

REVISÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA UTILIZAÇÃO NO PROCESSO DE MAPEAMENTO TECNOLÓGICO

MATHEUS GARCIA NACHTIGALL¹;
PAULO ROBERTO FERREIRA JÚNIOR²

¹Universidade Federal de Pelotas – PPGC – mgnachtigall@inf.ufpel.edu.br

²Universidade Federal de Pelotas – PPGC – paulo.ferreira@inf.ufpel.edu.br

1. INTRODUÇÃO

Em sistemas de hardware, a etapa de definição de configuração dos blocos lógicos contidos dentro dos componentes programáveis e a escolha de quais portas lógicas serão utilizadas na construção do *layout* é denominada de “Mapeamento Tecnológico”. Esta etapa é uma das mais críticas e com maior impacto no desempenho final de um sistema de Hardware, pois define como o circuito será construído e, conseqüentemente, qual será o desempenho e o consumo de energia do mesmo (MARQUES et al., 2009).

Devido a grande importância desta etapa na construção de hardware, existe hoje muita demanda por métodos de otimização alternativos aos já existentes para uma melhor alocação de circuitos, aumento de desempenho ou redução de consumo de energia.

O objetivo deste trabalho é avaliar técnicas conhecidas de Inteligência Artificial que possuem resultados favoráveis em outros problemas de otimização onde a solução ótima não é conhecida ou não é encontrada em tempo hábil, e analisar se estas podem ser adaptadas para a resolução do problema de mapeamento tecnológico.

No decorrer do trabalho, serão apresentadas as técnicas estudadas e avaliadas. A seguir, será apresentado um problema similar ao mapeamento tecnológico (problema do caixeiro viajante), onde foram aplicadas as técnicas e realizados testes e análises. Por fim, será mostrada a conclusão do experimento realizado.

2. METODOLOGIA

Foram escolhidas diferentes técnicas de Inteligência Artificial para tentar mapear qual técnica pode melhor se adaptar ao problema apresentado. Estas técnicas serão detalhadas a seguir:

- **Subida de Encosta (“*Hill-Climbing*”)**: É uma técnica simples de otimização local, que se resume basicamente a gerar uma solução aleatória inicial para um problema e, a partir desta, buscar soluções vizinhas com resultados melhores que os atuais. Se a solução vizinha é superior, esta vira a solução principal. Este processo é repetido até uma condição de parada, estabelecida pelo usuário.

Esta técnica, apesar de eficiente para otimizações rápidas, é ineficiente para otimizações globais de um problema, visto que ela tende a rapidamente gerar uma solução ótima local e não conseguir avançar após isso. Os pontos “1” e “2” da Figura 1 ilustram o problema descrito, onde o algoritmo encontra uma solução favorável, porém não ótima.

- **Têmpera Simulada (“*Simulated Annealing*”)**: É uma otimização da técnica de Subida de Encosta, criada com base no processo de resfriamento controlado de metais.

Um resfriamento rápido em um metal gera imperfeições. Para reduzir a quantidade de defeitos é realizado um resfriamento lento e controlado. Nessa analogia, a cada etapa da técnica, o algoritmo tenta trocar a solução atual por uma solução vizinha. A nova solução poderá ser aceita com base em uma probabilidade calculada com base nos valores da solução e de um parâmetro “temperatura”, que diminui constantemente durante a execução do algoritmo.

Quando a temperatura está alta, o algoritmo permite trocas mais frequente nas soluções, expandindo o espaço de busca e evitando soluções ótimas locais. Com a redução da temperatura, o algoritmo reduz a probabilidade de escolhas inferiores a atual, caminhando em direção a uma solução ótima global. Os pontos “1” a “7” da Figura 1 demonstram o comportamento descrito acima.

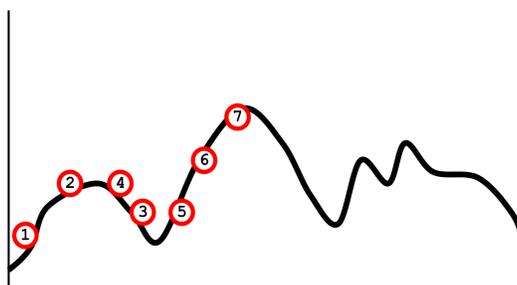


Figura 1: Comportamento das técnicas Subida de Encosta (1 - 2) e Têmpera Simulada (1 - 7)

- **Algoritmos Genéticos**: Técnica de otimização inspirada no princípio Darwiniano de seleção natural e reprodução genética (GOLDBERG, 1989). De acordo com a teoria de Darwin, o princípio da evolução favorece indivíduos melhores adaptados ao ambiente, proporcionando a estes maior possibilidade de longevidade e reprodução. Assim, indivíduos mais bem adaptados têm maior possibilidade de perpetuação do seu código genético nas próximas gerações.

Em algoritmos genéticos, um cromossomo é uma das estruturas de dados que representa uma das possíveis soluções do espaço de busca do problema, os cromossomos são então submetidos a um processo que inclui avaliação, seleção, recombinação (*crossover*) e mutação (AGUIAR, 1998). A Figura 3 ilustra a linha de execução de um algoritmo genético.

A técnica de algoritmos genéticos se baseia na utilização de uma população de indivíduos, cada um com seu próprio cromossomo, onde são aplicadas técnicas evolutivas para criar gerações mais desenvolvidas que a anterior.

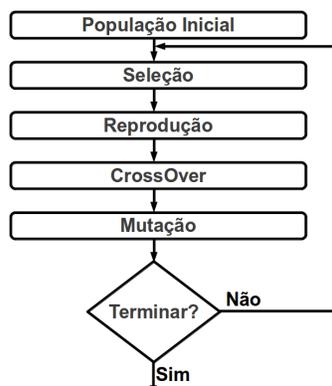


Figura 3: Funcionamento da técnica de Algoritmos Genéticos

• **Ant Colony System:** A técnica do Ant Colony System (DORIGO et al., 1997) foi criada com base no comportamento real de formigas. A técnica de otimização utiliza o princípio das mesmas de mapear um melhor caminho entre uma fonte de comida e a colônia.

Inicialmente, formigas caminham aleatoriamente até encontrarem uma fonte de alimento. Após este processo, as formigas traçam um caminho de volta à colônia, liberando feromônios no caminho onde passa. Este processo é repetido por várias formigas. Quando uma formiga encontra bifurcações em sua rota, esta decide para onde ir com base na quantidade de feromônios de cada rota. Com o passar do tempo, o feromônio dos caminhos menos escolhidos começam a evaporar mantendo apenas o caminho com o maior acúmulo de feromônio, que tende a resultar em um caminho mais direto entre a fonte e o destino. A Figura 4 exemplifica este funcionamento.

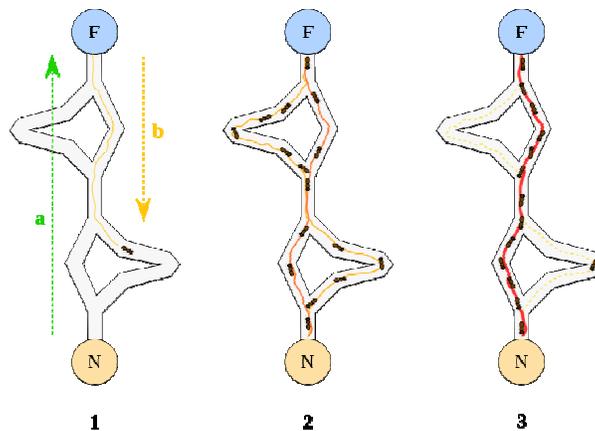


Figura 4: Comportamento Natural das Formigas utilizando feromônios

3. RESULTADOS E DISCUSSÕES

Para uma boa análise das técnicas, foi escolhido um problema onde todas as técnicas fossem aplicáveis. O problema escolhido foi o Problema do Caixeiro Viajante (LAWLER et al., 1985), onde o objetivo é encontrar a melhor rota entre um número arbitrário de cidades e retornar a cidade inicial.

Para realizar os testes, foi escolhido como métrica o número de execuções de cada algoritmo, fixando-se em 150000 execuções. Cada técnica foi executada 30 vezes, com estado inicial aleatório, para cálculos de média. Foram também escolhidos 4 casos de teste com números variados de cidades, para um melhor mapeamento das técnicas. Foi calculada a média de cada técnica para cada caso de teste e foi feita uma comparação dos valores entre si e com os resultados ótimos de cada caso de teste. Estes valores podem ser visualizados na Figura 5.

Para os testes realizados, foi realizado o teste t de Student para determinar se existe relevância estatística entre as amostras. Como se pode observar com o acréscimo de cidades no problema, os custos da melhor solução encontrada tendem a distanciar-se do valor ótimo, principalmente na técnica de Algoritmos Genéticos, onde os resultados foram significativamente maiores que o esperado. Nota-se também que, para problemas de grande escala, as técnicas de subida de encosta e têmpera simulada tendem a se equiparar, não possuindo relevância estatística.

Pode-se observar também que, com a métrica utilizada, o Ant Colony System foi a técnica que mais se aproximou do resultado ótimo, obtendo médias melhores do que as demais nos experimentos realizados (com médias estatisticamente diferentes, com 95% de confiança). Estes resultados mostram que a técnica em questão é uma forte candidata a ser aplicada no problema.

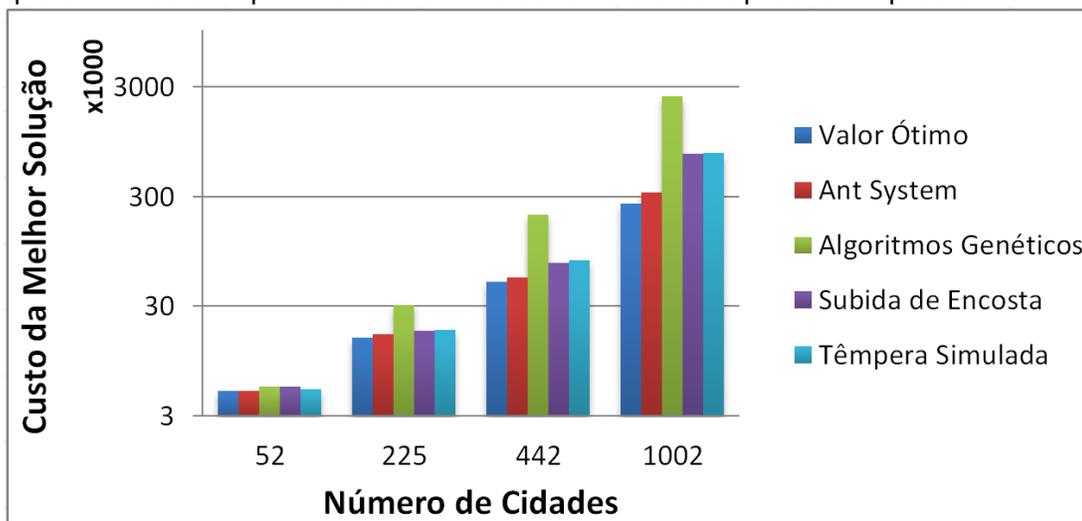


Figura 5: Custo x Número de Cidades dos casos de teste estudados

4. CONCLUSÕES

Neste trabalho foi avaliada a aplicação de técnicas de Inteligência Artificial ao problema do caixeiro viajante, com o intuito de escolher a técnica que melhor se adaptará ao problema do mapeamento tecnológico.

Em trabalhos futuros será feita a adaptação dessa técnica para a aplicação no problema, como também a utilização de outras métricas de avaliação, como por exemplo tempo de execução dos algoritmos.

5. REFERÊNCIAS BIBLIOGRÁFICAS

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Massachusetts: Addison-Wesley Publishing Company, 1989.

LAWLER, E.L.; LENSTRA, J.K. ; KAN, A.H.G.R. ; SHMOYS, DB. **The Traveling Salesman Problem: a Guided Tour of Combinatorial Optimization**. Wiley and Sons Publisher, 1985.

MARQUES, F. d. S.; JUNIOR, O.; RIBAS, R.; ROSA JUNIOR, L. da; REIS, A. Mapeamento Tecnológico no Projeto de Circuitos Integrados Digitais. **Desafios e Avanços em Computação: o Estado da Arte**. Pelotas: Ed. da Universidade Federal de Pelotas, 2009. Cap.8, p.177–195.

DORIGO, M.; GAMBARDELLA, L. Ant colony system: A cooperative learning approach to the traveling salesman problem. **Evolutionary Computation, IEEE Transactions**, v.1, n.1, p.53–66, 1997

AGUIAR, M. S. **Análise formal da complexidade de algoritmos genéticos**. 1998. Dissertação (Mestrado em Ciência da Computação) – Curso de Pós-Graduação em Computação, Universidade Federal do Rio Grande do Sul.