

GRASP e Redes Neurais Auto-Organizáveis: Uma Meta-Heurística para a Solução do TSP

Lucas de S. Batista¹, Alan R. R. de Freitas², Frederico G. Guimarães², Jaime A. Ramírez¹

¹Departamento de Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil

²Departamento de Computação, Universidade Federal de Ouro Preto, Ouro Preto, MG, Brasil

E-mail: lusoba@ufmg.br; alandefreitas@gmail.com; frederico.g.guimaraes@gmail.com; jramirez@ufmg.br

Abstract: Este artigo propõe uma meta-heurística para a solução do problema do caixeiro viajante (TSP), em que um procedimento de busca adaptativa aleatória gulosa (GRASP) é implementado, empregando-se um mapa auto-organizável (SOM) na fase construtiva, e a heurística Lin-Kernighan para a busca local.

I. INTRODUÇÃO

Problemas de otimização combinatória são comumente encontrados em diversas situações reais, e são usualmente classificados como *NP-difícil*, sendo por isso, frequentemente resolvidos por meio de heurísticas, pois são capazes de encontrar uma relação *custo/benefício* aceitável entre a qualidade da solução e o tempo de processamento. Neste contexto, este artigo propõe a resolução do problema do caixeiro viajante utilizando GRASP, em que a fase construtiva é desenvolvida por um mapa de Kohonen, e a busca local é desempenhada pela heurística Lin-Kernighan.

II. META-HEURÍSTICA PROPOSTA

O GRASP representa uma meta-heurística para a solução de problemas combinatórios, em que cada iteração consiste basicamente de duas fases, sendo a primeira *construtiva*, responsável pela geração de uma solução viável, e a segunda um *refinamento local*. Ao fim do procedimento, a melhor solução encontrada é retornada.

O GRASP possui um parâmetro principal ($\epsilon_0 \in [0, 1]$), o qual pondera entre a característica aleatória e determinística da solução gerada durante a fase construtiva. Dessa forma, pode-se assumir que para $\epsilon_0 = 0$ tem-se a construção de soluções de maneira mais determinística, enquanto $\epsilon_0 = 1$ equivale a uma construção mais aleatória.

Neste trabalho, o parâmetro ϵ_0 age sobre a etapa de competição da rede de Kohonen, em que para $\epsilon_0 = 0$ a unidade neural mais semelhante ao padrão apresentado é selecionada como vencedora, e para $\epsilon_0 > 0$ o neurônio vencedor é sorteado dentre os k neurônios com maior afinidade ao padrão, sendo k diretamente proporcional a ϵ_0 e exponencialmente decrescente ao longo das iterações.

As linhas seguintes apresentam uma breve análise baseada na instância *st70* (TSPLIB), considerando-se 200 execuções do GRASP. Os histogramas mostrados na Fig. 1 ilustram que quando $\epsilon_0 = 0$ os erros são menores, entretanto, quando $\epsilon_0 = 1$ tem-se soluções com maior diversidade, possibilitando encontrar resultados melhores após a aplicação da busca local (ver Fig. 2). A Fig. 3 apresenta o erro médio e a melhor solução encontrada para cada valor de ϵ_0 nas duas etapas do GRASP. Em particular, a fase de busca local mostra uma maior variância das soluções, em relação ao erro médio, para valores mais elevados de ϵ_0 , alcançando melhores resultados.




Figure 1. Distribuição das soluções após a fase construtiva (*st70*).




Figure 2. Distribuição das soluções após a busca local (*st70*).

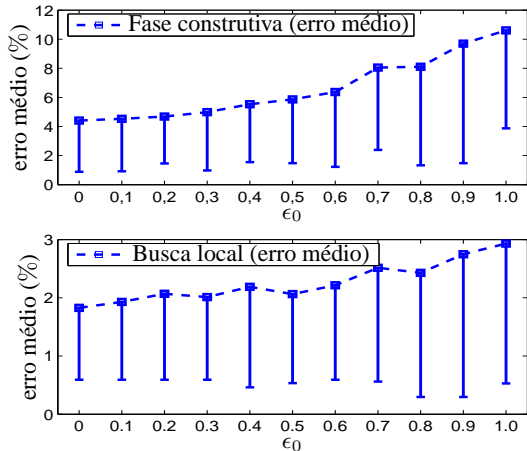


Figure 3. Erro médio percentual e a melhor solução encontrada dado ϵ_0 .

A seguir, mostra-se os resultados prévios considerando-se 50 iterações do GRASP sobre instâncias TSPLIB, com $\epsilon_0 = 0.8$. As melhores soluções apresentam erro inferior a 1% em relação aos valores ótimos da literatura.

Planta	\overline{erro}	\overline{std}	melhor	$\overline{t}(s)$
berlin52	5.13	2.84	0.00	1.72
eil51	2.83	1.07	0.47	1.71
lin105	3.34	2.13	0.44	6.65
pr76	2.97	1.33	0.72	3.75
pr107	1.74	1.09	0.52	7.13
pr152	2.50	1.49	0.55	14.32
rat99	3.90	1.95	0.50	6.16
rd100	3.85	1.81	0.01	6.22
st70	2.37	1.09	0.59	3.21