

## *Heurísticas Modernas para Problemas de Otimização Combinatória*

Luiz A N Lorena

*Pesquisador Titular*

*LAC/INPE*

*lorena@lac.inpe.br*

*<http://www.lac.inpe.br/~lorena>*

Problemas de Otimização Combinatória aparecem quando é necessário selecionar de um conjunto discreto e finito de dados, o melhor subconjunto que satisfaz a determinados critérios. Por exemplo, selecionar o melhor conjunto de itens indivisíveis a serem transportados em um veículo de capacidade limitada.

## BUSCA TABU

---

### **Busca Tabu** (Algoritmo básico)

$s_0$  = solução inicial;  
 $f\_melhor = f(s_0)$ ;  
 $niter = 0$  ( número de iterações sem melhora);  
 $melhiter = 0$  ( número da iteração da melhor solução encontrada);  
 $nbmax$  = número máximo de iterações sem obter uma melhora na solução;  
Inicializar a *lista Tabu L* ;  
Inicializar a função do *Critério de Aspiração*,  $A(f(s_0))$ ;  
 $s = s_0$ ;  
**Enquanto** ( $niter - melhiter < nbmax$ ) **faça**  
     $f\_atual = f\_melhor$ ;  
     $niter = melhiter + 1$ ;  
    // Pesquisa de vizinhança //  
    Gerar um conjunto  $V_1$  de soluções  $s_i$  em  $N$  ;  
    Escolha a melhor solução  $s_i^+$  em  $V$  que não é tabu ou  $f(s_i^+) < A(f(s))$  ;  
    Atualize a lista tabu  $L$  e a função critério de aspiração  $A$  ;  
    **Se**  $f(s_i^+) < f\_melhor$  **então**  
         $f\_melhor = f(s_i^+)$ ,  
         $s = s_i^+$  ;  
    **fim\_se**  
    **Se**  $f\_melhor < f\_atual$  **então**  $melhiter = niter$  ;  
**fim\_enquanto**.

---

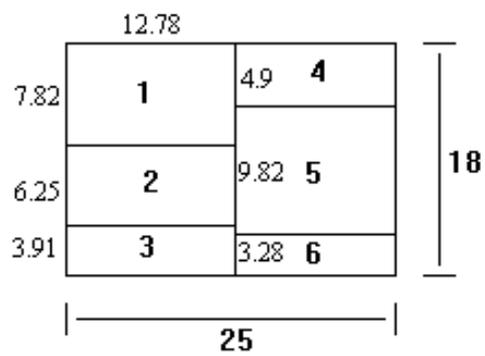
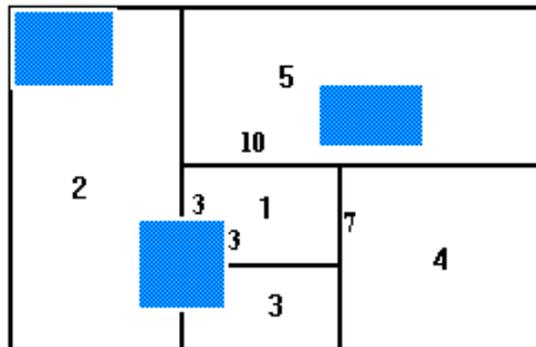
## LEIAUTE

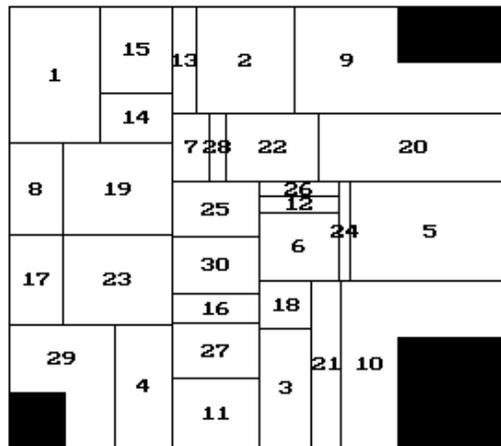
$$\text{Min } \sum_{i=1}^n \sum_{j=1}^n q_{ij} d_{ij}, \quad x \hat{\mathbf{I}} x$$

$$\text{sujeito a: } a_{i(\min)} \leq a_i \leq a_{i(\max)}$$

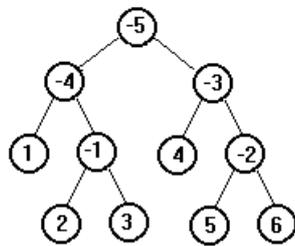
$$0 \leq s_i \leq s_{i(\max)}$$

$$i = 1, 2, \dots, n.$$





Funcao objetivo (global):24152

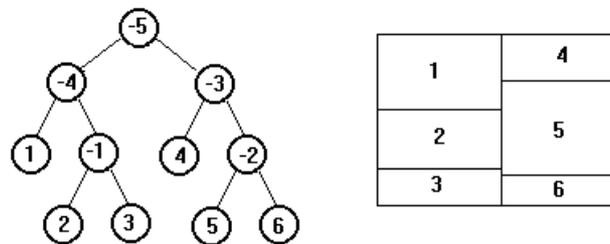


1	4
2	5
3	6

(1,2,3,4,5,6)

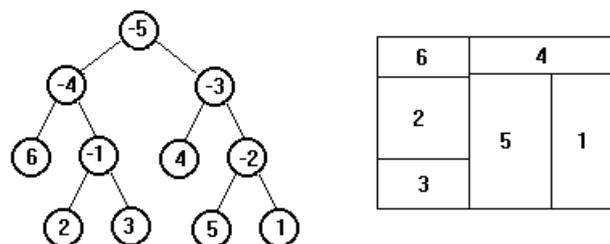
## Busca Tabu

→ Duas vizinhanças

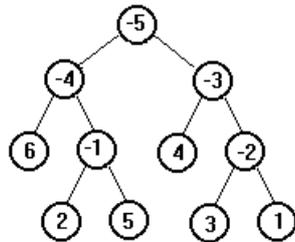


$$s = (1,2,3,4,5,6) \text{ ou } ((1(23))(4(56)))$$

1ª Vizinhança:  
Troca de duas folhas



$$s' = (6,2,3,4,5,1) \text{ ou } ((6(23))(4(51)))$$

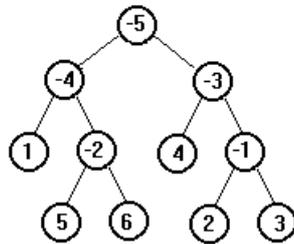


6	4
2	3
5	1

$$s' = (6,2,5,4,3,1) \text{ ou } ((6(25))(4(31)))$$

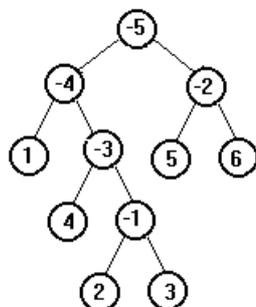
2ª Vizinhança:

Troca de dois nós internos



1	4
5	6
	2
	3

$$s = (1,5,6,4,2,3) \text{ ou } ((1(56))(4(23)))$$



	1	5
4	2	6
	3	

$$s' = (1,4,2,3,5,6) \text{ ou } ((1(4(23)))(56))$$

## SISTEMAS DE MANUFATURA FLEXÍVEIS

### Problema de "Scheduling" com restrições

- Cada parte requer um conjunto de ferramentas.
- A máquina possui um magazine com capacidade limitada. Esta restrição é crítica, pois restringe o número de ferramentas que podem ser carregadas e, conseqüentemente o número de partes que podem ser produzidas continuamente.
- Não existe "loop" no sistema. Uma parte que começa a ser processada é finalizada e não retorna. Isto significa que todas as partes são processadas e que o conjunto de ferramentas necessário para processar cada parte deve estar no magazine antes do início do processamento.
- Os tempos de "setup" são considerados separados dos tempos de processamento das partes, sendo constituídos por dois períodos: período de preparação do sistema para reinício de processamento (preparação da máquina e de dispositivos, limpeza da área de trabalho e manutenções) e o período de tempo gasto na troca de ferramentas. O tempo de preparação do sistema para o reinício de processamento é considerado fixo. O tempo de troca de ferramentas é considerado proporcional ao número de ferramentas trocadas.
- Os turnos de produção são respeitados; no momento de término de um turno, nenhuma parte pode estar em processamento ou vir a ser processada.

Para uma dada seqüência  $s_i$  de partes a serem processadas, a função objetivo a ser minimizada é definida pela soma dos seguintes termos:

$$f(s_i) = P_1 \cdot Tp(s_i) + P_2 \cdot At(s_i) + P_3 \cdot Sp(s_i) + P_4 \cdot Sf(s_i) + P_5 \cdot Tr(s_i) ,$$

onde:

$Tp(s_i)$  é o tempo total de produção ("makespan"),

$At(s_i)$  é o tempo total de atraso,

$Sp(s_i)$  é o tempo total de "setup" de preparação para reinício de operação do sistema,

$Sf(s_i)$  é o tempo total de "setup" referente a troca de ferramentas,

$Tr(s_i)$  é o tempo total ocioso dos turnos.

A cada parcela da função objetivo é associado um peso. Com relação as parcelas acima  $P_1$ ,  $P_2$ ,  $P_3$ ,  $P_4$  e  $P_5$ . Sendo que, conforme os valores definidos para os pesos a função objetivo poderá refletir várias estratégias.

		FERRAMENTAS								
		1	2	3	4	5	6	7	8	9
PARTES	1	1	0	0	1	0	0	0	1	1
	2	1	0	1	0	1	0	0	0	0
	3	0	1	0	0	0	1	1	1	0
	4	0	0	0	0	0	0	1	0	0
	5	0	0	0	0	0	1	0	0	0
	6	0	0	1	0	0	0	0	0	0
	7	1	0	0	0	1	0	1	0	1
	8	0	0	1	0	1	0	0	1	0
	9	0	0	0	0	1	0	1	0	0
	10	1	1	0	1	0	0	0	0	0

Capacidade do magazine de *quatro* ferramentas.

## Algoritmo de Identificação de Grupos

		FERRAMENTAS								
		3	5	1	8	2	6	7	4	9
PARTES	2	1	1	1	0	0	0	0	0	0
	6	1	0	0	0	0	0	0	0	0
	8	1	1	0	1	0	0	0	0	0
	3	0	0	0	1	1	1	1	0	0
	5	0	0	0	0	0	1	0	0	0
	7	0	1	1	0	0	0	1	0	1
	9	0	1	0	0	0	0	1	0	0
	10	0	0	1	0	1	0	0	1	0
	1	0	0	1	1	0	0	0	1	1

FP ← Família de partes

FF ← Família de ferramentas

FP1 = {2,6,8} e FF1 = {1,3,5,8}.

FP2 = {3,4,5} e FF2 = {2,6,7,8}.

FP3 = {7,9} e FF3 = {1,5,7,9}.

FP4 = {10} e FF4 = {1,2,4}.

FP5 = {1} e FF5 = {1,4,8,9}.

Seqüência  $s = (6,3,4,5,2,8,9,7,10,1)$

PARTES	FP	MAGAZINE				Nº DE TROCAS
		TIPOS DE FERRAMENTAS				
6	1	1	3	5	8	-
3, 4, 5	2	<u>2</u>	<u>6</u>	<u>7</u>	8	3
2, 8	1	<u>1</u>	<u>3</u>	<u>5</u>	8	3
9, 7	3	1	5	<u>7</u>	<u>9</u>	2
10	4	1	<u>2</u>	<u>4</u>	9	2
1	5	1	4	<u>8</u>	9	1
Nº de Sp = 5		Nº de Sf = 11				

5 instantes de parada para troca de ferramentas (Sp) e 11 trocas de ferramentas (Sf).

## Busca Tabu

---

### ALGORITMO TSS

$s_0$  = seqüência inicial;  
 $f\_melhor = f(s_0)$ ;  
 $niter = 0$  ( número de iterações sem melhora);  
 $melhiter = 0$  ( número da iteração da melhor solução encontrada);  
 $nbmax$  = número máximo de iterações sem obter uma melhora na solução;  
Inicializar as *listas Tabu* para duas pesquisas,  $L_1$  e  $L_2$ .  
Inicializar a função do *Critério de Aspiração*,  $A(f(s_0))$ ;  
 $s = s_0$  ;  
**Enquanto** (  $niter - melhiter < nbmax$  ) **faça**  
     $f\_atual = f\_melhor$ ;  
     $niter = melhiter + 1$ ;  
    // Primeira pesquisa de vizinhança //  
    Gerar um conjunto  $V_1$  de seqüências  $s_i$  em  $N_1$  ;  
    Escolha a melhor seqüência  $s_i^+$  em  $V_1$  que não é tabu ou  $f(s_i^+) < A(f(s))$  ;  
    Atualize a lista tabu  $L_1$  e a função critério de aspiração  $A$  ;  
    **Se**  $f(s_i^+) < f\_melhor$  **então**       $f\_melhor = f(s_i^+)$ ,  
   $s = s_i^+$  ;  
    **fim\_se**  
    // Segunda Pesquisa de Vizinhança //  
    Gerar um conjunto  $V_2$  de seqüências  $s_i$  em  $N_2$  ;  
    Escolha a melhor seqüência  $s_i^+$  em  $V_2$  que não é tabu ou  $f(s_i^+) < A(f(s))$  ;  
    Atualize a lista tabu  $L_2$  e a função critério de aspiração  $A$  ;  
    **Se**  $f(s_i^+) < f\_melhor$  **então**       $f\_melhor = f(s_i^+)$ ,  
   $s = s_i^+$  ;  
    **fim\_se**  
    **Se**  $f\_melhor < f\_atual$  **então**  $melhiter = niter$  ;  
**fim\_enquanto**.

---

→ Duas vizinhanças

$$s = (6,3,4,5,2,8,9,7,10,1)$$

1ª Vizinhança:

representação de lotes →  $s = [(6),(3,4,5), (2,8), (9,7), (10), (1)]$

posicionamento de dois lotes é alterado por um movimento de troca,

por exemplo →  $s' = [(6), (10), (2,8), (9,7), (3,4,5), (1)]$

2ª Vizinhança:

representação de partes →  $s = (6,10,2,8,9,7,3,4,5,1)$

uma parte passa a ser processada em outro lote por movimentos de retirada e de inserção

por exemplo →  $s' = (6,10,8,9,2,7,3,4,5,1)$   
ou  $s' = [(6), (10), (8), (9), (2), (7), (3,4,5), (1)]$

por exemplo →  $s' = (10,6,2,8,9,7,3,4,5,1)$   
ou  $s' = [(10), (6,2,8), (9,7), (3,4,5), (1)]$

PARTES DE	FP	MAGAZINE				Nº DE Sf	PARTES	FP	MAGAZINE				Nº Sf
		TIPOS DE FERRAMENTAS							TIPOS DE FERRAMENTAS				
1	5	1	4	8	9	-	1	5	1	4	8	9	-
10	4	1	<u>2</u>	4	8	1	10	4	1	<u>2</u>	4	8	1
3, 4, 5	2	2	<u>6</u>	<u>7</u>	8	2	3, 4, 5	2	2	<u>6</u>	<u>7</u>	8	2
6, 8, 2	1	<u>1</u>	<u>3</u>	<u>5</u>	8	3	6, 8	1	<u>3</u>	<u>5</u>	7	8	2
7, 9	3	1	5	<u>7</u>	<u>9</u>	2	2	6	1	3	5	7	1
							7, 9	3	1	5	7	<u>9</u>	1
Nº de Sp = 4						Nº de Sf = 8	Nº de Sp = 5						Nº de Sf = 7

Mesma de seqüência de partes:

$$s = (1,10,3,4,5,6,8,2,7,9)$$

→ 4 instantes de parada para troca de ferramentas com 8 trocas de ferramentas

→ 5 instantes de parada para troca de ferramentas com 7 trocas de ferramentas

## ALGORITMO GENÉTICO CONSTRUTIVO

### PROBLEMA DAS $P$ -MEDIANAS

Problema clássico de localização.

→ objetivo: localizar  $p$  facilidades (medianas), de forma a minimizar a soma das distâncias de cada vértice a sua facilidade mais próxima.

Seja  $m_j (\geq 0)$  o custo de atribuir o vértice  $j$  ao vértice  $i$ ,  
 $V$  o conjunto de vértices.

$x_{ij} = 1$  se o vértice  $j$  é atribuído ao vértice  $i$ ,  
 $x_{ij} = 0$  caso contrário.

$$\text{Min } z = \sum_{i \in V} \sum_{j \in V} m_j x_{ij}, \quad (1)$$

sujeito a  $\sum_{i \in V} x_{ij} = 1 \quad \forall j \in V$  (2)

$$\sum_{i \in V} x_{ii} = p, \quad (3)$$

$$x_{ij} \leq x_{ii}; i, j \in V \quad (4)$$

$$x_{ij} \in \{0,1\} \quad \forall i \in V, j \in V. \quad (5)$$

(2) e (4) asseguram que cada vértice  $j$  seja atribuída somente a um vértice  $i$ , que necessariamente deve ser uma mediana.

(3) determina o número exato de medianas que devem ser atribuídas a  $p$ .

## Algoritmo Genético

---

**AG** {Algoritmo Genético}

**t** := 0 ;

**Inicializar**  $P_t$  ; {população inicial}

**Avaliar**  $P_t$  ;

**Enquanto** (não satisfeita condição de parada) **fazer**

**t** := **t** + 1 ;

**Selecionar**  $P_t$  de  $P_{t-1}$  ; {operador reprodução}

**Recombinar**  $P_t$  ; {operador "crossover" e mutação}

**Avaliar**  $P_t$  ; {avaliar adaptação}

**Fim\_Enquanto**

---

→ Conjunto de variáveis denominadas *estruturas*. Na sua forma mais simples, a estrutura é representada por uma cadeia ("string") de dados elementares, possivelmente uma cadeia binária;

→ Estruturas combinam formando uma *população*.

→ Cada estrutura é avaliada através de uma *função de adaptação*.

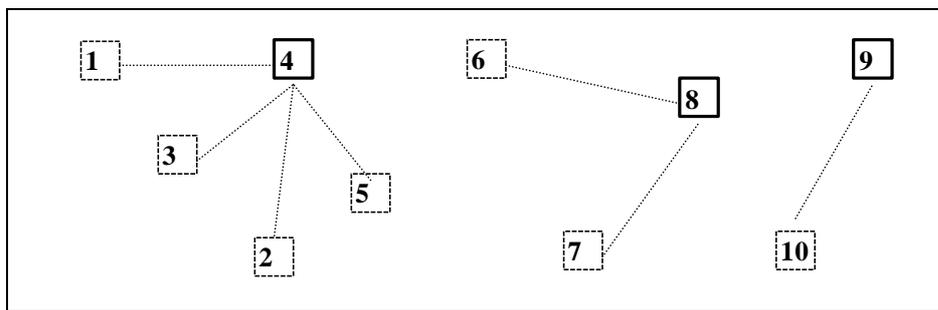
→ O principal operador no algoritmo genético é a *recombinação*. Na recombinação, duas estruturas da população são escolhidas, através de um critério de *seleção*, para produzir duas novas estruturas.

→ "*crossover*" quando escolhe um ou mais pontos nas estruturas pais, de tal forma que exista a mistura de ambas partes nas estruturas filhas. Cada elemento da cadeia, que forma a estrutura, pode ainda ser modificada, o que é denominado *mutação*.

Exemplo:

$$s_i = (2 \ 2 \ 2 \ 1 \ 2 \ 2 \ 2 \ 1 \ 1 \ 2)$$

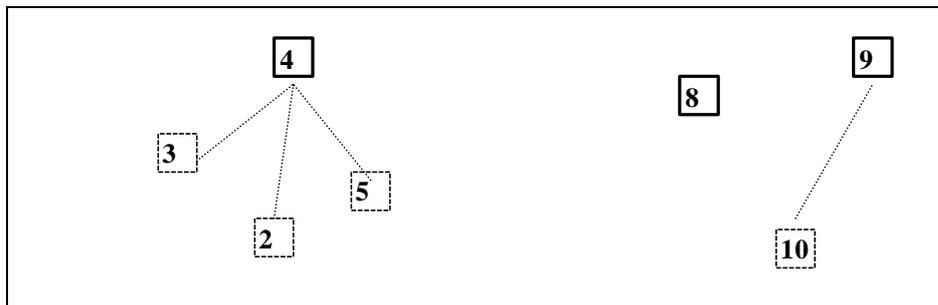
- $V_1$  : conjunto de vértices que representam as medianas  $\rightarrow V_1 = \{4,8,9\}$
- $V_2$  : conjunto de vértices que não são medianas  $\rightarrow V_2 = \{1,2,3,5,6,7,10\}$

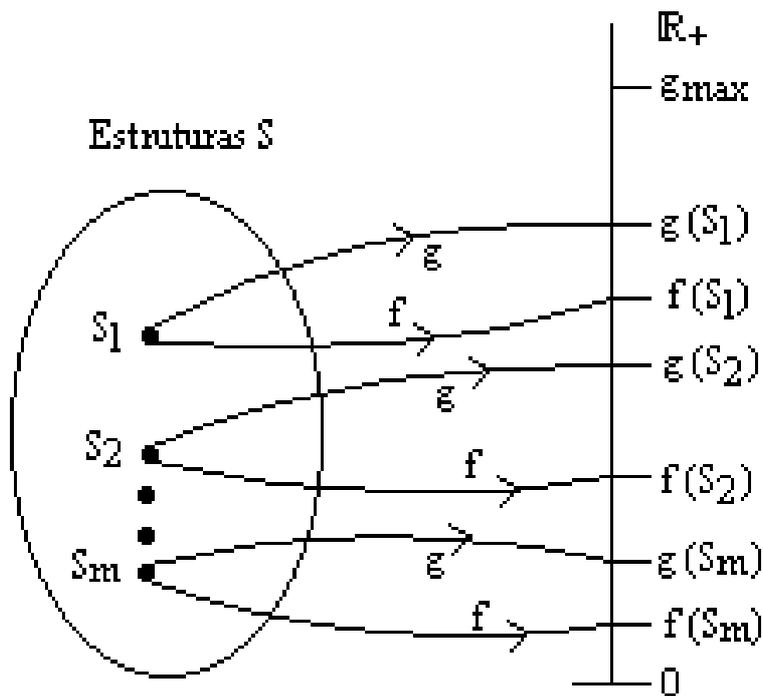


### Algoritmo Genético Construtivo

População de esquemas:

$$s_i = (\# \ 2 \ 2 \ 1 \ 2 \ \# \ \# \ 1 \ 1 \ 2)$$





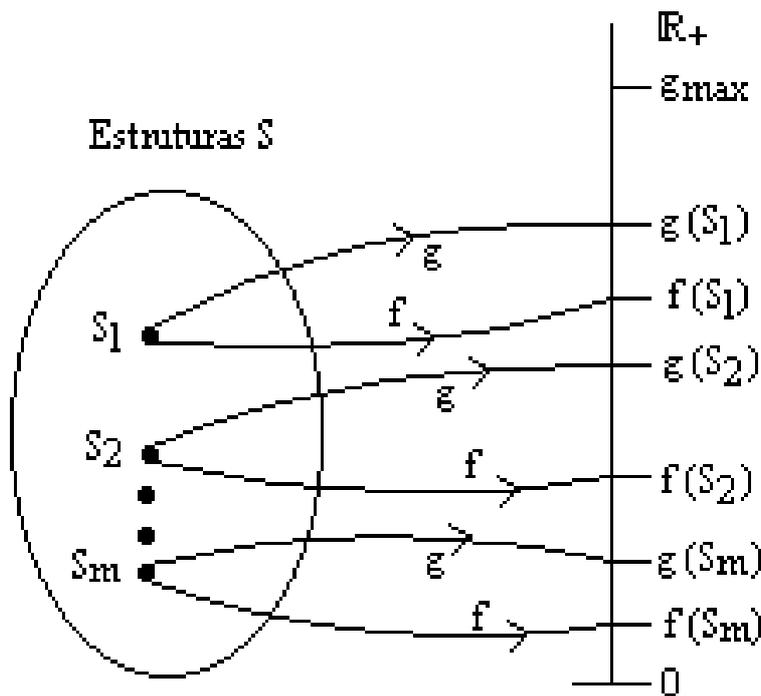
→ Baseado no Algoritmo A\* ;

$$\rightarrow d_i = \frac{g(s_i) - f(s_i)}{g(s_i)}, i = 1, \dots, m.$$

$$\rightarrow d g_{max} \leq d_i g(s_i) + \mathbf{a} d (g_{max} - g(s_i))$$

$$\rightarrow \mathbf{a} \geq \frac{d g_{max} - d_i g(s_i)}{d (g_{max} - g(s_i))} = \mathbf{d}(s_i)$$

- $V_1$  : conjunto de vértices que representam as medianas;
- $V_2$  : conjunto de vértices que não são medianas;
- $V_3$  : conjunto de vértices que ainda não estão representados na estrutura.



$$\rightarrow g(s_k) = \sum_{j \in V_2} \min_{i \in V_1} \{m_{ij}\};$$

→ Sejam  $\mathbf{I}_j = \min_{i \in V_2} m_{ij}, j \in V_1$  e seja  $C_j$  o conjunto formado pela mediana  $j$  e seus vértices associados.  $|C_j|$  é o número de elementos do conjunto  $C_j$ . Então:

$$\rightarrow f(s_k) = \sum_{j=1}^p \mathbf{I}_j |C_j|.$$

### Operador seleção

→ População ordenada pela equação:

$$\rightarrow \Delta(s_k) = \frac{1 + d_k}{V_1 + V_2}.$$

**Operador 1:** As estruturas  $s_i$  e  $s_j$  são selecionadas na população inteira;

**Operador 2:** A estrutura  $s_i$  é selecionada nas  $k_1$  melhores estruturas e  $s_j$  é selecionada na população inteira;

**Operador 3:** As estruturas  $s_i$  e  $s_j$  são selecionadas nas  $k_1$  melhores estruturas;

**Operador 4:** A estrutura  $s_i$  é seleccionada nas  $k_2\%$  melhores estruturas e  $s_j$  é seleccionada nas  $k_1$  melhores estruturas;

**Operador 5:** As estruturas  $s_i$  e  $s_j$  são seleccionadas nas  $k_2\%$  melhores estruturas, onde para o problema das  $p$ -medianas  $k_1$  é igual ao número de vértices do problema e  $k_2$  é igual a 30% das melhores estruturas.

### Operador recombinação

Caso 1:

base: (1 2 0 2 1 0 1 0)

guia: (0 2 1 1 1 0 2 2)

resultante: (\_ 2 \_ \_ 1 0 \_ \_)

Caso 2:

base: (1 2 0 2 1 2 1 0)

guia: (0 2 1 1 1 0 2 2)

resultante: (1 \_ \_ \_ \_ 2 \_ \_)

Caso 3:

base: (1 2 0 2 1 2 1 0)

guia: (0 2 1 1 1 0 2 2)

resultante: (\_ \_ \_ \_ \_ \_ \_ 2)

Caso 4:

base: (1 2 0 2 1 0 1 0)

guia: (0 2 1 1 1 0 2 2)

resultantes: (2 2 1 2 1 0 1 0)

(1 2 1 2 2 0 1 0)

(1 2 1 2 1 0 2 0)

Caso 5:

base: (1 2 0 2 1 0 1 0)

guia: (0 2 1 1 1 0 2 2)

resultantes: (1 1 0 2 1 0 2 0)

(1 2 0 1 1 0 2 0)

## Operador mutação

→ Apenas uma estrutura é selecionada (operadores 4 e 5). Cada mediana da estrutura permuta de posição com os vértices que não pertencem ao conjunto das medianas, gerando novas estruturas ( $|V| - |V_1|$  estruturas).

## Resultados Computacionais

Problema	Vértices	Medianas	Solução ótima	Função objetivo	Diferença %	Tempo segundos
pmed1	100	5	5819	5819	0	28
pmed2	100	10	4093	4093	0	37
pmed3	100	10	4250	4250	0	34
pmed4	100	20	3034	3034	0	230
pmed5	100	33	1355	1360	0.36	375
pmed6	200	5	7824	7824	0	172
pmed7	200	10	5631	5631	0	238
pmed8	200	20	4445	4454	0.20	1055
pmed9	200	40	2734	2754	0.73	3331
pmed10	200	67	1255	1257	0.15	4325
pmed11	300	5	7696	7696	0	369
pmed12	300	10	6634	6637	0.04	677
pmed16	400	5	8162	8162	0	555
pmed21	500	5	9138	9138	0	1875

Tabela 1: Resultados computacionais dos testes realizados.

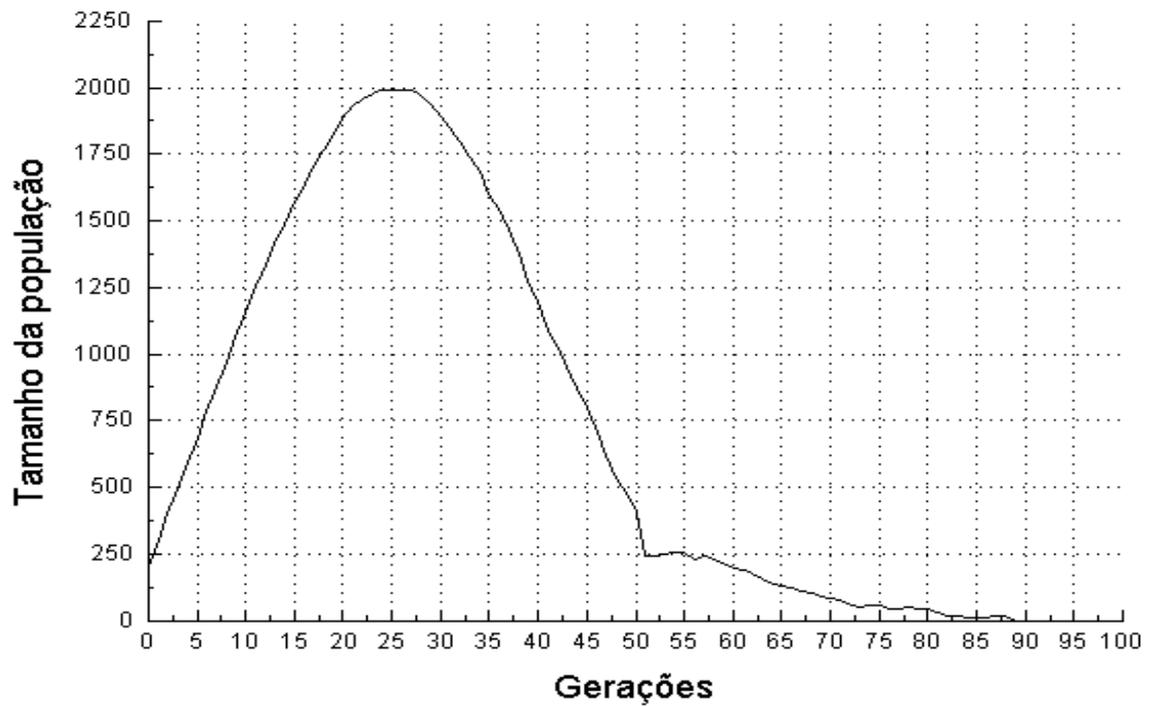


Gráfico 1: Tamanho da população de estruturas com o decorrer das gerações para o problema pmed1.

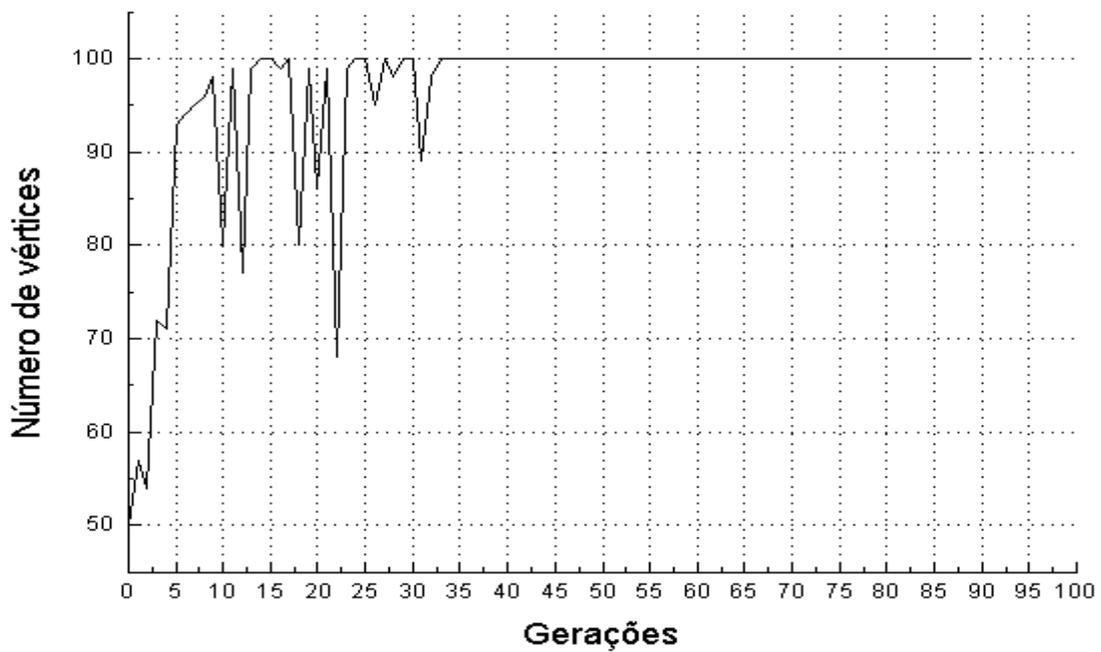


Gráfico 2: Número de vértices que participam da melhor estrutura gerada a cada geração para o problema pmed1.

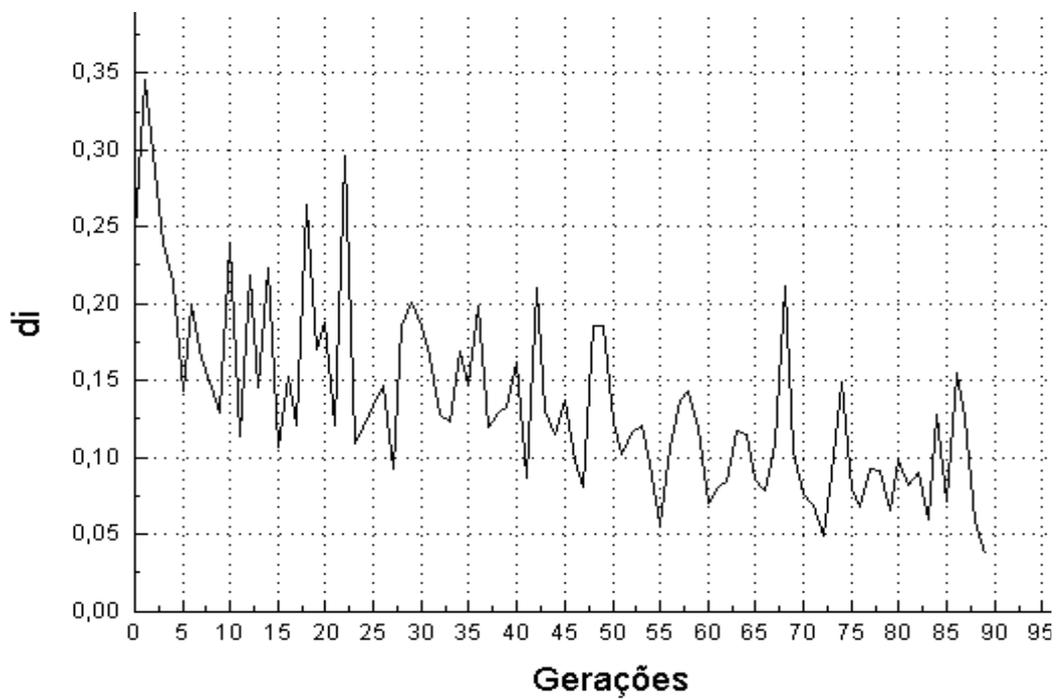


Gráfico 3: Gráfico de  $d_i$  em função do número de gerações, para o problema pmed1.

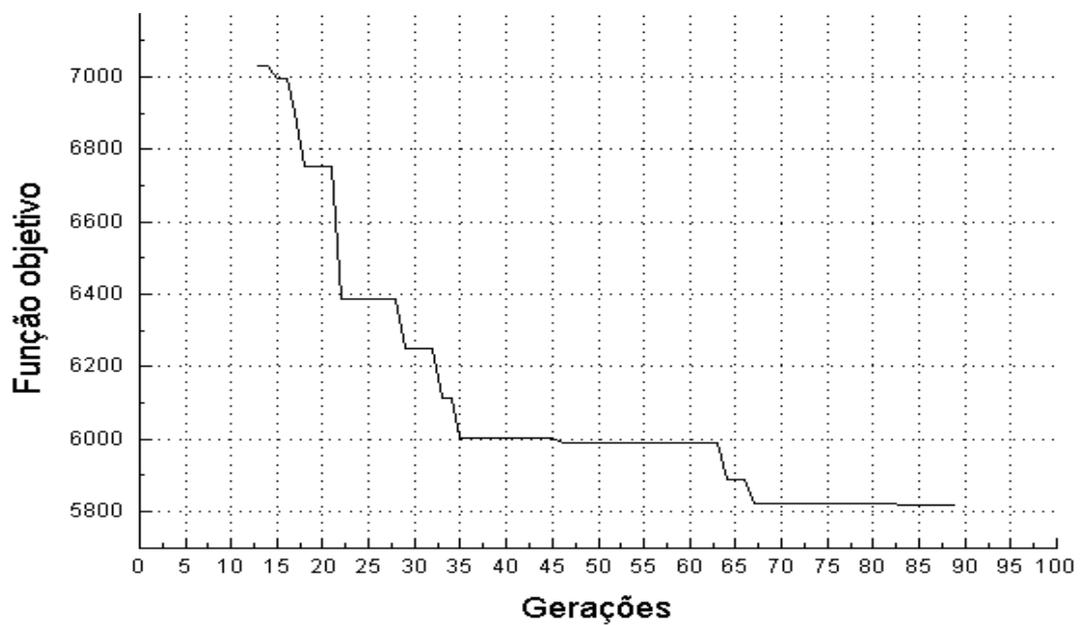
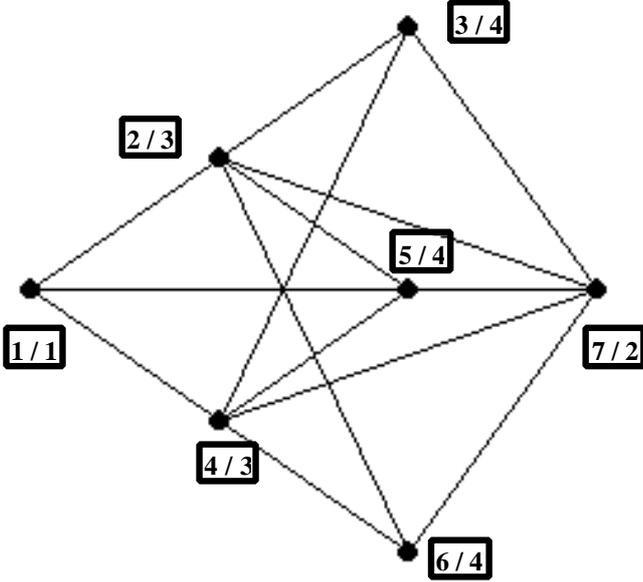
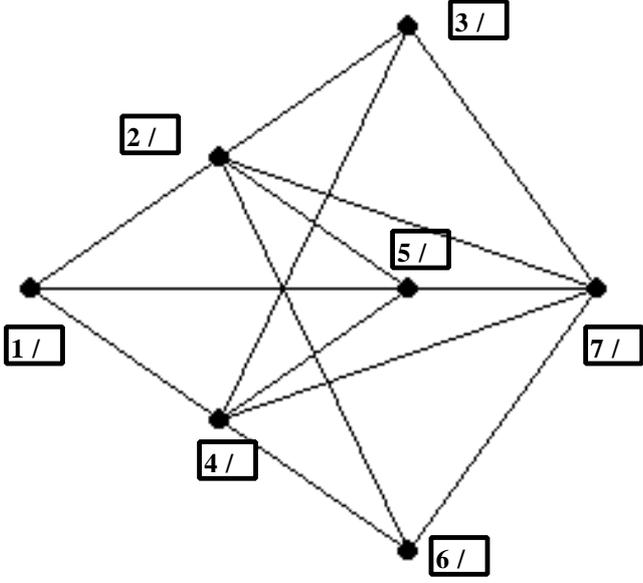


Gráfico 4: Função objetivo em função das gerações para o problema pmed1.

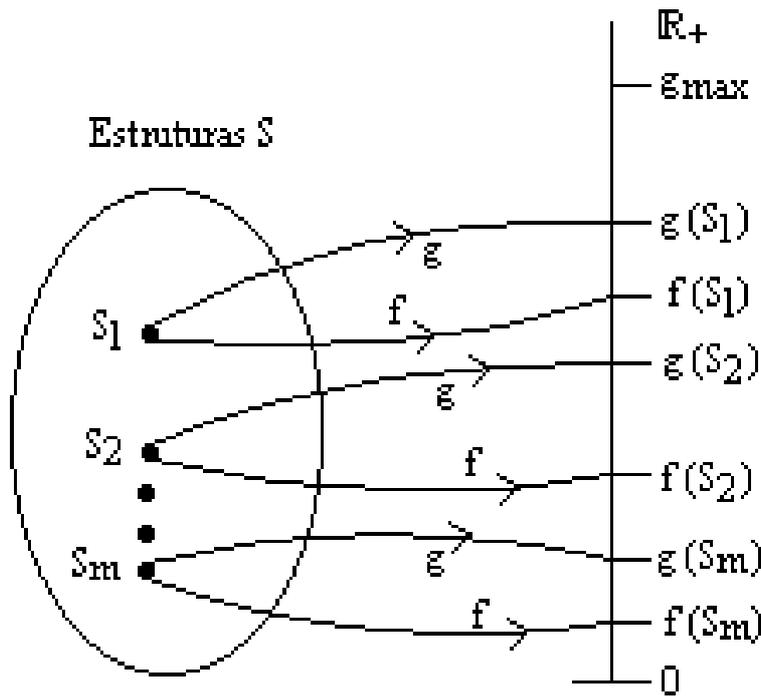
### Coloração de Grafos



Estrutura:  $s = (1,3,4,3,4,4,2)$



Esquema:  $s = (1, \#, 4, 3, \#, \#, 2)$



$$\rightarrow f(s) = \sum_{p=1}^k \left\{ \left[ \frac{(|C_p| - 1) \cdot |C_p|}{2} \right] - |E(C_p)| \right\},$$

$$\rightarrow g(s) = \sum_{p=1}^k \left[ \frac{(|C_p| - 1) \cdot |C_p|}{2} \right],$$

$$\rightarrow g_{\max} = \text{mult. } k. \left[ \frac{\left( \left[ \frac{m}{k} \right] - 1 \right) \cdot \left[ \frac{m}{k} \right]}{2} \right],$$

$$\rightarrow \Delta(s) = \frac{1 + \sum_{p=1}^k [ |E(C_p)| ]}{nv}.$$

## Graph Coloring Instances

Each instance includes the information: (nodes, edges), optimal coloring, source.

DSJC1000.1.col.b (1000,99258), ?, DSJ  
DSJC1000.5.col.b (1000,499652), ?, DSJ  
DSJC1000.9.col.b (1000,898898), ?, DSJ  
DSJC125.1.col.b (125,1472), ?, DSJ  
DSJC125.5.col.b (125,7782), ?, DSJ  
DSJC125.9.col.b (125,13922), ?, DSJ  
DSJC250.1.col.b (250,6436), ?, DSJ  
DSJC250.5.col.b (250,31366), ?, DSJ  
DSJC250.9.col.b (250,55794), ?, DSJ  
DSJC500.1.col.b (500,24916), ?, DSJ  
DSJC500.5.col.b (500,125249), ?, DSJ  
DSJC500.9.col.b (500,224874), ?, DSJ  
DSJR500.1.col.b (500,7110), ?, DSJ  
DSJR500.1c.col.b (500,242550), ?, DSJ  
DSJR500.5.col.b (500, 117724), ?, DSJ  
flat1000\_50\_0.col.b (1000,245000), 50, CUL  
flat1000\_60\_0.col.b (1000,245830), 60, CUL  
flat1000\_76\_0.col.b (1000,246708), 76, CUL  
flat300\_20\_0.col.b (300,21375), 20, CUL  
flat300\_26\_0.col.b (300, 21633), 26, CUL  
flat300\_28\_0.col.b (300, 21695), 28, CUL  
fpsol2.i.1.col (496,11654), 65, REG  
fpsol2.i.2.col (451,8691), 30, REG  
fpsol2.i.3.col (425,8688), 30, REG  
inithx.i.1.col (864,18707), 54, REG  
inithx.i.2.col (645, 13979), 31, REG  
inithx.i.3.col (621,13969), 31, REG  
latin\_square\_10.col (900,307350), ?,  
e450\_15a.col (450,8168), 15, LEI  
le450\_15b.col (450,8169), 15, LEI  
le450\_15c.col (450,16680), 15, LEI  
le450\_15d.col (450,16750), 15, LEI  
le450\_25a.col (450,8260), 25, LEI  
le450\_25b.col (450,8263), 25, LEI  
le450\_25c.col (450,17343), 25, LEI  
le450\_25d.col (450,17425), 25, LEI  
le450\_5a.col (450,5714), 5, LEI  
le450\_5b.col (450,5734), 5, LEI  
le450\_5c.col (450,9803), 5, LEI  
le450\_5d.col (450,9757), 5, LEI  
mulsol.i.1.col (197,3925), 49, REG  
mulsol.i.2.col (188,3885), 31, REG  
mulsol.i.3.col (184,3916), 31, REG  
mulsol.i.4.col (185,3946), 31, REG  
mulsol.i.5.col (186,3973), 31, REG  
school1.col (385,19095), ?, SCH  
school1\_nsh.col (352,14612), ?, SCH  
zeroin.i.1.col (211,4100), 49, REG  
zeroin.i.2.col (211, 3541), 30, REG  
zeroin.i.3.col (206, 3540), 30, REG  
anna.col (138,493), 11, SGB  
david.col (87,406), 11, SGB  
homer.col (561,1629), 13, SGB  
huck.col (74,301), 11, SGB  
jean.col (80,254), 10, SGB  
games120.col (120,638), 9, SGB  
miles1000.col (128,3216), 42, SGB  
miles1500.col (128,5198), 73, SGB  
miles250.col (128,387), 8, SGB  
miles500.col (128,1170), 20, SGB  
miles750.col (128,2113), 31, SGB  
queen10\_10.col (100,2940), ?, SGB  
queen11\_11.col (121,3960), 11, SGB  
queen12\_12.col (144,5192), ?, SGB  
queen13\_13.col (169,6656), 13, SGB  
queen14\_14.col (196,8372), ?, SGB  
queen15\_15.col (225,10360), ?, SGB  
queen16\_16.col (256,12640), ?, SGB  
queen5\_5.col (25,160), 5, SGB  
queen6\_6.col (36,290), 7, SGB  
queen7\_7.col (49,476), 7, SGB  
queen8\_12.col (96,1368), 12, SGB  
queen8\_8.col (64, 728), 9, SGB  
queen9\_9.col (81, 2112), 10, SGB  
myciel3.col (11,20), 4, MYC  
myciel4.col (23,71), 5, MYC  
myciel5.col (47,236), 6, MYC  
myciel6.col (95,755), 7, MYC  
myciel7.col (191,2360), 8, MYC

Notes:

DSJ: (From David Johnson (dsj@research.att.com)) Random graphs used in his paper with Aragon, McGeoch, and Schevon, "Optimization by Simulated Annealing: An Experimental Evaluation; Part II, Graph Coloring and Number Partitioning", *Operations Research*, 31, 378--406 (1991). DSJC are standard  $(n,p)$  random graphs. DSJR are geometric graphs, with DSJR..c being complements of geometric graphs.

CUL: (From Joe Culberson (joe@cs.ualberta.ca)) Quasi-random coloring problem.

REG: (From Gary Lewandowski (gary@cs.wisc.edu)) Problem based on register allocation for variables in real codes.

LEI: (From Craig Morgenstern (morgenst@riogrande.cs.tcu.edu)) Leighton graphs with guaranteed coloring size. A reference is F.T. Leighton, *Journal of Research of the National Bureau of Standards*, 84: 489—505 (1979).

SCH: (From Gary Lewandowski (lewandow@cs.wisc.edu)) Class scheduling graphs, with and without study halls.

LAT: (From Gary Lewandowski (lewandow@cs.wisc.edu)) Latin square problem.

SGB: (From Michael Trick (trick@cmu.edu)) Graphs from Donald Knuth's Stanford GraphBase. These can be divided into:

Book Graphs. Given a work of literature, a graph is created where each node represents a character. Two nodes are connected by an edge if the corresponding characters encounter each other in the book. Knuth creates the graphs for five classic works: Tolstoy's *Anna Karenina* (anna), Dicken's *David Copperfield* (david), Homer's *Iliad* (homer), Twain's *Huckleberry Finn* (huck), and Hugo's *Les Misérables* (jean).

Game Graphs. A graph representing the games played in a college football season can be represented by a graph where the nodes represent each college team. Two teams are connected by an edge if they played each other during the season. Knuth gives the graph for the 1990 college football season.

Miles Graphs. These graphs are similar to geometric graphs in that nodes are placed in space with two nodes connected if they are close enough. These graphs, however, are not random. The nodes represent a set of United States cities and the distance between them is given by road mileage from 1947. These graphs are also due to Knuth.

Queen Graphs. Given an  $n$  by  $n$  chessboard, a queen graph is a graph on  $n^2$  nodes, each corresponding to a square of the board. Two nodes are connected by an edge if the corresponding squares are in the same row, column, or diagonal. Unlike some of the other graphs, the coloring problem on this graph has a natural interpretation: Given such a chessboard, is it possible to place  $n$  sets of  $n$  queens on the board so that no two queens of the same set are in the same row, column, or

diagonal? The answer is yes if and only if the graph has coloring number  $n$ . Martin Gardner states without proof that this is the case if and only if  $n$  is not divisible by either 2 or 3. In all cases, the maximum clique in the graph is no more than  $n$ , and the coloring value is no less than  $n$ .

MYC: (From Michael Trick (trick@cmu.edu)) Graphs based on the Mycielski transformation. These graphs are difficult to solve because they are triangle free (clique number 2) but the coloring number increases in problem size.