

Algoritmos Evolutivos Aplicados a Problemas de Otimização Combinatória com Muitos Objetivos

Estudo de Caso Aplicado a um Problema de Transporte Reativo a Demanda

Renan José dos Santos Viana

renanjviana@gmail.com

9 de julho de 2021

1. Problemas de Otimização Multiobjetivo
2. Estudo de Caso
3. Algoritmos Evolutivos Avaliados
4. Experimentos Computacionais
5. Resultados
6. Conclusões
7. Trabalhos Futuros

Problemas de Otimização Multiobjetivo

Estudo de Caso

Algoritmos Evolutivos Avaliados

Experimentos Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- *Multi-objective Optimization Problems* (MOPs).
- Envolverem a otimização simultânea de vários objetivos frequentemente conflitantes.
- Usualmente, não há uma única solução ótima, em vez disso, busca-se um conjunto de soluções ótimas intitulado **conjunto Pareto-ótimo**.
 - Representam os possíveis *trade-offs* entre os objetivos.
- A imagem deste conjunto no espaço de objetivo é intitulada **fronteira Pareto-ótimo**.
- No mundo real, a grande maioria dos problemas de tomada de decisão apresentam natureza multiobjetivo.
- Frequentemente tratados por meio de algoritmos evolutivos multiobjetivo, do inglês *Multiobjective Evolutionary Algorithms* (MOEAs).

Problemas de Otimização Multiobjetivo

Estudo de Caso

Algoritmos Evolutivos Avaliados

Experimentos Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- *Many-Objective Optimization Problems* (MaOPs).
- MOPs compostos por múltiplos objetivos conflitantes (quatro ou mais objetivos).
- Assim como um MOP, usualmente, não há uma única solução ótima, em vez disso, busca-se o **conjunto Pareto-ótimo**.
- Promovem novos e complexos desafios, dado que otimizá-los é significativamente mais difícil que otimizar MOPs tradicionais.
- Usualmente tratados por meio de MOEAs e *Many-objective Evolutionary Algorithms* (MaOEAs).

Problemas de Otimização Multiobjetivo

Estudo de Caso

Algoritmos Evolutivos Avaliados

Experimentos Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Ineficácia da relação de dominância Pareto quando utilizada para comparar soluções em espaços de objetivo com alta dimensionalidade.
- Espaço de busca extremamente grande.
- Intensificação do conflito entre convergência e diversidade a medida que aumenta o número de objetivos conflituosos.
- Aumento exponencial no número de soluções necessárias para se obter uma completa aproximação da fronteira Pareto.
- Dificuldade de visualização da fronteira Pareto.
- Dificuldade e alto custo computacional para mensurar diversidade.
- Métricas de avaliação de performance computacionalmente custosas.
- ...

Problemas de Otimização Multiobjetivo

Estudo de Caso

Algoritmos Evolutivos Avaliados

Experimentos Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- De acordo com He and Yen (2017), frequentemente, os seguintes pontos são negligenciados ao se projetar um novo MaOEA:
 - O critério de seleção para reprodução adotado deve considerar tanto a qualidade de cada indivíduo pai, quanto a efetividade da combinação dos indivíduos pais selecionados.
 - O critério de seleção para sobrevivência escolhido deve focar na performance de toda a população em vez de focar em cada indivíduo individualmente.
 - Os critérios de seleção adotados na seleção para reprodução e na seleção de sobreviventes devem se complementar de forma que a combinação de ambos resulte em uma boa performance do algoritmo.

Problemas de Otimização Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Abordagens baseadas em relações de dominância alternativas a dominância Pareto;
- Abordagens de decomposição baseadas em agregação;
- Abordagens de decomposição baseadas em vetores de referência;
- Abordagens baseadas em indicador de qualidade;
- Abordagens baseadas em informação de preferência;
- Abordagens baseadas em redução de dimensionalidade.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Analisar e compreender a influência de algumas propriedades de um MaOP combinatório no desempenho de MOEAs/MaOEAs, projetados com base em diferentes estratégias.

- Transporte Reativo à Demanda, do inglês *Demand Responsive Transport* (DRT).
 - Termo utilizado para nomear serviços de transporte flexíveis que **operam sob-demanda**.
 - Operacionalizado por meio de uma frota de veículos (por exemplo, ônibus, vans, carros, etc.).
 - Programado para transportar passageiros de acordo com suas necessidades.
- Normalmente, é um serviço de transporte **compartilhado**.
- Este tipo de serviço é uma forma intermediária de transporte, localizado entre os **serviços de transporte convencionais** providos por meio de ônibus e os **serviços de táxis**.
- Introduzido em Chevrier et al. (2010) e posteriormente abordado em Chevrier et al. (2012).

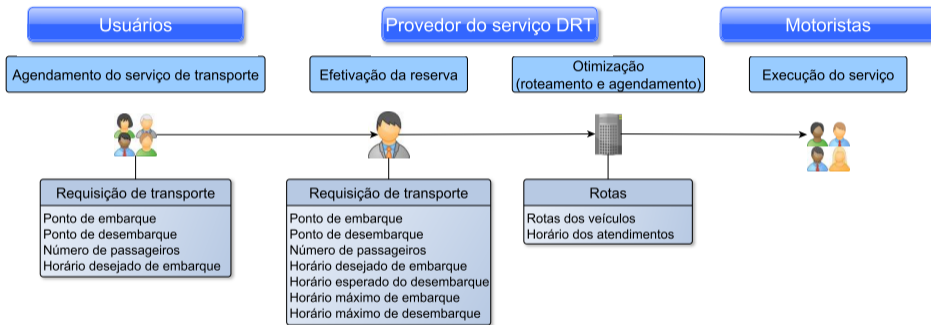


Figura 1: Representação esquemática do serviço DRT.

- Em geral, este planejamento é modelado como um problema de otimização combinatório intitulado *Dial-a-Ride Problem* (DARP).
- O DARP é um clássico problema de **roteirização** e **programação** de veículos e consiste em **projetar rotas** e **definir horários de atendimento** para um serviço de transporte coletivo sob demanda.
 - Diversos usuários formulam requisições de transporte.
 - O provedor do serviço busca atender todas as requisições de transporte minimizando os custos operacionais, enquanto um conjunto de restrições garante a qualidade do serviço.

- Inicialmente proposto como um MOP, o problema abordado foi formulado como um MaOP.
- O serviço DRT em estudo otimiza cinco funções objetivo $f = (f_1, f_2, f_3, f_4, f_5)$ enquanto satisfaz um conjunto de restrições. Busca-se minimizar:
 - O número de rotas necessárias (f_1);
 - A duração total das rotas (f_2);
 - O atraso total no desembarque dos passageiros (f_3);
 - A distância total das rotas (f_4);
 - O tempo total de espera dos usuários para o embarque (f_5).

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Abordagens baseadas na relação de dominância Pareto:

- *Non-Dominated Sorting Genetic Algorithm II (NSGA-II)*
 - Proposto por Deb et al. (2002).
 - Como critério de seleção primário emprega o conceito de Pareto otimalidade para promoção da convergência.
 - Como critério de seleção secundário utiliza um operador de preservação de diversidade baseado em distância de aglomeração, que estima a densidade de soluções ao redor de cada solução da população.

Abordagens baseadas na relação de dominância Pareto:

- *Strength Pareto Evolutionary Algorithm 2 (SPEA-2)*
 - Proposto por Zitzler et al. (2001).
 - Como critério de seleção primário emprega o conceito de Pareto otimalidade, mas a avaliação de cada indivíduo da população é realizada levando em consideração tanto os indivíduos que o dominam quanto os indivíduos que são dominadas pelo mesmo.
 - Como critério de seleção secundário utiliza um operador de preservação de diversidade que estima a densidade da vizinhança mais próxima para auxiliar a manutenção da diversidade.

Abordagens de decomposição baseadas em agregação:

- *Multiobjective Evolutionary Algorithm Based on Decomposition (MOEA/D)*
 - Proposto por Zhang and Li (2007).
 - Combina o tradicional método matemático de decomposição com algoritmos evolutivos.
 - Decompõe um MOP em vários problemas de otimização mono-objetivo (subproblemas) por meio de vetores de peso e funções de escalarização e otimiza todos simultaneamente em uma única execução.
- *MOEA/D with global replacement (MOEA/D-GR)*
 - Proposto por Wang et al. (2014).
 - Variante do MOEA/D que prioriza os subproblemas mais adequados em vez dos subproblemas vizinhos para execução do procedimento de atualização das soluções com o objetivo de realizar uma transferência de informação mais eficiente.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

**Algoritmos
Evolutivos Avaliados**

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Abordagens de decomposição baseadas em conjunto de vetores de referência:

- *Non-dominated Sorting Genetic Algorithm III (NSGA-III)*
 - Proposto por DEB and JAIN (2014).
 - Como critério de seleção primário emprega o conceito de Pareto otimalidade para promoção da convergência.
 - Como critério de seleção secundário utiliza um operador de preservação de diversidade baseado em decomposição para manutenção da diversidade.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Abordagens de decomposição baseadas em conjunto de vetores de referência:

- *Strength Pareto Evolutionary Algorithm Based on Reference Direction (SPEA/R)*
 - Proposto por Jiang and Yang (2017).
 - Variante do SPEA2 viabilizada para lidar com MaOPs.
 - Critério de seleção de sobreviventes projetado com base no paradigma *diversity-first-and-convergence-second*.
 - A atribuição de aptidão considera a convergência tanto local quanto global.
 - Adota uma técnica de estimação de diversidade baseada em ângulo vetorial para promoção da diversidade.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

**Algoritmos
Evolutivos Avaliados**

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Abordagens baseadas em indicador de qualidade:

- *Indicator-based Multi-objective Evolutionary Algorithm (IBEA)*
 - Proposto por Zitzler and Künzli (2004).
 - Emprega o indicador de qualidade $I_{\epsilon+}$ para guiar o processo de busca.

Abordagens baseadas em dois arquivos:

- *Two Arch Algorithm 2 (Two_Arch2)*
 - Proposto por Wang et al. (2015).
 - Mantém um arquivo com ênfase em convergência (CA) e um arquivo com ênfase em diversidade (DA).
 - Emprega o indicador de qualidade $I_{\epsilon+}$ para guiar o processo de busca em CA e utiliza a relação de dominância Pareto e uma análise do grau de similaridade (distância de *Minkowski*) para guiar o processo de busca em DA.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

**Algoritmos
Evolutivos Avaliados**

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Tanto o procedimento de geração da população inicial quanto os operadores de variação utilizados para compor os algoritmos utilizados foram introduzidos em VIANA (2016) e posteriormente utilizados em Viana et al. (2019).

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

**Experimentos
Computacionais**

Resultados

Conclusões

Trabalhos Futuros

Referências

Ambiente Computacional

- Os experimentos computacionais foram executados em um computador com processador Intel Xeon E5-2630 v4, com 2.2 GHz de frequência, com 10 cores, e com 32GB de memória RAM, executando o sistema operacional *CentOS* 6.6.
- Os algoritmos utilizados foram codificados em C++.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

**Experimentos
Computacionais**

Resultados

Conclusões

Trabalhos Futuros

Referências

Conjuntos de Instâncias de Teste

- Introduzidos em Chevrier et al. (2010) e posteriormente utilizados em Chevrier et al. (2012).
 - Rnd100: Composto por 10 instâncias de teste com uma **distribuição homogênea** de usuários. Cada uma delas contém 100 requisições de transporte geradas aleatoriamente.
 - Gravit100: Composto por 10 instâncias de teste com uma **distribuição heterogênea** de usuários. Cada uma delas contém 100 requisições de transporte geradas utilizando um modelo geográfico de pessoas ou de fluxos de mercadorias.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Hypervolume indicator (I_H)

- Proposto por Zitzler and Thiele (1998).
- Quantifica informações tanto de **convergência** quanto de **diversidade** do conjunto avaliado.
- $I_{HV}(A)$ calcula o hiper-volume da porção do espaço de objetivo que é fracamente dominada por um conjunto de aproximação A .
- Quanto **maior** o valor de $I_{HV}(A)$, **melhor** é a qualidade das soluções do conjunto avaliado.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Unary additive epsilon indicator ($I_{\epsilon+}$)

- Proposto por Zitzler et al. (2003).
- Mensura a qualidade do conjunto avaliado em termos de **convergência**.
- Baseado no conceito de ϵ -dominância, $I_{\epsilon+}(A, R)$ calcula o fator mínimo ϵ necessário para qualquer vetor de objetivo do conjunto de referência R seja ϵ -dominado por pelo menos um vetor de objetivo do conjunto de aproximação A .
- Quanto **menor** o valor de $I_{\epsilon+}(A, R)$, **melhor** é a qualidade de A .

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Com base nos valores de I_{HV} e I_{ϵ^+} obtidos, análises estatísticas foram conduzidas utilizando um procedimento estatístico **não paramétrico** uma vez que a hipótese de normalidade dos dados foi rejeitada em todos os casos.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Conforme proposto por Bader and Zitzler (2011), para cada instância de teste, uma comparação par-a-par dos algoritmos é realizada aplicando o teste de *Wilcoxon-Mann-Whitney* (*Wilcoxon rank-sum test*).
 - H_0 : os valores de indicadores de qualidade obtidos pelos dois algoritmos avaliados não diferem em localização, sendo a diferença nos resultados puramente ocasionada ao acaso.
 - H_1 : os valores diferem significativamente em localização.
- Os testes de hipóteses foram realizados usando um nível de significância de 95%.

- Suponha que para cada instância de teste, n algoritmos $A_1 \dots A_n$ são comparados com base nos valores de uma métrica de performance qualquer.
- Para cada $i \in \{1, \dots, n\}$ e $j \in \{1, \dots, n\} \setminus \{i\}$, δ_{ij} assumirá o valor 1, se o algoritmo A_j supera significativamente o algoritmo A_i com base no teste estatístico utilizado. Caso contrário, δ_{ij} assume 0.

$$P(A_i) = \sum_{j \in \{1, \dots, n\} \setminus \{i\}}^n \delta_{ij} \quad (4.1)$$

- $P(A_i)$ representa quantos algoritmos superam A_i em uma determinada instância de teste.
- Quanto menor $P(A_i)$, melhor é o desempenho do algoritmo A_i .

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Tamanho da população e critério de parada foram estabelecidos iguais para todos os algoritmos avaliados.
- 31 execuções independentes (diferentes sementes) foram realizadas para cada algoritmo em cada instância de teste.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Para geração do conjunto de vetores de peso (ou vetores de referência, ou direções de referência), elemento essencial para as **abordagens de decomposição**, foi utilizado a abordagem sistemática proposta por Das and Dennis (1998).
 - Foi estabelecido 6 divisões. Dado que são 5 objetivos, 210 vetores de peso serão gerados.
- Para os algoritmos MOEA/D e MOEA/D-GR foram utilizadas populações de tamanho $N = 210$. Para os demais MOEAs avaliados foi estabelecido tamanho da população igual a $N = 212$.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- As taxas de **recombinação** e de **mutação** foram calibradas por meio de experimentos computacionais com o intuito de identificar as condições nas quais as abordagens de busca avaliadas apresentam o melhor desempenho.
 - Probabilidade de recombinação (*crossover*): 100%.
 - Probabilidade de mutação: 20%.

■ Parâmetros específicos de cada MOEA:

- **MOEA/D e MOEA/D-GR:** A abordagem *Tchebychev* foi selecionada como método de escalarização, e o tamanho da vizinhança foi definido como $N \times 0.1$.
- **IBEA ϵ +**: O parâmetro k utilizado no cálculo da aptidão foi definido como 0.05.
- **SPEA2:** Tamanho do arquivo definido como 100.
- **Two_ARCH2:** Tamanho de CA definido como 100 e o p utilizado na norma L_p definido como $1/M$.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Tabela 1: Resultados obtidos pelos oito MOEAs para as instâncias de teste do conjunto “Gravit100” utilizando o I_{HV} .

Instância	IBEA	MOEA/D	MOEA/D-GR	NSGA-II	NSGA-III	SPEA2	SPEA-R	Two_ARCH2
Gravit100_0	0,9565 (2)	0,9028 (3)	0,8831 (4)	0,7991 (7)	0,8478 (5)	0,7285 (8)	0,813 (6)	0,9763 (1)
Gravit100_1	1,0017 (2)	0,9293 (3)	0,932 (3)	0,7777 (7)	0,8719 (5)	0,7142 (8)	0,8214 (6)	1,0229 (1)
Gravit100_2	0,9538 (1)	0,8957 (3)	0,8942 (3)	0,7784 (7)	0,8488 (5)	0,7311 (8)	0,7951 (6)	0,9458 (1)
Gravit100_3	0,979 (2)	0,9263 (3)	0,9279 (3)	0,8332 (7)	0,8636 (5)	0,765 (8)	0,8556 (5)	1,0171 (1)
Gravit100_4	1,0689 (1)	0,9825 (3)	0,9727 (3)	0,886 (7)	0,9443 (5)	0,8172 (8)	0,9142 (6)	1,0711 (1)
Gravit100_5	1,0066 (2)	0,9398 (3)	0,9398 (3)	0,8297 (7)	0,8972 (5)	0,791 (8)	0,8461 (6)	1,0316 (1)
Gravit100_6	0,9514 (1)	0,8835 (4)	0,8947 (3)	0,781 (6)	0,8329 (5)	0,7256 (8)	0,7942 (6)	0,9535 (1)
Gravit100_7	1,0215 (1)	0,9788 (3)	0,9588 (4)	0,869 (7)	0,9204 (5)	0,8078 (8)	0,8939 (6)	1,0329 (1)
Gravit100_8	1,0866 (1)	1,0262 (3)	1,0196 (3)	0,9024 (7)	0,9662 (5)	0,8433 (8)	0,9528 (6)	1,0976 (1)
Gravit100_9	1,0466 (2)	0,9667 (3)	0,9755 (3)	0,8441 (7)	0,932 (5)	0,7681 (8)	0,875 (6)	1,0677 (1)

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Tabela 2: Resultados obtidos pelos oito MOEAs para as instâncias de teste do conjunto “Gravit100” utilizando o I_{ϵ^+} .

Instância	IBEA	MOEA/D	MOEA/D-GR	NSGA-II	NSGA-III	SPEA2	SPEA-R	Two_ARCH2
Gravit100_0	0,1123 (1)	0,1317 (3)	0,1411 (4)	0,1892 (6)	0,1504 (5)	0,2072 (7)	0,2195 (8)	0,1119 (1)
Gravit100_1	0,0938 (2)	0,1428 (4)	0,1364 (3)	0,2028 (6)	0,1484 (4)	0,2152 (7)	0,2133 (7)	0,0881 (1)
Gravit100_2	0,1056 (1)	0,1389 (3)	0,1385 (3)	0,1679 (6)	0,145 (5)	0,1846 (7)	0,2126 (8)	0,1154 (2)
Gravit100_3	0,1059 (1)	0,136 (3)	0,1337 (3)	0,1916 (6)	0,1496 (5)	0,1961 (6)	0,2162 (8)	0,1032 (1)
Gravit100_4	0,1024 (1)	0,1446 (3)	0,1534 (4)	0,1847 (6)	0,1581 (4)	0,1981 (7)	0,208 (8)	0,1032 (1)
Gravit100_5	0,0957 (2)	0,1369 (3)	0,135 (3)	0,1761 (6)	0,1538 (5)	0,1927 (7)	0,2221 (8)	0,0864 (1)
Gravit100_6	0,1043 (1)	0,1471 (3)	0,1413 (3)	0,1748 (6)	0,1566 (5)	0,205 (7)	0,2102 (7)	0,1009 (1)
Gravit100_7	0,0953 (1)	0,1212 (3)	0,1229 (3)	0,1667 (6)	0,1371 (5)	0,1797 (7)	0,1887 (7)	0,095 (1)
Gravit100_8	0,095 (1)	0,1359 (3)	0,1303 (3)	0,1823 (6)	0,1556 (5)	0,2027 (8)	0,1948 (7)	0,0989 (1)
Gravit100_9	0,0994 (1)	0,1376 (3)	0,1352 (3)	0,1861 (6)	0,1429 (3)	0,2072 (7)	0,199 (7)	0,0942 (1)

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Tabela 3: Resultados obtidos pelos oito MOEAs para as instâncias de teste do conjunto “*Rnd100*” utilizando o I_{HV} .

Instância	IBEA	MOEA/D	MOEA/D-GR	NSGA-II	NSGA-III	SPEA2	SPEA-R	Two_ARCH2
Rnd100_0	0,8786 (2)	0,7991 (3)	0,7885 (4)	0,7837 (4)	0,7836 (4)	0,7787 (7)	0,7307 (8)	0,907 (1)
Rnd100_1	0,8464 (2)	0,7547 (3)	0,7436 (5)	0,7262 (6)	0,7553 (3)	0,7184 (7)	0,7015 (8)	0,8648 (1)
Rnd100_2	0,8428 (2)	0,7614 (3)	0,7505 (4)	0,7394 (6)	0,7541 (4)	0,721 (7)	0,6775 (8)	0,8616 (1)
Rnd100_3	0,8277 (2)	0,7492 (3)	0,7427 (4)	0,7141 (6)	0,7392 (4)	0,7101 (6)	0,6623 (8)	0,8472 (1)
Rnd100_4	0,888 (2)	0,8293 (4)	0,8211 (7)	0,8285 (4)	0,8247 (6)	0,8364 (3)	0,7611 (8)	0,9063 (1)
Rnd100_5	0,851 (2)	0,7813 (3)	0,7728 (4)	0,7736 (4)	0,7649 (6)	0,7577 (6)	0,7026 (8)	0,8684 (1)
Rnd100_6	0,8149 (2)	0,7584 (3)	0,7404 (4)	0,6935 (7)	0,7387 (4)	0,7249 (6)	0,6874 (7)	0,8381 (1)
Rnd100_7	0,8085 (2)	0,7504 (3)	0,7404 (4)	0,7021 (6)	0,7172 (5)	0,7044 (6)	0,6756 (8)	0,8266 (1)
Rnd100_8	0,8495 (2)	0,7667 (3)	0,749 (4)	0,7278 (6)	0,7366 (5)	0,724 (6)	0,696 (8)	0,8726 (1)
Rnd100_9	0,8901 (2)	0,828 (3)	0,8166 (5)	0,8223 (4)	0,8096 (6)	0,8014 (7)	0,7205 (8)	0,8995 (1)

Tabela 4: Resultados obtidos pelos oito MOEAs para as instâncias de teste do conjunto “*Rnd100*” utilizando o I_{ϵ^+} .

Instância	IBEA	MOEA/D	MOEA/D-GR	NSGA-II	NSGA-III	SPEA2	SPEA-R	Two_ARCH2
Rnd100_0	0,0458 (2)	0,1304 (4)	0,1429 (7)	0,1364 (4)	0,1309 (4)	0,1197 (3)	0,2441 (8)	0,0422 (1)
Rnd100_1	0,0441 (2)	0,1424 (5)	0,1532 (6)	0,1585 (6)	0,1318 (3)	0,1293 (3)	0,2421 (8)	0,038 (1)
Rnd100_2	0,0463 (2)	0,1118 (4)	0,1226 (5)	0,137 (7)	0,1077 (3)	0,1211 (5)	0,2331 (8)	0,0418 (1)
Rnd100_3	0,0428 (2)	0,1224 (3)	0,1502 (7)	0,1206 (3)	0,1351 (6)	0,1173 (3)	0,2435 (8)	0,037 (1)
Rnd100_4	0,0417 (2)	0,13 (5)	0,1495 (7)	0,1083 (4)	0,1306 (5)	0,0889 (3)	0,2311 (8)	0,0296 (1)
Rnd100_5	0,0474 (1)	0,1108 (3)	0,1313 (6)	0,1253 (6)	0,1121 (3)	0,1177 (3)	0,2187 (8)	0,0496 (1)
Rnd100_6	0,0611 (2)	0,1323 (5)	0,1427 (6)	0,1443 (6)	0,1205 (3)	0,1158 (3)	0,2373 (8)	0,0431 (1)
Rnd100_7	0,0494 (2)	0,1333 (3)	0,1408 (6)	0,1523 (7)	0,1301 (3)	0,1277 (3)	0,229 (8)	0,0469 (1)
Rnd100_8	0,0466 (1)	0,1282 (4)	0,135 (6)	0,1511 (7)	0,1183 (3)	0,1278 (4)	0,2364 (8)	0,0448 (1)
Rnd100_9	0,0396 (2)	0,1115 (6)	0,1296 (7)	0,1062 (3)	0,1076 (3)	0,1073 (3)	0,2393 (8)	0,0366 (1)

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Neste trabalho foi apresentada uma análise comparativa aplicada à uma formulação com muitos objetivos do problema combinatório *Dial-a-Ride Problem*.
- Esta análise foi realizada com o objetivo de comparar o desempenho de oito MOEAs/MaOEAs, projetados com base em diferentes estratégias, ao serem aplicados a um complexo problema combinatório.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Abordagens baseadas na relação de dominância Pareto apresentam dificuldades quando lidam com um alto número de objetivos.
- Para uma mesma formulação do problema, diferentes observações podem ser feitas sobre o comportamento dos algoritmos quando utilizados conjuntos de teste com diferentes características.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Embora o algoritmo IBEA seja originalmente proposto para lidar com MOPs, o mesmo superou MaOEA's projetados recentemente para tratar MaOPs.
- O bom desempenho dos algoritmos Two_ARCH2 e IBEA evidencia a importância de se utilizar indicadores de qualidade (com baixo custo computacional) para condução do processo de busca substituindo ou combinado à tradicional relação de dominância Pareto.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- MaOEA que combina simultaneamente múltiplas relações de dominância para promoção da convergência.
- MaOEA que combina múltiplas relações de dominância de forma que a escolha da relação de dominância seja baseada no momento do processo evolutivo. Isto é, a escolha da forma e do grau de relaxamento da dominância é realizada em tempo de execução.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- Hiper-heurística baseada em relações de preferência alternativas.
 - Abordagem hiper-heurística de seleção com aprendizado online.
 - Combina um conjunto de relações de preferência.
 - Promove uma seleção automatizada da relação de preferência mais adequada ao momento da busca.
- Abordagem de partição de objetivos baseada no modelo de ilhas.
 - Transforma o MaOP em problemas relacionados de menor tamanho.
 - Por meio de uma estratégia de partição de objetivos divide o problema original em diversos subproblemas de menor dimensão, e posteriormente executa uma ou várias gerações da busca evolutiva em cada subproblema.
 - Mantém uma população independente para cada subproblema durante todo o processo evolutivo.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Bader, J. and Zitzler, E. (2011). Hype: An algorithm for fast hypervolume-based many-objective optimization. *Evolutionary computation*, 19(1):45–76.

Chevrier, R., Liefoghe, A., Jourdan, L., and Dhaenens, C. (2010). On optimizing a demand responsive transport with an evolutionary multi-objective approach. In *Intelligent Transportation Systems (ITSC), 2010 13th International IEEE Conference on*, pages 575–580. IEEE.

Chevrier, R., Liefoghe, A., Jourdan, L., and Dhaenens, C. (2012). Solving a dial-a-ride problem with a hybrid evolutionary multi-objective approach: Application to demand responsive transport. *Applied Soft Computing*, 12(4):1247–1258.

Das, I. and Dennis, J. E. (1998). Normal-boundary intersection: A new method for generating the pareto surface in nonlinear multicriteria optimization problems. *SIAM journal on optimization*, 8(3):631–657.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

- DEB, K. and JAIN, H. (2014). 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*, 18(4):577–601.
- Deb, K., Pratap, A., Agarwal, S., and Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: Nsga-ii. *Evolutionary Computation, IEEE Transactions on*, 6(2):182–197.
- He, Z. and Yen, G. G. (2017). Many-objective evolutionary algorithms based on coordinated selection strategy. *IEEE Transactions on Evolutionary Computation*, 21(2):220–233.
- Jiang, S. and Yang, S. (2017). A strength pareto evolutionary algorithm based on reference direction for multiobjective and many-objective optimization. *IEEE Transactions on Evolutionary Computation*, 21(3):329–346.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

VIANA, R. J. D. S. (2016). Abordagens heurísticas para otimização de um serviço de transporte reativo a demanda. Master's thesis, Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Viçosa.

Viana, R. J. S., Santos, A. G., Martins, F. V. C., and Wanner, E. F. (2019). Optimization of a demand responsive transport service using multi-objective evolutionary algorithms. In *Proceedings of the Genetic and Evolutionary Computation Conference Companion, GECCO '19*, page 2064–2067, New York, NY, USA. Association for Computing Machinery.

Wang, H., Jiao, L., and Yao, X. (2015). Two_arch2: An improved two-archive algorithm for many-objective optimization. *IEEE Transactions on Evolutionary Computation*, 19(4):524–541.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Wang, Z., Zhang, Q., Gong, M., and Zhou, A. (2014). A replacement strategy for balancing convergence and diversity in moea/d. In *2014 IEEE Congress on Evolutionary Computation (CEC)*, pages 2132–2139. IEEE.

Zhang, Q. and Li, H. (2007). Moea/d: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on evolutionary computation*, 11(6):712–731.

Zitzler, E. and Künzli, S. (2004). Indicator-based selection in multiobjective search. In *Parallel Problem Solving from Nature-PPSN VIII*, pages 832–842. Springer.

Problemas de
Otimização
Multiobjetivo

Estudo de Caso

Algoritmos
Evolutivos Avaliados

Experimentos
Computacionais

Resultados

Conclusões

Trabalhos Futuros

Referências

Zitzler, E., Laumanns, M., Thiele, L., Zitzler, E., Zitzler, E., Thiele, L., and Thiele, L. (2001). SPEA2: Improving the strength pareto evolutionary algorithm. Technical report, Eidgenössische Technische Hochschule Zürich (ETH), Institut für Technische Informatik und Kommunikationsnetze (TIK).

Zitzler, E. and Thiele, L. (1998). Multiobjective optimization using evolutionary algorithms - a comparative case study. In *Parallel problem solving from nature - PPSN V*, pages 292–301. Springer.

Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C. M., and Da Fonseca, V. G. (2003). Performance assessment of multiobjective optimizers: An analysis and review. *Evolutionary Computation, IEEE Transactions on*, 7(2):117–132.

Thank You!



renanjviana@gmail.com