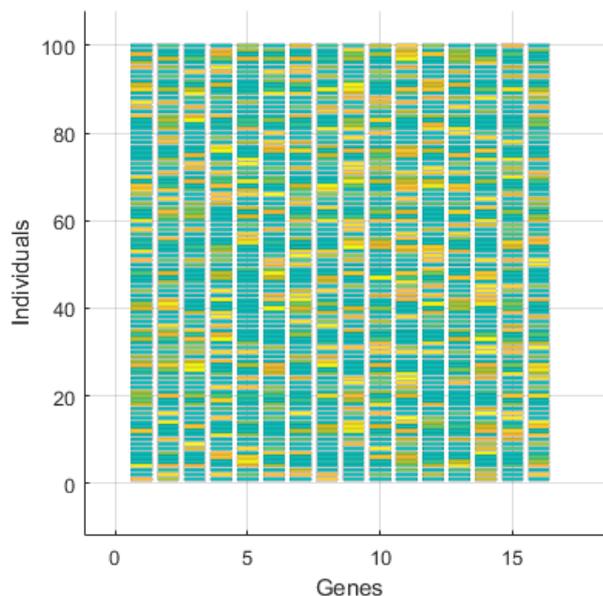
Figura 8 – Eletroforese em Gel de Agarose



Fonte: AL-MAYALI.et. al (2019).

A Figura 8 mostra um gene presente em múltiplas amostras, auxiliando na identificação de determinadas proteínas em diferentes indivíduos. Esta dissertação usa um método semelhante para ilustrar a estrutura de valores da população gerada pelo algoritmo, criando um mecanismo de visualização de dados para a representação do padrão genético da população de soluções gerada, que auxilia na análise de convergência das variáveis de cada problema, como pode ser visto na Figura 9.

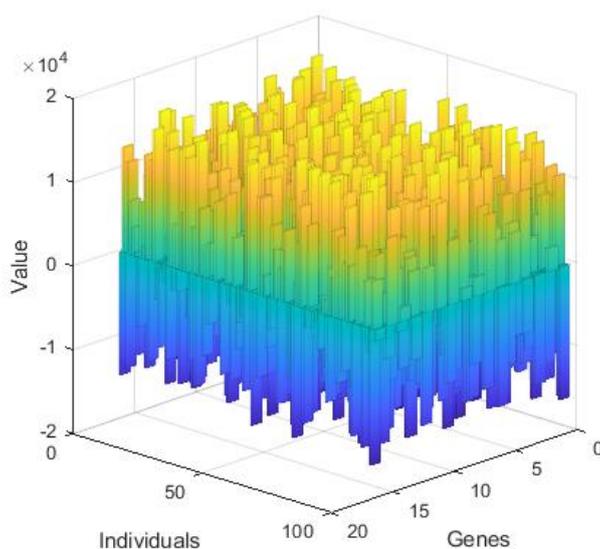
Figura 9 – Visualização de Padrões Genéticos de Populações - Vista Superior



Fonte: Autor (2024).

A Figura 9 mostra como exemplo uma população com 100 indivíduos e 16 genes, em sua primeira geração, ou seja, com os valores de Genes homogeneamente distribuídos por uma intervalo de busca. As cores desta ilustração são relativas aos valores de cada gene, que são melhor representados em uma visão isométrica, como mostra a Figura 10.

Figura 10 – Visualização de Padrões Genéticos de Populações - Visão Isométrica



Fonte: Autor (2024).

A Figura 10 acrescenta o eixo vertical (*Value*), que apresenta o valor numérico de cada Gene em todos os indivíduos nesta população. É importante notar que as Figuras 9 e 10 representam

a mesma população, alternando apenas os ângulos de visão. É importante ressaltar que, por as figuras 9 e 10 ilustrarem de populações iniciais, elas não apresentam padrões de convergência, e sim comportamentos randômicos. A função Inicialização da População gera os dados necessários para a produção do gráfico de padrões genéticos apresentados na seção Resultados.

#### 4.2. Avaliação de Aptidão

Para medir a qualidade de um indivíduo, assim o quão boa é uma solução, mede-se sua resposta a uma função matemática (adaptabilidade), conhecida como Função Aptidão, ou Função de Adaptação. As Funções Aptidão adotadas são os modelos apresentados na Seção 3. O processo de cálculo do valor de aptidão é o primeiro passo de cada geração/iteração nos algoritmos.

A pontuação da qualidade de uma solução baseia-se em seu valor de aptidão, sendo a medida o resultado direto de um indivíduo para a função. No caso das funções CEC-2019, sabe-se que a solução global para cada função adotada é  $f = 1$  (Price, 2018).

#### 4.3. Processo de Escolha da Função de Seleção

Um recente estudo comparativo entre os métodos Roleta Proporcional, *Ranking* Linear e Exponencial e Seleção de Torneios em GA apresenta o método do Torneio como o mais eficiente, por apresentar menor complexidade de tempo ( $O(n)$ ), e sem necessidade de um método de classificação (Bala e Sharma, 2015). Esse método também apresenta comportamento biologicamente mais equilibrado, por reduzir a possibilidade de ser tomado pela tendência de cópia de indivíduos dominantes, o que reduz as chances de convergência prematura. Assim, adotou-se o Torneio como método de seleção para esta pesquisa.

Esse método realiza múltiplos comparativos pareados, selecionando apenas o indivíduo com melhor valor de aptidão física de cada par, o que reduz o tamanho da população em 50% após essa etapa (Shukla, Pandey e Mehrotra, 2015).

#### 4.4. Organização da Estratégia Comparativa

Esta pesquisa testou os métodos de mutação *Permutation* (P), *Scramble* (S) e *Reset* (R), e os métodos *Crossover Single-Point Cut* (SP), *Double-Point Cut* (DP) e *Uniform-Point Cut*

(UP). Cada combinação de estratégia é nomeada a partir da concatenação respectiva das abreviaturas do método de Mutação e de *Crossover*, por exemplo, *Permutation* (P) com Corte de Ponto Uniforme (UP) é reconhecida pela abreviatura PUP, sendo todas as combinações de estratégias mostradas na Tabela 4.

TABELA 4 – ESTRATÉGIAS DE AG

|                               | <i>Permutation</i> (P) | <i>Scramble</i> (S) | <i>Reset</i> (R) |
|-------------------------------|------------------------|---------------------|------------------|
| <i>Single-Point Cut</i> (SP)  | PSP                    | SSP                 | RSP              |
| <i>Double-Point Cut</i> (DP)  | PDP                    | SDP                 | RDP              |
| <i>Uniform-Point Cut</i> (UP) | PUP                    | SUP                 | RUP              |

Fonte: Autor (2024).

#### 4.5. Escolha do método de *Crossover*

Para o desenvolvimento deste algoritmo, adotou-se trabalhar com população constante, para isso, a função *Crossover* deve restaurar o número de indivíduos, fazendo com que cada casal produza 4 filhos. A preferência por manter uma população constante depende de referências biológicas, uma vez que a eficiência de uma espécie está frequentemente relacionada à sua capacidade de regulação da densidade (SHAO et al., 2008; ARAYA-AJOY, 2021). Além disso, existe uma relação linear entre o tamanho da população e a capacidade de aptidão, portanto, se uma população reduz imensamente, ela perde sua proteção contra a permutação ambiental, aumentando as taxas de extinção (REED, 2005).

O método SP envolve a seleção de um único ponto de corte nos cromossomos de ambos os pais, e a intercalação dos segmentos opostos. Enquanto o cruzamento DP envolve a seleção de dois pontos de corte nos cromossomos de ambos os pais e a intercalação dos segmentos entre o par de indivíduos. Por fim, a abordagem de *Crossover* UP envolve a seleção aleatória de pontos de corte ao longo dos cromossomos de ambos os pais, e a permutação dos valores, em suas respectivas posições, entre o par de indivíduos (BALA e SHARMA, 2015).

A eficiência de cada método de ponto de corte depende do problema específico que está sendo resolvido e das características do espaço de busca. A eficácia de cada método também pode variar dependendo dos operadores genéticos específicos utilizados e dos parâmetros escolhidos para o GA, assim, as estratégias comparativas surgem como uma forma de basear a escolha do método *Crossover*.

#### 4.6. Método de Escolha da Função de Mutação

O fator estocástico ruidoso da natureza está embutido nos passos do GA pela introdução da Função de Mutação, este componente afeta uma porcentagem da população, multiplicando os genes de alguns indivíduos por coeficientes aleatórios. Esse processo aumenta a similaridade do algoritmo computacional com sua referência biológica, de modo a abordar as infinitas variáveis que interferem no ambiente ecológico.

Conforme detalhado na subseção 4.5, esta pesquisa comparou o desempenho de 3 diferentes estratégias (P, S e R). O método de mutação *Permutation* envolve a seleção de duas posições no cromossomo, aleatoriamente, e a troca dos elementos nessas posições (PURSHOUSE e FLEMING, 2007). O método de mutação *Scramble* envolve a seleção aleatória de duas posições no cromossomo e o embaralhamento dos elementos entre essas posições (SONI e KUMAR, 2014). Por fim, o método de mutação *Reset* envolve selecionar posições aleatórias do indivíduo, e redefinir o elemento nessa posição para um valor randômico, dentro do espaço de busca (SRIVATSA, TEJA, PRATHYUSHA e JEYAKUMAR, 2019).

Para cada método de mutação, o número de indivíduos afetados é definido pelo valor da variável Taxa de Mutação (M). O valor foi definido como constante para todos os testes de *benchmark*.

#### 4.7. Radiação Adaptativa

Endemismo é o termo usado em biologia para uma espécie ou grupo taxonômico que é restrito a uma determinada região geográfica (STAUDE, NAVARRO e PEREIRA, 2020). Os cientistas acham as espécies endêmicas interessantes pois oferecem informações valiosas sobre a história e a ecologia de uma região. Por exemplo, muitas espécies de plantas e animais no Havaí são endêmicas e não encontradas em nenhum outro lugar do planeta (GILLESPIE, CROOM e PALUMBI, 1994; LOSOS, 2010). Isso sugere que as ilhas estão isoladas há muito tempo, o que permitiu que formas de vida únicas evoluíssem.

Vários fatores podem contribuir para o desenvolvimento de espécies endêmicas, incluindo isolamento geográfico, clima e competição com outras espécies. Espécies endêmicas também podem surgir através da AR, um processo no qual uma única espécie se diversifica em uma variedade de formas, cada uma adaptada a um nicho ecológico específico.

A AR é um processo biológico que acontece quando uma espécie se diversifica em várias espécies descendentes, cada uma adaptada a um nicho específico (RICHARDS et al., 2021). Isso geralmente acontece quando há uma grande mudança ambiental, como o surgimento de um novo habitat ou a extinção de outras espécies. A AR impulsiona a biodiversidade, permitindo que os organismos explorem novas oportunidades e ocupem novos nichos no ecossistema de forma eficiente, graças a um surto de mutação (BERNER e SALZBURGUER, 2015).

Como o AR é um produto do endemismo, o impacto da radiação pode ser medido por métricas semelhantes às unidades endêmicas. Shipley e McGuire (2021) apresentam um estudo de diferentes relações métricas, que indica as mais efetivas para cada cenário, comprovando que para o estudo de Dados Filogênicos de Unidades Discretas, que é o caso da metodologia proposta neste presente estudo, o Endemismo de Diversidade Filogenética (PDE) é a métrica mais efetiva. Essa relação é de imensa contribuição para esta pesquisa, sendo a principal referência para o modelo matemático da função AR apresentado na seção Metodologia.

#### 4.8. Formulação da Função de Radiação Adaptativa

De acordo com a subseção 4.7, a AR diversifica a população ao mesmo tempo em que adapta os indivíduos a novos nichos de configurações ambientais, ação promovida por uma intensa explosão de mutação. Diante dos conceitos introduzidos sobre o fenômeno AR, seu modelo de implementação visou causar à população do algoritmo, sintomas semelhantes aos percebidos em comportamentos naturais.

Para evitar dubiedades quanto ao impacto da função AR, é importante comparar suas diferenças operacionais com a função de mutação clássica. A grande divergência entre eles é sua estratégia de aplicação, devido à sua inspiração biológica, como explicado mais adiante.

Com base no fluxo de trabalho da Função de Mutação, detalhado na seção 4.6, a cada iteração, para cada indivíduo afetado, uma parte de seus genes é substituída de maneira aleatória. Este procedimento de geração de números aleatórios ocorre individualmente, assim, a semente (*seed*) aleatória para cada indivíduo tem tempo para progredir evitando repetição ou alta similaridade. O processo de mutação natural acontece, em maioria, individualmente, com configurações e resultados únicos. Assim, tal característica computacional é fundamental nessa etapa para simular as combinações de elementos biológicos diários que, direta ou indiretamente, interferem nas alterações genéticas de cada indivíduo.

O procedimento de AR, por outro lado, não se repete de maneira individual, este acontece uma vez a cada geração, afetando um número variável de indivíduos ao longo do processo de otimização. A variável responsável por indicar quanto da população será afetada pelo AR é chamada de Taxa Dinâmica (DR), e seu valor é ajustado automaticamente a cada geração pelo algoritmo, como mostrado mais adiante nesta seção.

O AR gera uma matriz DR-por-D de valores aleatórios, cujos limites de amplitude são  $[-1,1]$ , a matriz de valores aleatórios multiplica a matriz dos indivíduos afetados, promovendo mudanças coletivas a partir de uma mesma semente. Os valores de amplitude são definidos para representar estatisticamente a concordância mínima e máxima, respectivamente, o que representa a aceitação (correlação estocástica) de um gene atual nessa mudança ambiental introduzida com o efeito da RA.

Como apresentado na seção 4.7, o PDE é a métrica mais compatível para esta pesquisa, pois mede a proporção de diversidade filogenética restrita a uma região de estudo (SHIPLEY e MCGUIRE, 2021; FAITH, REID e HUNTER, 2004). A medida do PDE é apresentada na Equação 6.

$$PDE = \frac{\sum_{e=1}^E L_e}{\sum_{s=1}^S L_s} \quad (6)$$

Sendo  $E$  a riqueza endêmica,  $S$  a riqueza total de espécies,  $L_s$  o comprimento do ramo (*branch*) filogenético de todas as espécies residentes e  $L_e$  o comprimento dos ramos filogenético das espécies endêmicas.

A DR (Taxa Dinâmica) é um valor responsável por indicar o número de indivíduos acometidos pela AR, seu valor muda de acordo com a necessidade de a população evoluir, comparando a geração atual com a inicial, portanto, seu ancestral. A DR é dada pelo valor de um fator  $\delta$ , modelado matematicamente após o PDE, que consiste na relação percentual entre a variância da população atual e da população inicial, conforme apresentado nas Equações 7 e 8.

$$\delta = \frac{\sum_{i=1}^p \sigma^2(Pp_i)}{\sum_{i=1}^p \sigma^2(Po_i)} \quad (7)$$

$$DR = \begin{cases} \delta, & \text{se } \delta \leq 100\% \\ 100\%, & \text{caso contrário} \end{cases} \quad (8)$$

onde  $Pp$  é a população atual e  $P_0$  a população inicial,  $p$  é o tamanho da população e  $\sigma^2$  é a variância definida pela Equação 9,

$$\sigma^2 = \frac{\sum_{i=1}^p (x_i - \mu)^2}{p} \quad (9)$$

sendo  $x_i$  o  $i$ -ésimo indivíduo da população e  $\mu$  a média da população.

Esta abordagem fornece uma excelente maneira de comparar a dispersão genética de populações enquanto simula fenômenos biológicos. A geração inicial é uniformemente distribuída por todo o espaço de busca, fazendo com que a DR atinja seu valor máximo nos estágios iniciais do algoritmo, uma vez que a população ainda não tem progressão evolutiva de nicho. Isso aumenta os efeitos da mutação na população, mimetizando os efeitos de uma alteração ambiental.

Depois que a AR afeta a população atual, a geração termina e a nova geração começa, iniciando a próxima iteração no loop com a etapa de Avaliação da Aptidão.

O GAAR segue grande parte do fluxo de trabalho regular do AG, com a adição da função RA. As etapas do GAAR são mostradas na Figura 11.

Figura 11 – Estrutura do GAAR



Fonte: Autor (2024).

#### 4.9. Escolha de Parceiros

A escolha de parceiros sexuais, na natureza, apresenta diversas estratégias evolutivas diferentes, entretanto, possuem em comum a busca por características que representem maior adaptação ao ambiente em que os indivíduos se encontram (BUSS E SCHMITT, 2018). Este

comportamento é identificado em diversas espécies, assim como com humanos, como características físicas, psicológicas e sociais.

As preferências por parceiros influenciam drasticamente nas táticas evolutivas de atrações, como priorizar elementos que identifiquem um indivíduo como mais fértil, mais capaz de agregar e proteger recursos, ou mais inteligentes, por exemplo. A preferência por características específicas pode generalizar julgamentos para indivíduos inéditos, por meio de um processo chamado aprendizagem social (LITTLE ET AL, 2011).

Diversos modelos biológicos apresentaram como espécies distintas lidam com a preferência genética. Em um dos casos foi percebido que, para uma dada espécie, quando o valor de referência principal dos indivíduos de uma população está normalmente distribuído ao redor de um valor ótimo, a seleção efetiva depende da preferência característica configurada pela população (NAKAHASHI, 2008). Essa ordenação de subpreferências, para a seleção de parceiros, cria um precedente para ser implementada em ambiente computacional, basta que esse processo seja modelado via processos lógicos.

Uma vez que, esta pesquisa busca propor a implementação de técnicas biológicas para um modelo de autoajuste de algoritmos evolutivos, a escolha de parceiros também é adotada como mecanismo para promover um algoritmo mais flexível. Os detalhes de como esses fenômenos biológicos são colocados nas etapas computacionais são apresentados nas próximas seções deste trabalho.

#### 4.10. Formulação da função de Escolha Multicritérios

A implementação da análise multicritérios é mais simples que a RA, por ser estruturada com base em etapas algébricas de menor complexidade. Este método inicia identificando, a cada geração, o gene que apresenta maior influência na qualidade dos resultados, processo que ocorre por meio do cálculo de variância, como apresentado na Equação 10.

$$VarGene = \frac{\sum_{g=1}^D (x_g - \mu_m)^2}{D} \quad (10)$$

Em que D é a quantidade dimensões do problema,  $x_g$  é o g-ésimo gene de cada indivíduo,  $\mu_m$  é o valor médio desse gene na população. A partir da Equação 10, é identificado ao longo da população, o gene que possui maior índice de mínimo valor de variância, dado que no processo evolutivo, isso significa que este gene teve prioridade de busca no processo de otimização. A função que representa o comportamento citado é a Equação 11.

$$k = \gamma_{i=1}^p \text{VarGene}_i \quad (11)$$

Logo,  $k$  é o gene mais influente para a execução em questão, e  $\gamma$  indica um combinador de ponto fixo de cálculo lambda, que satisfaz a relação  $\gamma f = f(\gamma f)$ , assim, a expressão combinada  $\gamma_{Inf}^{Sup} f$  é um laço de repetição definido, sendo  $Inf$  e  $Sup$  os limites inferior e superior do índice de contagem, respectivamente, e  $f$  é um conjunto de instruções dentro do escopo da estrutura de repetição em questão. O parâmetro  $k$  é inserido no método de seleção do algoritmo que utiliza a escolha multicritério.

Dentro do processo de seleção, em que foi adotado o método de Torneio, os indivíduos continuam sendo comparados aos pares, porém, ao comparar indivíduos com valores de aptidão próximos, ou até iguais, é dada prioridade para o indivíduo que apresenta o melhor valor para o gene reconhecido como mais influente, como apresentado na Equação 12,

$$\gamma_{i=1}^{\frac{p}{2}} PEsc_i = \begin{cases} x_i, & \text{se } x_{i,k} \leq x_{\frac{p}{2}+i,k} \\ x_{\frac{p}{2}+i}, & \text{se } x_{\frac{p}{2}+i,k} < x_{i,k} \end{cases} \quad (12)$$

em que  $PEsc$  é a população dos escolhidos para o cruzamento de cada par,  $x_i$  o  $i$ -ésimo indivíduo da população, e  $k$  é o gene dado como o mais influente. O termo  $x_{\frac{p}{2}+i}$  indica o  $i$ -ésimo indivíduo após o número de metade da população, então, por exemplo, para uma população  $p = 100$ , e um contador de repetição  $i = 3$ , os indivíduos selecionados serão  $Pp_3$  e  $Pp_{\frac{100}{2}+3}$ , portanto,  $Pp_{53}$ . Dessa forma, o mesmo indivíduo não é selecionado mais de uma vez na mesma iteração. O MCGA apresenta uma estrutura mais próxima do fluxo de etapas do GA clássico, sendo o diferencial as sub-processos da etapa de Seleção. A estrutura do MCGA é apresentada na Figura 12.

Figura 12 – Estrutura do MCGA



Fonte: Autor (2024).

#### 4.11. Radiação Adaptativa + Multicritério

Essa pesquisa também incorpora, em sua análise comparativa, uma versão dos algoritmos que implementa as duas principais inovações desse estudo, que são as funções da AR e do método multicritério. A versão em questão é denominada Algoritmo Genético com Radiação Adaptativa e Multicritério (MCGAAR), e sua estrutura é apresentada na Figura 13.

Figura 13 – Estrutura do MCGAAR



Fonte: Autor (2024).

#### 4.12. Comparação de Algoritmos

Uma parte importante desta metodologia de pesquisa é comparar os algoritmos propostos com algumas abordagens rivais, reconhecidas e confiáveis na literatura. Dessa forma, os algoritmos apresentados nesta obra competem, nas funções apresentadas em Estudos de Caso, com o GA Clássico (GA), o Enxame de Partículas Clássico (PSO) e o Enxame de Partículas Adaptativo (APSO).

As versões do GA foram adotadas como referências diretas entre si, adotando parâmetros semelhantes (Tabela 5 e Tabela 6), sendo diferenciadas apenas pelas suas componentes inéditas exclusivas (RA, MC e RA+MC). O PSO também foi selecionado como rival para essa metodologia, apesar de ser um algoritmo bioinspirado populacional, apresentar características essencialmente diferentes, como não evolutivo, cooperativo e consideravelmente mais exploratório (GHOSH et al, 2019). Por fim, o Enxame de Partículas Adaptativo (Adaptive Particle Swarm Optimization – APSO) foi incluído por possuir uma componente equivalente à AR para PSO (NAYEEM, FAN e AKHTER, 2021), para comparativos de comportamentos adaptativos, porém, adotando-se os mesmos valores para os demais parâmetros (Tabela 7).

Tabela 5 – Parâmetros de GA e GAAR

| <b>Parâmetro</b>        | <b>GA</b> | <b>GAAR</b> |
|-------------------------|-----------|-------------|
| Tamanho da População    | 1000      | 1000        |
| Taxa de mutação         | 5%        | 5%          |
| Gerações                | 300       | 300         |
| Método <i>Crossover</i> | DP        | DP          |
| Método de mutação       | Reset     | Reset       |
| Tipo de RA              | Nulo      | Dinâmico    |

Fonte: Autor (2024).

Tabela 6 – Parâmetros de MCGA e MCGAAR

| <b>Parâmetro</b>        | <b>MCGA</b> | <b>MCGAAR</b> |
|-------------------------|-------------|---------------|
| Tamanho da População    | 1000        | 1000          |
| Taxa de mutação         | 5%          | 5%            |
| Gerações                | 300         | 300           |
| Método <i>Crossover</i> | DP          | DP            |
| Método de mutação       | Reset       | Reset         |
| Tipo de RA              | Nulo        | Dinâmico      |
| Seleção Multicritério   | Ativada     | Ativada       |

Fonte: Autor (2024).

Tabela 7 – Parâmetros de PSO e APSO

| <b>Parâmetro</b>      | <b>PSO</b> | <b>APSO</b> |
|-----------------------|------------|-------------|
| Tamanho do enxame     | 1000       | 1000        |
| Peso de Inércia       | 1          | [0.1,1]     |
| Peso de Auto Ajuste   | 1.60       | 1.60        |
| Peso do Ajuste Social | 1.20       | 1.20        |
| Iterações             | 300        | 300         |

Fonte: Autor (2024).

Para analisar a diferença de desempenho desses algoritmos, foram utilizadas diferentes métricas, como o valor das melhores soluções encontradas, média e variância dos valores de aptidão, e o Teste de Friedman.

O teste de Friedman permite a comparação de múltiplos algoritmos de otimização em várias funções, o que é ideal para o cenário das funções CEC 2019, caracterizadas por uma série de elementos desafiadores, como multimodalidade, presença de mínimos locais e globais e complexidade de topologia. Cada um desses aspectos apresenta um conjunto único de desafios para os algoritmos de otimização, e poder avaliar o desempenho de um algoritmo em todas essas funções simultaneamente é uma grande vantagem.

Além disso, o teste de Friedman é um teste não-paramétrico, o que significa que ele não faz suposições sobre a distribuição dos dados. Isso é particularmente útil no contexto das funções CEC2019, pois os desempenhos dos algoritmos sobre essas funções podem não seguir uma distribuição normal. Com o teste de Friedman, ainda é possível determinar se as diferenças no desempenho dos algoritmos são estatisticamente significativas, mesmo quando os dados não seguem uma distribuição normal.

Este teste utiliza o valor-p em sua análise, que é definido como probabilidade de ocorrência da hipótese nula. O valor-p indica a probabilidade de a diferença dos resultados observados entre os grupos, ser um acaso. Para valores próximos de 1, é interpretado que não há diferença entre os grupos, exceto pelas alterações do acaso, enquanto valores próximos de 0 indicam o contrário. Para este estudo, adotou-se o valor máximo de 5% (0.05) como referência para rejeitar a hipótese nula (hipótese de que não há interferência dos algoritmos na qualidade dos resultados), portanto, se o valor-p for maior que 0.05, os resultados serão considerados insatisfatórios.

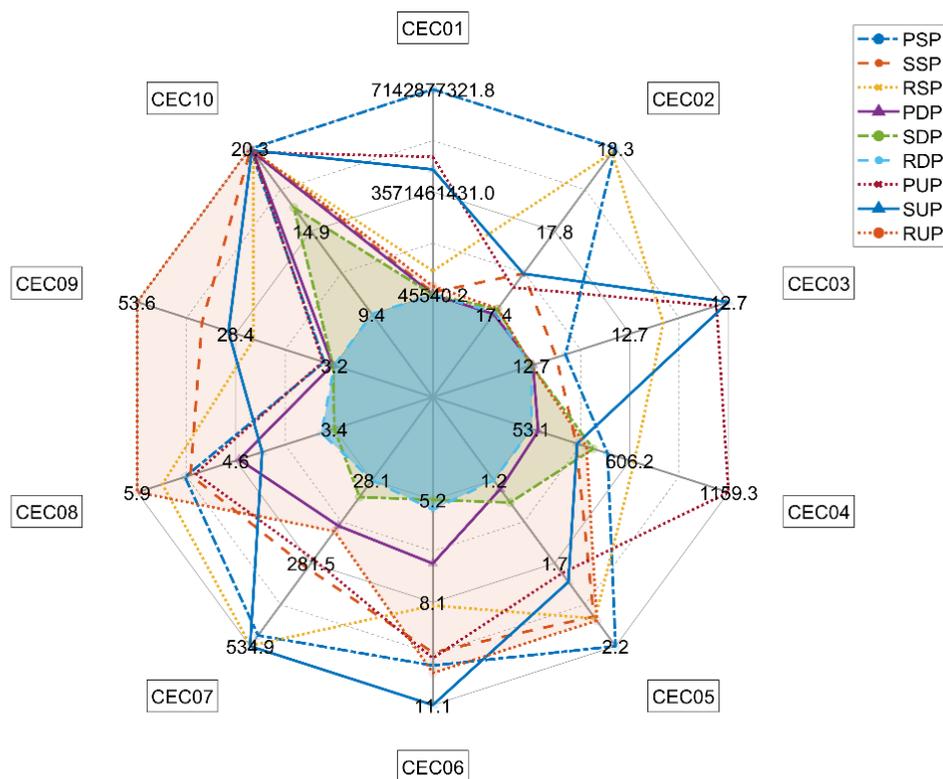
O teste de Friedman é especialmente útil quando se lida com amostras pequenas. Em muitos casos, os algoritmos de otimização podem ser avaliados em um número limitado de funções ou cenários, o que pode resultar em um conjunto de dados relativamente pequeno. O teste de Friedman é capaz de lidar com esses cenários e ainda fornecer resultados confiáveis.

Após a configuração do ambiente de referência, esta pesquisa realizou múltiplos testes nas funções de aptidão, e percebeu-se que 20 testes eram um valor ótimo para a obtenção de dados confiáveis, uma vez que era suficiente para abranger toda a magnitude dos diferentes desempenhos dos algoritmos, causados por motivadores estocásticos. Os resultados e observações desses testes são detalhados na próxima seção.

## 5. RESULTADOS

O primeiro resultado da pesquisa proposta é um produto da etapa Estratégia Comparativa. Esse resultado foi útil para selecionar a melhor alternativa, dentre as 9 estratégias disponíveis. Os resultados de uma execução singular das funções são apresentados na Figura 14, no formato de um *Spider Plot* (MOSES, 2023).

Figura 14 – Resultados das Estratégias nas Funções CEC2019



Fonte: Autor (2024).

Os valores mais próximos do centro são os melhores resultados (valores mínimos) para cada função de aptidão, e quanto mais distantes são os piores resultados, portanto, a melhor estratégia é apresentar a maioria de seus resultados mais próximos de 1. Seguindo esse método de análise, o RDP foi a estratégia que mais vezes alcançou as melhores soluções. Esse comportamento é uma ilustração geral de todo o grupo de teste, por representar a maioria do padrão de resultados.

Para o método *Crossover*, os resultados totais apresentam o DP alcançando os melhores resultados em 92% dos testes, sendo, assim, eleito como a melhor estratégia para esta pesquisa. Os dados de *benchmark* também informam que o *Reset* foi o melhor método de mutação,

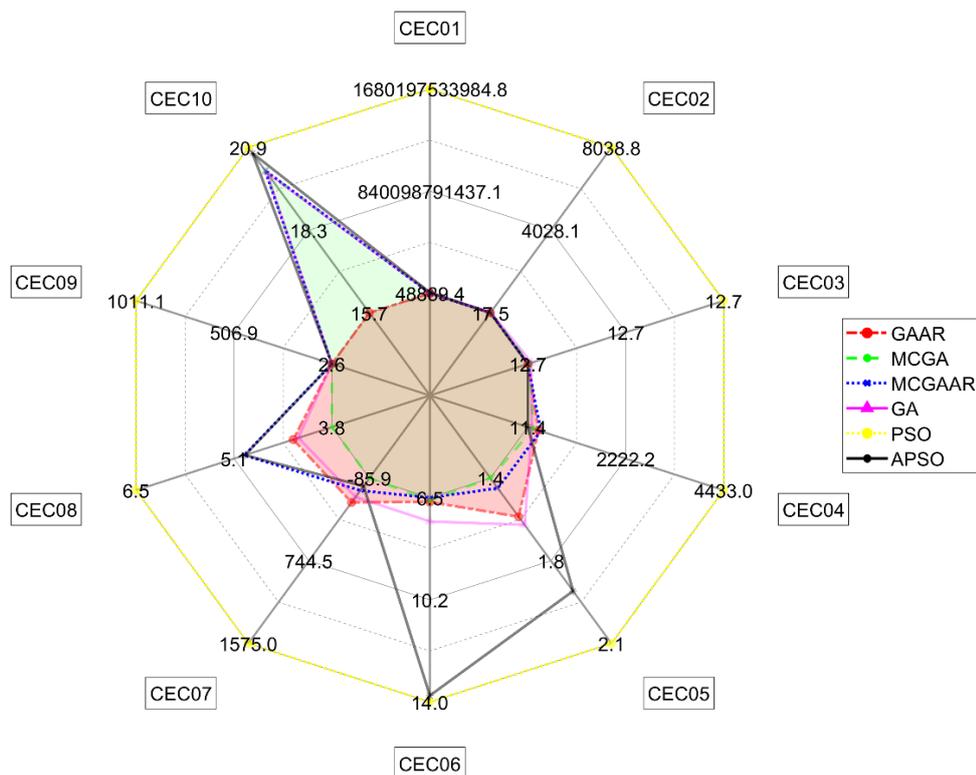
alcançando os melhores resultados em 44% dos testes, enquanto os métodos *Scramble* e *Permutation* aparecem com 29% e 27% de eficiência, respectivamente.

A quantidade de execuções para compor os resultados, 20 execuções por função teste, foi necessária para evitar divergências temporárias ou medidas baseadas em um episódio singular de alto erro, causado principalmente por uma semente ruim.

### 5.1. Funções CEC2019:

A Figura 15 apresenta os resultados dos comparativos entre os algoritmos adotados, com uma abordagem de *spider plot* (MOSES, 2023), assim, os menores valores estão mais próximos do centro, enquanto os maiores valores estão na periferia da malha.

Figura 15 – Resultados dos Algoritmos nas Funções CEC2019



Fonte: Autor (2024).

Essa figura apresenta os resultados de uma das execuções dos testes de performance. Para auxiliar a análise dos algoritmos, a Tabela 8 apresenta, como exemplo, as melhores soluções

encontradas pelos algoritmos ao longo de cada função, marcadas em negrito, em uma das execuções performadas.

Tabela 8 – Melhores Soluções dos Algoritmos nas Funções CEC2019

| Função | GAAR              | MCGA            | MCGAAR            | GA       | PSO      | APSO     |
|--------|-------------------|-----------------|-------------------|----------|----------|----------|
| cec01  | <b>45420.8140</b> | 26383.00        | 51982.2228        | 38143.   | 49931.01 | 15159.45 |
|        | <b>7</b>          | 426E+5          | 1                 | 24900E+5 | 852E+6   | 958E+6   |
| cec02  | <b>17.36476</b>   | 25.24752        | 17.45404          | 214.68   | 23195.36 | 17.58812 |
|        |                   |                 |                   | 957      | 894      |          |
| cec03  | 12.7024052        | 12.70241        | <b>12.7024051</b> | 12.702   | 12.70758 | 12.70640 |
|        | 1                 | 043             | <b>2</b>          | 42518    | 085      | 148      |
| cec04  | 180.911455        | <b>114.9832</b> | 180.767421        | 132.28   | 19197.37 | 4981.225 |
|        | 4                 | <b>064</b>      | 3                 | 82179    | 036      | 32       |
| cec05  | 1.53748444        | <b>1.420370</b> | 1.48721061        | 1.4701   | 4.723908 | 3.636699 |
|        | 4                 | <b>331</b>      | 4                 | 78736    | 174      | 538      |
| cec06  | 8.66720668        | <b>5.441532</b> | 6.54971940        | 6.5074   | 16.46405 | 17.55740 |
|        | 3                 | <b>699</b>      | 2                 | 55619    | 063      | 088      |
| cec07  | 275.514039        | 405.1343        | <b>230.518708</b> | 233.67   | 1678.334 | 2309.965 |
|        | 9                 | 661             | <b>2</b>          | 37251    | 266      | 267      |
| cec08  | 4.63881522        | 5.485728        | <b>4.60877730</b> | 5.1675   | 7.759035 | 8.377266 |
|        | 9                 | 78              | <b>7</b>          | 21837    | 57       | 21       |
| cec09  | 3.43942373        | 3.188114        | <b>2.74583622</b> | 4.6499   | 3623.205 | 2150.923 |
|        | 3                 | 432             | <b>1</b>          | 08097    | 691      | 318      |
| cec10  | 10.4802714        | 20.23172        | <b>6.59837258</b> | 20.048   | 21.09367 | 21.22927 |
|        | 6                 | 72              |                   | 95503    | 356      | 311      |

Fonte: Autor (2024).

Os resultados dos testes mostraram que o MCGAAR se apresenta, nas funções CEC2019, como o algoritmo mais eficiente, seguido pelo GAAR e o MCGA, respectivamente. Todos os dados coletados pelos *benchmarks*, mostram o MCGAAR fornecendo a melhor solução em aproximadamente 48% dos testes, o GAAR em aproximadamente 29% e o MCGA em 21%. Em 2% dos testes o GA e o APSO encontraram as melhores soluções. É importante destacar que os algoritmos evolutivos nunca apresentaram o pior desempenho, enquanto o PSO

apresentou 88% das piores soluções, e o APSO 12%. A Tabela 9 apresenta a média das soluções encontradas pelos algoritmos nas funções CEC2019

Tabela 9 – Médias da Soluções dos Algoritmos nas Funções CEC2019

| <b>Função</b> | <b>GAA</b>    | <b>MCG</b>    | <b>MCG</b>    | <b>GA</b> | <b>PSO</b> | <b>APSO</b> |
|---------------|---------------|---------------|---------------|-----------|------------|-------------|
|               | <b>R</b>      | <b>A</b>      | <b>AAR</b>    |           |            |             |
| cec01         | <b>63659</b>  | 12750         | 85271         | 98657     | 10014E     | 38871E      |
|               |               | E+6           |               | E+5       | +9         | +7          |
| cec02         | <b>17.436</b> | 118.70        | 17.466        | 101.14    | 10323.3    | 31.8178     |
|               | <b>06</b>     | 797           | 34            | 446       | 1615       | 9           |
| cec03         | <b>12.702</b> | 12.702        | 12.702        | 12.702    | 12.7054    | 12.7047     |
|               | <b>40</b>     | 41            | 40            | 41        | 1          | 8           |
| cec04         | 244.81        | <b>135.97</b> | 247.13        | 158.94    | 16928.9    | 13416.6     |
|               | 560           | <b>902</b>    | 797           | 004       | 5016       | 6678        |
| cec05         | 1.4412        | <b>1.3581</b> | 1.4279        | 1.4211    | 4.28079    | 3.46399     |
|               | 3             | <b>5</b>      | 1             | 3         |            |             |
| cec06         | 7.2237        | <b>6.6115</b> | 7.0279        | 6.9528    | 15.5561    | 14.1700     |
|               | 8             | <b>9</b>      | 2             | 5         | 9          | 59          |
| cec07         | 161.76        | 185.65        | <b>92.490</b> | 137.13    | 1836.53    | 1604.99     |
|               | 944           | 769           | <b>19</b>     | 686       | 719        | 457         |
| cec08         | 4.6436        | 4.8755        | <b>4.2339</b> | 4.6844    | 8.05159    | 7.70836     |
|               | 5             | 6             | <b>2</b>      | 9         |            |             |
| cec09         | 3.3389        | 3.3130        | <b>3.2719</b> | 4.9666    | 3670.25    | 2420.30     |
|               | 0             | 0             | <b>9</b>      | 4         | 604        | 739         |
| cec10         | 13.329        | 20.130        | <b>12.415</b> | 18.777    | 21.1472    | 21.0673     |
|               | 01            | 91            | <b>09</b>     | 80        | 5          | 4           |

Fonte: Autor (2024).

Os resultados apresentados na Tabela 9 reafirmam a distribuição observada na Tabela 8, porém de maneira mais generalizada, por demonstrar um comportamento médio dos algoritmos. Além dos melhores e médios valores encontrados, também foi calculada a variância das soluções obtidas ao final da otimização, portanto, a variância da população final (última geração). Essas informações são apresentadas na Tabela 10.

Tabela 10 – Médias das Variâncias dos Algoritmos nas Funções CEC2019

| Função | GAAR           | MCGA           | MCGA<br>AR     | GA            | PSO            | APSO           |
|--------|----------------|----------------|----------------|---------------|----------------|----------------|
| cec0   | 5.64877        | 1.10581        | <b>3.81148</b> | 5.77099       | 6.67125        | 1.00867        |
| 1      | E+26           | E+27           | <b>E+26</b>    | E+26          | E+28           | E+27           |
| cec0   | <b>990.712</b> | 66195E         | 51433.2        | 98168.2       | 19712          | 96946          |
| 2      | <b>71</b>      | +1             | 9              | E+1           | E+4            | E+2            |
| cec0   | 6.39015        | 8.83773        | 4.79352        | 1.03016       | <b>8.44493</b> | 1.73068        |
| 3      | E-06           | E-07           | E-06           | E-06          | <b>E-08</b>    | E-05           |
| cec0   | 28076E         | 18721E         | 24898E         | 14292E        | <b>64573E</b>  | 16852E         |
| 4      | +4             | +4             | +4             | +4            | <b>+3</b>      | +4             |
| cec0   | 2.22291        | <b>1.47130</b> | 2.77036        | 1.86053       | 7.08566        | 2.69315        |
| 5      |                |                |                |               |                |                |
| cec0   | 4.78478        | 3.96283        | 3.68228        | 3.97337       | 4.40297        | <b>3.63573</b> |
| 6      |                |                |                |               |                |                |
| cec0   | 37604E         | 24635E         | 31989E         | <b>18431E</b> | 49781E         | 12136E         |
| 7      | +1             | +1             | +1             | <b>+1</b>     | +1             | +2             |
| cec0   | 1.06483        | <b>0.72615</b> | 1.18983        | 0.89161       | 2.22931        | 1.53263        |
| 8      |                |                |                |               |                |                |
| cec0   | 21141E         | <b>96998.6</b> | 47130.3        | 24239.9       | 51802.6        | 41276.8        |
| 9      | +1             | <b>8</b>       | E+1            | E+1           | 5E+2           | 1E+2           |
| cec1   | 5.85608        | 0.04633        | 0.08352        | 0.03731       | <b>0.03066</b> | 0.05076        |
| 0      |                |                |                |               |                |                |

Fonte: Autor (2024).

A Tabela 10 apresenta, de maneira numérica, um comportamento diferente quanto à distribuição dos melhores valores, sob essa análise estatística de dispersão. Para a análise de variância, nesse estudo, é definido que o menor valor corresponde ao melhor resultado, pois indica menor dispersão da qualidade das soluções, logo, a maior incidência de indivíduos na região de prosperidade. O PSO e o MCGA, ambos, apresentam os melhores valores de variância em 30% das funções, porém o PSO apresenta 50% dos piores resultados de variância, indicando baixa adaptabilidade do algoritmo, em questão de consistência populacional, para problemas de características diversas, enquanto o MCGA não apresentou episódios de pior

variância. Entre os demais algoritmos (GAAR, MCGAAR, GA e APSO), cada um apresentou o melhor a melhor variância em apenas 10% dos problemas, ou seja, em uma das funções do CEC2019.

Para auxiliar na análise dos resultados dos algoritmos, nas funções CEC2019, foi utilizado o teste não-paramétrico de Friedman. Os resultados do teste de Friedman para as funções CEC2019 são apresentados na Tabela 11.

Tabela 11 – Resultados de Friedman nas Funções CEC2019

|                  | <b>GAAR</b> | <b>MCGA</b> | <b>MCGAAR</b> | <b>GA</b> | <b>PSO</b> | <b>APSO</b> |
|------------------|-------------|-------------|---------------|-----------|------------|-------------|
| <b>Resultado</b> | 2.6         | 2.7         | <b>1.8</b>    | 3.1       | 5.6        | 5.2         |
| <b>Rank</b>      | 2           | 3           | <b>1</b>      | 4         | 6          | 5           |

Fonte: Autor (2024).

Na Tabela 11 é possível identificar que o MCGAAR apresentou o melhor valor de resultado, seguido pelo GAAR, MCGA, GA, APSO e PSO. Além disso, para o teste de Friedman nas funções CEC2019, o valor-p obtido foi  $p = 2.7141e^{-6}$ , o que restringe a hipótese nula para a comparação dos algoritmos.

Em relação aos valores de aptidão das soluções, o GAAR apresentou melhor desempenho, principalmente, nas funções CEC 01 e 02, o MCGA nas funções CEC 04, 05 e 06, o MCGAAR foi o melhor algoritmo nas funções CEC 03, 07, 08, 09 e 10. A consistência desse padrão identificado nos resultados, foi refletido no ranqueamento do teste de Friedman, que somado aos resultados de valores absolutos dos testes, confirmam que o MCGAAR é o melhor algoritmo para esse grupo de funções.

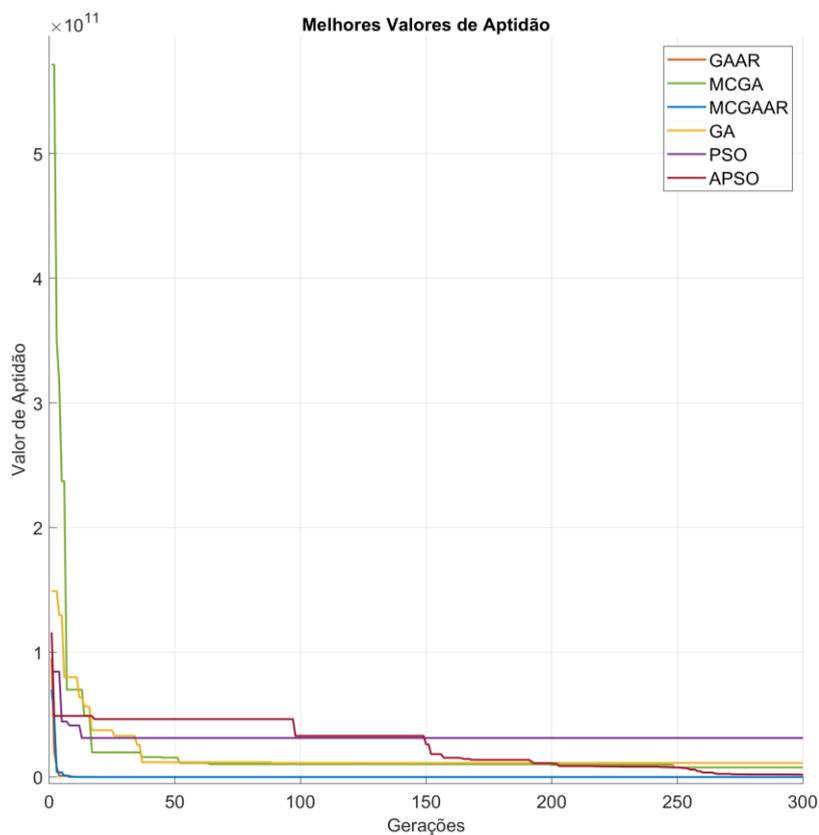
A causa desses comportamentos é compreendida pela análise topológica a seguir.

#### 5.1.1. CEC 01:

A função mais complexa de seu grupo, possui o mais alto nível de condicionalidade, modelado após três sistemas de equações independentes baseados em pulsos de sinal cobrindo nove dimensões. Cada sistema apresenta intervalos e comportamentos diferentes, alterando drasticamente o espaço de solução da função ao percorrer um caminho contínuo e unidirecional sobre sua superfície. Requer maior ajuste de precisão à medida que a população se aproxima

da solução global. O PSO apresentou o pior desempenho entre os algoritmos, possuindo caráter exploratório por natureza, porém sem uma componente adaptativa, enquanto o GAAR obteve o melhor desempenho devido à sua natureza auto-adaptativa (RA), o que permitiu contornar as direções de otimização até obter o melhor espaço de soluções, ainda que seguindo uma convergência acelerada. As curvas de convergência dos algoritmos, ao longo do processo de otimização, são apresentadas na Figura 16.

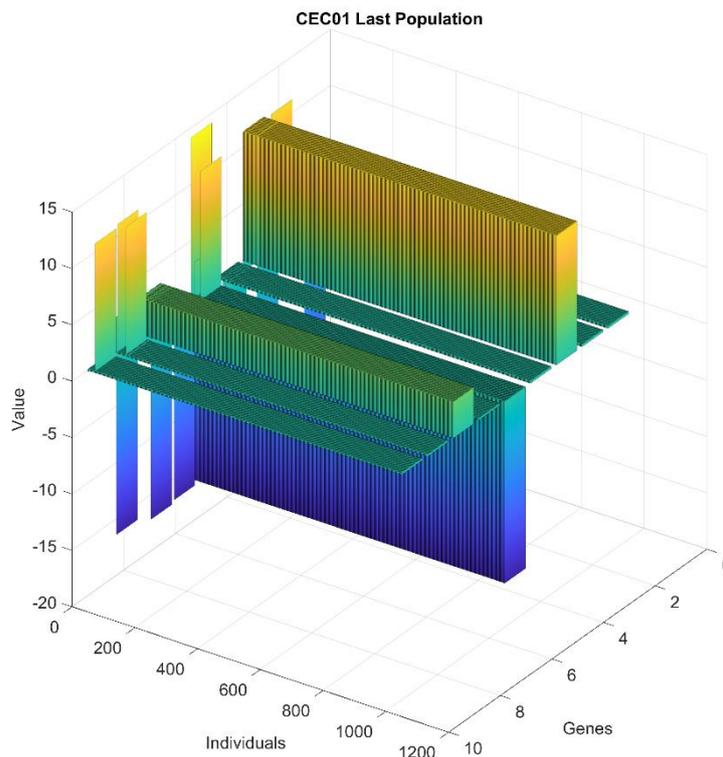
Figura 16 – Melhores Valores de Aptidão em CEC01



Fonte: Autor (2024).

Uma consequência da condicionalidade da função CEC01 é observada na forma da população na última geração, como mostra a Figura 17.

Figura 17 – Última População do GAAR em CEC01



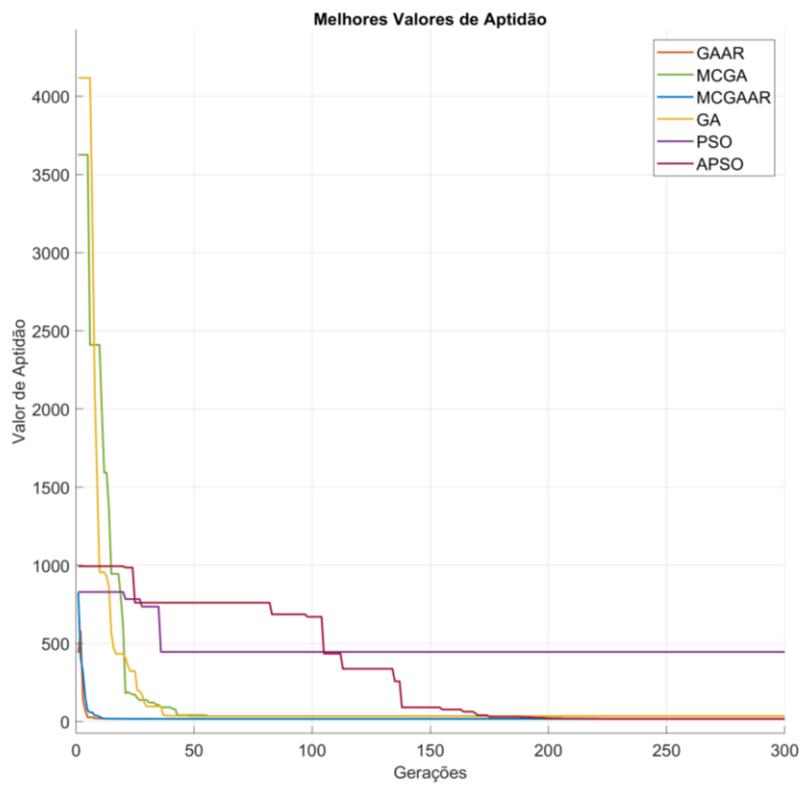
Fonte: Autor (2024).

A Figura 17 demonstra visualmente um padrão perceptível na adaptação genética da população, à medida que atinge valores ótimos. É evidente que, mesmo sem ponderação intencional das preferências genéticas, o algoritmo se concentra em minimizar certos genes com um esquema de prioridade. No entanto, os valores de amplitude dos genes apresentados permanecem distantes dos limites do espaço de busca.

### 5.1.2. CEC 02:

O GAAR produziu os melhores resultados otimizando a Matriz Inversa de Hilbert. Isso ocorre porque a relação algébrica entre três componentes principais (duas funções e uma matriz) cria uma natureza padronizada que beneficia os algoritmos que dão prioridade pelo comportamento exploratório, por isso os três melhores algoritmos nessa função foram o GAAR, o MCGAAR e o APSO, respectivamente. A Figura 18 apresenta as curvas de convergência dos algoritmos otimização da função CEC02.

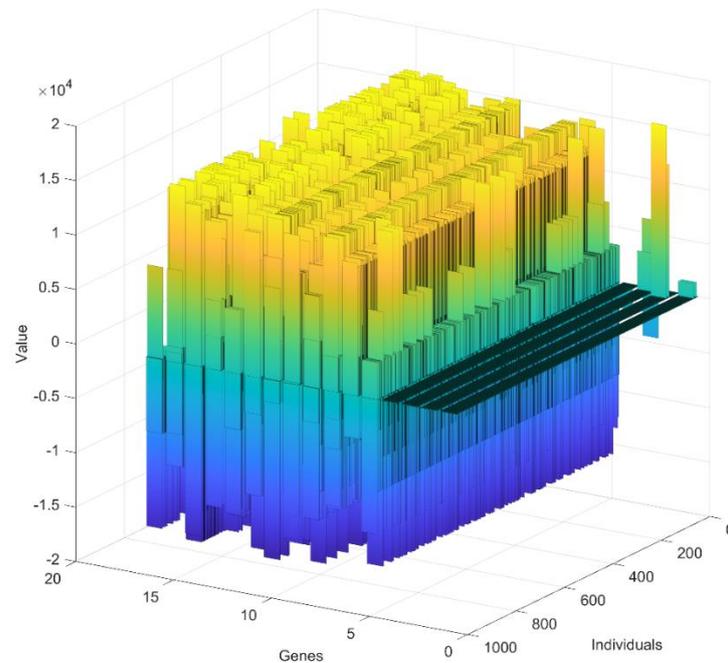
Figura 18 – Melhores Valores de Aptidão em CEC02



Fonte: Autor (2024).

A consequência da vantagem dos algoritmos exploratórios é visível na Figura 19.

Figura 19 – Última População do GAAR em CEC02



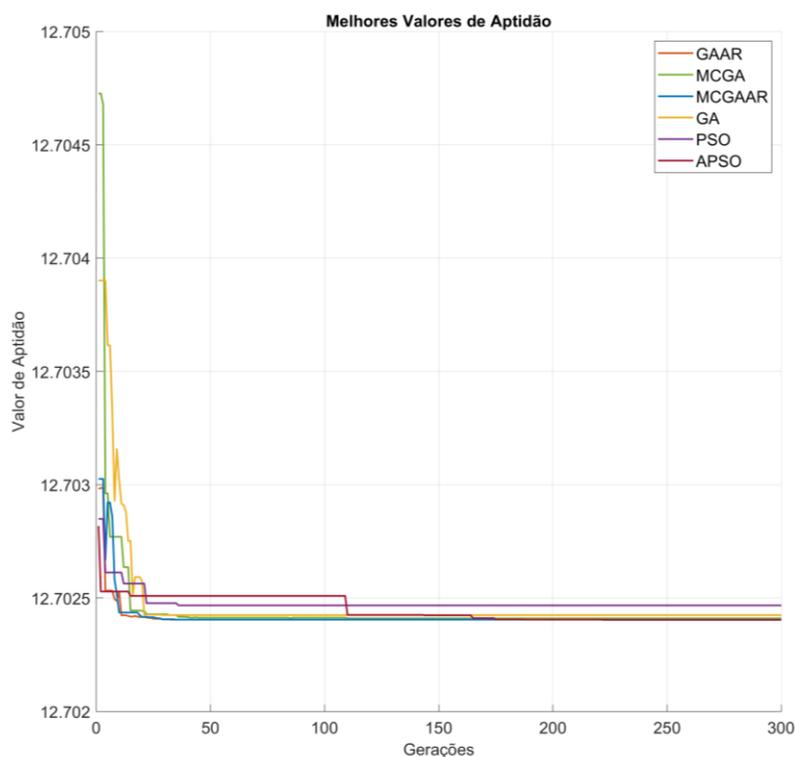
Fonte: Autor (2024).

Ao analisar a Figura 19, e principalmente, ao comparar com a Figura 17, é possível perceber uma diferença de dinâmicas. A última geração produzida pela otimização da CEC02 apresenta maior grau de diversidade, identificada pela amplitude final dos valores de genes, que demonstra 75% dos genes com baixa convergência, enquanto a última geração na função CEC01 obteve aproximadamente 33,33% dos genes com alta amplitude, e consequente, baixa diversidade.

### 5.1.3. CEC 03:

A função que está sendo otimizada é relativamente menos complexa que as funções anteriores, pois os valores de energia das interações atômicas mudam com base na distância entre as partículas. Este problema envolve 6 átomos, mas 4 deles têm soluções triviais, o que significa que os valores ótimos dos parâmetros não são únicos. Neste problema, a orientação de pesquisa não afeta a eficiência da otimização. A complexidade da função surge da sobreposição acidental de átomos, o que causa um valor energético infinito. Porém, esse valor não é calculado devido às limitações matemáticas, levando a uma redução no valor total da solução de forma imprecisa. A Figura 20 apresenta as curvas de convergência dos algoritmos.

Figura 19 – Melhores Aptidão em CEC03



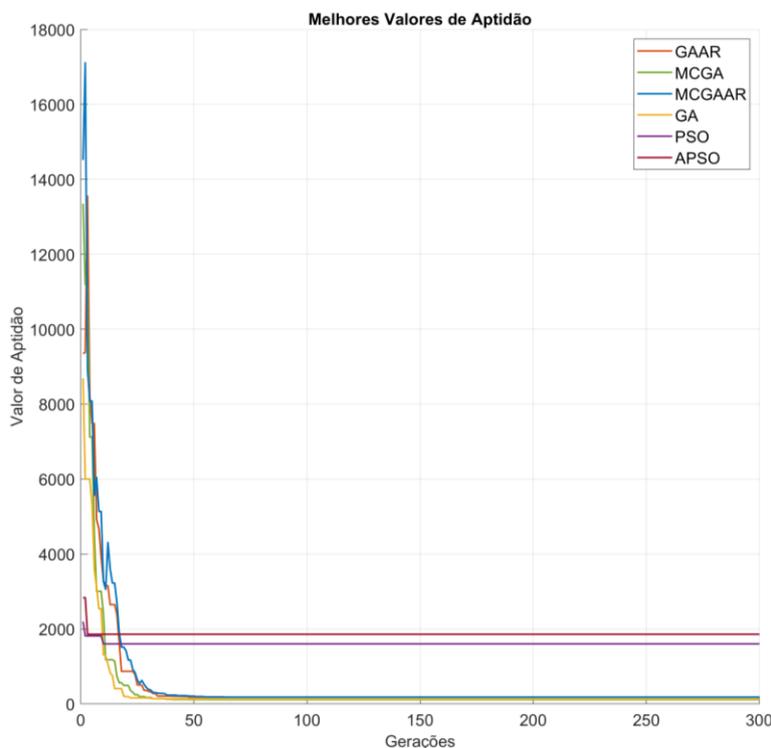
Fonte: Autor (2024).

A topologia desta função proporcionou um atraso nos algoritmos MCGA e MCGAAR, ambos com componentes de seleção multicritério. Por sua baixa complexidade, os demais algoritmos encontraram facilmente uma região de prosperidade, entretanto, os algoritmos multicritério adotaram um comportamento mais oscilatório, até o momento em que incorporam a escolha de seleção preferencial de gene (após a geração 100). Por fim, o GAAR teve maior índices de sucesso na minimização desta função, gerando a melhor solução em aproximadamente 60% dos testes.

#### 5.1.4. CEC 04:

A função Rastrigin é composta de uma topologia que apresenta grande distância entre o penúltimo e o ótimo global, proporcionando maior eficiência de algoritmos mais exploratórios, por evitarem a convergência em um ótimo local. A função geradora é simples, mas a topologia inclui a soma de funções cosseno D (onde D é o número de dimensões), resultando em uma função densa com regiões pseudo-prósperas. As curvas de convergência dos algoritmos na otimização dessa função são apresentadas na Figura 21.

Figura 21 – Melhores Valores de Aptidão em CEC04



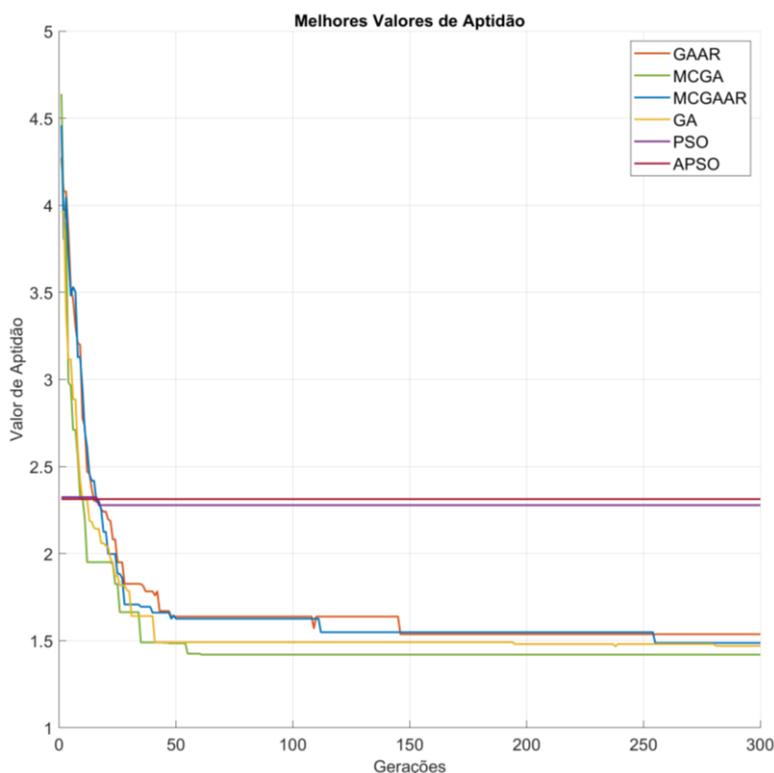
Fonte: Autor (2024).

Apesar da topologia descrita, devido ao seu caráter, os algoritmos de enxame apresentaram uma convergência extremamente rápida, entretanto, certa dificuldade de intensificação. Os algoritmos evolutivos, seguiram uma dinâmica de convergência mais tardia, porém apresentaram os melhores resultados ao longo das execuções. O MCGAAR foi o algoritmo que apresentou a melhor solução em 50% dos testes, seguido pelo GAAR com aproximadamente 30% dos melhores desempenhos, os restantes 20% foram garantidos pelo GA, enquanto que os algoritmos de enxame apresentaram os piores resultados em todos os testes, o PSO com 60% e o APSO com 40% destes.

#### 5.1.5. CEC 05:

Esta função apresenta, principalmente, superfícies suaves, mas são mais planas perto do ponto ideal. Por apresentar um caminho de soluções que progride de maneira mais homogênea em direção ao ótimo global, o caráter exploratório não possui vantagens nessa topologia. A Figura 22 apresenta as curvas de convergência dos algoritmos na otimização desta função.

Figura 22 – Melhores Valores de Aptidão em CEC05



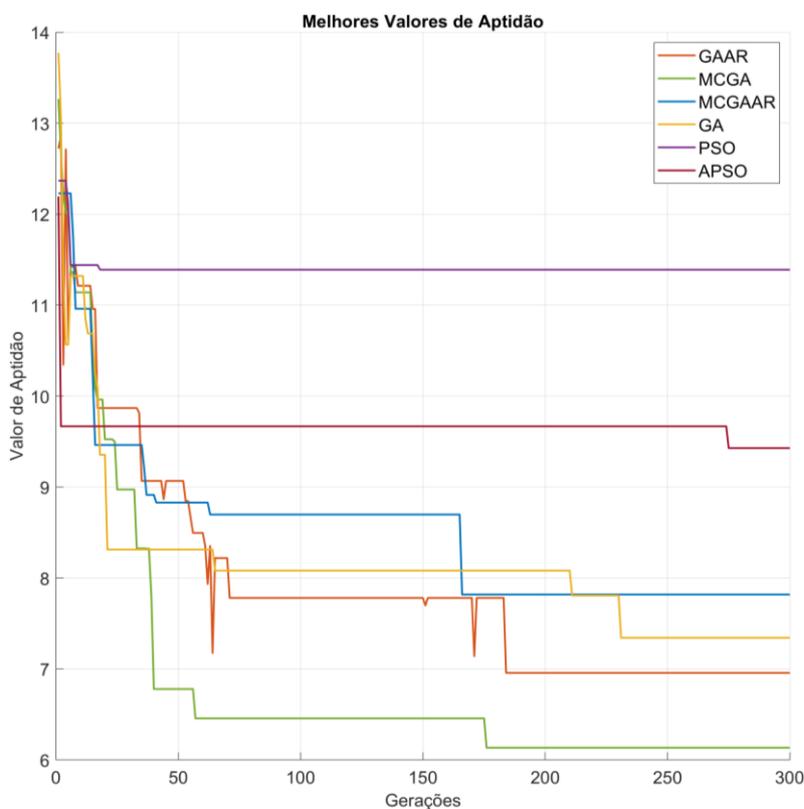
Fonte: Autor (2024).

Por consequência da topologia citada, a função CEC 05 foi melhor otimizada pelas versões dos algoritmos genéticos adotados nessa pesquisa. O MCGAAR, com melhor desempenho nessa função, apresentou as melhores soluções em 40% dos testes, sendo os 60% restantes igualmente distribuídos entre o MCGA e o GA. Apesar de ser evolutivo, o GAAR não conseguiu ser o melhor rival para esta função, pois a amplitude numérica na última região de prosperidade desta função é pequena, dessa forma, o valor da Taxa Dinâmica possui um baixo decaimento, o que dificulta sua convergência prezando precisão numérica.

#### 5.1.6. CEC 06:

Observa-se alta oscilação em determinadas faixas de amplitude, levando a muitos ótimos locais dentro do intervalo de busca. O MCGA consistentemente teve o melhor desempenho nesta função, com aproximadamente 70% dos melhores resultados.

Figura 23 – Melhores Valores de Aptidão em CEC06



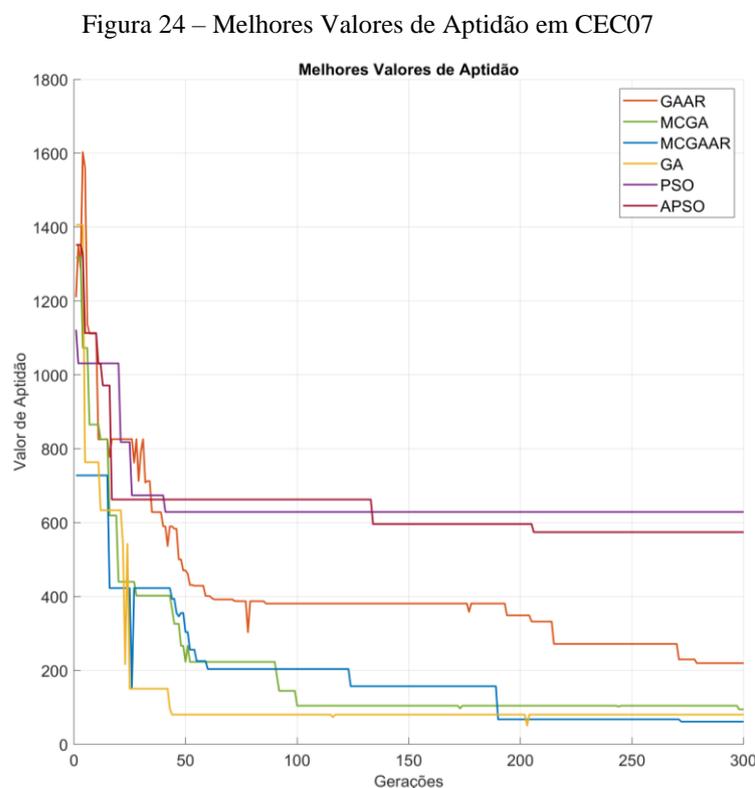
Fonte: Autor (2024).

Nesta função, o MCGA alcança ambos, rápida convergência e melhor precisão numérica. É possível identificar um padrão ao analisar os desempenhos dos algoritmos nas funções, e um

dos mais presentes é o alto desempenho do MCGA para problemas multimodais, de variáveis não separáveis com alto número de ótimos locais, ou seja, com superfície topológica oscilatória.

#### 5.1.7. CEC 07:

Esta função é caracterizada por um amplo espaço de busca e a presença de vários mínimos locais. Assim como a função CEC 06, a CEC 07 também é apresenta variáveis não separáveis, dinâmica multimodal e alto número de ótimos locais. As curvas de convergência dos algoritmos na otimização desta função são apresentadas na Figura 24.



Fonte: Autor (2024).

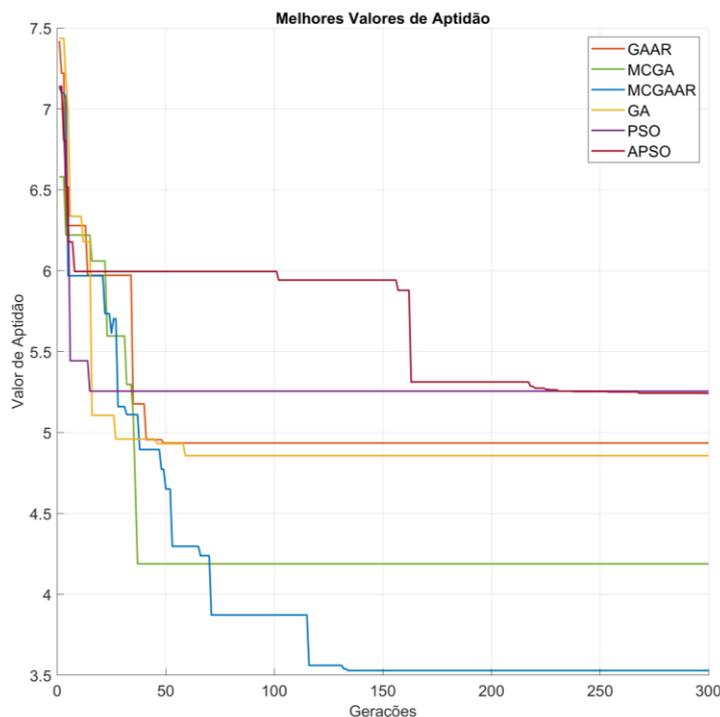
Na Figura 24, é possível perceber que o MCGA alcançou a melhor solução, ultrapassando o desempenho dos algoritmos rivais em 70% dos testes. Assim como na otimização da função CEC 06, o MCGA também apresentou rápida convergência e alta precisão.

#### 5.1.8. CEC 08:

A função expandida F6 de Schaffer é conhecida por sua complexidade estrutural e topologia desafiadora. A versão dessa função para esse teste apresenta rotação e deslocamento de eixos,

o que dificulta o direcionamento dos algoritmos. As curvas de convergência dos algoritmos na otimização desta função são apresentadas na Figura 25.

Figura 25 – Melhores Valores de Aptidão em CEC08



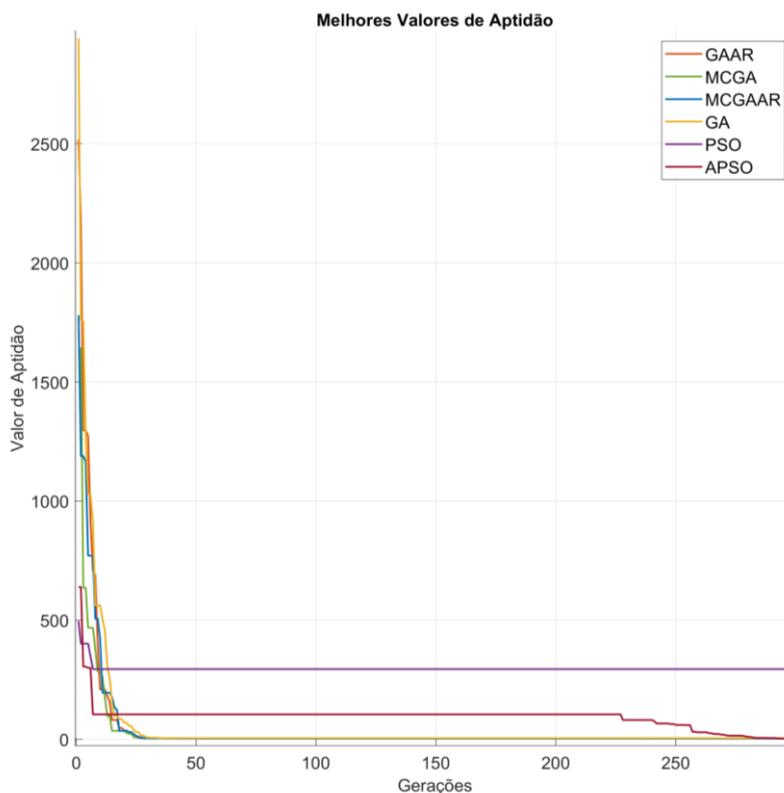
Fonte: Autor (2024).

A otimização dessa função apresentou uma distribuição bastante homogênea, com as seguintes porcentagens de melhores desempenhos, MCGAAR com 30%, GA com 40%, GAAR com 20% e o MCGA com 10%. Apesar de possuir características oscilatórias próximas ao ótimo local, o descolamento de eixo também interfere bastante na análise de continuidade de superfície realizada pelos algoritmos, por isso, nenhum algoritmo conseguiu apresentar uma constância soberana nessa função.

#### 5.1.9. CEC 09:

A topologia desta função apresenta um desafio para algoritmos de otimização, devido a sua superfície de busca não-linear e variáveis não separáveis. A característica distintiva desta função é que ela tem um único mínimo global, mas é cercada por uma série de mínimos locais, entre uma região de relativa suavidade, que podem facilmente enganar algoritmos de otimização, levando-os a convergir prematuramente para soluções subótimas. As curvas de convergência dos algoritmos na otimização desta função são apresentadas na Figura 26.

Figura 26 – Melhores Valores de Aptidão em CEC09



Fonte: Autor (2024).

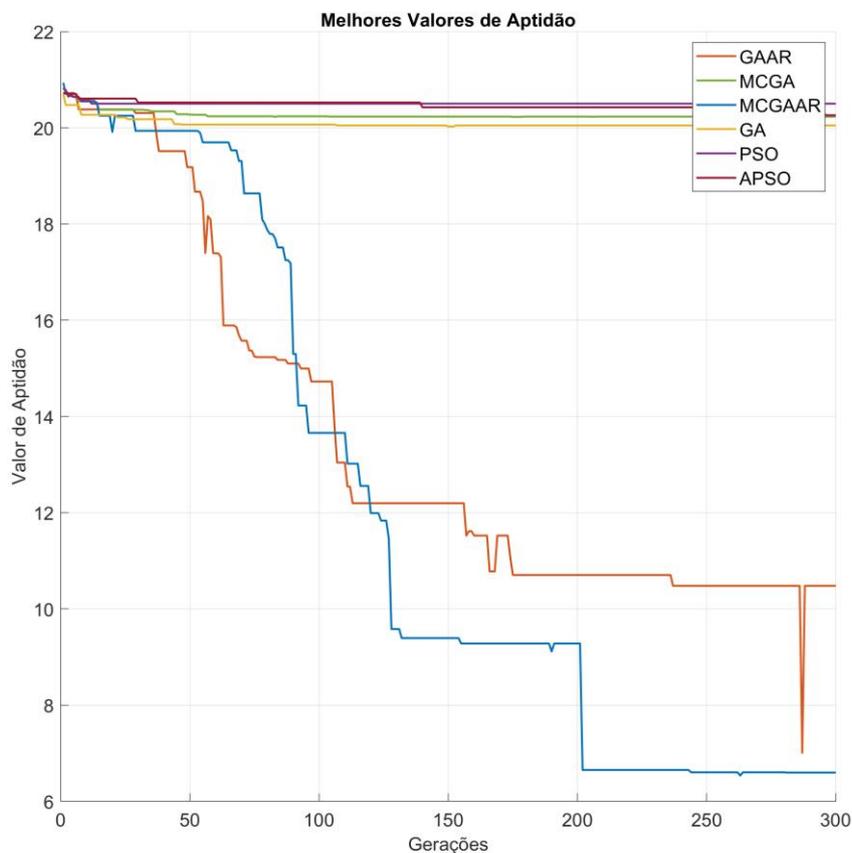
Na otimização desta função, as distribuições de melhores resultados também foram bastante distribuídas, o GAAR com 40%, o MCGAAR com 30%, o GA com 20% e o MCGA com 10%. A função em questão apresenta grande parte de sua superfície suave, e com um caminho de soluções que gradativamente aponta para a solução global, entretanto, a região de prosperidade é cercada por uma textura irregular e com oscilações de baixa amplitude, o que promove a estabilização de algoritmos na solução local. Apesar de não haver uma alta diferença entre os percentuais dos melhores algoritmos, os 2 melhores apresentam componentes de AR, o que os permitiu escapar desses mínimos locais.

#### 5.1.10. CEC 10:

GAAR foi o melhor algoritmo em todas as execuções, apesar dos mínimos locais e regiões de pseudo-prosperidade da função. O efeito intenso da radiação adaptativa nas gerações iniciais rapidamente retira os indivíduos dos mínimos locais, promovendo maior agitação

populacional. Embora não seja o mais rápido, os indivíduos que entram na região de prosperidade atingem altos níveis de intensificação, resultando em excelentes valores ótimos.

Figura 27 – Melhores Valores de Aptidão em CEC10



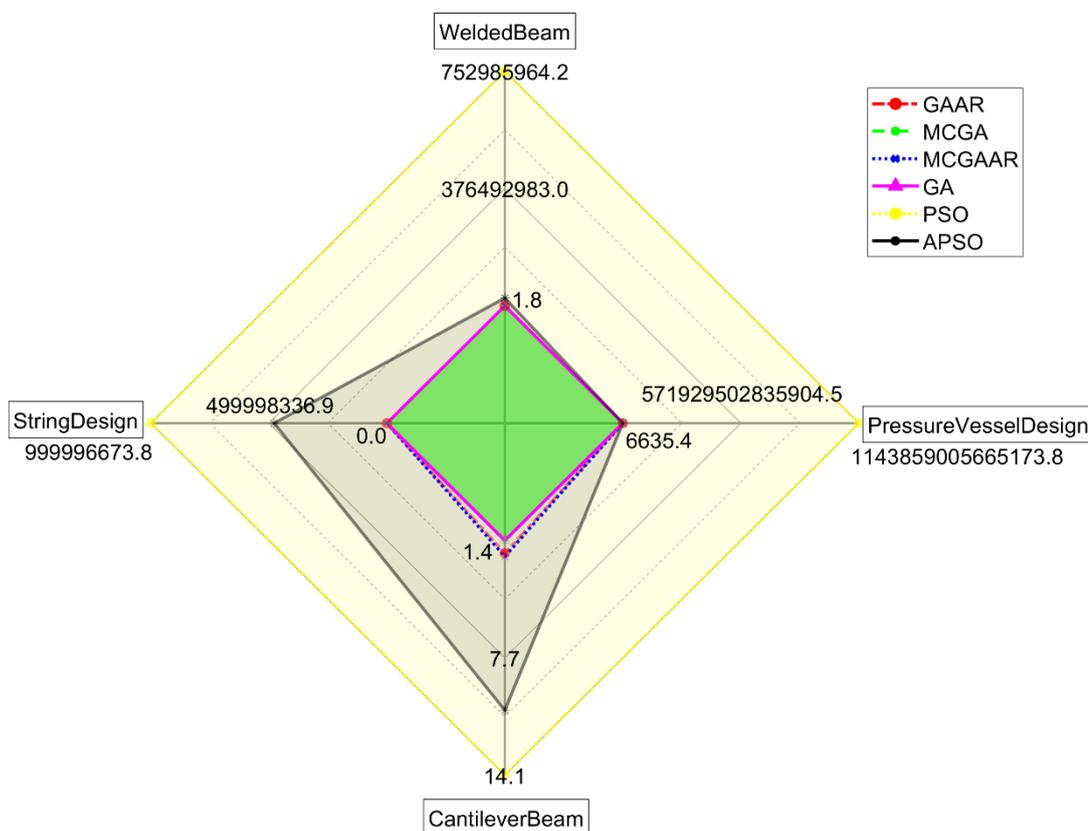
Fonte: Autor (2024).

Para os resultados o MCGAAR apresentou 50% dos melhores resultados nos testes, o GAAR 40% e o GA 10%. Essa proximidade da qualidade entre os 2 melhores algoritmos é identificável observando a amostra ilustrada na Figura 27, em que ambos apresentam comportamentos próximos, e distantes dos demais rivais. Novamente, o caráter exploratório garantido inicialmente pela componente de AR, permitiu que estes algoritmos conseguissem se direcionar corretamente para região de prosperidade. Entretanto, a componente multicritério do MCGAAR acabou apresentando maior influência do que sua parte mutagênica, fazendo com que em eles convergisse para um mínimo local, ainda que dentro da região prospera. É importante ressaltar que, os valores da solução global encontrados pelo GAAR são  $f(x) \cong 10.5$ , enquanto que os valores encontrados pelo MCGAAR são  $f(x) \cong 6.6$ . Essa métrica torna capaz identificar que o MCGAAR, indubitavelmente apresenta um melhor caráter de intensificação que o GAAR.

## 5.2. Problemas de Engenharia:

A Figura 25 apresenta os resultados dos comparativos entre os algoritmos adotados, com uma abordagem de spider plot (MOSES, 2023), assim, os menores valores estão mais próximos do centro, enquanto os maiores valores estão na periferia da malha.

Figura 28 – Resultados dos Algoritmos nos Problemas de Engenharia



Fonte: Autor (2024).

Para os resultados da otimização dos problemas de Engenharia, a Tabela 12 apresenta as melhores soluções encontradas pelos algoritmos em cada uma das funções, marcadas em negrito, em uma das execuções performadas.

Tabela 12 – Melhores Soluções dos Algoritmos nos Problemas de Engenharia

| Função                     | GAAR     | MCGA            | MCGA     | GA       | PSO      | APSO            |
|----------------------------|----------|-----------------|----------|----------|----------|-----------------|
|                            | AR       |                 |          |          |          |                 |
| Viga soldada               | 2.803709 | <b>1.502838</b> | 2.325691 | 1.617159 | 1.635376 | 1.521472        |
|                            | 905      | <b>708</b>      | 594      | 25       | 867      | 776             |
| Desenho de Vaso de Pressão | 6695.762 | <b>6308.841</b> | 7166.906 | 6497.042 | 7542.076 | 7303.642        |
|                            | 856      | <b>369</b>      | 268      | 287      | 645      | 89              |
| Viga Cantiléver            | 1.885541 | <b>1.350677</b> | 2.339179 | 1.383820 | 2.608473 | 2.083170        |
|                            | 342      | <b>911</b>      | 586      | 059      | 977      | 57              |
| Mola de Tensão             | 0.016244 | 0.013264        | 0.015468 | 0.014023 | 0.013208 | <b>0.013192</b> |
|                            | 555      | 583             | 603      | 324      | 117      | <b>769</b>      |

Fonte: Autor (2024).

Na Tabela 12 é representado um padrão dos testes realizados, em que o MCGA obteve o melhor rendimento para as funções. A Tabela 13 apresenta a média dos valores de aptidão dos algoritmos nos problemas de engenharia.

Tabela 13 – Média das Soluções dos Algoritmos nos Problemas de Engenharia

| Função                     | GAAR    | MCGA           | MCGAAR   | GA     | PSO     | APSO           |
|----------------------------|---------|----------------|----------|--------|---------|----------------|
| Viga soldada               | 2.77982 | <b>1.61153</b> | 2.556949 | 1.7151 | 1.72243 | 1.65900        |
|                            | 2       | <b>8</b>       |          | 03     |         | 8              |
| Desenho de Vaso de Pressão | 6897.72 | <b>6510.03</b> | 7217.371 | 6670.6 | 11104.9 | 8923.67        |
|                            | 9       | <b>5</b>       |          | 76     | 8       | 9              |
| Viga Cantiléver            | 2.15531 | <b>1.36448</b> | 2.784762 | 1.3705 | 2.88597 | 2.36339        |
|                            | 1       | <b>4</b>       |          | 74     | 4       | 9              |
| Mola de Tensão             | 0.02077 | 0.01393        | 0.018185 | 0.0152 | 0.01314 | <b>0.01310</b> |
|                            | 7       | 1              |          | 73     | 9       | <b>7</b>       |

Fonte: Autor (2024).

Assim como nas funções CEC2019, para os Problemas de Engenharia, os valores de média demonstram comportamentos similares aos de melhores valores, quando se trata dos algoritmos com melhor desempenho. A Tabela 15 apresenta os resultados para o teste de Friedman no Problema Real.

Tabela 15 – Resultados de Friedman nas Função IEEE300

|           | <b>GAAR</b> | <b>MCGA</b> | <b>MCGAAR</b> | <b>GA</b> | <b>PSO</b> | <b>APSO</b> |
|-----------|-------------|-------------|---------------|-----------|------------|-------------|
| Resultado | 4.5         | <b>1.5</b>  | 4.75          | 3         | 4.5        | 2.75        |
| Rank      | 4           | <b>1</b>    | 5             | 3         | 4          | 2           |

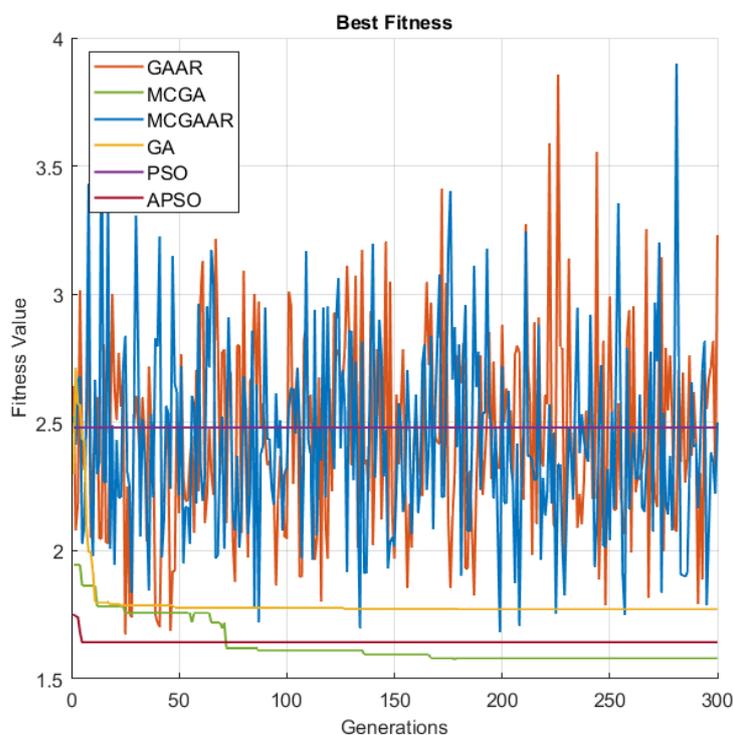
Fonte: Autor (2024).

Na Tabela 15 é possível identificar que o MCGA apresentou o melhor valor de resultado, seguido pelo APSO, GA, e o GAAR e o PSO empatados. Além disso, para o teste de Friedman nos problemas de engenharia, o valor-p obtido foi  $p = 0.00883$ , o que restringe a hipótese nula para a comparação dos algoritmos.

### 5.2.1. Viga soldada

A Figura 29 apresenta as curvas de convergência dos algoritmos na otimização do problema Viga soldada.

Figura 29 – Melhores Valores de Aptidão em Viga soldada



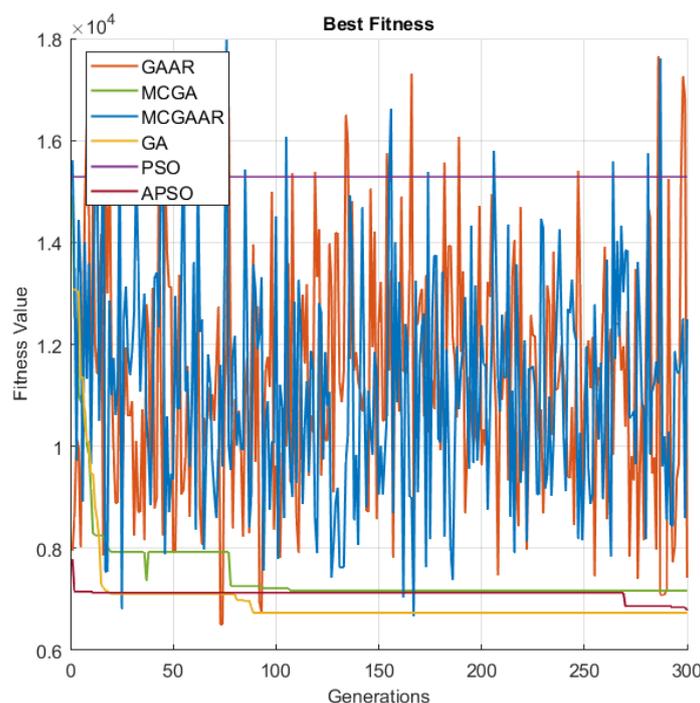
Fonte: Autor (2024).

Nessa figura, é possível perceber a convergência prematura dos algoritmos APSO, GA e principalmente do PSO, com o último apresentando o pior resultado entre estes. O GAAR e o MCGAAR apresentam os desempenhos de convergências insatisfatórias, já que oscilam bastante dentro da região de prosperidade, consequência do pequeno valor de amplitude dessa região. O MCGA apresentou uma convergência mais lenta e progressiva, o que garantiu maior precisão e consistência no encontro das soluções, esse processo explica o motivo desse algoritmo ter atingido os melhores resultados na otimização deste problema em 60% das execuções.

### 5.2.2. Vaso de Pressão:

A Figura 30 apresenta as curvas de convergência dos algoritmos na otimização do problema Vaso de Pressão.

Figura 30 – Melhores Valores de Aptidão em Vaso de Pressão



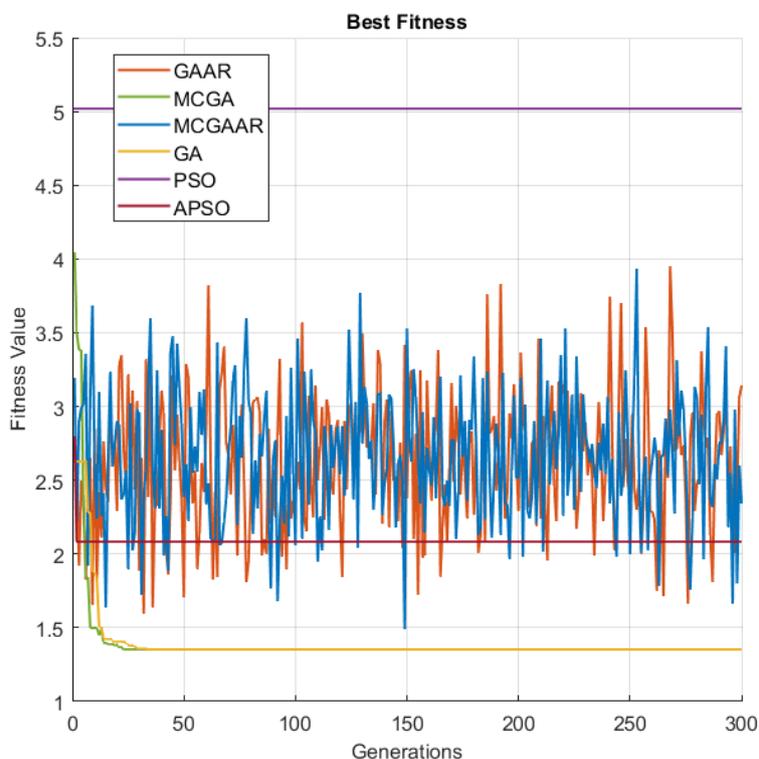
Fonte: Autor (2024).

Nesta função, os algoritmos MCGA e GA empataram em melhores desempenhos, com ambos apresentando 30% das melhores soluções, enquanto os demais algoritmos também ficaram empatados, com 10% cada.

### 5.2.3. Viga Cantilever:

A Figura 31 apresenta as curvas de convergência dos algoritmos na otimização do problema Viga Cantilever.

Figura 31 – Melhores Valores de Aptidão em Viga Cantilever



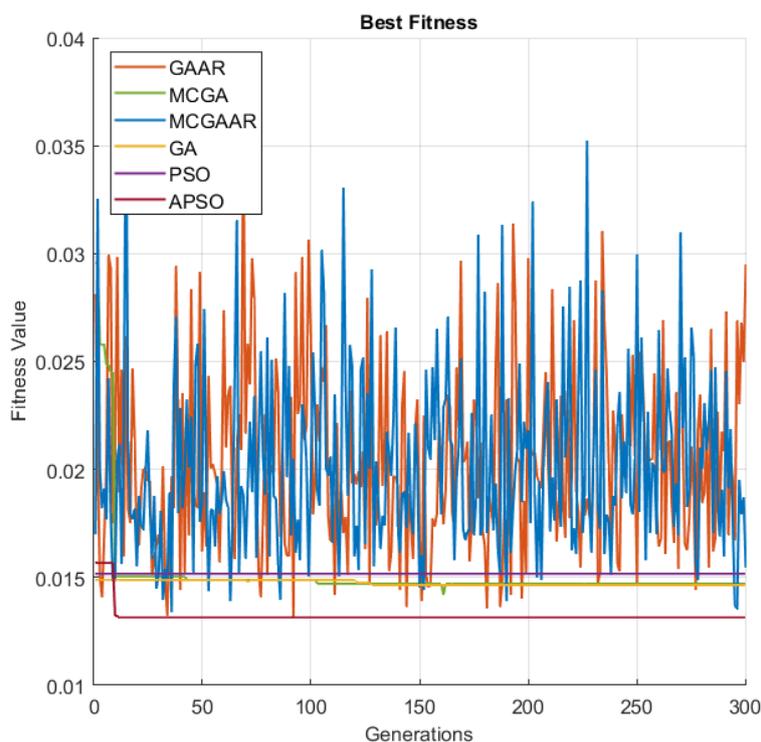
Fonte: Autor (2024).

A figura ilustra o comportamento dos algoritmos MCGA e GA, seguindo um caminho de convergência semelhante, principalmente após a geração 30. Ambos estes algoritmos empataram em apresentar os melhores desempenhos na otimização desta função, com 50% cada. Por causa da baixa amplitude dentro da região de prosperidade, os algoritmos com AR apresentam maior dificuldade em convergir, enquanto os algoritmos evolutivos sem componente radiativa conseguem convergir suavemente.

### 5.2.4. Mola de Tensão

A Figura 32 apresenta as curvas de convergência dos algoritmos na otimização do problema Mola de Tensão.

Figura 32 – Melhores Valores de Aptidão em Mola de Tensão



Fonte: Autor (2024).

Nesta função, o APSO foi dominante em desempenho, apresentando 60% dos melhores resultados ao longo dos testes. Apresentando apenas 3 variáveis, essa função apresenta os menores intervalos de busca nesta categoria, principalmente para as variáveis  $x_1$  e  $x_2$ , coeficientes de maior grau na função modeladora, fazendo com que a variável  $x_3$  fosse o elemento com maior amplitude, porém representando o elemento que mais caracteriza o ajuste fino de precisão do valor da solução, por apresentar o menor grau nas inequações apresentadas. Quanto ao APSO, seu caráter exploratório o permitiu encontrar com maior eficiência a região de prosperidade, mas seu comportamento adaptativo de decaimento auxiliou no ajuste de maior precisão, principalmente para com a variável  $x_3$ .

### 5.3. Problema Real

Nesta categoria de problema, foi trabalhada a otimização do despacho energético de uma rede IEEE de 300 barras. Os resultados do processo de otimização entre os algoritmos são apresentados na Tabela 16.

Tabela 16 – Melhores Soluções no Problema Real

| Função      | GAAR        | MCGA               | MCGAAR      | GA          | PSO         | APSO        |
|-------------|-------------|--------------------|-------------|-------------|-------------|-------------|
| IEEE<br>300 | 1241847.005 | <b>4.964111328</b> | 15276218.08 | 23.75695801 | 163.6936646 | 5.899108887 |

Fonte: Autor (2024).

A Tabela 16 representa o comportamento repetitivo observado nos testes, em que o MCGA obteve o melhor desempenho em 40% dos experimentos de otimização desse problema, e o APSO, em segundo lugar, alcançou a melhor solução em 20% dos testes. A Tabela 17 apresenta as médias das soluções encontrada nos Problemas de Engenharia.

Tabela 17 – Média das Soluções no Problema Real

| Função      | GAAR     | MCGA          | MCGAAR   | GA     | PSO     | APSO   |
|-------------|----------|---------------|----------|--------|---------|--------|
| IEEE<br>300 | 1.68E+06 | <b>45.852</b> | 2.54E+07 | 77.507 | 118.199 | 71.507 |

Fonte: Autor (2024).

As tabelas 16 e 17 colaboram para a apresentação de comportamentos similares, em que o MCGA apresenta os melhores resultados e melhor consistência. A Tabela 18 apresenta os resultados para o teste de Friedman no Problema Real.

Tabela 18 – Resultados de Friedman nas Função IEEE300

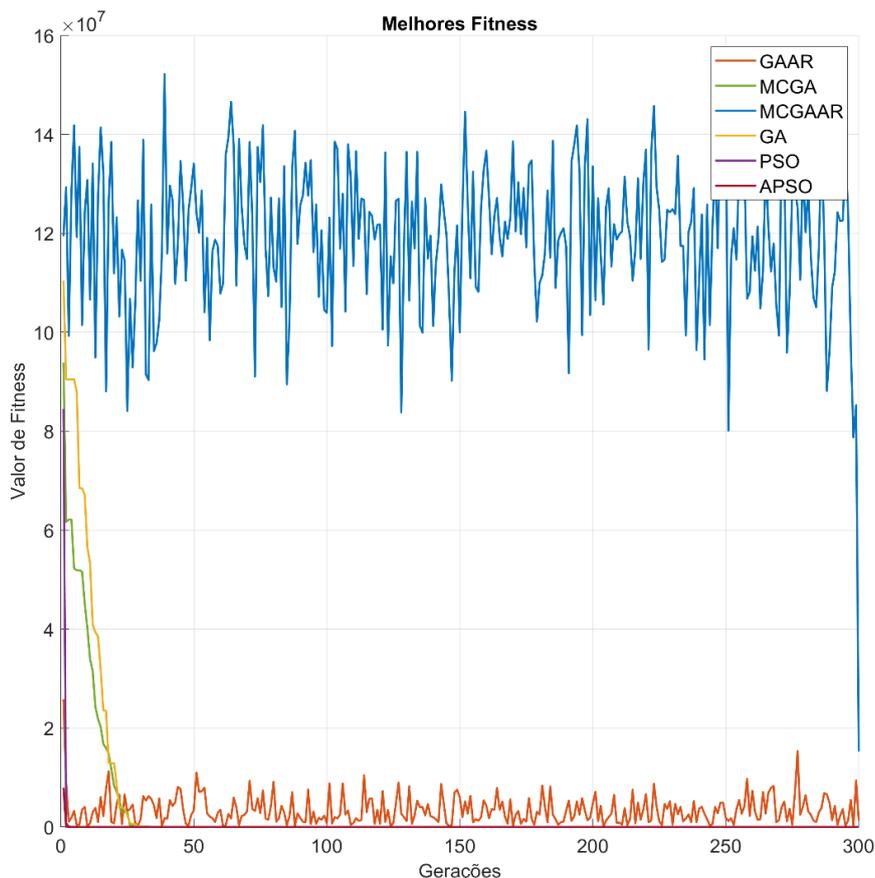
|           | GAAR | MCGA       | MCGAAR | GA  | PSO | APSO |
|-----------|------|------------|--------|-----|-----|------|
| Resultado | 5    | <b>2.5</b> | 6      | 2.8 | 2.9 | 2.6  |
| Rank      | 5    | <b>1</b>   | 6      | 3   | 4   | 2    |

Fonte: Autor (2024).

Na Tabela 18 é possível identificar que o MCGA apresentou o melhor valor de resultado, seguido pelo APSO, GA, PSO, GAAR e MCGAR. Além disso, para o teste de Friedman nas funções CEC2019, o valor-p obtido foi  $p = 7.1092e^{-7}$ , o que restringe a hipótese nula para a comparação dos algoritmos.

A Figura 33 apresenta os melhores valores de aptidão dos algoritmos.

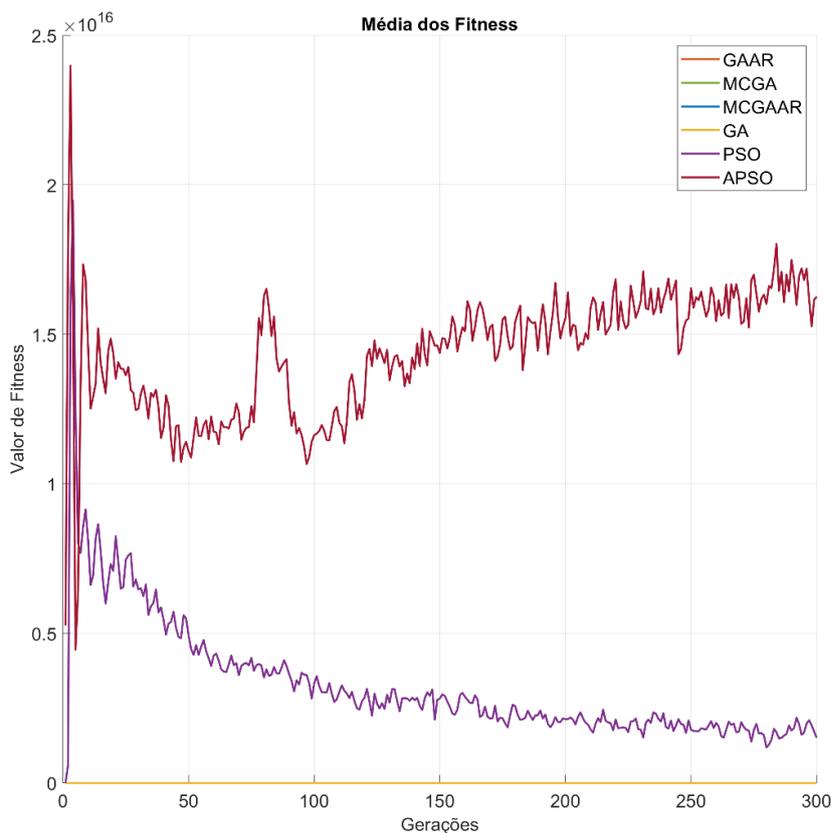
Figura 33 – Melhores Valores de Aptidão em IEEE300



Fonte: Autor (2024).

A Figura 33 mostra que os algoritmos com componentes de AR apresentaram maior amplitude oscilatória. Por ter seguido uma convergência rápida, GAAR manteve um nível de radiação estável, dado a proximidade genética das gerações ancestrais. Os demais algoritmos apresentaram convergências rápidas, contudo, os evolutivos que não apresentam componentes de AR, possuem convergências mais lentas que os algoritmos cooperativos, o que garantiu alcançar os melhores resultados por parte do MCGA e do GA. Para compreender melhor o processo de otimização desse problema, é importante analisar os valores médios de aptidão dos algoritmos, como ilustrado na Figura 34.

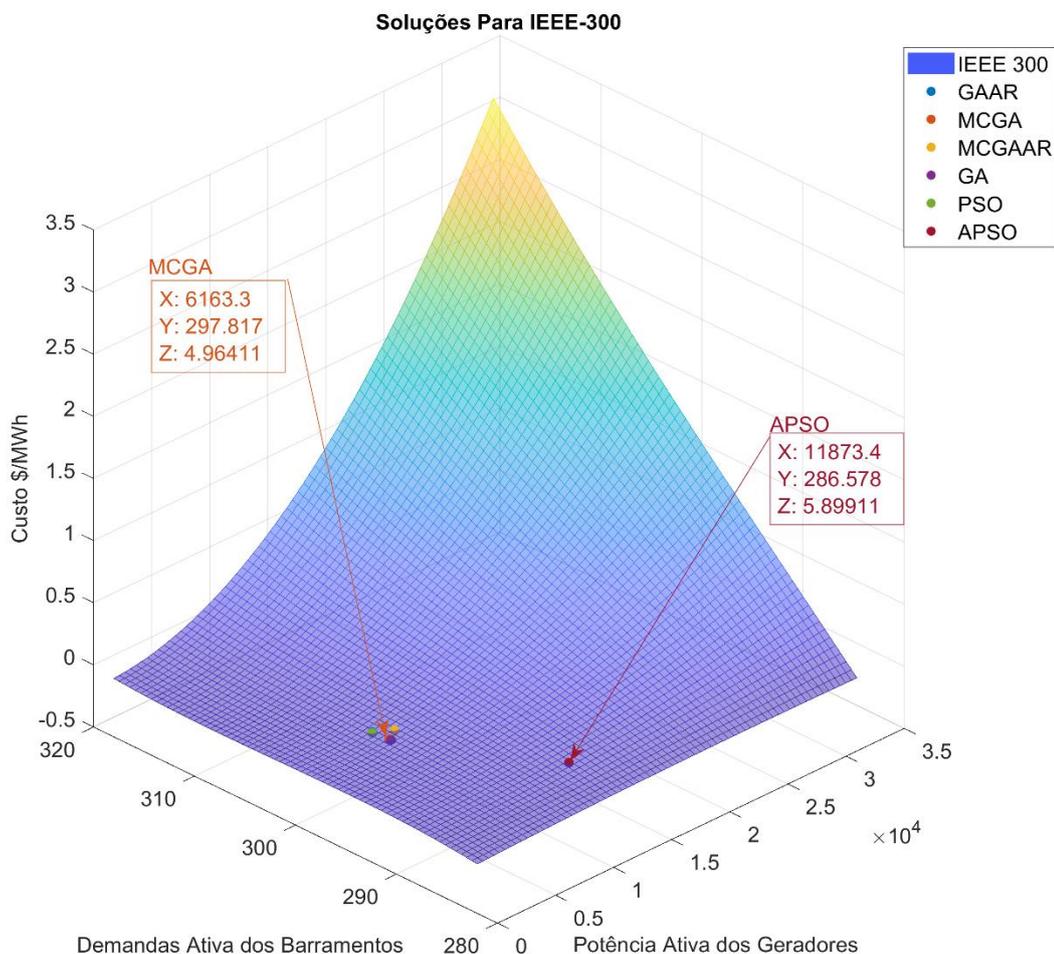
Figura 34 – Média dos Valores de Aptidão em IEEE300



Fonte: Autor (2024).

A Figura 34 mostra que, apesar de terem apresentado a mais rápida convergência dos melhores valores de aptidão, o comportamento médio das populações dos algoritmos PSO e APSO apresentou maior dificuldade de convergência coletiva, o que se repetiu em todos os testes realizados. Porém, o caráter não estabilizado dos valores médios do APSO, serviu como diagnóstico para apontar um comportamento causado pela topologia do problema em questão. A Figura 35 serve como referência para compreender esse comportamento.

Figura 35 – Soluções dos Algoritmos em IEEE300



Fonte: Autor (2024).

A Figura 35 mostra que o APSO encontrou uma outra região de prosperidade, em que permitiu atingir uma solução ótima próxima da melhor solução global. Entretanto, os demais algoritmos, múltiplas vezes convergiram para uma mesma região, como foi o caso do MCGA. A principal diferença comportamental entre essas escolhas, de otimização, foi que o MCGA obteve maior consistência de alcançar o ótimo global.

## 6. CONCLUSÃO

Nesta obra, foram apresentadas novas abordagens para o GA, que consistem em métodos de autoajustes (*autotuning*), para otimização de problemas de diferentes naturezas, através da implementação de uma etapa adaptativa de radiação e da seleção multicritério. Estas abordagens são baseadas em fenômenos biológicos, na radiação adaptativa, que permite que as populações se diversifiquem enquanto se adaptam a novos nichos ambientais, e na escolha multicritério de parceiros, que ocorre na natureza quando características específicas apresentam influência na seleção dos indivíduos escolhidos para o cruzamento. Foram propostos modelos matemáticos, tanto para a função de radiação adaptativa, quando para a função de seleção multicritério, e as recombinações de algoritmos foram comparadas, levando em consideração seu desempenho com algoritmos genéticos clássicos e outros algoritmos bio-inspirados, como a otimização de enxame de partículas.

Os resultados apresentados, demonstram as soluções encontradas pelos algoritmos de otimização nas diversas funções de teste, para comprovar a influência dos métodos propostos na qualidade do desempenho dos algoritmos. As funções de teste foram divididas em 3 categorias: Funções de *Benchmark*, Problemas de Engenharia e Problema Real. Sendo cada grupo destacado por características únicas, que testam diferentes aspectos dos algoritmos. As Funções de *Benchmark*, grupo composto pelas funções do CEC2019, desafiam os algoritmos em problemas de diferentes topologias, exigindo alta versatilidade dos algoritmos. Nessas, o MCGAAR apresentou o melhor resultado em 48% das execuções, classificado em primeiro lugar pelo teste não-paramétrico de Friedman, seguido pelo GAAR e pelo MCGA, com 29% e 21%, respectivamente. Os Problemas de Engenharia, *Viga soldada*, *Vaso de Pressão*, *Viga Cantilever* e *Mola de Tensão*, exigem dos algoritmos alta precisão para os ajustes finos, assim como a coerência entre os valores das variáveis, que apresentam diferentes unidades e escalas decimais. Neste conjunto de funções, o algoritmo que se destacou foi o MCGA, que apresentou o melhor resultado em 75% dos testes, seguido pelo APSO com aproximadamente 14%. O Problema Real adotado, baseado no despacho ótimo da rede elétrica IEEE de 300 barramentos, propõe um cenário de magnitude muito maior, com 368 variáveis, com valores operacionais e dimensões específicas, além de uma topologia não padronizada. No problema real, o MCGA também foi algoritmo que alcançou o melhor desempenho, apresentando o melhor resultado em 40% dos testes, seguido pelo APSO com 20%. Ainda que, para alguns problemas e execuções, os demais algoritmos apresentassem melhor solução, os valores médios de suas

populações eram altos, o que representa a instabilidade e ausência da constância na conquista desses melhores resultados.

Para continuação da vertente dessa pesquisa, almeja-se aplicar os métodos propostos em outros problemas, com foco em situações dinâmicas, como o despacho ideal em redes elétricas, mais especificamente, em sistemas de combustíveis híbridos, que exigem mudanças dinâmicas em seus parâmetros operacionais. Este tipo de problema exigirá mais da característica de adaptabilidade do algoritmo, assim como deve requisitar que os elementos de auto sintonização trabalhem com maior frequência e constância.

Ainda nas propostas de continuidade dessa pesquisa, planeja-se investigar demais comportamentos e dinâmicas biológicas, para aumentar a proximidade dos modelos suas respectivas referências biológicas, evitando operações computacionalmente ineficientes, para perpetuar esse algoritmo como uma ferramenta de ponta. E propor o modelo de codominância, para que a componente multicritério possa rever suas decisões em tempo de execução, caso as ordens de prioridade ou importância dos certos genes sejam alteradas.

No geral, as abordagens apresentam o potencial de melhorar significativamente o desempenho de algoritmos genéticos em problemas de diferentes naturezas e comportamentos, tornando-os ferramentas mais eficazes para resolver problemas dinâmicos de otimização do mundo real. Compreende-se que essa pesquisa, e seus produtos, apresentam algo grau de relevância e ineditismo, além de demonstrar resultados que garantem a eficiência das novas componentes AR e MC.

## REFERÊNCIAS

- A. Bala e A. K. Sharma, "A comparative study of modified *Crossover* operators," 2015 Third International Conference on Image Information Processing (ICIIP), Wagnaghat, Índia, 2015, pp. 281-284, doi: 10.1109/ICIIP.2015.7414781.
- A. Shukla, H. M. Pandey e D. Mehrotra, "Comparative review of selection techniques in genetic algorithm", 2015 International Conference on Futuristic Trends on Computational Analysis and Knowledge Management (ABLAZE), Greater Noida, Índia, 2015, pp. 515-519, doi: 10.1109/ABLAZE.2015.7154916.
- A. Vlasov; A. Khomchenko; A. Faizliev; S. Mironov; A. Grigoriev. Parameter tuning of a genetic algorithm for finding central vertices in graphs. *Journal of Physics: Conf. Ser.* 1784, 012009, 2021. DOI:10.1088/1742-6596/1784/1/012009
- A., Rapini, C., Bitencourt, F., Luebert, D., Cardoso. An escape-to-radiate model for explaining the high plant diversity and endemism in campos rupestres, *Biological Journal of the Linnean Society*, vol. 133, no. 2, pp. 481–498, setembro, 2020, DOI: 10.1093/biolinnean/blaa179
- Adibi, M., "IEEE 300-Bus System", EEE Test Systems Task Force, 1993.
- Ali R. Al-Roomi (2015). Power Flow Test Systems Repository [<https://al-roomi.org/power-flow>]. Halifax, Nova Scotia, Canada: Dalhousie University, Electrical and Computer Engineering.
- Araya-Ajoy, Y. G., Niskanen, A. K., Froy, H., Ranke, P. S., Kvalnes, T., Rønning, B., Pepke, M. L., Jensen, H., Ringsby, T. H., Saether, B. E., & Wright, J. " Variation in generation time reveals density regulation as an important driver of pace of life in a bird metapopulation". *Ecology Letters*, 24, 2077– 2087, 2021 <https://doi.org/10.1111/ele.13835>
- B.V., Natesha, R. M. R., Guddeti. "Adopting elitism-based Genetic Algorithm for minimizing multi-objective problems of IoT service placement in fog computing environment". *Journal of Network and Computer Applications*, vol. 178, pp. 102972, março, 2021. DOI: 10.1016/j.jnca.2020.102972.
- Berner, D., Salzburger, W.; The genomics of organismal diversification illuminated by adaptive radiations. *Trends in genetics*, vol. 31, n. 9, pp: 491-499. Agosto, 2015. DOI: 10.1016/j.tig.2015.07.002.
- Darren M. Chitty. 2022. Accelerating genetic algorithm evolution via ant-based mutation and *Crossover* for application to large-scale TSPs. In *Proceedings of the Genetic and Evolutionary Computation Conference Companion (GECCO '22)*. Association for Computing Machinery, Nova York, NY, EUA, 2046–2053. DOI: 10.1145/3520304.3534020
- Darwish, A. "Bio-inspired computing: Algorithms review, deep analysis, and the scope of applications". *Future Computing and Informatics Journal*, vol. 3, n. 2, pp. 231-246, dezembro, 2018. DOI: 10.1016/j.fcij.2018.06.001
- E. J., Richards, J. A., McGirr, J. R., Wang, M. E., São João, J. W., Poelstra, M. J., Solano, D. C., O'Connell, B. J., Turner, C. H., Martin. "A vertebrate adaptive radiation is assembled from an ancient and disjunct spatiotemporal landscape". *Proceedings of the National Academy of Sciences*, vol. 118, n. 20, pp. e2011811118. Maio, 2021, DOI: 10.1073/pnas.2011811118

Enas Jalil Al-Mayali.et. al., " Molecular Detection of Bio Film Gene in Pseudomonas Aeruginosa Isolates from Tonsillitis". Journal of Global Pharma Technology, vol.10, n.03, pp: 57-64. 2018.

F. Sim; C. Doerr; H. Wang; T. Bäck. Automated Configuration of Genetic Algorithms by Tuning for Anytime Performance. IEEE Transactions on Evolutionary Computation, vol. 26, n. 6, pp. 1526-1538, dezembro de 2022. DOI: 10.1109/TEVC.2022.3159087.

Faith, D.P., Reid, C. A. M., Hunter, J. "Integrating Phylogenetic Diversity, Complementarity, and Endemism for Conservation Assessment ". Biologia da Conservação. 18, n. 1, pp.255-261, 2004. DOI: <https://doi.org/10.1111/j.1523-1739.2004.00330.x>

G. M. Nayeem, M. Fan e Y. Akhter, "A Time-Varying Adaptive Inertia Weight based Modified PSO Algorithm for UAV Path Planning", 2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST), DHAKA, Bangladesh, 2021, pp. 573-576, DOI: 10.1109/ICREST51555.2021.9331101.

Gillespie, R. G., Croom, H. B., & Palumbi, S. R. Multiple origins of a spider radiation in Hawaii. Proceedings of the National Academy of Sciences, vol. 91, n. 6, pp: 2290-2294. Novembro, 1994. DOI: 10.1073/pnas.91.6.2290

Giti Javadi; Ehsan Aminian. A New Method for Tuning Mutation and *Crossover* Rate in Genetic Algorithm. 9th International Conference on Machine Learning and Computing - ICMLC 2017, fevereiro, pp 217–220, 2017. <http://dx.doi.org/10.1145/3055635.3056622>

Henshaw, J. M., Fromhage, L., & Jones, A. G. "The evolution of mating preferences for genetic attractiveness and quality in the presence of sensory bias". Proceedings of the National Academy of Sciences of the United States of America, 119(33), e2206262119. Agosto, 2022. DOI:10.1073/pnas.2206262119.

J. H. Holland. Adaptation in Natural and Artificial Systems, 2ª ed., Ann Arbor: MIT Press, 1992.

J. Li e L. Li, "An Improvement Proposal of Genetic Algorithms Based on Information Entropy and Game Theory", 2019 Sexta Conferência Internacional sobre Análise, Gestão e Segurança de Redes Sociais (SNAMS), Granada, Espanha, 2019, pp. 36-43, doi: 10.1109/SNAMS.2019.8931847.

Juraj Spalek; Michal Gregor. Adaptive Switching of Mutation Rate for Genetic Algorithms and Genetic Programming, Volume 7, Número 1, 2011.

K. V. Price, N. H. Awad, M. Z. Ali, P. N. Suganthan, "Problem definitions and evaluation criteria for the 100-digit challenge special session and competition on single objective numerical optimization", Relatório Técnico, Nanyang Technological University, Singapura, novembro de 2018.

L. Cao, H. Chen, Y. Chen, Y. Yue e X. Zhang, "Bio-Inspired Swarm Intelligence Optimization Algorithm-Aided Hybrid TDOA/AOA-Based Localization", Biomimetics, vol. 8, no. 2, p. 186, abril de 2023, doi: 10.3390/biomimetics8020186.

Lance D. Câmaras; Lance D. Câmaras. Practical Handbook of Genetic Algorithms Applications - Complex Coding Systems - Volume III. Editora CRC, 592 páginas, 2019.

- Lin, L., Gen, M. Auto-tuning strategy for evolutionary algorithms: balancing between exploration and exploitation. *Soft Computing* 13, 157–168 (2009). <https://doi.org/10.1007/s00500-008-0303-2>
- Losos J. B. Adaptive radiation, ecological opportunity, and evolutionary determinism. *American Society of Naturalists E. O. Wilson award address. The American naturalist*, vol. 175, n. 6, pp: 623-639. Junho, 2010. DOI: 10.1086/652433
- M. A. Franco; N. Krasnogor; J. Bacardit. Automatic Tuning of Rule-Based Evolutionary Machine Learning via Problem Structure Identification. *IEEE Computational Intelligence Magazine*, vol. 15, n. 3, pp. 28-46, agosto de 2020. DOI: 10.1109/MCI.2020.2998232.
- Marcelo Favoretto Castoldi; Sérgio Carlos Mazucato Júnior; Danilo Sipoli Sanches; Carolina Ribeiro Rodrigues; Rodrigo Andrade Ramos. Automatic Tuning of PSSs and PODs Using a Parallel Differential Evolution Algorithm. *International Journal of Natural Computing Research (IJNCR)*, 4(1), 2014. DOI: 10.4018/ijnrcr.2014010101
- Moisés (2023). spider\_plot ([https://github.com/NewGuy012/spider\\_plot/releases/tag/20.2](https://github.com/NewGuy012/spider_plot/releases/tag/20.2)), GitHub.
- N.-E. Croitoru. High Probability Mutation and Error Thresholds in Genetic Algorithms. 17th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC), Timisoara, Romênia, pp. 271-276, 2015. DOI: 10.1109/SYNASC.2015.51.
- Oliveira, A. H.; Maragatham, G. Automatic tuning of hyperparameters using Bayesian optimization. *Evolving Systems* 12, 217–223 (2021). <https://doi.org/10.1007/s12530-020-09345-2>
- Oliveira, A.; J. Maher; C. O'Riordan; F. Morgan. Maintaining Healthy Population Diversity Using Adaptive *Crossover*, Mutation, and Selection. *IEEE Transactions on Evolutionary Computation*, 15:692-714, 2011. DOI: 10.1109/TEVC.2010.2046173
- Oliveira, A.; Messer, P. ncreasing Diversity in Genetic Algorithms. *Developments in Soft Computing - Advances in Soft Computing*, John, R., Birkenhead, R. (eds), vol 9, Physica, Heidelberg, 2001. [https://doi.org/10.1007/978-3-7908-1829-1\\_14](https://doi.org/10.1007/978-3-7908-1829-1_14)
- Oliveira, J.-T.; Oliveira, D.-D.; Nguyen, H.-N. An Approach for Designing an Optimal CNN Model Based on Auto-Tuning GA with 2D Chromosome for Defect Detection and Classification. *Sustainability*, 15, 5455, 2023. <https://doi.org/10.3390/su15065455>
- Oliveira, M.-Y.; Oliveira, Y.-C.; Oliveira, C.-Y. Auto-tuning SOS Algorithm for Two-Dimensional Orthogonal Cutting Optimization. *KSCE Journal of Civil Engineering* 25, 3605–3619, 2021. <https://doi.org/10.1007/s12205-021-0522-y>
- P. Pongcharoen; C. Hicks; P. M. Braiden,; D. J. Stewardson. Determining optimum Genetic Algorithm parameters for scheduling the manufacturing and assembly of complex products. *International Journal of Production Economics*, Volume 78, Número 3, Páginas 311-322, 2002. [https://doi.org/10.1016/S0925-5273\(02\)00104-4](https://doi.org/10.1016/S0925-5273(02)00104-4)
- R. C. Purshouse e P. J. Fleming, "On the Evolutionary Optimization of Many Conflicting Objectives", in *IEEE Transactions on Evolutionary Computation*, vol. 11, n. 6, pp. 770-784, dezembro de 2007, doi: 10.1109/TEVC.2007.910138.

- R. D. Zimmerman, C. E. Murillo-Sanchez, and R. J. Thomas, "MATPOWER: Steady-State Operations, Planning and Analysis Tools for Power Systems Research and Education," *Power Systems, IEEE Transactions on*, vol. 26, no. 1, pp. 12–19, Feb. 2011.
- R. R. Karn; P. Kudva; I. A. M. Elfadel. Dynamic Autoselection and Autotuning of Machine Learning Models for Cloud Network Analytics. *IEEE Transactions on Parallel and Distributed Systems*, vol. 30, n. 5, pp. 1052-1064, 1 de maio de 2019, doi: 10.1109/TPDS.2018.2876844.
- R., Cortez, R., Garrido R., Mezura-Montes. "Spectral Richness PSO algorithm for parameter identification of dynamical systems under non-ideal excitation conditions". *Applied Soft Computing*, vol. 128, n. 1, pp. 109490, outubro, 2022. DOI: 10.1016/j.asoc.2022.109490.
- Rajani, N., Kumar, K. S., Kaswan. "Soft Hunting Algorithm for Auto-Tuning Software Reliability Growth Model". *Wireless Communications and Mobile Computing*, vol. 3752264, n. 1, pp. 1-10, agosto, 2022. DOI: 10.1155/2022/3752264
- Reed, D. H. " Relationship between Population Size and Fitness". *Biologia da Conservação*, vol. 19, n. 2, pp. 563-568, 2005. <http://www.jstor.org/stable/3591269>
- Ribeiro, A.; Oliveira, J.; Oliveira, E.; Ribeiro, E.; Oliveira, A.; Prasath, V.B.S. Choosing Mutation and *Crossover* Ratios for Genetic Algorithms—A Review with a New Dynamic Approach. *Informações* 2019, 10, 390. <https://doi.org/10.3390/info10120390>
- Richards, E. J., McGirr, J. A., Wang, J. R., St John, M. E., Poelstra, J. W., Solano, M. J., et al. A vertebrate adaptive radiation is assembled from an ancient and disjunct spatiotemporal landscape. *Proc.* 118 (20), e2011811118. DOI:10.1073/pnas.2011811118
- Roberto Ugolotti; Stefano Cagnoni. Automatic Tuning of Standard PSO Versions. *Proceedings of the Companion Publication of the 2015 Annual Conference on Genetic and Evolutionary Computation - GECCO'15*, julho, pp 1501–1502, 2015. <https://doi.org/10.1145/2739482.2764706>
- S., Mao, F., Hu, J., Lang, T., Chen, S., Cheng. "Comparative Study of Impacts of Typical Bio-Inspired Optimization Algorithms on Source Inversion Performance". *Frontiers in Environmental Science*, vol. 10, n.1, pp. 1-14, junho, 2022. DOI: 10.3389/fenvs.2022.894255.
- Shao, J. W., Zhang, X. P., Zhang, Z. X., & Zhu, G. P. " Effects of Population Size on Reproductive Success of the Endangered and Endemic Species *Primula merrilliana* ". *Journal of Integrative Plant Biology*, vol. 50, n. 9, pp. 1151-1160. 2008. <https://doi.org/10.1111/j.1744-7909.2008.00655.x>
- Shiple, B. R., & McGuire, J. L. (2021). "Interpreting and integrating multiple endemism metrics to identify hotspots for conservation priorities". *Biological Conservation*, vol. 265, n. 1, pp: 109403. DOI: 10.1016/j.biocon.2021.109403.
- Soni, N., & Kumar, T. " Study of Various Mutation Operators in Genetic Algorithms ". *International Journal of Computer Science and Information Technologies*, vol.5, no. 3, 2014, 4519-4521

Srivatsa D, Teja TPVK, Prathyusha I, Jeyakumar G. An Empirical Analysis of Genetic Algorithm with Different Mutation and *Crossover* Operators for Solving Sudoku. In: B. Deka, P. Maji, S. Mitra, D. Bhattacharyya, P. Bora e S. Pal (orgs), International Conference on Pattern Recognition and Machine Intelligence (PReMI 2019). Lecture Notes in Computer Science, vol 11941, Springer, Cham, pp 356–364, Tezpur, Índia

Staude, I. R., Navarro, L. M., Pereira, H. M. "Range size predicts the risk of local extinction from habitat loss". *Global Ecology and Biogeography*, 29(1), 16–25. Setembro, 2020. DOI:10.1111/geb.13003

Taherdoost H, Madanchian M. Multi-Criteria Decision Making (MCDM) Methods and Concepts. *Encyclopedia*. 2023; 3(1):77-87. <https://doi.org/10.3390/encyclopedia3010006>

U. R. Acharya; M. R. K. Mookiah; S. Vinitha Sree; R. Yanti1, R. J. Martis; L. Saba; F. Molinari; S. Guerriero; J. S. Suri. Evolutionary Algorithm-Based Classifier Parameter Tuning for Automatic Ovarian Cancer Tissue Characterization and Classification. *Ultraschall em Med*, 35: 237–245, 2014. DOI: 10.1055/s-0032-1330336

Vasto-Terrientes, L. D., Valls, A., Slowinski, R., Zielniewicz, P. "ELECTRE-III-H: An *outRanking*-based decision aiding method for hierarchically structured criteria". *Expert System with Applications*, 42(11), 4910-4926. Julho, 2015. DOI: 10.1016/j.eswa.2015.02.016.

Żak, J., e Kruszyński, M. "Application of AHP and ELECTRE III/IV Methods to Multiple Level, Multiple Criteria Evaluation of Urban Transportation Projects". *Transportation Research Procedia*, 10(1), 890-830. Julho, 2015. DOI: 10.1016/j.trpro.2015.09.035