

Operador de cruzamento de partição generalizado aplicado no problema do caixeiro viajante

Generalized partition crossover operator applied to the traveling salesman problem

Vinicius Macedo Noda
viniciusnoda@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

Daniilo Sipoli Sanches
daniilosanches@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil

RESUMO

O problema do Caixeiro Viajante é um problema clássico de recombinação, por pertencer a família de problemas NP-difícil, não é possível resolvê-lo em tempo polinomial utilizando algoritmos exatos. Um meio de obter soluções próximas do ótimo em tempo reduzido é a utilização de algoritmos genéticos. Neste trabalho é proposto a utilização do operador de Cruzamento de Partição Generalizado juntamente a Otimização por Colônia de Formigas, para caminhar entre as estruturas do espaço de soluções do problema denominados funis, sendo estes agrupamentos de ótimos locais, a procura da solução global.

PALAVRAS-CHAVE: Problema do Caixeiro Viajante. Algoritmo Genético. Operador de Cruzamento de Partição Generalizado.

ABSTRACT

The traveling salesman problem is a classic problem of recombination, because it belongs to the family of NP-difficult problems, it is not possible to solve it in polynomial time using exact algorithms. One way to get close to optimal solutions in a reduced time is the use of genetic algorithms. In this work it is proposed the use of the Generalized Partition Crossing operator together with the Ant Colony Optimization to walk between the solution space structures called funnels, these clustering of optimal locations, the search for the global solution.

KEYWORDS: Traveling Salesman Problem, Genetic Algorithm. Generalized Partition Crossover.

Recebido: 31 ago 2018.

Aprovado: 04 out 2018.

Direito autoral:

Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.





INTRODUÇÃO

Estudos anteriores relatam que a estrutura de soluções do problema do caixeiro viajante (Traveling Salesman Problem, TSP) não é tão simples quanto se pensava. Ochoa e Veerapen (2016) descreve em seu artigo uma nova estrutura chamada de "funis", onde os ótimos locais se distribuem em vários vales e o ótimo global nem sempre está no maior vale explicando a necessidade de inícios aleatórios quando utilizando buscas locais.

O operador de Cruzamento de Partição (PX) foi proposto por Whitley et al. (2009) para permitir o "tunelamento" entre ótimos locais, ou seja, utilizar dois pais que são ótimos locais e gerar um filho que também é um ótimo local. Neste trabalho será utilizada uma implementação baseada no PX chamado Operador de Cruzamento de partição generalizada 2 (GPX2), proposto por Sanches et al. (2017).

Ele possui melhorias em relação ao operador original que permitem aproveitar melhor as soluções de boa qualidade, garantindo que se as arestas da solução ótima global estiverem presentes na população inicial, ela pode ser encontrada. Porém uma das características do GPX2 que serão descritas mais a frente é que ele não gera novas arestas, necessitando assim de uma outra fonte de variedade na população, sendo utilizado nesse trabalho a Otimização por Colônia de Formigas (ACO).

MÉTODOS

Nesta seção serão apresentados os conceitos base para o entendimento do trabalho e os operadores mais importantes utilizados no algoritmo genético desenvolvido.

CONCEITOS BASE

Neste trabalho o algoritmo genético será utilizado para encontrar soluções para o Problema do Caixeiro Viajante, que consiste em percorrer uma lista de cidades passando uma única vez por cidade e no final retornar a cidade inicial percorrendo a menor distância possível.

O 2-opt é um algoritmo de busca local simples para o TSP, proposto por Croes (1958), que diminui a distância fazendo a troca de duas arestas do grafo. Todas as arestas são testadas em pares, duas arestas são quebradas e as cidades são conectadas da outra forma possível. Se as arestas novas tiverem uma distância menor que as originais o movimento é então realizado e esse procedimento é repetido até nenhuma melhora for mais possível. Ele foi utilizado nesse trabalho para a geração da população inicial.

Os algoritmos genéticos são um método aproximado de encontrar soluções de boa qualidade para problemas de otimização em um tempo menor que os métodos exatos. Eles são baseados nos conceitos de Darwin da sobrevivência do mais forte, onde as soluções com melhor aptidão tem suas características transmitidas para a próxima geração. Empréstam também conceitos de genética



como cromossomos e os operadores de cruzamento e mutação. (KORA; YADLAPALLI, 2017)

OTIMIZAÇÃO POR COLÔNIA DE FORMIGAS

É uma meta-heurística utilizada para a resolução de problemas combinatórios baseada em como as formigas encontram o menor caminho entre uma fonte de comida e o ninho. Como descrita por Carvalho e Ramos (CARVALHO; RAMOS, 2007, no prelo), as formigas utilizam os feromônios deixados por outras formigas para decidir qual direção seguir. É levado em conta também a evaporação do feromônio, onde quanto maior a aresta maior a evaporação.

A ACO é uma meta-heurística probabilística, onde quanto mais formigas escolherem um caminho, mais feromônio será depositado e maior a probabilidade de outras formigas escolherem ele também. Devido a natureza probabilística da meta-heurística é possível que novos caminhos tenham a chance de serem escolhidos mesmo que eles possuam pouco feromônio.

OPERADOR DE CRUZAMENTO DE PARTIÇÕES 2

Foi primeiramente definido por Whitley et al. (2009), ele utiliza heurísticas para garantir que o operador tenha as características de *Respectful*, todos os nós que são comum aos dois pais são passados para o filho, e *Transmit Alleles*, os filhos são montados a partir de partições obtidas dos pais, logo nenhuma nova aresta é introduzida no filho. O PX, o operador de cruzamento em que o GPX2 se baseia, garante que se as duas soluções recombinadas forem ótimos locais, os filhos têm alta chance de serem ótimos locais. Podendo ser utilizado então para caminhar entre os ótimos locais, definido como Tunneling.

Neste trabalho será utilizada uma implementação adaptada e melhorada do PX, o Operador de Cruzamento de Partições Generalizado 2, baseada no algoritmo utilizado por Sanches et al. (2017).

O GPX2 funciona em sete passos, primeiramente é construído o grafo da união dos dois pais utilizado no cruzamento. Na união são criados então os nós *ghosts* nos nós que possuem grau quatro, ou seja, quatro arestas conectadas a um nó, isso é realizado para melhorar as chances de encontrar partições. O próximo passo é então cortar as arestas comuns aos dois pais no grafo da união. Utilizando as arestas restantes é então avaliado se a partição pode ser utilizada no cruzamento, chamada *feasible*, ou não, chamada *unfeasible*.

Após isso é utilizado o processo de *fusion*, nele duas partições *unfeasible* vizinhas são fundidas e avaliadas, se obedecerem as condições elas se tornam *feasible* e podem ser utilizadas no cruzamento, esse processo é então repetido até que não haja mais partições para fundir.

Na construção do filho, todas as arestas comuns são copiadas e cada partição *feasible* é avaliada em cada pai e a que tiver a menor distância é escolhida. Dessa forma, todas as arestas comuns são preservadas, garantindo a característica de *Respectful* e a de *Transmit Alleles*, pois as partições são sempre obtidas de um dos pais.

PROPOSTA

O objetivo deste trabalho é utilizar o Operador de Cruzamento de Partição Generalizado 2 (GPX2) para realizar o *Tunneling* entre os ótimos locais, descritos nas estruturas chamadas de *funnels*, e encontrar os ótimos globais das instâncias. Devido as características do operador de cruzamento será utilizado a Otimização por Colônia de Formigas para gerar variabilidade na população durante a execução do algoritmo genético.

RESULTADOS E DISCUSSÕES

Para a obtenção dos resultados foram utilizadas quatro configurações para o algoritmo genético, uma configuração utiliza o elitismo para escolher os cinco melhores indivíduos para passarem para a próxima geração e então preenche o resto dela utilizando o método de seleção da roleta para escolher pares que são então cruzados utilizando o operador de cruzamento OX, esta configuração foi utilizada como base para medir a eficácia do GPX2.

As outras três configurações utilizaram o GPX2, cruzando os cinco melhores indivíduos com toda a população e então salvando-os para a próxima geração, uma das configurações utilizou a reinicialização dos indivíduos para preencher a população. Outra configuração utilizou a ACO para gerar os outros indivíduos necessários para completar a população e uma terceira configuração combinou a reinicialização com a ACO para preencher a população.

Cada uma dessas configurações foi executada 20 vezes, variando-se o tamanho da população entre 25 e 50 indivíduos e a utilização ou não da heurística Lin-Kernighan para produzir soluções de alta qualidade na população inicial. Os *datasets* utilizados foram retirados da *TSPLIB* catalogada e disponibilizada por Reinelt (1991), são eles *att48*, *berlin52* e *eil101*. As execuções em que o ótimo global foram encontradas pela busca local na população inicial foram desconsideradas.

Nos resultados obtidos com o *dataset berlin52* foi observado que se comparado com o operador OX, o GPX2 converge rapidamente encontrando soluções de alta qualidade em poucas gerações e em problemas relativamente fáceis ele consegue encontrar os ótimos globais frequentemente.

Tabela 1 – Resultados para o problema *att48*

Tamanho da População	Lin-Kernighan	Configuração	Porcentagem de sol. Ótimas
25	Não	GPX2 e ACO com reinicialização	100
50	Sim		100
25	Não		100
50	Sim		100
25	Não	GPX2 e ACO	5
50	Sim		50
25	Não		35

Tamanho da População	Lin-Kerninghan	Configuração	Porcentagem de sol. Ótimas
50	Sim		100

Fonte: Autoria Própria.

Como pode ser observado na Tabela 1, a ACO não foi suficiente para inserir variabilidade suficiente na população, sendo necessário a utilização da reinicialização para melhores resultados. Para os resultados do *dataset eil101* foi observado a influência do tamanho da população para melhor explorar o espaço de busca do problema, possibilitando assim que o GPX2 tivesse acesso a soluções mais diversas e assim encontrar as características presentes nos ótimos globais mais frequentemente, como observado na Tabela 2. Pode também ser observado que a presença de soluções de alta qualidade obtidas pela heurística *Lin-Kerninghan* permitiu que a solução fosse encontrada com maior frequência e na análise da progressão do algoritmo, em menor tempo.

Tabela 2 – Resultados para o problema *eil101*

Tamanho da População	Lin-Kerninghan	Configuração	Porcentagem de sol. Ótimas
25	Não	GPX2 e ACO com reinicialização	30,00
50	Sim		66,67
25	Não		65,00
50	Sim		87,50

Fonte: Autoria Própria.

CONSIDERAÇÕES FINAIS

Os objetivos do trabalho eram realizar a implementação do GPX2 e devido as suas limitações, utilizar a ACO para melhorar o seu desempenho. Os resultados do GPX2 estão dentro do esperado e sua implementação mostrou-se válida para a utilização em futuros trabalhos. Porém as suas características apareceram nos testes onde populações pequenas mostraram rápida estagnação devido a não terem um espaço de busca grande o suficiente para agregar todas as características da solução ótima. Dessa forma as execuções com a reinicialização da população mostraram-se melhores para explorar o espaço de busca.

A utilização da Otimização por Colônia de Formiga apresentou melhorias nas execuções, se comparado a apenas o GPX2, porém não no nível esperado, utilizando apenas o ACO para introduzir variabilidade na população se mostrou insuficiente, com o GPX2 estagnando a população ainda precocemente.

Apesar dos resultados com o ACO é possível que com um ajuste dos parâmetros e uma integração melhor com o Operador de Cruzamento por Partições 2, talvez limitando sua execução, ele pudesse ser utilizado como uma forma de substituir a reinicialização para introduzir variabilidade.



REFERÊNCIAS

CARVALHO, E. M. de; RAMOS, G. S. Otimização por colônia de formigas (Ant Colony Optimization-ACO). 2007. No prelo.

CROES, Georges A. A method for solving traveling-salesman problems. Operations research, v. 6, n. 6, p. 791-812, 1958.

KORA, Padmavathi; YADLAPALLI, Priyanka. Crossover operators in genetic algorithms: A review. International Journal of Computer Applications, v. 162, n. 10, 2017.

OCHOA, Gabriela; VEERAPEN, Nadarajen. Deconstructing the big valley search space hypothesis. In: European Conference on Evolutionary Computation in Combinatorial Optimization. Springer, Cham, 2016. p. 58-73.

REINELT, Gerhard. TSPLIB—A traveling salesman problem library. ORSA journal on computing, v. 3, n. 4, p. 376-384, 1991.

SANCHES, Danilo; WHITLEY, Darrell; TINÓS, Renato. Building a better heuristic for the traveling salesman problem: Combining edge assembly crossover and partition crossover. In: Proceedings of the Genetic and Evolutionary Computation Conference. ACM, 2017. p. 329-336.

WHITLEY, Darrell; HAINS, Doug; HOWE, Adele. Tunneling between optima: partition crossover for the traveling salesman problem. In: Proceedings of the 11th Annual conference on Genetic and evolutionary computation. ACM, 2009. p. 915-922.

AGRADECIMENTOS

Agradeço ao CNPq pela oportunidade e auxílio financeiro que permitiram a realização desta pesquisa e ao meu orientador pelo apoio e conhecimento, o qual permitiu que este trabalho tivesse sucesso.