


GA em Otimização Combinatorial


- Problemas onde a busca da solução depende da avaliação de diversas combinações (ORDEM) dos elementos considerados
 - Problema do Caixeiro Viajante
 - Problemas de Planejamento
 - Problemas de Cronogramas
 - Alocação de Salas
 - Grafos: Colorir, Particionar, Percorrer



Problema de Colorir o Grafo




- Regras:
 - Colorir os nós do grafo de modo a maximizar a soma total dos pesos.
 - Pares de nós conectados por um arco não podem possuir a mesma cor




Algoritmo Guloso

- Considera apenas uma das possíveis soluções, colorindo os nós em ordem decrescente de peso.
- Nós em ordem decrescente de peso:
(9, 7, 8, 4, 2, 6, 5, 1, 3)
- Solução Ótima p/ 1 cor:
(9, 4, 2) $\Rightarrow \sum P_i = 32$




Algoritmo Guloso

- Considera apenas uma das possíveis soluções, colorindo os nós em ordem decrescente de peso.
- Nós em ordem decrescente de peso:
(9, 7, 8, 4, 2, 6, 5, 1, 3)
- Solução Ótima p/ 1 cor:
(9, 4, 2) $\Rightarrow \sum P_i = 32$




Algoritmo Guloso

- Considera apenas uma das possíveis soluções, colorindo os nós em ordem decrescente de peso.
- Nós em ordem decrescente de peso:
(9, 7, 8, 4, 2, 6, 5, 1, 3)
- Solução Ótima p/ 1 cor:
(9, 4, 2) $\Rightarrow \sum P_i = 32$




Algoritmo Guloso

- Considera apenas uma das possíveis soluções, colorindo os nós em ordem decrescente de peso.
- Nós em ordem decrescente de peso:
(9, 7, 8, 4, 2, 6, 5, 1, 3)
- Solução Ótima p/ 2 cores:
(9, 4, 2) e (7, 6, 5)
 $\Rightarrow \sum P_i = 32 + 26$




Aplicando o Algoritmo Guloso

- Nós em ordem decrescente de peso:
(7, 3, 4, 1, 6, 5, 2)




Aplicando o Algoritmo Guloso

- Nós em ordem decrescente de peso:
(7, 3, 4, 1, 6, 5, 2)
- Algoritmo Guloso começa e para no nó 7



Aplicando o Algoritmo Guloso

- Nós em ordem decrescente de peso:
(7, 3, 4, 1, 6, 5, 2)
- Soluções Ótimas:
 - 1 cor: (1, 5, 3)
 - 2 cores: (2, 4, 6)



Características do Problema

- A modificação dos pesos, número de cores e arcos, altera radicalmente a solução do problema.
- Estratégias como o algoritmo guloso não funcionam bem para todos os problemas de colorir o grafo.
- Heurísticas (Ex: avaliar número de arcos ou pesos de nós vizinhos antes colorir um nó) podem não ser eficientes para grandes espaços de busca.
- Algoritmos Genéticos oferecem uma solução (sub-ótima ou ótima) para qualquer problema de colorir o grafo



Componentes de um Algoritmo Genético

1. Problema
2. **Representação**
3. Decodificação
4. Avaliação
5. Operadores
6. Técnicas
7. Parâmetros




Tentando a Representação Binária

- Cada nó do grafo é representado por um campo (gene) no cromossoma:
Símbolo do Campo \equiv Cor do nó
- Podemos usar a representação binária. Para apenas 1 cor :

0 \equiv não colorido 1 \equiv colorido

Cromossoma \equiv **0 1 0 1 1 0 0 0 1**


Nó 1 2 3 4 5 6 7 8 9



Avaliando Representação Binária

- C é um cromossoma **ILEGAL**.
- Inicialização, crossover e mutação vão gerar soluções ilegais.
- Seria necessário um módulo reparador de cromossomas
- Representação binária permite soluções sub-ótimas:

C \equiv **0 1 0 1 0 0 0 0 0**
Nó 1 2 3 4 5 6 7 8 9



- C ainda poderia ter o nó 6, ou 8 ou 9 colorido e ser legal.

Representação Baseada em Ordem

- GA Híbrido \equiv Técnicas de GA + Algoritmo Guloso
- **Algoritmo Guloso:**
 - Cria uma lista de nós (ordem decrescente de peso)
 - Constrói a solução: atribui ao próximo nó da lista uma cor legal
- **Algoritmo Genético**
 - Cria uma lista (nós em ordem qualquer)
 - Constrói a solução: atribui ao próximo nó da lista uma cor legal



Exemplo

- Cromossoma = lista

$C_1 \equiv (9, 7, 8, 4, 2, 6, 5, 1, 3)$


$C_2 \equiv (2, 3, 7, 4, 9, 6, 5, 1, 8)$

$C_3 \equiv (4, 5, 1, 2, 9, 6, 8, 7, 3)$

- $C_1 C_2 C_3$ resultam na solução ótima p/ 1 cor:

$(9, 4, 2) \Rightarrow \sum P_i = 32$

- Informação codificada é a **ordem relativa dos nós**



Operadores Genéticos

- Testando o Crossover de 1 ponto:

$P_1 \equiv (9, 7, 8, 4, 2, 6, 5, 1, 3)$

$P_2 \equiv (2, 6, 7, 4, 9, 3, 5, 1, 8)$

$F_1 \equiv (9, 7, 8, 4, 2, 3, 5, 1, 8)$

$F_2 \equiv (2, 6, 7, 4, 9, 6, 5, 1, 3)$

- Descendentes são cromossomas ilegais: nós repetidos e ausência de determinados nós.
- Crossover e mutação devem garantir uma lista válida de todos os nós



Modelagem do Algoritmo Genético

1. Problema

- Problema de Colorir o Grafo

2. Representação

- Permutação dos índices dos nós

3. Decodificação

- Da esquerda para direita, atribui uma cor válida ao próximo nó

4. Avaliação

- $\sum P_i$

5. Operadores

- Crossover Uniforme Baseado em Ordem
- Mutação por Embaralhamento



Crossover Uniforme Baseado em Ordem

- Dados dos genitores P_1 e P_2 , criar descendente F_1 ;
- Gere um padrão de bits do mesmo comprimento que os genitores;
- Preencha F_1 , copiando o genitor P_1 nas posições em que o padrão é igual a "1";
- Faça uma lista dos elementos de P_1 associados com os bits "0" do padrão;
- Permute estes elementos de modo que eles apareçam na mesma ordem em que aparecem em P_2 ;
- Preencha as lacunas de F_1 com os elementos ordenados no passo anterior;



Exemplo

P ₁	1	2	3	4	5	6	7	8
P ₂	8	6	4	2	7	5	3	1

Padrão	0	1	1	0	1	1	0	0
--------	---	---	---	---	---	---	---	---

F ₁	-	2	3	-	5	6	-	-
F ₂	8	-	-	2	-	-	3	1

Elementos de P₁ associados a "0": 1, 4, 7, 8.

Ordenados segundo P₂: 8, 4, 7, 1

Elementos de P₂ associados a "1": 6, 4, 7, 5.

Ordenados segundo P₁: 4, 5, 6, 7

F ₁	8	2	3	4	5	6	7	1
F ₂	8	4	5	2	6	7	3	1



Mutação por Embaralhamento

- Seleciona aleatoriamente uma sub-lista do cromossoma
- Embaralha sub-lista

1	2	3	4	5	6	7	8	9
---	---	---	---	---	---	---	---	---

1	2	3	6	4	8	7	5	9
---	---	---	---	---	---	---	---	---



<ul style="list-style-type: none"> ● Módulo de Avaliação <ul style="list-style-type: none"> → Função de Avaliação: ● Módulo de População <ul style="list-style-type: none"> → Técnica de Representação: → Técnica Inicialização da População: Técnica Eliminação da População: Técnica de Reprodução: <ul style="list-style-type: none"> Gap Técnica de Seleção de Genitores: Técnica de Aptidão: Técnica de Parametrização: <ul style="list-style-type: none"> <i>Populafon Size:</i> <i>Total de Indivíduos:</i> ● Módulo de Reprodução <ul style="list-style-type: none"> Técnica de Seleção de Operadores: → Operadores: → → Técnica de Parametrização: → 	<p>GA6-1</p> <p><i>Avaliador do problema de colorir o grafo ΣP_i</i></p> <p><i>Lista de nós</i></p> <p><i>Permutação aleatória</i></p> <p><i>Elimina o último</i></p> <p><i>Steady State s/ duplicados</i></p> <p><i>Testar de 5 em 5</i></p> <p><i>Roleta</i></p> <p><i>Normalização Linear (100 a 1)</i></p> <p><i>Interpolar taxa de incremento (0,2 a 1,2)</i></p> <p>100</p> <p>4000</p> <p><i>Roleta</i></p> <p><i>Crossover Uniforme Baseado em Ordem</i></p> <p><i>Mutação por Embaralhamento</i></p> <p><i>Interpolar Pesos dos Operadores de (60 40) a (30 70)</i></p>
---	--

Problema de Colorir o Grafo

- Grafo com 100 nós ➔ 100! permutações diferentes
- 3 cores possíveis
- Listagem descreve o grafo através de:

(índice_nó, peso (lista de nós conectados))

(1 62 (20 58 74 82))
(2 183 (6 12 20 28 29 32 51 53 70 79 84 94))
(3 247 (18 24 33 50 88 92))
.....
.....
(99 254 (29 52 53 67 75 80 84 89))
(100 145 (15 20 22 29 34 44 60 87))

Busca Aleatória

- Muitas vezes não temos como comparar os resultados obtidos por um GA.
- Nestes casos, podemos usar a busca exaustiva como base de comparação.
- Gera-se uma curva média de desempenho para a busca aleatória com o mesmo número de tentativas que o GA.
- Um modelo de GA desempenhando abaixo da busca exaustiva deve provavelmente conter erros de modelagem e/ou programação.



Busca Aleatória

```
procedure busca_aleatória
begin
  t = 0
  inicializa P(t)
  avalia P(t)
  salva_melhor de P(t)
  while (not total_indivíduos) do
    begin
      t = t + 1
      inicializa P(t)
      avalia P(t)
      compara_melhor P(t) com melhor P(t-1)
      salva_melhor
    end
  end
end
```

primeira geração
população inicial aleatória
calcula f(i) p/ cada indivíduo
salva melhor indivíduo

próxima geração
população aleatória
calcula f(i) p/ cada indivíduo



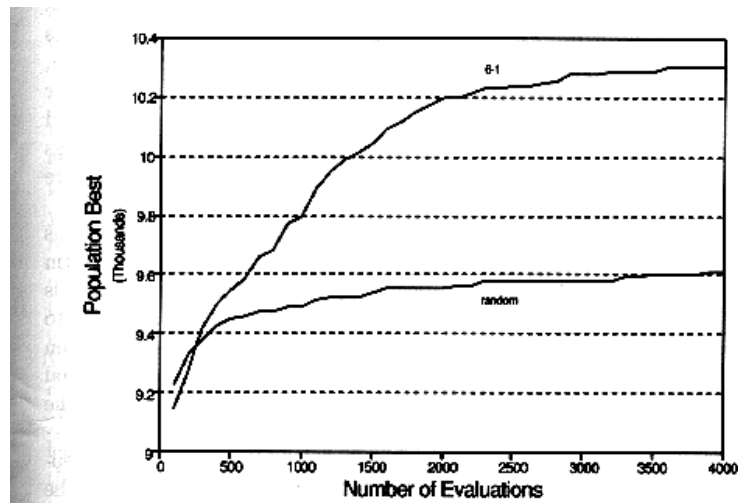


Figure 6.8: Performance curves for GA 6-1 and random generation on a 3-color graph coloring problem. The greedy algorithm scores 9,590.

Resultados do GA 6-1

- GA 6-1 é em média 7,4% que a busca aleatória após 4000 tentativas:
 - média GA 6-1= **10300**; média busca aleatória=**9600**
- GA 6-1 é em média 7,4% que a Algoritmo Guloso:
 - máximo do Alg. Guloso= **9590**
- GA 6-2 com pop_size=1200 e total_indivíduos=10000 encontrou avaliação=**10594**