

ALGORITMOS GENÉTICOS: PRINCÍPIOS E APLICAÇÕES

Marco Aurélio Cavalcanti Pacheco
ICA: Laboratório de Inteligência Computacional Aplicada
Departamento de Engenharia Elétrica
Pontifícia Universidade Católica do Rio de Janeiro
Email: marco@ele.puc-rio.br
Tel: (+55 21) 2529-9445
Rua Marques de São Vicente 225, Gávea
CEP 22453-900, Rio de Janeiro, RJ, Brasil

RESUMO

Algoritmos Genéticos são inspirados no princípio Darwiniano da evolução das espécies e na genética [1]. São algoritmos probabilísticos que fornecem um mecanismo de busca paralela e adaptativa baseado no princípio de sobrevivência dos mais aptos e na reprodução. Este artigo introduz as técnicas computacionais inteligentes, Redes Neurais, Lógica Fuzzy e Sistemas Especialistas, e apresenta os princípios básicos e aplicações dos Algoritmos Genéticos.

1. SISTEMAS INTELIGENTES

A Inteligência Computacional é uma área da ciência que busca, através de técnicas inspiradas na Natureza, o desenvolvimento de sistemas inteligentes que imitam aspectos do comportamento humano, tais como: aprendizado, percepção, raciocínio, evolução e adaptação.

<u>Técnica</u>	<u>Inspiração</u>
Redes Neurais	Neurônios biológicos
Algoritmos Genéticos	Evolução biológica
Lógica Fuzzy	Proc. linguístico
Sistemas Especialistas	Inferência Humana

Redes Neurais são modelos computacionais não lineares, inspirados na estrutura e operação do cérebro humano, que procuram reproduzir características humanas, tais como: *aprendizado, associação, generalização e abstração*. Redes Neurais são efetivas no aprendizado de padrões a partir de dados não lineares, incompletos, com ruído ou compostos de exemplos contraditórios.

Algoritmos Genéticos (GAs: Genetic Algorithms) são algoritmos matemáticos inspirados nos mecanismos de evolução natural e recombinação genética. A técnica de Algoritmos Genéticos fornece um mecanismo de busca adaptativa que se baseia no princípio Darwiniano de reprodução e sobrevivência dos mais aptos.

Lógica Nebulosa (*Fuzzy Logic*) tem por objetivo modelar o modo aproximado de raciocínio humano, visando desenvolver sistemas computacionais capazes de tomar decisões racionais em um ambiente de incerteza e imprecisão. A Lógica Nebulosa oferece um mecanismo para manipular informações imprecisas, tais como os conceitos de muito, pouco, pequeno, alto, bom, quente, frio, etc, fornecendo uma resposta aproximada para uma questão baseada em um conhecimento que é inexato, incompleto ou não totalmente confiável.

Sistemas Especialistas são programas computacionais destinados a solucionar problemas em um campo especializado do conhecimento humano. Usa técnicas de IA, base de conhecimento e raciocínio inferencial.

As técnicas da Inteligência Computacional têm sido empregadas com sucesso no desenvolvimento de sistemas inteligentes de previsão, suporte à decisão, controle, otimização, modelagem, classificação e reconhecimento de padrões em geral, aplicados em diversos setores: Energia, Industrial, Econômico, Financeiro, Comercial e Outros, Síntese de Circuitos, Meio Ambiente, entre outros.[2]

2. ALGORITMOS GENÉTICOS: PRINCÍPIOS E APLICAÇÕES

Algoritmos Genéticos (Gas-Genetic Algorithms) constituem uma técnica de busca e otimização, altamente paralela, inspirada no princípio Darwiniano de seleção natural e reprodução genética [1].

Os princípios da natureza nos quais os GAs se inspiram são simples. De acordo com a teoria de C. Darwin, o princípio de seleção privilegia os indivíduos mais aptos com maior longevidade e, portanto, com maior probabilidade de reprodução. Indivíduos com mais descendentes têm mais chance de perpetuarem seus códigos genéticos nas próximas gerações. Tais códigos

genéticos constituem a identidade de cada indivíduo e estão representados nos cromossomas.

Estes princípios são imitados na construção de algoritmos computacionais que buscam uma melhor solução para um determinado problema, através da evolução de populações de soluções codificadas através de cromossomas artificiais.

Em GAs um cromossoma é uma estrutura de dados que representa uma das possíveis soluções do espaço de busca do problema. Cromossomas são então submetidos a um processo evolucionário que envolve avaliação, seleção, recombinação sexual (crossover) e mutação. Após vários ciclos de evolução a população deverá conter indivíduos mais aptos.

A analogia entre Algoritmos Genéticos e o sistema natural é representada através da tabela abaixo:

Tabela 1

Natureza	Algoritmos Genéticos
Cromossoma	Palavra binária, vetor, etc
Gene	Característica do problema
Alelo	Valor da característica
Loco	Posição na palavra, vetor
Genótipo	Estrutura
Fenótipo	Estrutura submetida ao problema
Indivíduo	Solução
Geração	Ciclo

Podemos caracterizar os Algoritmos Genéticos através dos seguintes componentes [2]:

1. Problema a ser otimizado
2. Representação das Soluções de Problema
3. Decodificação do Cromossoma
4. Avaliação
5. Seleção
6. Operadores Genéticos
7. Inicialização da População

A seguir é apresentada uma breve discussão sobre cada um desses aspectos, exemplificando-se quando apropriado.

1 – Problema

GAs são particularmente aplicados em problemas complexos de otimização: problemas com diversos parâmetros ou características que precisam ser combinadas em busca da melhor solução; problemas com muitas restrições ou condições que não podem ser representadas matematicamente; e problemas com grandes espaços de busca.

GAs têm sido aplicados a diversos problemas de otimização [3], tais como: Otimização de Funções Matemáticas, Otimização Combinatorial, Otimização de Planejamento, Problema do Caixeiro Viajante, Problema de

Otimização de Rota de Veículos, Otimização de Layout de Circuitos, Otimização de Distribuição, Otimização em Negócios e Síntese de Circuitos Eletrônicos. Alguns exemplos de produtos desenvolvidos no ICA são:

- Fluxo de Caixa Inteligente
- Classificação de Clientes (Data Mining)
- Alocação de Espaço Físico
- Planejamento e Otimização de Embarque de Minério no Porto de Tubarão
- Análise de Alternativas de Investimento em Projetos de Exploração e Prospecção de Petróleo sob Incertezas Técnicas e de Mercado
- Otimização da Quantidade e Localização de Poços Petrolíferos para o Desenvolvimento de um Campo de Petróleo sob condições de certeza

2 – Representação

A representação das possíveis soluções do espaço de busca de um problema define a estrutura do cromossoma a ser manipulado pelo algoritmo.

A representação do cromossoma depende do tipo de problema e do que, essencialmente, se deseja manipular geneticamente. Os principais tipos de representação são:

Representação	Problemas
Binária	Numéricos, Inteiros
Números Reais	Numéricos
Permutação de Símbolos	Baseados em Ordem
Símbolos Repetidos	Grupamento

A representação binária é simples, fácil de manipular cromossomas através dos operadores genéticos, fácil de ser transformada em inteiro ou real e, ainda, facilita a prova de alguns teoremas. Todavia, a representação por números reais (ponto flutuante) oferece melhor desempenho.

Por exemplo, seja o problema de encontrar o valor máximo da função $f(x) = x^2$, x inteiro $[0,63]$. Podemos representar as soluções do problema através de um cromossoma de 6 bits.

- C1 0 0 1 0 0 1 representa $x=9$
 C2 0 0 0 1 0 0 representa $x=4$

Um binário também pode representar um número real $X_R \in [X_{\min}, X_{\max}]$, com precisão de p casas decimais. Para isso são necessários K bits, sendo K calculado pela inequação:

Equação 1

$$2^k \leq (X_{\max} - X_{\min}) \times 10^p$$

A representação binária, entretanto, nem sempre pode ser empregada; o problema muitas vezes exige um alfabeto de representação com mais símbolos. Qualquer que seja a representação empregada, ela deve ser capaz de representar todo o espaço de busca que se deseja investigar.

3 – Decodificação

A decodificação do cromossoma consiste basicamente na construção da solução real do problema a partir do cromossoma. O processo de decodificação constrói a solução para que esta seja avaliada pelo problema. A vantagem da representação binária é a fácil transformação para inteiro ou real.

Na transformação para número real, considera-se o intervalo de valores ou comprimento contínuo do domínio (C) dos reais de tal forma que

Equação 2

$$X_R = Xb \times \frac{C}{2^n - 1} - X_{\min}$$

Onde $X_R \in [X_{\min}, X_{\max}]$; Xb é o inteiro correspondente ao binário; n é o número de bits de do cromossoma; e C é o comprimento do domínio da variável X , dado por $C = |X_{\max} - X_{\min}|$.

4 – Avaliação

A avaliação é o elo entre o GA e o mundo externo. A avaliação é feita através de uma função que melhor representa o problema e tem por objetivo fornecer uma medida de aptidão de cada indivíduo na população corrente, que irá dirigir o processo de busca. A função de avaliação é para um GA o que o meio ambiente é para seres humanos. Funções de avaliação são específicas de cada problema. No exemplo, a função matemática $f(x) = x^2$ mede aptidão de cada indivíduo. Na Tabela 2, C1 é um indivíduo mais apto que C2.

Tabela 2

	Cromossoma	x	f(x)
C1	0 0 1 0 0 1	9	81
C2	0 0 0 1 0 0	4	16

5 – Seleção

O processo de seleção em algoritmos genéticos seleciona indivíduos para a reprodução.

A seleção é baseada na aptidão dos indivíduos: indivíduos mais aptos têm maior probabilidade de serem escolhidos para reprodução.

Assim, se f_i é a avaliação do indivíduo i na população corrente, a probabilidade p_i do indivíduo i ser selecionado é proporcional a

Equação 3

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j}$$

Onde N é o número de indivíduos na População.

A seleção em GAs é tipicamente implementada por uma roleta onde cada indivíduo é representado por uma fatia proporcional a sua aptidão relativa.

O operador de seleção é um componente essencial de algoritmos genéticos. A literatura identifica cinco principais mecanismos de seleção: proporcional, por torneios, com truncamento, por normalização linear e por normalização exponencial [5]. Um mecanismo de seleção é caracterizado pela pressão seletiva ou intensidade de seleção que o mesmo introduz no algoritmo genético. O termo pressão seletiva é utilizado em diferentes contextos e com significados diferentes na literatura de computação evolucionária. A definição de intensidade de seleção empregada em genética é a variação na aptidão média da população induzida pelo método de seleção [5]. A expressão da intensidade de seleção I é dada por:

Equação 4

$$I = \frac{M^* - M}{S}$$

Onde M é a aptidão média da população, M^* é o valor esperado da aptidão média após a seleção, e σ é o desvio padrão dos valores de aptidão da população antes da seleção.

No caso de seleção proporcional, a probabilidade de um indivíduo ser selecionado é simplesmente proporcional ao seu valor de aptidão, isto é:

Equação 5

$$p_i = \frac{f_i}{NM}$$

Onde p_i é a probabilidade de seleção de um indivíduo i , f_i é a aptidão do mesmo e N é o tamanho da população. Demonstra-se que a intensidade de seleção é dada por [5]:

Equação 6

$$I = \frac{S}{M}$$

Isto é, a pressão seletiva é dada pela razão entre o desvio padrão das aptidões e a média das mesmas. O método de seleção proporcional apresenta dois problemas: existência de super-indivíduos e competição próxima [2]. O primeiro

ocorre quando um indivíduo apresenta uma aptidão bem maior que a dos restantes, o que determinará uma convergência prematura do algoritmo. O segundo problema ocorre quando indivíduos apresentam aptidões semelhantes, mas não idênticas; neste caso, a intensidade de seleção pode ser bem menor do que a desejável.

No método de seleção por torneios, um grupo de t indivíduos é aleatoriamente escolhido, e o indivíduo de melhor aptidão é selecionado. A intensidade de seleção é dada neste caso pela solução da seguinte equação integral [5]:

Equação 7

$$I = \int_{-\infty}^{\infty} t \cdot x \cdot \frac{1}{\sqrt{2p}} \cdot e^{-\frac{x^2}{2}} \left(\int_{-\infty}^x \frac{1}{\sqrt{2p}} \cdot e^{-\frac{y^2}{2}} dy \right)^{t-1} dx$$

As variáveis de integração x e y representam os valores de aptidão da população. Assume-se uma distribuição Gaussiana de valores de aptidão por indivíduos. A partir da solução numérica da equação acima, observa-se que a pressão seletiva aumenta a medida em que o número de indivíduos envolvidos no torneio, t , aumenta.

No mecanismo de seleção por truncamento, dado um limiar T , apenas os T melhores indivíduos podem ser selecionados. Cada um desses indivíduos apresenta a mesma probabilidade de seleção. Demonstra-se [5] que a intensidade de seleção é dada por:

Equação 8

$$I = \frac{1}{T} \cdot \frac{1}{\sqrt{2p}} \cdot e^{-\frac{f_c^2}{2}}$$

Onde f_c é o valor da menor aptidão entre os T melhores indivíduos. Traçando-se o gráfico da intensidade de seleção em função do limiar T , observa-se que a pressão seletiva diminui a medida em que T aumenta.

No método de seleção por normalização linear, os indivíduos são inicialmente ordenados de acordo com sua aptidão. A seguir, estes valores de aptidão são alterados de acordo com a posição relativa de cada indivíduo. Ao melhor indivíduo é assinalada uma aptidão de valor $máx$ e ao pior indivíduo uma aptidão $mín$. Estes dois valores são determinados pelo usuário, mas a forma original deste método prevê que as condições $máx = 2 \cdot mín$ e $mín \geq 0$ devam ser atendidas. Os demais indivíduos têm valores de aptidão linearmente distribuídos entre $mín$ e $máx$, de acordo com sua posição relativa na ordenação ($i=1$ corresponde ao pior elemento).

Equação 9

$$A_i \equiv mín + \frac{(máx - mín)}{n - 1} \times (i - 1)$$

No exemplo da Tabela 3 o método reduz o domínio exercido por super indivíduos (cromossoma 6) e aumenta a pressão seletiva entre indivíduos com avaliação próxima (cromossomas 5, 4, 3, 2) em função da taxa de decremento, em função da taxa de incremento.

Tabela 3

CROMOSSOMAS	6	5	4	3	2	1
Avaliação Original	200	15	14	13	10	9
Aptidão (taxa=1)	100	99	98	97	96	95
Aptidão (taxa=20)	101	81	61	41	21	1

A intensidade de seleção é dada por:

Equação 10

$$I = (1 - mín) \frac{1}{\sqrt{p}}$$

A equação acima mostra que a pressão seletiva diminui a medida em que $mín$ aumenta.

O método de seleção por normalização exponencial diferencia-se da normalização linear pelo fato das probabilidades de seleção de cada indivíduo seguirem uma função exponencial. Esta probabilidade é dada por:

Equação 11

$$p_i = \frac{c - 1}{c^N - 1} c^{N-i}; \quad i \in \{1, \dots, N\}$$

Onde c determina a grau de ‘exponencialidade’ da função, podendo variar de 0 até 1. Quanto mais próximo de 1, menor a ‘exponencialidade’. A intensidade de seleção é dada por:

Equação 12

$$I \approx \frac{\ln(k)}{-2.548 - 1.086\sqrt{k} + 0.4028 \ln(k)}$$

Onde $k = c^N$. Através da característica de I em função de c dada pela equação acima, verifica-se que a pressão seletiva diminui a medida em que c aumenta [5].

6 – Operadores Genéticos

Indivíduos selecionados (e reproduzidos na população seguinte) são recombinados sexualmente através do operador de crossover (com uma probabilidade p_c). O operador de crossover é

considerado a característica fundamental dos GAs. Pares de genitores são escolhidos aleatoriamente da população, baseado na aptidão, e novos indivíduos são criados a partir da troca do material genético. Os descendentes serão diferentes de seus pais, mas com características genéticas de ambos os genitores. Por exemplo:

		ponto de corte aleatório		
G1	1 1 0	0 0 0		
G2	0 0 0	1 0 0		
D1	1 1 0	1 0 0		
D2	0 0 0	0 0 0		

Na sua forma mais simples, o crossover de um ponto de corte (one-point crossover) corta os dois genitores em uma posição aleatoriamente escolhida, criando dois possíveis descendentes:

D1 é um cromossoma mais apto que seus genitores, todavia D2 é um indivíduo medíocre (baixa avaliação em $f(x) = x^2$).

Os cromossomas criados a partir do operador de crossover são então submetidos a operação de mutação (com uma probabilidade p_m). Mutação é um operador exploratório que tem por objetivo aumentar a diversidade na população.

O operador de mutação troca o conteúdo de uma posição do cromossoma (alelo, símbolo, valor do gene), com uma determinada probabilidade, em geral baixa (<1%).

C1	1 1 1 1 0	0	antes	↻
C1	1 1 1 1 0	1	depois da mutação	

Existem várias outras formas de se efetuar mutação. Por exemplo, o operador genético denominado inversão troca de posição dois genes aleatoriamente escolhidos. A importância deste operador é, no entanto, restrita a problemas baseados em ordem [1, 3].

7 – Inicialização da População

A inicialização da população determina o processo de criação dos indivíduos para o primeiro ciclo do algoritmo. Tipicamente, a população inicial é formada a partir de indivíduos aleatoriamente criados. Populações iniciais aleatórias podem ser semeadas com bons cromossomas para uma evolução mais rápida, quando se conhece, a priori, o valor de boas “sementes”.

Uma técnica eficiente para se encontrar por GA boas soluções em um problema, consiste em executar evoluções (rodadas) sucessivas, semeando-se a população inicial da evolução seguinte com as melhores soluções encontradas na anterior.

8 – Parâmetros e Critérios de Parada

Em um algoritmo genético vários parâmetros controlam o processo evolucionário:

- Tamanho da População → número de pontos do espaço de busca sendo considerados em paralelo a cada ciclo.
- Taxa de Crossover → probabilidade (p_c) de um indivíduo ser recombinado com outro.
- Taxa de Mutação → probabilidade (p_m) do conteúdo de uma posição/gene do cromossoma ser alterado.
- Número de Gerações → total de ciclos de evolução de um GA.
- Total de Indivíduos → total de tentativas em um experimento (tamanho da população x número de gerações)

Os dois últimos parâmetros são em geral empregados como critério de parada de um algoritmo genético.

Um algoritmo genético pode ser descrito como um processo contínuo que repete ciclos de evolução controlados por um critério de parada, conforme apresentado pela figura abaixo:

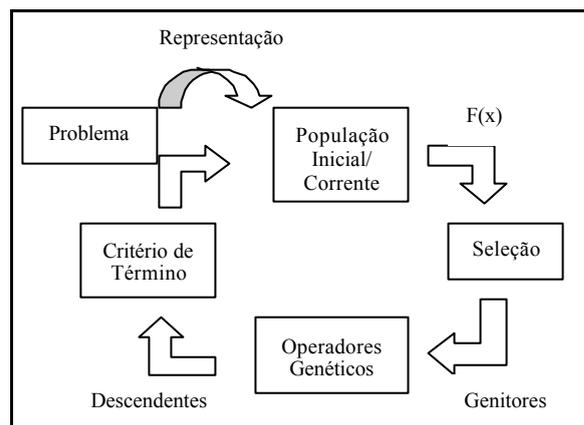


Figura 1

3. FUNDAMENTOS MATEMÁTICOS DE ALGORITMOS GENÉTICOS

Podemos compreender melhor o princípio de funcionamento de algoritmos genéticos a partir da Teoria de Schema (padrões) formulada por John Holland em 1975 [1].

John Holland definiu schema como um padrão que descreve um conjunto de cromossomas com similaridades em algumas posições.

Para representar schemata (plural de schema) utiliza-se um símbolo adicional "Σ".

Assim, para um espaço de busca representado por K^L existem $(K+1)^L$ schemata.

$K \equiv$ número de símbolos do alfabeto

$L \equiv$ comprimento do cromossoma

Seja $K = 2$ e $L = 3$ definindo em espaço de busca de 8 pontos. Seja o schema $H = 11\Sigma$. H descreve o conjunto de elementos 111 e 110. H refere-se a conjectura que a razão pela qual 111 (ou 110) é um bom (ou mal) indivíduo são os dois bits mais significativos iguais a 1, não importando (don't care) os demais. Esta conjectura possui dois possíveis representantes que podem ou não estar presentes em determinada geração do GA.

Para compreendermos melhor porque os GAs funcionam, basta analisarmos o efeito dos processos de seleção, recombinação e mutação sobre schemata. Ou seja, estamos interessados em saber o que acontece, ciclo a ciclo, com os representantes de determinado grupo, aqueles indivíduos que possuem o padrão H . Utiliza-se nesta análise duas definições:

- $O(H)$: ordem ou especificidade de um schema, como o número de posições fixas diferentes de Σ ; e
- $\delta(H)$: comprimento do schema, como a distância entre a 1ª e a última posições fixas.

3.1. ANÁLISE DO EFEITO DA SELEÇÃO

Seja $m(H, t)$ o número de representações de H em um ciclo t do algoritmo com n indivíduos na população. Assim, podemos calcular o número provável de representantes de H no próximo ciclo, seguinte como:

Equação 13

$$m(H, t + 1) = n \times \frac{\sum_{i \in H} f_i}{\sum_{j=1}^n f_j}$$

Define-se $f(H)$ como a aptidão média do schema H , dada por:

Equação 14

$$f(H) = \frac{\sum_{i \in H} f_i}{m(H, t)}$$

Assim, podemos rescrever $m(H, t+1)$ através da equação abaixo:

Equação 15

$$m(H, t + 1) = m(H, t) \times n \times \frac{f(H)}{\sum_{j=1}^n f_j}$$

A aptidão média da população, dada pela equação a seguir, nos permite fazer uma última transformação na fórmula de $m(H, t+1)$.

Equação 16

$$\bar{f} = \frac{\sum_{j=1}^n f_j}{n}$$

Equação 17

$$m(H, t + 1) = m(H, t) \times \frac{f(H)}{\bar{f}}$$

A interpretação desta equação reflete o efeito da seleção em GAs:

- 1) Schemata (padrões) com aptidão acima da média tendem a proliferar nas gerações seguintes.
- 2) Schemata com aptidão abaixo da média tendem a desaparecer.

Para estimarmos a eficiência do processo de evolução, suponha um schema H com aptidão acima (ou abaixo) da média de um fator C estacionário, a partir de $t = 0$. Assim temos:

Equação 18

$$m(H, t) = m(H, 0) \times \frac{\bar{f} + C\bar{f}}{\bar{f}} = m(H, 0) \times (1 + C)^t$$

portanto,

Equação 49

$$m(H, t) = m(H, 0) \times (1 + C)^t$$

Isto significa que o número de representantes de H em gerações sucessivas cresce (ou decresce) exponencialmente durante a evolução.

3.2. ANÁLISE DO EFEITO DO CROSSOVER

Nesta análise estamos interessados no impacto que o corte de um indivíduo venha a destruir um padrão, não transmitindo-o aos seus descendentes.

Seja $p_d(H)$ a probabilidade de destruição de um schema H pelo crossover de um ponto:

Equação 20

$$p_d(H) = \frac{d(H)}{L - 1}$$

Portanto,

Equação 21

$$p_s(H) = 1 - \frac{d(H)}{L-1}$$

é a probabilidade de sobrevivência desse padrão.

Seja p_c a taxa de aplicação de crossover e considerando-se que o par genitor de um cromossoma pode recuperar parte de um padrão destruído pelo crossover, temos a desigualdade:

Equação 22

$$p_s \geq 1 - p_c \times \frac{d(H)}{L-1}$$

Isto significa que schemata curtos tem maior probabilidade de sobrevivência (se manterem intactos) após o crossover.

3.3. ANÁLISE DO EFEITO DA MUTAÇÃO

Seja p_m a probabilidade do operador de mutação ser aplicado a uma determinada posição do cromossoma. Assim a probabilidade de sobrevivência do cromossoma é dada por:

Equação 23

$$p_s = (1 - p_m)^{O(H)}$$

Para taxas de mutação $p_m \ll 1$, temos

Equação 24

$$p_s \cong 1 - p_m \times O(H)$$

Isto significa que cromossomas de baixa ordem tem maiores chances de não serem destruídos pela mutação.

Combinando o efeito da seleção, crossover e mutação, temos:

Equação 25

$$n(H,t+1) \geq n(H,t) \times \frac{f(H)}{f} \times \left[1 - p_c \times \frac{d(H)}{L-1} \right] \times \left[1 - p_m \times O(H) \right]$$

A interpretação desta equação nos leva ao Teorema Fundamental de GAs:

“Schemata curtos e de baixa ordem tendem a se proliferar ou desaparecer nas gerações seguintes, de acordo com a aptidão média”.

4. DESEMPENHO DE ALGORITMO GENÉTICOS

Algoritmos genéticos são sistemas não lineares com comportamento fortemente ecológico. GAs combinam mudanças aleatórias com processos probabilísticos. GAs são, portanto, estocásticos: dificilmente repetem um resultado de um experimento para outro.

O desempenho de um algoritmo genético é medido pelo grau de evolução alcançado durante todo o processo evolucionário (experimento). Devido à natureza estocástica dos GAs é necessário se avaliar o resultado médio de vários experimentos de um GA, para se ter uma idéia de seu desempenho.

As principais medidas de desempenho são:

1. Curva da média dos melhores cromossomas a cada ciclo em vários experimentos.
2. Curva on-line da média da avaliação de todos os indivíduos até um determinado instante t em um experimento.
3. Curva off-line da média da avaliação do melhores indivíduos até um instante t em um experimento.

A curva média dos melhores indivíduos em vários experimentos apresenta o desempenho médio de um GA e serve para ajuste de parâmetros.

A curva on-line mede a velocidade com que o GA consegue produzir boas soluções para o consumo "on-line" das soluções [1].

A curva off-line mede o grau de convergência do GA na criação de soluções mais aptas, geradas off-line em relação ao problema [1].

5. TÉCNICAS, PARAMETROS E OUTROS OPERADORES GENÉTICOS

Técnicas, parâmetros e tipos de operadores genéticos afetam significativamente o desempenho de um algoritmo genético. Em geral, o algoritmo genético é extremamente sensível a introdução ou combinação de técnicas empregadas. A escolha de técnicas, parâmetros e tipos de operadores é empírica, porém em sintonia com o problema.

Podemos classificar as técnicas empregadas em GAs nas seguintes classes:

- 1- Técnica de Reprodução
- 2- Técnica de Aptidão
- 3- Técnica de Interpolação de Parâmetros

Quanto aos operadores genéticos, os principais tipos são:

- 1- Crossover de Um-Ponto
- 2- Crossover de Dois-Pontos
- 3- Crossover Uniforme.

5.1. TÉCNICAS DE REPRODUÇÃO:

Essas técnicas determinam o critério de substituição dos indivíduos de uma população para a próxima geração. Existem basicamente os seguintes métodos:

1- Troca de toda população:

A cada ciclo, N novos indivíduos são criados substituindo a população anterior: N/2 pares são escolhidos para o acasalamento, gerando N descendentes.

2- Troca de toda a população com elitismo:

Todos os cromossomas são substituídos, sendo o cromossoma mais apto da população corrente copiado na população seguinte.

3- Troca parcial da população (steady state):

Gera M indivíduos ($M < N$), que substituem os piores indivíduos da população corrente (o número de indivíduos substituídos também é conhecido como GAP). Técnica elitista que mantém população mais estática, permitindo, portanto, a utilização de operadores menos conservadores como o crossover uniforme.

4- Troca parcial da população (steady state) sem duplicados:

Semelhante ao anterior, sem permitir a presença de indivíduos duplicados que são descartados da população. Garante, assim, o melhor aproveitamento do paralelismo intrínseco dos GAs (N pontos diferentes do espaço de busca sendo avaliados a cada ciclo). Todavia, implica em "overhead" para a detecção de duplicados e criação de novos indivíduos.

5.2. TÉCNICAS DE INTERPOLAÇÃO DE PARÂMETROS:

A interpolação de parâmetros de um GA tem por objetivo buscar o valor ideal de um determinado parâmetro para cada ciclo, durante toda a evolução. Durante a evolução de um GA alguns aspectos estão fortemente relacionados:

- a convergência do algoritmo
- a aptidão dos cromossomas
- as taxas e parâmetros

Por exemplo, é intuitivamente óbvio que a taxa de aplicação do crossover seja maior nas primeiras gerações quando a população se apresenta dispersar no espaço de busca. Após várias gerações os indivíduos tendem a apresentar, na sua maioria, características muito similares. Um aumento da taxa de mutação nesta fase de evolução irá dispersar a população, trazendo novo material genético para a formação de melhores indivíduos.

A interpolação de parâmetros pode ser linear ou adaptativa. Na interpolação linear uma taxa ou um parâmetro qualquer é variado entre um valor inicial e final, através de ajustes fixos, linearmente, a cada K gerações.

A interpolação adaptativa, normalmente empregada para ajuste da taxa de aplicação de operadores, considera o desempenho destes operadores nos ciclos anteriores. Este desempenho é medido em função do sucesso destes operadores na criação de melhores indivíduos. Este esquema requer um processo de pontuação a indivíduos e seus descendentes, envolvendo razoável "overhead" computacional. O efeito, no entanto, é atingir trajetórias quase ótimas para um parâmetro, durante a evolução [4].

5.3. OPERADORES GENÉTICOS

Operadores genéticos se classificam em:

- operadores de recombinação (crossover)
- operadores de mutação
- operadores de inversão
- operadores específicos ao domínio do problema.

Dentre estes, os operadores de crossover, devido a sua importância fundamental nos GAs, apresentam variações que merecem destaque.

Crossover de Dois Pontos:

Executa a recombinação de dois indivíduos a partir de dois pontos escolhidos aleatoriamente. Este operador é capaz de combinar schemata com posições fixas nas extremidades, como no exemplo abaixo.

$$\begin{array}{cc|ccccccc} H_1 & 1 & 1 & \Sigma & \Sigma & \Sigma & \Sigma & \emptyset \\ H_2 & \Sigma & \Sigma & \Sigma & 1 & 0 & 1 & \Sigma \end{array}$$

Crossover Uniforme:

O crossover de dois pontos também apresenta limitações na recombinação de schemata.

O crossover uniforme, por sua vez, é capaz de recombinar quaisquer posições entre dois genitores. Este operador utiliza um padrão (palavra binária) escolhida aleatoriamente para designar os bits selecionados em cada genitor na criação dos descendentes. Por exemplo:

$$\begin{array}{cc} G_1 & 1 & 1 & 0 & 0 & 1 & 0 & 1 \\ G_2 & 0 & 1 & 1 & 1 & 1 & 1 & 0 \\ \text{Padrão} & 0 & 1 & 1 & 0 & 1 & 0 & 0 \\ D_1 & 0 & 1 & 0 & 1 & 1 & 1 & 0 \\ D_2 & 1 & 1 & 1 & 0 & 1 & 0 & 1 \end{array}$$

O crossover uniforme apresenta um poder de destruição maior que o crossover de um ponto e o de dois pontos que, por sua vez, preservam os códigos (schemata curtos) compactos. O crossover uniforme pode prejudicar a formação de padrões a

partir de schemata curtos. Sua utilização deve ser, portanto, em ambientes altamente elitistas como na reprodução parcial da população (steady state), que garantem a permanência dos melhores indivíduos.

[1] D. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley 1989.

[2] Marco Aurélio Pacheco, *Notas de Aula em Computação Evolucionária*, (www.ica.ele.puc-rio.br).

[3] Z. Michalewicz, *Genetic Algorithms+Data Structures=Evolution Programs*, Springer-Verlag-1994.

[4] L. Davis, *Handbook of Genetic Algorithms*, VNR Comp. Library, 1990.

[5] Blickle, T., "Theory of Evolutionary Algorithms and Application to System Synthesis", dissertação de doutorado, Swiss Federal Institute of Technology, Zurique, 1996.