

# ESTUDO DOS PARAMETROS DE UM ALGORITMO GENÉTICO PARA POSTERIOR USO NA SOLUÇÃO DE PROBLEMAS DO TIPO JOB-SHOP

**Gilson Rogério Batista, Gideon Villar Leandro**  
Universidade Regional do Noroeste do Estado do Rio Grande do Sul – UNIJUI  
Faculdade de Engenharia Elétrica, DETEC – Ijuí - RS.  
[gilson.batista@unijui.edu.br](mailto:gilson.batista@unijui.edu.br), [gede@unijui.edu.br](mailto:gede@unijui.edu.br)

*Resumo. Este documento tem o objetivo de mostrar o estudo dos principais parâmetros que envolvem o desenvolvimento e implementação de algoritmos genéticos para posterior uso na resolução de problemas do tipo Job-Shop.*

**Palavras-chave:** Algoritmos Genéticos, escalonamento de tarefas, Job-Shop.

## 1. INTRODUÇÃO

No final da década de 60, John Holland, estudou formalmente a evolução das espécies e propôs um modelo heurístico computacional que quando implementado poderia oferecer boas soluções para problemas extremamente difíceis que eram insolúveis computacionalmente até aquela época.

Holland apresenta os algoritmos genéticos como uma metáfora para os processos evolutivos.

Em um trabalho recente, Ricardo et. al [1] afirma que os algoritmos genéticos são uma técnica de busca extremamente eficiente no seu objetivo de varrer o espaço de soluções e encontrar soluções próximas da solução ótima, quase sem necessitar interferência humana, sendo uma das várias técnicas da inteligência computacional dignas de estudo.

O problema Job-Shop é um problema de alocação de um conjunto de jobs para as máquinas, de tal forma que os jobs sejam

executados em um menor intervalo de tempo.

Cada job pode consistir de diversas tarefas e cada tarefa deve ser processada numa máquina particular. Além disso, as tarefas em cada job estarão sujeitas às restrições de precedência.

Os algoritmos genéticos têm sido amplamente usados na resolução de problemas do tipo job-shop, pois embora não garantam uma solução ótima para o problema, são capazes de oferecer uma solução de boa qualidade, em um tempo de processamento aceitável.

## 2. ALGORITMOS GENÉTICOS (GAs)

Pode-se dizer que algoritmos genéticos são algoritmos de busca baseados nos mecanismos de seleção natural e genética. Eles combinam a sobrevivência entre os melhores com uma forma estruturada de troca de informação genética entre dois indivíduos para formar uma estrutura heurística de busca.

Segundo a Ref. [1], um algoritmo genético tem o mesmo comportamento que a evolução natural: a competição entre os indivíduos é que determina as soluções obtidas. Eventualmente, devido à sobrevivência do mais apto, os melhores indivíduos prevalecerão.

Em seu trabalho sobre Sistemas Inteligentes Solange et. al. [2] afirma que os algoritmos genéticos diferenciam-se de

esquemas aleatórios por serem uma busca que utiliza informação pertinente ao problema e não trabalham com caminhadas aleatórias pelo espaço de soluções, mas sim direcionando sua busca através do mecanismo de seleção, equivalente ao processo natural.

Por isso algoritmos genéticos são usados geralmente para a solução de problemas de busca com espaços de busca intratavelmente grandes, como é o caso dos problemas do tipo Job-Shop, que não podem ser resolvidos por técnicas tradicionais.

### **3. ESQUEMA DE UM ALGORITMO GENÉTICO**

Os algoritmos genéticos funcionam mantendo uma população de estruturas, denominadas indivíduos ou cromossomos.

Cada indivíduo recebe uma avaliação que é uma quantificação da sua qualidade como solução do problema em questão. Com base nesta avaliação serão aplicados os operadores genéticos, como recombinação e mutação, entre outros, de forma a simular a sobrevivência do mais apto.

#### **3.1. Representação cromossomial**

Do ponto de vista dos algoritmos genéticos, o cromossomo é uma solução candidata, ou seja, um ponto no espaço de busca.

Cromossomos são usualmente implementados na forma de listas de atributos ou vetores, onde cada atributo é conhecido como *gene*. Os possíveis valores que um determinado gene pode assumir são denominados *alelos*.

A representação cromossomial é fundamental para o algoritmo genético. Basicamente ela consiste em uma maneira de traduzir a informação do nosso problema em uma maneira viável de ser tratada pelo computador. Quanto mais ela for adequada ao problema, maior será a qualidade dos

resultados obtidos.

#### **3.2. Função de avaliação**

Segundo a ref. [1] a função de avaliação é a maneira utilizada pelos GAs para determinar a qualidade de um indivíduo como solução do problema em questão e deve refletir as necessidades do problema da forma mais direta possível. Ela deve embutir todas as restrições do problema, através de punições apropriadas para os cromossomos que as desrespeitarem. Estas punições devem ser feitas de forma proporcional à sua gravidade. Isto é, uma restrição mais rígida deve impor uma punição maior a um cromossomo que a desrespeite.

#### **3.3. Seleção de pais**

O método de seleção de pais deve simular o mecanismo de seleção natural que atua sobre as espécies biológicas, em que os pais mais capazes geram mais filhos, ao mesmo tempo em que os pais menos aptos também podem gerar descendentes.

Na Ref. [1] afirma-se que os indivíduos são selecionados de acordo com seu valor de aptidão. O princípio básico do funcionamento dos algoritmos genéticos é que um critério de seleção vai fazer com que, depois de muitas gerações, o conjunto inicial de indivíduos gere indivíduos mais aptos.

#### **3.4. Operador de crossover**

O operador de crossover ou recombinação cria novos indivíduos através da combinação de dois ou mais indivíduos. A idéia intuitiva por trás do operador de crossover é a troca de informação entre diferentes soluções candidatas.

O crossover é o operador responsável pela recombinação de características dos pais durante a reprodução, permitindo que as

próximas gerações herdem essas características. Ele é considerado o operador genético predominante, por isso é aplicado com probabilidade dada pela taxa de cruzamento, que deve ser maior que a taxa de mutação.

### 3.5. Operador de mutação

A “fig. 1” apresenta o operador de mutação que modifica aleatoriamente um ou mais genes de um cromossomo. A probabilidade de ocorrência de mutação em um gene é denominada taxa de mutação. Usualmente, são atribuídos valores pequenos para a taxa de mutação. A idéia intuitiva por trás do operador de mutação é criar uma variabilidade extra na população, mas sem destruir o progresso já obtido com a busca.

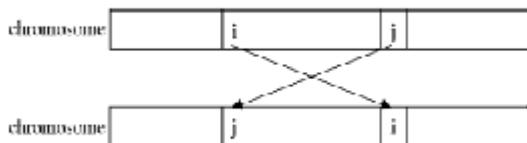


Figura 1: Operador mutação

### 3.6. Módulo de população

Para a ref. [1] o desempenho do algoritmo genético é extremamente sensível ao tamanho da população, logo este parâmetro deve ser definido com cuidado. Caso este número seja pequeno demais, não haverá espaço para termos uma variedade genética suficientemente grande dentro da nossa população, o que fará com que nosso algoritmo seja incapaz de achar boas soluções e caso este número seja grande demais, o algoritmo demorará demais e poderemos estar nos aproximando perigosamente de uma busca exaustiva.

## 4. RESULTADOS

Com a finalidade de entender a aplicação

dos algoritmos genéticos à solução de problemas, desenvolveu-se o estudo da solução de um problema de maximização de uma função definida pela “Eq. 1”.

$$\max g(x, y) = -[x \sin(4x) + 1,1 y \sin(2y)] \quad (1)$$

no intervalo,  $8 < x < 10$ ,  $8 < y < 10$ , que define a região viável do problema.

O primeiro passo para a aplicação de algoritmos genéticos a um problema qualquer é encontrar alguma representação cromossômica conveniente, cujo gene represente o espaço de busca do problema, optou-se neste trabalho por representar os cromossomos como vetores binários de zeros e um (0,1), os quais são gerados aleatoriamente, onde os 8 primeiros bits representam os valores correspondentes a variável x e os 8 últimos os valores correspondentes a variável y.

Definiu-se o tamanho da população inicial como sendo 6 cromossomos, gerados aleatoriamente e representados na “Tabela 1”.

Após a definição da população inicial, o próximo passo foi a conversão da seqüência binária (base 2) para base 10 e posterior cálculo do valor da função adaptação  $g(x,y)$  através da “Eq. 1”.

Tabela 1. População Inicial, valores reais para x e y, valor da função avaliação.

| Cromossomos      | x     | y     | $g(x,y)$ |
|------------------|-------|-------|----------|
| 1000010100100111 | 9,04  | 8,31  | 16,26    |
| 0000111000001001 | 8,11  | 8,07  | -3,21    |
| 1001000100000001 | 9,14  | 8,01  | 11,01    |
| 1100010100101001 | 9,55  | 8,32  | 2,76     |
| 0111110010101100 | 8,98  | 9,35  | 10,32    |
| 1110001001001010 | 9,77  | 8,58  | -0,22    |
| $\sum g(x,y)$    | ----- | ----- | 36,92    |

A “Tabela 1” apresenta os valores dos cromossomos da população inicial e seus respectivos valores para função adaptação.

O mecanismo para seleção das melhores cadeias, ou seja, as mais adaptadas é definido pelo uso das probabilidades proporcionais, dadas pela “Eq. 3” e pelo uso das probabilidades acumulativas, dada pela “Eq. 4” resultando nos valores da “Tabela 2”.

$$P_i = \frac{f(x)}{F(x)}, \text{ sendo } F(x) = \sum f(x) \quad (3)$$

$$q_i = \sum_{j=1}^i p_j \quad (4)$$

Tabela 2. Propriedades Proporcionais e Propriedades Acumulativas.

| Cromossomo | Probabilidades Proporcionais | Probabilidades Acumulativas |
|------------|------------------------------|-----------------------------|
| 1          | 0,44                         | 0,44                        |
| 2          | 0,09                         | 0,35                        |
| 3          | 0,30                         | 0,65                        |
| 4          | 0,07                         | 0,72                        |
| 5          | 0,28                         | 1,00                        |
| 6          | 0,00                         | 1,00                        |

Para a seleção dos cromossomos que contribuem para a geração seguinte considerou-se um conjunto de números r, escolhidos aleatoriamente entre [0,1], em quantidade igual ao número de cromossomos.

Os valores gerados aleatoriamente foram: r1 = 0,64; r2 = 0,08; r3 = 0,47; r4 = 0,88; r5 = 0,93; r6 = 0,70.

A análise é feita através das seguintes opções:

Se  $r <$  probabilidade acumulativa do elemento, então se seleciona o 1º cromossomo C1.

Se  $r >$  probabilidade acumulativa do elemento, então se passa para o subsequente e faz a análise novamente.

Depois de selecionados, os cromossomos dão origem a uma população intermediária representada na “Tabela 3”.

Selecionados os pais que contribuíram

para a formação da geração seguinte o próximo passo foi aplicar o operador crossover. A quantidade de cromossomos a ser submetida ao processo de crossover é definida através da probabilidade de cruzamento (pc) que foi usada como sendo 25%.

Tabela 3. População intermediária cromossomos selecionados para gerar a próxima geração.

| Cromossomos             | Função de adaptação |
|-------------------------|---------------------|
| C1' - 1001000100000001  | $g(x, y) = 11,01$   |
| C2'' - 1000010100101100 | $g(x, y) = 16,72$   |
| C3' - 1001000100000001  | $g(x, y) = 11,01$   |
| C4'' - 0111110010100111 | $g(x, y) = 11,02$   |
| C5'' - 0111110010101001 | $g(x, y) = 10,67$   |
| C6'' - 1100010100101100 | $g(x, y) = 3,10$    |

O processo de escolha de quem será cruzado é feito em pares, sorteando números randômicos (ri).

Por exemplo, se r1 for menor que a probabilidade pc, então o cromossomo C1' será selecionado.

A “Fig. 2” ilustra o esquema do operador crossover utilizado, onde após ter sido selecionado um cromossomo, deve-se gerar um novo número randômico para determinar a posição k, onde duas novas cadeias são formadas pela troca de todos os caracteres compreendidos entre as posições k + 1 e m. Esta posição k é determinada pela “Eq. 5”.

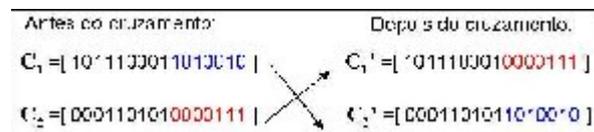


Figura 2: Operador crossover

$$k = 1 + \text{rand} [(m - 1) - 1] \quad (5)$$

Assim, após a aplicação do operador crossover, a população é dada pelos valores contidos na “Tabela 4”.

Tabela 4: População gerada após o uso do operador crossover.

| Cromossomo Gerado     | Cromossomo Gerador - g(x,y) |
|-----------------------|-----------------------------|
| C1'- 1001000100000001 | C3 - g(x, y) = 11,01        |
| C2'- 1000010100100111 | C1 - g(x, y) = 16,26        |
| C3'- 1001000100000001 | C3 - g(x, y) = 11,01        |
| C4'- 0111110010101100 | C5 - g(x, y) = 10,32        |
| C5'- 0111110010101100 | C5 - g(x, y) = 10,32        |
| C4'- 1100010100101001 | C4 - g(x, y) = 2,76         |

O último operador aplicado é o operador de mutação que consiste em uma modificação aleatória do valor de um alelo da cadeia.

O processo de mutação é controlado por um parâmetro fixo pm, probabilidade de mutação, que é geralmente recomendado como sendo 1%.

A metodologia utilizada para o operador mutação foi a de selecionar aleatoriamente uma posição em um cromossomo, obedecendo a probabilidade de mutação pm, e mudar o valor do bit correspondente a esta posição.

Para a aplicação do operador mutação ao problema em estudo, foi necessário gerar 96 (6 x 16) números randômicos r entre [0,1]. Se r for menor que a probabilidade pm = 0,01 será feita a mutação no bit correspondente. Gerados os 96 números r entre 0 e 1, três tiveram probabilidades menores que pm. Sendo os seguintes:

$$r_{13} = 0,009 ; r_{39} = 0,0025 ; r_{83} = 0,0004$$

Submetendo os bits 13, 39 e 83 ao processo de mutação têm-se os valores dos mesmos alterados conforme a "Tabela 5", onde os valores em vermelho correspondem aos bits alterados.

Após a aplicação dos três operadores, tem-se encerrado o ciclo da 1ª geração. Observando-se os valores das funções de adaptação da população na "Tabela 1" e na "Tabela 5" nota-se que a população inicial

melhorou no sentido de caminhar na direção da maximização da função objetiva.

Observa-se que o valor de  $\sum g(x,y)$  passou de 36,92 para 58,52. Obviamente, executando outras iterações espera-se uma adaptação muito melhor da população.

Tabela 5: Cromossomos após o operador mutação.

| Cromossomos         | x     | y     | g(x,y) |
|---------------------|-------|-------|--------|
| C1'1001000100001001 | 9,14  | 8,04  | 11,52  |
| C2'1000010100101100 | 9,04  | 8,35  | 16,72  |
| C3'1001001100000001 | 9,15  | 8,00  | 10,68  |
| C4'0111110010100111 | 8,97  | 9,31  | 11,06  |
| C5'0111110010101001 | 8,97  | 9,33  | 10,63  |
| C6'1110010100101100 | 9,80  | 8,35  | -2,09  |
| $\sum g(x,y)$       | ----- | ----- | 58,22  |

## 5. CONSIDERAÇÕES FINAIS

Algoritmos genéticos ainda são recentes e são considerados um instrumento novo de pesquisa. Podendo ser utilizados em diversas áreas de atividade humana.

Um bom resultado a ser obtido pelos Algoritmos Genéticos, dependerá do rendimento de detalhes como o método de codificação das soluções candidatas, os tipos de operadores genéticos utilizados, os ajustes de parâmetros e outros critérios particulares.

Por este motivo, as decisões sobre cada passo da elaboração do algoritmo devem ser analisadas cuidadosamente, visto que existem muitas possibilidades de implementação e o relacionamento entre os objetos de decisão geralmente não estão suficientemente claros e simples.

## REFERÊNCIAS

- [1] R. Linden, Algoritmos Genéticos – Uma importante ferramenta da Inteligência Computacional, Brasport, RJ:2006.p.348

- [2] S.O. Rezende, Sistemas Inteligentes – Fundamentos e Aplicações, Manole, SP:2002,p.550