

## **Algoritmos Genéticos Aplicados ao Problema de Grade Horária em Instituições de Ensino Superior**

**Suelen Vinter, Heber R. Serra, Hermínio V. Ramos Filho, Éldman de Oliveira Nunes**

Faculdade Hélio Rocha (FHR) – Rua Fernando Menezes Góes 570, Pituba, CEP 41.820-035 – Salvador – BA – Brasil.

{svinter,hrserra,herminiof}@gmail.com, eldman@bol.com.br

***Resumo.** Uma grade horária bem elaborada é um requisito importante para a boa administração de qualquer instituição de ensino superior. Porém, o grande número de variáveis envolvidas, como a quantidade de disciplinas e a disponibilidade de professores, tornam o problema da geração da grade horária muito complexo. O presente artigo apresenta uma solução para o problema de grade horária de instituições de ensino superior, utilizando uma abordagem heurística, os algoritmos genéticos. O sistema desenvolvido foi aplicado ao estudo de caso da Faculdade Hélio Rocha. Através dos vários testes realizados, comprovou-se a viabilidade da ferramenta e como resultado obteve-se uma considerável redução de tempo na elaboração da grade horária.*

***Palavras-Chave:** Grade Horária, Algoritmos Genéticos, Heurísticas.*

***Abstract.** A well elaborated horary grating is an important requirement for the good administration of any institution of superior education. However, the great number of subjects and the availability of the teachers make the problem of the generation from horary grating very complex. This work shows a solution for the problem of horary grating from institutions of superior education, using a heuristically boarding, the genetic algorithms. The developed system is applied to the study of case of the College Hélio Rocha. Some tests had been carried through to prove the viability of the tool proposal and as resulted got to be a considerable reduction of tome in preparing the horary grating.*

***Key-words:** Horary Grating, Genetic Algorithms, Heuristically.*

### **1. Introdução**

O problema de programação horária, há tempos, é amplamente discutido e estudado, principalmente no meio acadêmico onde compor, manualmente, uma solução que satisfaça todas as restrições do problema, é uma tarefa difícil que demanda tempo. Nesse contexto, as aulas de uma instituição são reuniões entre professores e alunos num conjunto de períodos de tempo.

O processo de elaboração de grade horária é um problema de otimização combinatória da classe dos NP-Difíceis [Even *et al.* 1976]. Várias técnicas foram propostas na tentativa de se obter uma solução, entre as quais pode-se destacar: *Simulated Annealing* [Abramson 1991], Busca Tabu [Costa 1994], GRASP [Feo e Resende 1995] e Algoritmos Genéticos [Holland 1975].

Este artigo visa apresentar um estudo e a implementação de uma solução para o problema de geração de grade horária através da metaheurística algoritmos genéticos. Os algoritmos genéticos fazem uma analogia às teorias de Seleção Natural de Charles Darwin [Holland 1975].

O objetivo deste trabalho é definir uma representação genética para o problema de geração de grade horária de uma instituição, levando em consideração as disponibilidades e habilidades dos professores, utilizando Algoritmos Genéticos para alcançar uma solução viável.

A representação deste problema mediante algoritmos genéticos é definida através de um vetor de caracteres, chamado cromossomo. O processo de busca por uma solução aceitável é iniciado através de operadores genéticos que realizam o papel da evolução natural, seguindo os limites definidos que são os parâmetros genéticos. As restrições do problema são transformadas em funções que avaliam cada geração de indivíduos, possibilitando ou não a evolução dos mesmos.

## 2. O Problema de Programação Horária de Ensino Superior (PPHES)

O problema da construção da grade horária é um processo que busca ajustar, em uma tabela de horários disponíveis, todas as disciplinas que serão oferecidas em um semestre, atendendo às necessidades da instituição, dos docentes e discentes.

A alocação de professores, disciplinas, turmas, horários e dias da semana é considerado um problema NP-Difícil [Even *et al.* 1976], o que significa que possui ordem de complexidade exponencial, e o esforço computacional para a sua resolução cresce de acordo com o tamanho do problema [Gary; Johnson 1979]. Para exemplificar a complexidade do problema de grade horária considerou-se apenas um semestre, dez horários (agrupados em pares), cinco disciplinas e seis professores, sendo os professores aptos a lecionarem as cinco disciplinas. Após aplicar os conceitos de arranjo conforme equação (1), como resultado tem-se 86.400 possíveis soluções de grade horária.

$$A_{n,k} = n! / (n-k)! \quad (1)$$

Comumente este problema é abordado por técnicas heurísticas, nas quais destacam-se as metaheurísticas, que vêm sendo aplicadas com sucesso ao problema. As metaheurísticas que mais se destacam são: *Simulated Annealing* [Abramson 1991], Busca Tabu [Costa 1994], GRASP [Feo e Resende 1995] e Algoritmos Genéticos [Holland 1975].

O conjunto de restrições varia de acordo com as características da instituição. Burker (1995) divide-as em duas categorias:

- **Restrições Rígidas:** um horário que viola uma restrição rígida não pode ser considerado parte da solução, e deve ser rejeitado pelo algoritmo. Por exemplo, um docente não pode ser alocado a um horário no qual não esteja disponível (solução infactível).

- **Restrições Flexíveis:** dificilmente levam uma grade horária a ser rejeitada. Geralmente são avaliadas por uma função que penaliza o horário, calculando até que ponto este violou sua restrição. As restrições flexíveis podem ter sua prioridade variável, umas com menor e outras com maior prioridade.

### 3. Algoritmos Genéticos

Os Algoritmos Genéticos (AG's) são algoritmos de busca, baseados em mecanismos de seleção natural e genética, proposto por Charles Darwin [Goldberg 1989].

Trata-se de uma metaheurística que se fundamenta em uma analogia com processos naturais de evolução, nos quais, dada uma população, os indivíduos com características genéticas melhores têm maiores chances de sobrevivência e de produzirem filhos cada vez mais aptos, enquanto indivíduos com características genéticas inferiores tendem a desaparecer [Souza 2002].

#### 3.4. Funcionamento Geral dos AG's

Os AG's são algoritmos iterativos, e a cada iteração a população é modificada. A criação dos indivíduos da nova população é feita através da utilização de operadores genéticos de cruzamento e mutação, simulando o processo de seleção natural. Após cada geração, os indivíduos são avaliados e qualificados. O processo de geração de novas populações é repetido iterativamente até que o AG chegue a uma solução aceitável ou satisfaça alguma condição de parada.

O funcionamento de um AG pode ser resumido algoritmicamente pela figura 1:

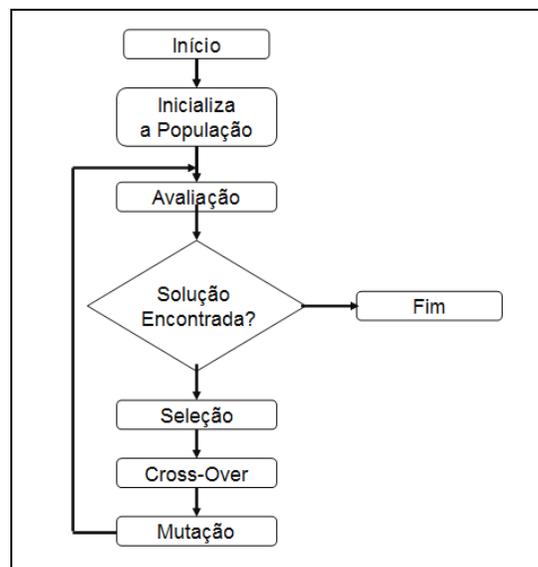


Figura 1. Funcionamento do AG.

#### 3.4.1. Representação Cromossomial

Considerando um problema de otimização qualquer, os AG's inicializam a busca da melhor solução a partir de um conjunto inicial de soluções aleatórias, sendo esta a primeira geração de populações. Cada elemento do conjunto de soluções é denominado

um indivíduo ou cromossomo. Um cromossomo é composto por uma cadeia de informações, onde cada informação (gene) representa os parâmetros de uma solução.

A representação mais simples e mais usada é binária, isto é, um cromossomo é formado por uma seqüência de bits, adotada por Holland em seu livro [Holland 1975]. A figura 2 representa um cromossomo binário.

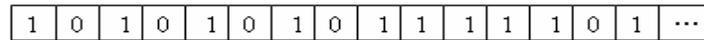


Figura 2. Cromossomo binário proposto por Holland.

### 3.4.2. Função de Avaliação / Função Objetivo

A função de avaliação é a forma utilizada pelos AG's para determinar a qualidade de um indivíduo como solução para o problema em questão. Pode-se dizer que a função de avaliação é a nota dada ao indivíduo na resolução do problema. Esta nota irá diferenciar as boas e más soluções para um problema [Linden 2006].

A função de avaliação em problemas de otimização está diretamente relacionada com a função objetivo, que pode devolver valores oriundos de penalizações devidas ao não cumprimento das restrições [Queirós 2002].

### 3.4.3. Operadores Genéticos

Para criar os indivíduos da nova população, são utilizados os operadores genéticos de *seleção*, *cruzamento* e *mutação*. Os operadores genéticos são mecanismos utilizados pelos AG's para transformar uma determinada população em uma geração subsequente, criando novos indivíduos com qualidade superior aos seus antecessores. [Massa 2004].

#### 3.4.3.1. Seleção

Seleção é o processo que simula o mecanismo de seleção natural, onde os pais mais aptos tem maior probabilidade de reprodução. O principal objetivo deste operador é guardar boas soluções, eliminando soluções de baixa aptidão, enquanto o tamanho da população permanece constante [Deb 2001].

Os métodos de seleção mais conhecidos são pelo torneio, seleção proporcional, seleção por ranking e seleção por roleta. De acordo com Goldberg (1989), o método de seleção usado pelos AG's clássicos é chamado *Roulette Whell*. Neste método, cada indivíduo da população é representado de forma proporcional ao seu valor de aptidão, como mostra a figura 3. Desta forma, todos os indivíduos possuem chances de serem selecionados, uns com pouca e outros com maior probabilidade, de forma semelhante à natureza (os mais fortes têm preferência para a próxima geração).

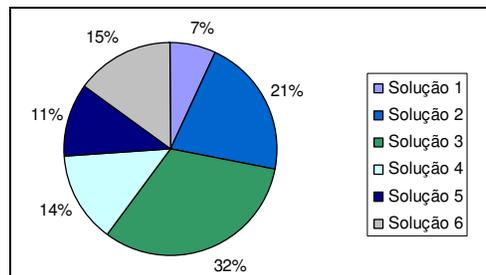


Figura 3. Método de seleção *Roulette Whell*.

### 3.4.3.2. Crossover

O operador de *crossover* é considerado o operador principal dos AG's. [Coury 2002]. Este operador cria novos indivíduos por intermédio de dois ou mais indivíduos. Com a utilização deste operador, existe a troca de informação entre diferentes soluções candidatas [Linden 2006].

Vários tipos de operadores de *crossover* já foram utilizados, entre eles *crossover* de um ponto, de dois pontos e uniforme, porém não foi comprovado um melhor desempenho de algum deles. Cada operador pode obter melhores ou piores resultados, a depender do problema [Concilio 2000].

O *crossover* de um ponto (figura 4) é o operador mais simples. Depois de selecionados dois pais pelo método da seleção, um ponto de corte é escolhido aleatoriamente. Um ponto de corte constitui uma posição entre dois genes de um cromossomo [Linden 2006].

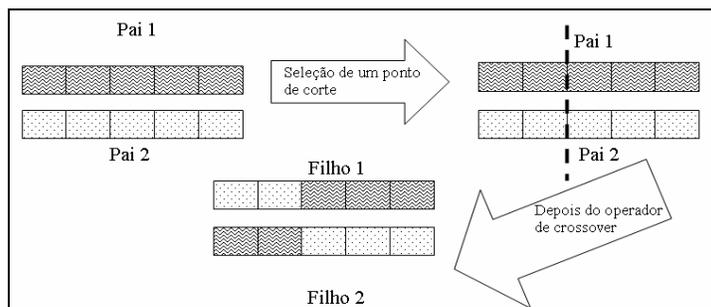


Figura 4. Crossover de um ponto.

### 3.4.3.3. Mutação

A mutação, diferentemente do cruzamento, é uma transformação unitária que cria novos indivíduos através de modificação aleatória de um ou mais genes do cromossomo de um único indivíduo da geração anterior, conforme figura 5 [Massa 2004].

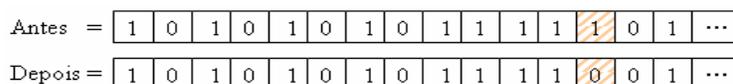


Figura 5. Mutação por bit.

### 3.4.4. Parâmetros Genéticos

Existem vários parâmetros do algoritmo genético que podem ser configurados para melhorar seu desempenho. É importante analisar de que maneira alguns parâmetros implicam no comportamento dos AG's. Os parâmetros genéticos mais comuns são o método utilizado para inicializar a população, o percentual de taxa de cruzamento, o percentual de taxa de mutação [Victorino 2005]

## 4. A Ferramenta SISGH

Nessa seção será descrita a ferramenta SISGH, baseada em algoritmos genéticos para a solução do problema de geração de grade horária.

Para a implementação da solução proposta, é necessário, primeiramente, elaborar o modelo de cromossomo. Após definida a estrutura cromossomial, segue-se para o funcionamento do algoritmo genético, onde envolve a geração da população inicial, a avaliação do cromossomo, a seleção e os operadores genéticos.

#### 4.1. Especificação do Problema

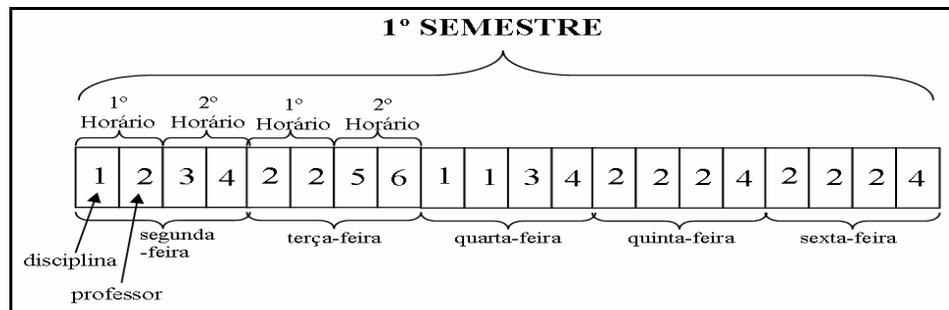
A solução proposta atende a uma Instituição de Ensino de apenas um turno, seja ele matutino, vespertino ou noturno. Uma semana de aulas deve corresponder a 20 aulas, sendo cada uma composta de 50 minutos. As aulas são agrupadas de duas em duas, implicando em 10 possíveis horários para um professor/disciplina, conforme tabela 1.

**Tabela 1. Distribuição dos Horários Disponíveis.**

	Segunda	Terça	Quarta	Quinta	Sexta
Horário 1	I	III	V	VII	IX
Horário 2	II	IV	VI	VIII	X

#### 4.2. Modelo de cromossomo

No modelo proposto, são utilizados pares de genes, onde o primeiro gene do par representa a informação da disciplina e o segundo representa o professor. Cada posição do par de genes está relacionada a um determinado horário, de um determinado dia da semana, de um determinado semestre. O cromossomo completo representa uma possível solução. A figura 6 apresenta um exemplo de vetor solução.



**Figura 6. Exemplo de vetor solução.**

#### 4.3. Inicialização da População

A geração da população inicial é realizada de forma aleatória. A população inicial possui um número, configurável, de cromossomos, com 160 genes cada. Sabendo-se que os AGs são algoritmos iterativos, a cada iteração a população é modificada.

Na criação de uma população inicial, são usados apenas um turno e um curso, sendo que o referido curso possui oito semestres. No processo de geração da população, cada par de alelos do cromossomo representa uma disciplina de um semestre do curso em um determinado horário, associada a um determinado professor.

#### 4.4. Função de Avaliação

Cada cromossomo é avaliado segundo o grau de atendimento às restrições flexíveis e rígidas. Os cromossomos que não atenderem às restrições rígidas terão seu *fitness* zerado, sendo uma solução infactível. Cada restrição flexível apresenta um valor, que

será utilizado como pontos para aqueles cromossomos que consigam cumprir estes requisitos. Todo cromossomo tem uma pontuação, resultado de uma avaliação sobre o atendimento das restrições flexíveis e rígidas.

O cálculo da pontuação de cada restrição é realizado pela equação (2).

$$\text{Pontuação}_{(\text{restrição})} = 100 / \text{número de restrições} \quad (2)$$

Os valores 2 e 8 atribuídos as restrições flexíveis (PRF) e rígidas (PRR), respectivamente, foram selecionados após diversas simulações empíricas não descritas neste artigo. A avaliação de um cromossomo é dada pela equação (3).

$$\text{Fitness} = ((\text{PRR}). 8) + ((\text{PRF}). 2) \quad (3)$$

onde,

- $\text{PRR} = \sum \text{pontosRR}$ , para as restrições rígidas (RR);
- e,  $\text{PRF} = \sum \text{pontosRF}$ , para as restrições flexíveis (RF).

A cada restrição não violada, aumenta-se a pontuação para o cromossomo, e este tende a ser selecionado para a nova população.

Considerando que o sistema possua três restrições rígidas e duas flexíveis implementadas, e, por exemplo, uma grade horária que viola uma restrição rígida e uma flexível, tem-se a seguinte função de avaliação:

$$\text{Fitness} = ((2 \times 20). 8) + ((1 \times 20). 2) = 360$$

Neste exemplo, o melhor indivíduo é aquele que obtiver a pontuação igual a 560, e o pior *fitness* terá a pontuação igual a zero.

Como cada cromossomo deve ser avaliado baseado em restrições rígidas e flexíveis, foram utilizadas cinco restrições, podendo ser adicionadas outras. Dentre as restrições levantadas, foram implementadas as seguintes:

#### **Restrições Rígidas:**

- Duas disciplinas não podem ocupar o primeiro e segundo horário de um mesmo dia;
- Um professor não pode ser alocado a um horário no qual não esteja disponível;
- Uma disciplina não pode ser alocada fora do semestre o qual pertence;
- Um professor não pode lecionar mais de uma disciplina no mesmo dia e horário.

#### **Restrição Flexível:**

- Evitar aulas consecutivas.

### **4.5. Seleção**

O método da roleta foi escolhido neste trabalho tendo em vista permitir que os indivíduos tenham chances de serem selecionados de forma proporcional a sua avaliação, o que tem fornecido bons resultados.

#### 4.6. Crossover

Devido à estrutura de codificação, o operador de *crossover* escolhido foi o de um ponto. Historicamente, o operador de *crossover* tem recebido uma percentagem e escolha muito alta, variando de 50% a 95% [Linden 2006]. O valor taxa de cruzamento pode ser configurado pelo usuário.

#### 4.7. Mutação

A mutação vai atuar sobre um dos parâmetros da grade horária, que pode ser professor, disciplina, semestre ou horário. Evitando várias alterações na possível solução, optou-se pela utilização da mutação de apenas um ponto. A taxa é configurável, como probabilidade dos cromossomos participarem ou não da mutação. O cromossomo mutante gerado será considerado um novo cromossomo e, durante a seleção, estará sujeito às mesmas regras de sobrevivência dos demais cromossomos.

#### 4.8. Critério de Parada

Adotou-se o critério do número de gerações, onde o número de gerações que o AG deve percorrer é parametrizável pelo usuário.

### 5. Testes e Resultados

O AG foi testado com o objeto estudo de caso Faculdade Hélio Rocha. Não foi possível fazer uma avaliação e comparação com resultados científicos de trabalhos correlatos, pelo fato de cada instituição trabalhar dentro de contextos distintos que definem a instância do problema.

Foram levados em consideração apenas o curso de Sistemas de Informação, o turno noturno, quarenta disciplinas e quinze professores. Nos testes foram feitas variações do tamanho da população, número de gerações, porcentagem de cruzamento e porcentagem de mutação. A tabela A.1 do apêndice A representa os principais testes realizados.

#### 5.1. Teste da Geração

O primeiro teste permitiu identificar, em primeira instância, a quantidade de gerações necessárias para se conseguir alguma melhoria no *fitness* dos indivíduos. Para o referido teste, foram fixados os parâmetros taxa de cruzamento e taxa de mutação, em 50% e 0,5%, respectivamente. Foi possível notar que os valores maiores 150 apresentam bons resultados (Gráfico 1).

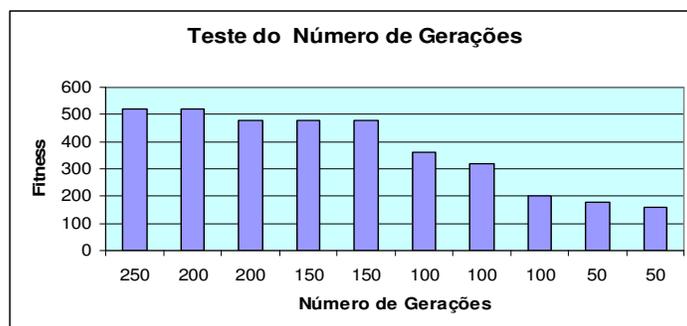


Gráfico 1. Melhor *fitness* x Teste do Número de Gerações.

## 5.2. Teste da População

A segunda avaliação permitiu identificar valores para o tamanho da população. Neste teste, os parâmetros escolhidos foram taxa de cruzamento e taxa de mutação, com percentuais de 50% e 0,5%, respectivamente. Foi constatado que valores acima de 150 forneceram melhores resultados para o progresso dos indivíduos (Gráfico 2).

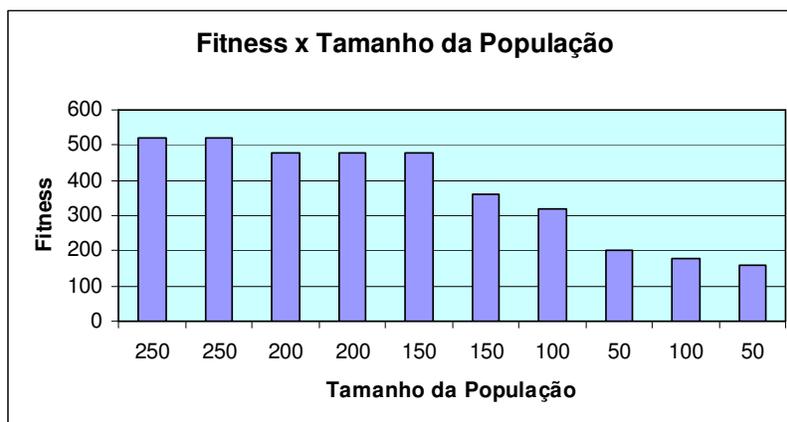


Gráfico 2. Melhor *fitness* x Teste do Tamanho da População.

## 5.3. Teste do Cruzamento

O próximo parâmetro observado foi o percentual de cruzamento da população. Para este teste, fixou-se o tamanho da população e o valor da taxa de mutação em 250 e 0,5%, respectivamente. Concluiu-se que os melhores resultados são obtidos com percentuais variando de 60% a 75% para este parâmetro (Gráfico 3).

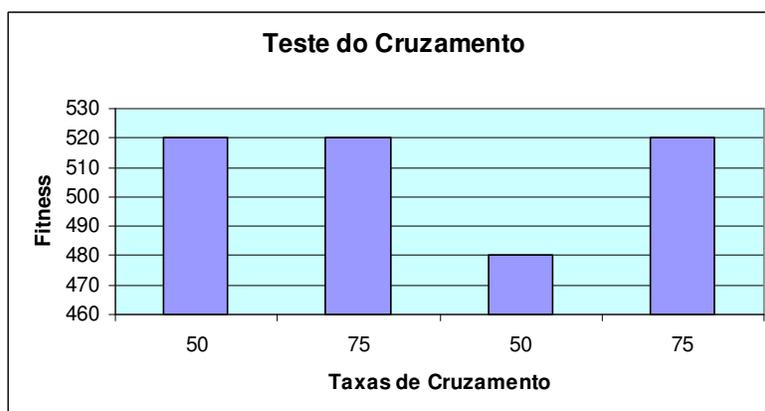
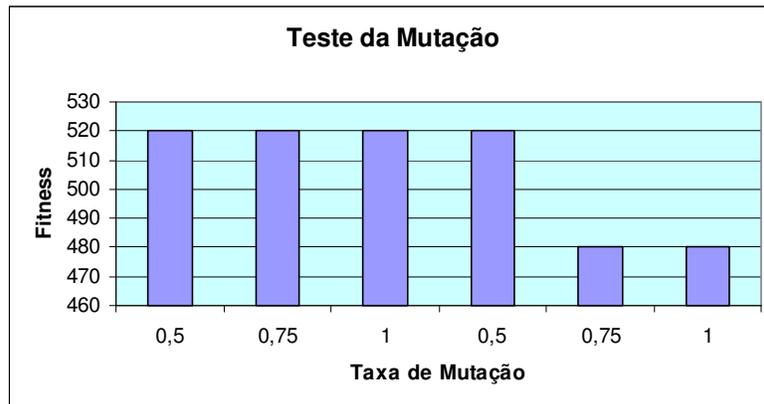


Gráfico 3. Melhor *fitness* x Teste Cruzamento

## 5.4. Teste de Mutação

O último parâmetro definido foi o percentual de mutação. Neste teste, fixou-se o tamanho da população em 250 e o valor da taxa de mutação em 75%. Os resultados obtidos apontaram para valores variando de 0,50% a 0,75%, conforme observação do gráfico 4.



**Gráfico 4. Melhor fitness x Teste Mutaçao**

Levando em consideraçao o tempo de execuçao do processo iterativo, observou-se que se por um lado, aumentando o número de geraçoes e tamanho da populaçao melhora o desempenho do algoritmo, por outro lado o tempo computacional cresce.

A partir da observaçao dos resultados dos testes, foram entao definidos os seguintes parâmetros, como mais adequados, para a geraçao da grade horaria:

- Tamanho da populaçao: 250
- Número de geraçoes: 250
- Percentagem de Cruzamento: 75%
- Percentagem de Mutaçao: 0,50%

## 6. Conclusao

Diversos estudos vem sendo realizados na tentativa de resolver o problema de grade horaria. Apesar de existirem varias ferramentas, ha dificuldade de encontrar uma que satisfaça todas as necessidades da instituicao. Naturalmente, os criterios de alocaçao de aula e das atividades administrativas mudam de instituicao para instituicao.

Neste trabalho não foram feitos testes comparativos porque o objetivo foi apresentar uma implementaçao computacional para solucionar o problema de grade horaria de uma instituicao de ensino especifica, adotando seus problemas caracteristicos. Baseando-se nos testes realizados, verificou-se que o modelo desenvolvido representa uma alternativa satisfatoria para a soluçao deste problema.

Com base na elaboraçao manual das grades horarias que ja ocorreram na instituicao objeto de analise, o algoritmo mostrou eficiencia com relaçao ao tempo e qualidade na confecçao em todos os casos de teste.

O tempo medio de processamento foi, aproximadamente, 22 minutos e 30 segundos, garantindo uma boa soluçao em tempo razoavel se comparado a elaboraçao manual que e realizada em um mes.

Como sugestoes para trabalhos futuros, ficam: a inicializaçao da populaçao atraves de uma tecnica heuristica; a implementaçao de outros tipos de *crossover*; inclusoes de novas funçoes de avaliacao, incluindo a prioridade de uma disciplina em ser alocada em determinado dia da semana e a prioridade de uma disciplina ser alocada

para um determinado recurso, como laboratórios ou recursos áudios-visuais. Outra sugestão é a expansão do AG para abranger outros cursos, permitindo disciplinas compartilhadas entre os mesmos.

## Referências

- Abramson, D. (1991). "Constructing School Timetables Using Simulated Annealing: Sequential and Parallel Algorithms", *Management Science*, 37:98-113.
- Burke, E., ELLIMAN, D. G. and WEARE, R. F. Specialised Recombinative Operatos for Timetabling Problems. v. 3-7 p. 75-85, abril, 1995.
- Concilio,R. (2000). Contribuições à Solução de Problemas de Escalonamento pela Aplicação Conjunta de Computação Evolutiva e Otimização com Restrições. Dissertação de Mestrado, Universidade Estadual de Campinas - Unicamp, FEEC,DCA.
- Costa, D. (1994). "A tabu search algorithm for computing an operational timetable". *European Journal of Operational Research*, 76: 98-110.
- Coury V. D. (2002). "Algoritmos Genéticos: Uma Nova Abordagem para Resolução de Problemas em Sistemas Elétricos de Potência".
- Deb, Kalyanmoy. (2001). Multi-Objective Optimization Using Evolutionary Algorithms. 1 ed. Chichester, John Wiley & Sons.
- Even, S., et al. (1976) "On the complexity of timetabling and multicommodity flow problems", *SIAM Journal of Computation*, 5: 691-703.
- Feo, T.A. and Resend, M.G.C. (1995) "Greedy randomized adaptive search procedures", *Journal of Global Optimization*, 6:109-133.
- Gary,M.R.; Johnson,D.S. (1979). "Computers and Intractability: a Guide to the Theory of NP-Completeness". Freeman.
- Goldberg, D. E. (1989), *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley Publishing Company, Inc., Reading, MA.
- Holland, J. H. (1975). *Adaption in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor.
- Linden, Ricardo. Algoritmos Genéticos: Uma importante ferramenta da Inteligência Computacional. Rio de Janeiro: Brasport, 2006.
- Massa, E.S.(2004) "Hibridização de Algoritmos Genéticos com Relaxação Lagrangeana Aplicada ao Job Shop". Dissertação de Mestrado, Departamento de Matemática - UFBA, Salvador,Bahia.
- Prado, Oclair Gallacini. Computação evolutiva empregada na reconstrução de Árvores Filogenéticas. 2001. 186 f. Dissertação (Mestrado) - Departamento de Engenharia de Computação e Automação Industrial, Universidade Estadual de Campinas, Campinas, 2001.
- Queirós, Francisco Henrique: Construção automática de Horários de Aulas: Algoritmos Genéticos. 2002. Universidade Portucalense.

- Souza, M.J.F.; Guimarães, I.F.; Costa, F.P. (2002) Um Algoritmo Evolutivo Híbrido para o Problema de Programação de Horários em Escolas.
- Viana, G.V.R. (1998) “Meta-heurísticas e programação paralela em otimização combinatória”. Fortaleza: EUFC.
- Victorino, Igor Ricardo de Souza. Otimização de um reator industrial de produção de álcool cíclico utilizando Algoritmos Genéticos. 2005. 527 f. Tese (Doutorado) - Curso de Engenharia Química, Departamento de Faculdade de Engenharia Química, Unicamp, Campinas, 2005.

## APÊNDICE A

**Tabela A.1 – Principais testes realizados.**

Teste	TamPop	NumGer	%Elit	% C	%M	Max. n	FitMedio	Tempo
1	50	50	10	50	0,50	160	140	00:02:10
2	50	50	10	50	0,75	160	140	00:02:30
3	50	50	10	50	1	200	160	00:03:20
4	50	50	10	75	0,50	200	160	00:03:45
5	50	50	10	75	0,75	160	140	00:03:20
6	50	50	10	75	1	200	180	00:04:10
7	50	100	10	50	0,50	200	180	00:04:20
8	50	100	10	50	0,75	200	160	00:05:10
9	50	100	10	50	1	320	240	00:04:10
10	50	100	10	75	0,50	200	160	00:05:25
11	50	100	10	75	0,75	160	140	00:05:35
12	50	100	10	75	1	160	130	00:05:35
13	100	50	10	50	0,50	180	140	00:07:10
14	100	50	10	50	0,75	240	200	00:07:25
15	100	50	10	50	1	240	200	00:07:10
16	100	50	10	75	0,50	200	180	00:07:20
17	100	50	10	75	0,75	200	180	00:08:10
18	100	50	10	75	1	240	200	00:08:25
19	100	50	10	100	0,50	240	200	00:08:40
20	100	50	10	100	0,75	320	280	00:08:30
21	100	50	10	100	1	360	300	00:09:10
22	100	100	10	50	0,50	320	280	00:10:40
23	100	100	10	50	0,75	360	320	00:10:45
24	100	100	10	50	1	360	300	00:10:55
25	100	100	10	75	0,50	360	300	00:11:10
26	100	100	10	75	0,75	320	280	00:11:10
27	100	100	10	75	1	360	300	00:11:25
28	100	100	10	100	0,50	320	280	00:11:20
29	100	100	10	100	0,75	360	320	00:11:25
30	150	100	10	50	0,50	360	300	00:12:15
31	150	100	10	50	0,75	320	280	00:12:30
32	150	100	10	50	1	360	300	00:12:25
33	150	100	10	75	0,50	320	280	00:12:30
34	150	100	10	75	0,75	360	320	00:12:55
35	150	100	10	75	1	480	400	00:12:30
36	150	100	10	100	0,50	360	320	00:13:00
37	150	100	10	100	0,75	480	400	00:12:50
38	150	150	10	50	0,50	480	420	00:13:50
39	150	150	10	50	0,75	360	320	00:14:10
40	150	150	10	50	1	360	320	00:14:15
41	150	150	10	75	0,50	480	420	00:14:10
42	150	150	10	75	0,75	360	320	00:14:25
43	150	150	10	75	1	360	320	00:14:10
44	200	150	10	50	0,50	480	400	00:15:00
45	200	150	10	50	0,75	480	420	00:15:30
46	200	150	10	50	1	480	420	00:15:20
47	200	150	10	75	0,50	480	420	00:15:10
48	200	150	10	75	0,75	480	460	00:15:50
49	200	150	10	75	1	480	460	00:16:00
50	200	150	10	100	0,50	480	420	00:16:20
51	200	150	10	100	0,75	480	420	00:16:15
52	200	200	10	50	0,50	480	460	00:16:40
53	200	200	10	50	0,75	480	460	00:16:30
54	200	200	10	50	1	480	420	00:17:20
55	200	200	10	75	0,50	480	460	00:17:30

56	200	200	10	75	0,75	480	460	00:18:20
57	200	200	10	75	1	520	500	00:18:25
58	200	200	10	100	0,50	520	500	00:18:40
59	250	200	10	50	0,50	520	500	00:21:14
60	250	200	10	50	0,75	480	400	00:21:35
61	250	200	10	50	1	520	500	00:22:15
62	250	200	10	75	0,50	520	500	00:22:35
63	250	200	10	75	0,75	520	500	00:22:35
64	250	200	10	75	1	480	460	00:21:40
65	250	200	10	100	0,50	520	500	00:23:00
66	250	200	10	100	0,75	520	500	00:23:14
67	250	250	10	50	0,50	480	460	00:23:44
68	250	250	10	50	0,75	520	500	00:23:15
69	250	250	10	50	1	520	500	00:23:22
70	250	250	10	75	0,50	520	500	00:24:40
71	250	250	10	75	0,75	520	500	00:25:20
72	250	250	10	75	1	520	500	00:25:18