

Algoritmo evolucionário híbrido aplicado a problemas com muitos objetivos

Alan Cândido de Souza ¹; Breno Costa Dolabela Dias ²; Bruno Alberto Soares Oliveira ³

1 Programa de Pós-Graduação em Engenharia Elétrica, UFMG, Belo Horizonte – MG; alancsouza04@gmail.com

2 Programa de Pós-Graduação em Engenharia Elétrica, UFMG, Belo Horizonte – MG

3 Programa de Pós-Graduação em Engenharia Elétrica, UFMG, Belo Horizonte – MG; brunoalbertobambui@ufmg.br

RESUMO

Algoritmos evolucionários baseados em métodos de decomposição e Pareto dominância são amplamente utilizados em problemas de otimização multiobjetivo. Entretanto, para problemas com muitos objetivos (aqueles que possuem mais de três objetivos), muitas vezes a pressão de seleção é prejudicada devido ao espaço de busca de alta dimensão. Nesse contexto, trabalhos na literatura buscam desenvolver métodos os quais sejam capazes de garantir a convergência e a diversidade das soluções em problemas com muitos objetivos. Dentre os principais algoritmos utilizados para a solução de tais problemas destacam-se o MOEA/DD, baseado nos critérios de dominância e decomposição, e o NSGA-III, o qual busca garantir a diversidade no critério de seleção. Tais algoritmos possuem qualidades específicas, o que torna difícil realizar uma comparação de forma a determinar o melhor algoritmo, uma vez que essa afirmação depende do contexto do problema ao qual serão aplicados. Dessa forma, busca-se neste trabalho apresentar um método para combinação de dois algoritmos evolucionários em problemas multi e com muitos objetivos. O método proposto baseia-se na combinação de dois algoritmos considerados estado da arte para problemas multi e com muitos objetivos, onde, em cada geração, é feita a mudança do algoritmo utilizado de maneira aleatória, de forma a buscar combinar as qualidades dos dois algoritmos em um formato híbrido, implementando os critérios de dominância e decomposição e buscando garantir a diversidade no espaço de soluções. Foram realizados testes em problemas benchmarking com 3 e 5 objetivos. Os resultados foram comparados com os algoritmos MOEA/DD e NSGA-III, através do critério de distância geracional invertida (IGD). O desempenho alcançado no entanto não supera os resultados obtidos nos algoritmos considerados estado da arte. Contudo, o método apresenta potencial para aplicações que necessitam modelos mais robustos aplicáveis a diferentes contextos. É apresentado ainda o tempo computacional de forma a avaliar a eficiência do método proposto.

INTRODUÇÃO:

Otimização multiobjetivo (OMO) trata de problemas definidos por mais de um critério a ser otimizado e que são mutuamente conflitantes. Dentre os algoritmos que se destacam para resolução dessa categoria de problemas pode-se citar o Non-dominated Sorting Genetic Algorithm II (NSGA-II) DEB et al. (2000) e o Strength Pareto Evolutionary Algorithm II (SPEA2) ZITZLER, LAUMANNNS e THIELE (2001). Tais métodos apresentam o conceito de Pareto-dominância, responsável pela comparação dos diferentes indivíduos no espaço de soluções, dado que alguns indivíduos são melhores em determinados objetivos e piores em outros. Através da dominância, são geradas diversas fronteiras onde os indivíduos são ordenados pelo fato de dominarem ou serem dominados por outras soluções.

Dessa forma, o conceito de dominância pode ser relacionado ao conceito de convergência do algoritmo, que nada mais é que a direcionalidade das soluções à fronteira Pareto real, que é a região dos valores ótimos do problema. Pode-se notar que, ao contrário das aplicações que apresentam apenas um objetivo (maximização ou minimização), temos neste caso várias soluções do problema multiobjetivo, as quais são incomparáveis entre si. Outro conceito importante é o conceito de diversidade, que está relacionado à distribuição das soluções na fronteira Pareto. Um resultado com boa diversidade apresenta os pontos bem distribuídos na fronteira. Já resultados indesejáveis apresentam pouca diversidade ao gerar soluções muito próximas entre si e que não representam bem o espaço de soluções ótimas.

Uma vez que existem dois parâmetros comumente utilizados para a avaliação do desempenho de algoritmos multiobjetivos (convergência e diversidade), não é uma tarefa trivial estabelecer critérios de comparação entre diferentes algoritmos, ZITZLER et al. (2002). Inicialmente foi proposto o método de Distância Geracional (GD), que mede a proximidade da fronteira Pareto (conjunto de soluções não dominadas) do algoritmo em relação à fronteira real. Entretanto este método avalia apenas a convergência do algoritmo proposto, sem observar a diversidade do mesmo, e ainda faz-se necessário o conhecimento da fronteira Pareto real do problema de otimização, de forma que, em algumas aplicações, não se sabe

previamente a região ótima. Por outro lado, para avaliação de algoritmos em testes benchmarking, essa informação está disponível, uma vez que tais problemas já foram exaustivamente abordados na literatura.

Nesse contexto foi proposto o método GD invertido, denominado de IGD, que mede a divergência entre os pontos da fronteira Pareto real com a fronteira obtida BEZERRA et al. (2017). Essa inversão possibilita que além da convergência, seja também avaliado o critério da diversidade da solução proposta. No entanto, novamente existe o problema da necessidade de conhecimento prévio da fronteira Pareto real. Dessa forma, foi proposto o método de Hipervolume ZITZLER et al. (2007), cuja proposta é avaliar a distribuição das soluções geradas pelo algoritmo em relação ao espaço de busca, através da medida da região dominada pelas soluções em relação a um ponto de referência. Este método destaca-se por eliminar a necessidade do conhecimento prévio da fronteira Pareto real, entretanto apresenta um custo computacional elevado em comparação com outras métricas.

Segundo EMMERICH e DEUTZ (2018), uma determinada solução pertence ao conjunto Pareto-ótimo caso não existam outras soluções viáveis capazes de melhorar determinado objetivo sem consequentemente piorar qualquer outro objetivo pertencente ao problema. Nesse contexto é apresentado o conceito de dominância. Dado uma solução qualquer, a mesma domina outra solução caso seja melhor ou igual em todos os objetivos do problema ou caso exista algum objetivo em que seja estritamente melhor que a outra solução, sendo que esta passa a ser dominada por aquela.

De forma análoga, a região ótima do problema de OMO no espaço de variáveis pode ser definida como a solução a qual não é dominada por nenhuma outra solução. Graficamente podemos visualizar a dominância através da região cinza da Figura 1-a, que mostra a dominância dos indivíduos a, b e c em um problema de maximização GALVAN et al. (2013). Pode-se notar, através da representação gráfica na Figura 1-b que, uma vez que a área de dominância aumenta, torna-se possível estabelecer relações de dominância e não dominância entre as possíveis soluções da população, de forma a solucionar o problema de baixa pressão de seleção.

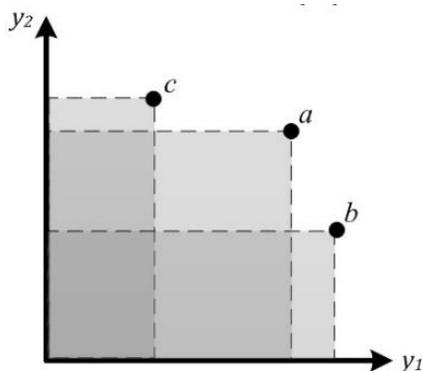


Figura 1-a: Representação Gráfica da região de dominância

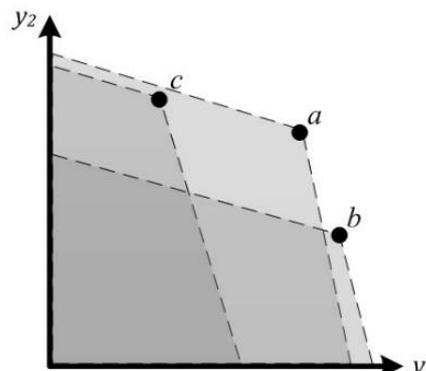


Figura 1-b: Região de dominância ajustada

No entanto, para aplicações com mais de três objetivos, surgem alguns problemas em relação à definição da fronteira Pareto através do critério de dominância, uma vez que as soluções geradas se tornam incomparáveis entre si, produzindo muitas vezes, uma fronteira com soluções equivalentes ao tamanho da população inicial, devido à baixa pressão de seleção que ocorre em aplicações desse tipo, as quais são chamadas de problemas com muitos objetivos. Segundo FRITSCHÉ e POZO (2017), outro problema comum é a geração de filhos drasticamente diferentes dos pais, nos operadores de recombinação, devido ao espaço de busca de alta dimensão. Para solucionar tais problemas, alguns algoritmos implementam o conceito de decomposição, que é a divisão do problema com muitos objetivos em diversos subproblemas – através de vetores de ponderação – que são otimizados de forma paralela. Dentre os métodos propostos neste tipo de aplicação, destaca-se se o Multiobjective Evolutionary Algorithm Based on Decomposition (MOEA-D) ZHANG e LI (2007).

Alguns métodos baseados na evolução de métodos anteriores, apresentaram resultados interessantes nos últimos anos, para problemas com muitos objetivos LI et al. (2015a), dentre os quais destacam-se o NSGA-III e o MOEA-DD. Entretanto, FRITSCHÉ e POZO (2017) afirma que nenhum dos algoritmos é superior aos demais quando avaliado em diferentes classes de problemas com dimensões variadas.

O algoritmo NSGA-II proposto por DEB et al. (2000), é uma evolução do algoritmo NSGA proposto inicialmente em 1995, e foi bastante importante no sentido de apresentar um método para a preservação da

diversidade no espaço de objetivos, através de um mecanismo de seleção denominado distância de multidão, o qual seleciona os indivíduos com base na perímetro formado pelos cuboides em que os vértices são formados pelos vizinhos mais próximos. O algoritmo se baseia na subdivisão do espaço de soluções em diversas fronteiras Pareto baseadas no princípio de dominância e implementa mecanismos de seleção, cruzamento e mutação assim como outros algoritmos genéticos clássicos, entretanto, na etapa de seleção, utiliza o conceito de seleção pelo método de torneio por multidão, o qual compara diferentes soluções baseado na comparação dos níveis de dominância de cada solução, buscando garantir a convergência do algoritmo.

Sendo uma evolução do NSGA-II, focado em problemas com muitos objetivos, o NSGA-III DEB e JAIN (2014), apresenta sua principal diferença no mecanismo de seleção de diversidade dado que, a diversidade implementada no método anterior é computacionalmente custosa para problemas com um maior número de dimensões. Ao contrário do NSGA-II o qual utiliza o critério de distância de multidão, o NSGA-III baseia-se no critério de distância de nichos, baseado em pontos de referência distribuídos no espaço de objetivos. Tais pontos podem ser inseridos pelo usuário ou através da estruturação balanceada dos objetivos e servirão para organizar as soluções no espaço de objetivos e manter a diversidade dos indivíduos durante as etapas do processo evolutivo. Nesse contexto, define-se o conceito de distância das soluções através de nichos, que substitui o critério de distância de multidão implementado na versão anterior do algoritmo.

Para a implementação da distância de nichos, são gerados os pontos de referência. É realizada ainda, uma normalização das avaliações das funções objetivo, de maneira que tenham valores entre zero e um. Posteriormente calcula-se a distância de cada solução normalizada em relação aos pontos de referência. Com isso, associa-se cada solução ao ponto de referência mais próximo. É feita então a contagem dos pontos associados a cada nicho de forma que, no processo de seleção baseado nas diversas fronteiras Pareto, caso o número de indivíduos a serem inseridos na próxima população seja menor que o número de indivíduos na fronteira atual, é dada preferência para indivíduos que pertencem aos nichos com menor número de soluções associadas. As Figuras 2a e 2b, retiradas de ZHU et al. (2017), ilustram a definição dos pontos de referência e associação aos nichos em um espaço normalizado com três objetivos.

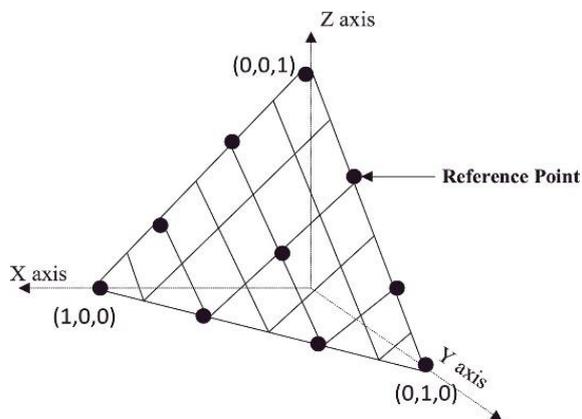


Figura 2-a: Pontos de referência

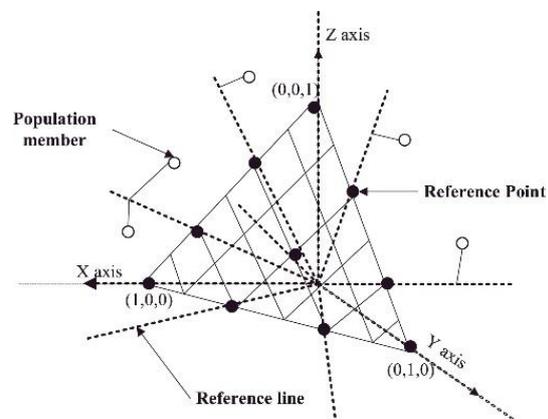


Figura 2-b: Associação aos nichos

Com o objetivo de propor soluções para o problema da perda de pressão de seleção, foram propostos algoritmos baseados no método de decomposição, que substitui o elitismo baseado nas fronteiras Pareto. A decomposição do espaço de objetivos é realizada através de um conjunto de vetores de peso, cuja finalidade é transformar um problema multiobjetivo em um conjunto de diversos problemas mono-objetivos, de forma que os mesmos sejam otimizados de forma paralela. O algoritmo é iniciado de maneira que cada membro da população seja associado de forma aleatória a um dos vetores de peso. A decomposição do espaço é realizada através da decomposição de Chebyshev CARVALHO et al. (2012). Dessa forma, definem-se as funções de penalidade baseada nos limites de interseção PBI (Penalty Boundary Intersection) ZHANG e LI (2007).

O MOEA/DD (Multiobjective Evolutionary Algorithm Based on Decomposition and Dominance) LI et al. (2015b) é a evolução do algoritmo citado na seção anterior, onde, além do método de decomposição descrito anteriormente, implementa ainda o método de dominância, de forma que cada vetor não defina apenas subproblemas, mas especifica ainda sub-regiões no espaço dos objetivos. Um dos problemas do algoritmo anterior era a gestão da diversidade para dimensões mais altas. No MOEA/DD, é estimada a densidade populacional nas sub-regiões, associada à contagem de soluções por nichos, de modo a

preservar a diversidade. Outro fator importante é a geração de filhos próximos aos pais. Vale ressaltar que a proposta deste algoritmo é estendida também para problemas de otimização restritos.

Dessa forma, o principal objetivo deste trabalho é apresentar um método generalizado que utiliza os dois principais conceitos dos algoritmos evolucionários para problemas multi e com muitos objetivos, que são a dominância e a decomposição, baseado nesses dois algoritmos, os quais são o estado-da-arte de problemas com muitos objetivos.

METODOLOGIA:

A metodologia proposta busca combinar os algoritmos NSGA-III e MOEA/D de forma dinâmica, através de um critério de seleção de algoritmo em cada geração. Para tanto, busca-se definir um método de avaliação baseado no contexto problema-solução, de forma que seja aplicado o algoritmo mais adequado em cada etapa do processo evolutivo. A Figura 3 apresenta um fluxograma resumindo as principais propostas da metodologia. O principal desafio foi encontrar um método de combinar os dois algoritmos de forma automática e adaptativa, em relação ao contexto do problema. A princípio foi avaliada a variação do critério IGD, como fator de combinação dos algoritmos. Entretanto, a taxa de variação do IGD é notória a cada geração, sendo seu valor diminuído cada vez que a solução se aproxima da fronteira Pareto real.

Dessa forma, é proposto um método de mudança de algoritmo através de uma variável aleatória que define o modelo a ser utilizado (MOEA/D ou NSGA-III). Este método apresenta a falha de não conter informações a respeito do contexto do problema e, portanto não o tornar adaptativo à diferentes circunstâncias. Contudo, é um método simples que pode garantir maior robustez ao aliar dois algoritmos de características distintas.

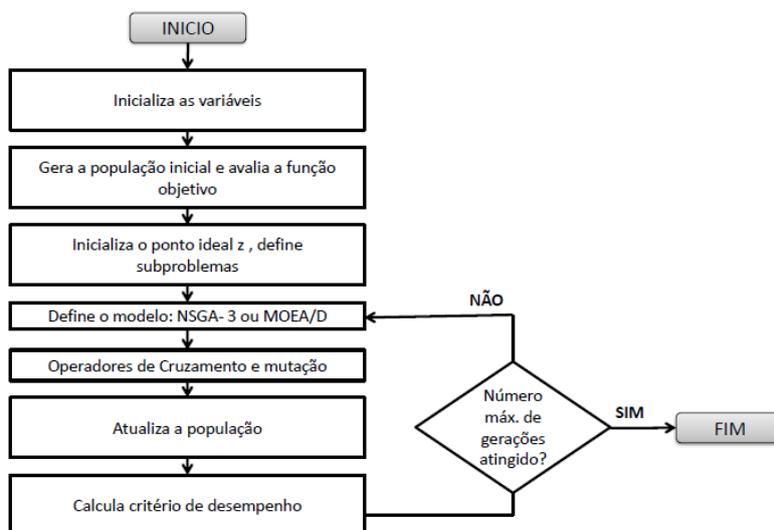


Figura 2: Fluxograma do método de combinação dos algoritmos

RESULTADOS E DISCUSSÕES:

O método proposto foi testado nos problemas benchmarking da família de funções DTLZ1 e DTLZ2 com três e cinco objetivos. Os valores foram obtidos em um computador com processador Intel Celeron de 1.7 GHz e memória RAM de dois GB. Os valores de IGD do modelo proposto são apresentados na Tabela 1, em comparação com os resultados dos principais algoritmos considerados estado-da-arte para esta classe de problemas, onde m representa o número de objetivos nos problemas avaliados. Nota-se que o desempenho foi relativamente menor, quando comparado com esses algoritmos. O tempo de execução é apresentado na Tabela 2.

Tabela 1: Comparação dos valores de IGD (melhor, médio e pior) para as funções DTLZ1 e DTLZ2 com 3 e 5 objetivos

Função	m	MOEA/DD	NSGA-III	Proposto
DTLZ1	3	3.191E-4	4.880E-4	1.87E-2
		5.848E-4	1.308E-3	3.51E-2
		6.573E-4	4.880E-3	6.51E-2
	5	2.635E-4	5.116E-4	6.68E-2
		2.916E-4	9.799E-4	8.79E-2
		3.109E-4	1.979E-3	1.04E-1
DTLZ2	3	6.666E-4	1.262E-3	3.75E-2
		8.073E-4	1.357E-3	7.16E-2
		1.243E-3	2.114E-3	1.13E-1
	5	1.128E-3	4.254E-3	1.51E-1
		1.291E-3	4.982E-3	1.89E-1
		1.424E-3	5.862E-3	2.38E-1

Tabela 2: Tempo de Execução da metodologia proposta

Função	m	Tempo (seg/execução)
DTLZ1	3	132.58
	5	942.50
DTLZ2	3	82.35
	5	552.26

A Figura 4 apresenta os resultados para DTLZ1 para três e cinco objetivos. Já a Figura 5 apresenta os resultados para DTLZ2. Embora os valores de IGD dos métodos estado da arte não foram alcançados, ressalta-se que a variância entre os melhores, médios e piores valores do IGD não foi muito significativa, podendo-se concluir que é um método que apresenta estabilidade.

O método proposto teve ainda dificuldades no critério de divergência nas dimensões mais altas, como apresentado nos gráficos de coordenadas paralelas das Figuras 5b e 6b, assim também como o custo computacional elevado para cinco dimensões. Em relação à diversidade, pode-se, em trabalhos futuros, utilizar métodos de criação de população que distribuam melhor os indivíduos no espaço de busca (kmeans++ ou método de distribuição estatístico).

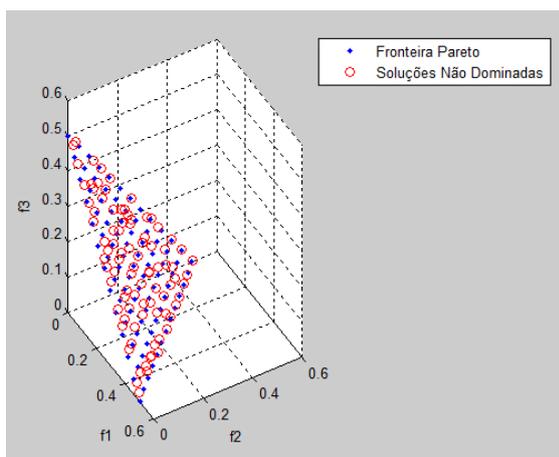


Figura 4-a: Resultados DTLZ1 com 3 objetivos

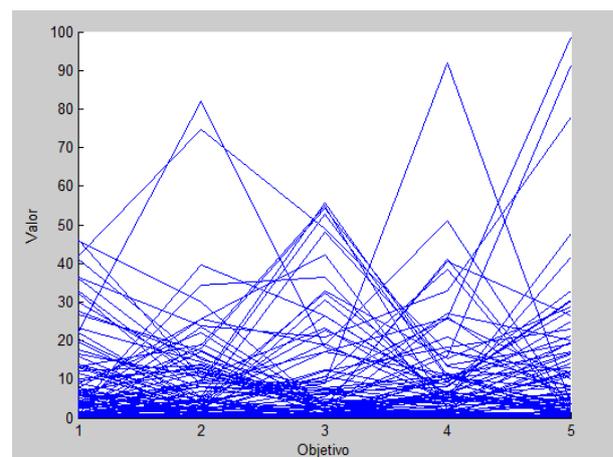


Figura 4-b: Resultados DTLZ1 com 5 objetivos

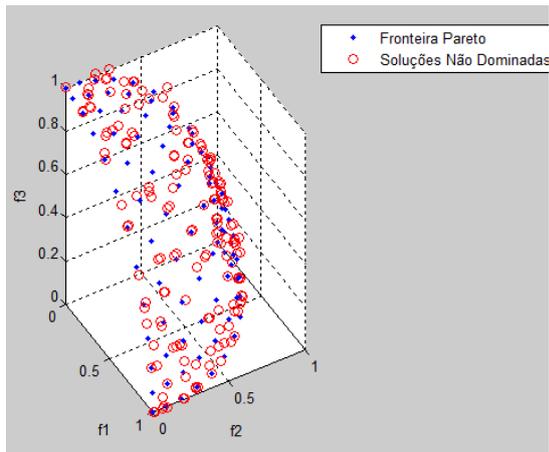


Figura 5-a: Resultados DTLZ2 com 3 objetivos

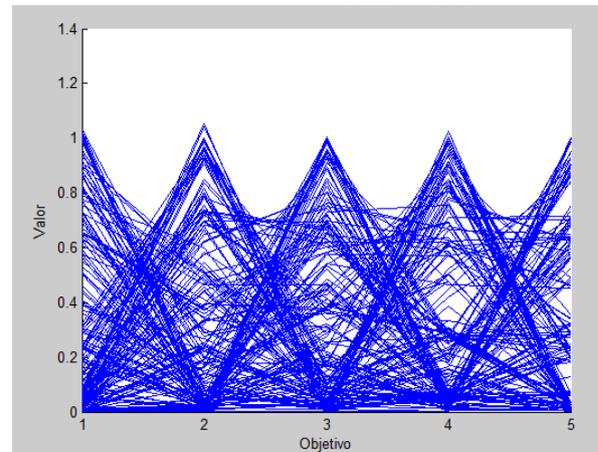


Figura 5-b: Resultados DTLZ2 com 5 objetivos

CONCLUSÕES:

Este trabalho apresentou uma revisão bibliográfica dos principais algoritmos evolucionários para solução de problemas multi e com muitos objetivos. Foi proposto ainda um método que busca a combinação adaptativa dos algoritmos NSGA-III e MOEA/D. O modelo proposto foi comparado com algoritmos estado-da-arte em testes benchmarking da família de funções DTLZ1 e 2 com 3 e 5 objetivos. Embora os resultados não foram melhores em comparação aos demais algoritmos, o método proposto apresenta um potencial para soluções que dependem de adaptação em relação ao contexto do problema.

Entretanto, por utilizar dois algoritmos distintos de forma alternada, o método proposto apresenta um custo computacional elevado. Pretende-se em trabalhos futuros, desenvolver mecanismos para melhorar a eficiência do mesmo, com o objetivo de reduzir o custo computacional, assim como desenvolver novos métodos de combinação de diferentes algoritmos de forma adaptativa em relação ao contexto do problema e aplicação.

REFERÊNCIAS BIBLIOGRÁFICAS:

BEZERRA, Leonardo CT; LÓPEZ-IBÁÑEZ, Manuel; STÜTZLE, Thomas. An empirical assessment of the properties of inverted generational distance on multi-and many-objective optimization. In: **International Conference on Evolutionary Multi-Criterion Optimization**. Springer, Cham, 2017. p. 31-45.

CARVALHO, Rodrigo de et al. A multi-objective evolutionary algorithm based on decomposition for optimal design of Yagi-Uda antennas. **IEEE Transactions on Magnetics**, v. 48, n. 2, p. 803-806, 2012.

DEB, Kalyanmoy et al. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. In: **International conference on parallel problem solving from nature**. Springer, Berlin, Heidelberg, 2000. p. 849-858.

DEB, Kalyanmoy; JAIN, Himanshu. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part I: solving problems with box constraints. **IEEE Transactions on Evolutionary Computation**, v. 18, n. 4, p. 577-601, 2013.

EMMERICH, Michael TM; DEUTZ, André H. A tutorial on multiobjective optimization: fundamentals and evolutionary methods. **Natural computing**, v. 17, n. 3, p. 585-609, 2018.

FRITSCHÉ, Gian; POZO, Aurora. A Heterogeneous Distributed Approach for Many-Objective Optimization. In: **2017 Brazilian Conference on Intelligent Systems (BRACIS)**. IEEE, 2017. p. 288-293.

GALVAN, Edgar et al. Performance assessment of a multi-objective parametric optimization algorithm with application to a multi-physical engineering system. **Structural and Multidisciplinary Optimization**, v. 58, n. 2, p. 489-509, 2018.

LI, Bingdong et al. Many-objective evolutionary algorithms: A survey. **ACM Computing Surveys (CSUR)**, v. 48, n. 1, p. 13, 2015.

LI, Ke et al. An evolutionary many-objective optimization algorithm based on dominance and decomposition. **IEEE Transactions on Evolutionary Computation**, v. 19, n. 5, p. 694-716, 2014.

ZHANG, Qingfu; LI, Hui. MOEA/D: A multiobjective evolutionary algorithm based on decomposition. **IEEE Transactions on evolutionary computation**, v. 11, n. 6, p. 712-731, 2007.

ZHU, Yingying et al. An improved NSGA-III algorithm for feature selection used in intrusion detection. **Knowledge-Based Systems**, v. 116, p. 74-85, 2017.

ZITZLER, Eckart et al. Why quality assessment of multiobjective optimizers is difficult. In: **Proceedings of the 4th Annual Conference on Genetic and Evolutionary Computation**. Morgan Kaufmann Publishers Inc., 2002. p. 666-674.

ZITZLER, Eckart; BROCKHOFF, Dimo; THIELE, Lothar. The hypervolume indicator revisited: On the design of Pareto-compliant indicators via weighted integration. In: **International Conference on Evolutionary Multi-Criterion Optimization**. Springer, Berlin, Heidelberg, 2007. p. 862-876.

ZITZLER, Eckart; LAUMANN, Marco; THIELE, Lothar. SPEA2: Improving the strength Pareto evolutionary algorithm. **TIK-report**, v. 103, 2001.