

5 Algoritmos Genéticos

Este capítulo dispõe sobre a técnica de inteligência computacional utilizada neste trabalho: Algoritmos Genéticos em que é fornecida uma breve explicação sobre os princípios de funcionamento do algoritmo genético incluindo sua composição e os parâmetros de evolução utilizados.

5.1. Aspectos Gerais

Algoritmos Genéticos são métodos de busca estocásticos que emulam teorias evolucionárias biológicas para solucionar problemas de otimização (Goldberg, 1989; Koza, 1992), compreendendo um conjunto de elementos individuais (a população) e um conjunto de operadores biologicamente inspirados definidos sobre a própria população. De acordo com as teorias evolucionárias, somente os elementos mais adequados em uma população, têm maior probabilidade de sobrevivência e geram descendentes, assim transmitindo sua identidade biológica hereditária às novas gerações. Em termos computacionais, um algoritmo genético mapeia a solução de um problema em uma estrutura denominada cromossoma, onde cada termo dessa estrutura (gene) representa uma das variáveis de interesse da função objetivo a otimizar.

Os sistemas desenvolvidos a partir deste princípio são utilizados para procurar soluções de problemas complexos ou com espaço de soluções muito grande (espaço de busca), o que os tornam problemas de difícil modelagem e solução, quando se aplicam métodos de otimização convencionais.

Antes de prosseguir com a análise das características destes algoritmos, alguns conceitos básicos são necessários; estes conceitos podem ser naturalmente expostos explicando o funcionamento básico destes algoritmos.

Inicialmente, é gerada uma população formada por um conjunto aleatório de indivíduos que representam as possíveis soluções do problema. Durante o processo evolutivo, esta população é avaliada: para cada indivíduo é dada uma nota, ou índice, refletindo sua habilidade de adaptação a determinado ambiente (melhores soluções ao problema). Uma porcentagem dos mais adaptados (melhores soluções) são mantidos, enquanto os outros são descartados (darwinismo). Os indivíduos mantidos pela seleção podem sofrer modificações em suas

características fundamentais através de mutações e cruzamento (*crossover*) ou recombinação genética gerando descendentes (novas soluções ao problema) para a próxima geração. Este processo, chamado de reprodução, é repetido até que uma solução satisfatória seja encontrada.

Embora possam parecer simplistas do ponto de vista biológico, estes algoritmos são suficientemente complexos para fornecer mecanismos de busca adaptativo poderosos e robustos (na Figura 2 pode-se observar a estrutura de um Algoritmo Genético básico).

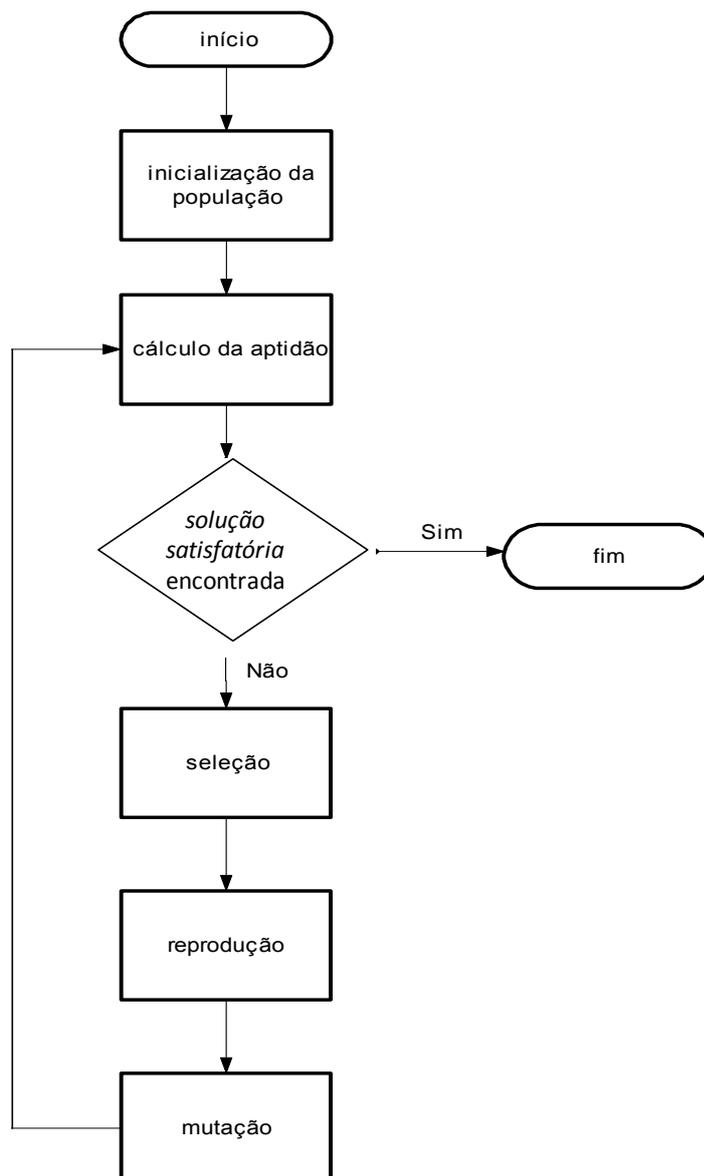


Figura 2– Estrutura básica de um Algoritmo Genético

5.2. Representação

A representação é um aspecto fundamental na modelagem de um algoritmo para a solução do problema. Neste estágio, define-se a estrutura do cromossoma, os respectivos genes que o compõem, de maneira que este seja capaz de descrever todo o espaço de busca relevante do problema.

A representação do tradicionalmente é feita de forma binária (0 ou 1), entretanto diversas outras podem ser utilizadas como números reais que e a utilizada neste trabalho.

5.3. Codificação e Decodificação

A solução de um problema pode ser representada por um conjunto de parâmetros (genes) unidos para formar uma cadeia de valores (cromossoma), cujo processo é conhecido por codificação. Os cromossomas são codificados através de uma seqüências de símbolos podendo ser binária, real ou com outros alfabetos.

5.4. Função de Avaliação

A função de avaliação é a função objetivo responsável por fornecer o mecanismo que irá avaliar o indivíduo da população, atribuindo um conceito (valor ou aptidão) para cada solução potencial. É a partir do resultado desta função que os cromossomas evoluem. A avaliação é que permite ao algoritmo genético determinar sua proximidade da solução.

5.5. Seleção

O mecanismo de seleção modela o mecanismo natural de sobrevivência do indivíduo mais apto. Assim sendo, as soluções inaptas tendem a desaparecer. No esquema de seleção proporcional, um indivíduo com maior aptidão tem maior probabilidade de sobrevivência. Utilizamos a Regra da Roleta para seleção, onde cada indivíduo é alocado a um setor da roleta virtual ocupando uma área proporcional à sua aptidão (Figura 3).

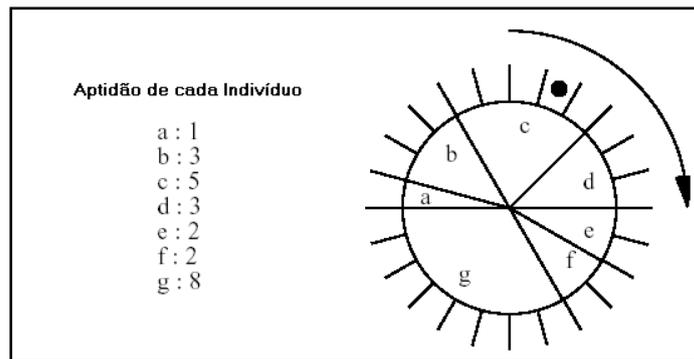


Figura 3 – Regra da Roleta

5.6. Operadores Genéticos

5.6.1. Reprodução

Trata-se do processo de selecionar e copiar um determinado indivíduo na geração seguinte de acordo com a sua aptidão, isto é, os indivíduos mais aptos têm maior probabilidade de contribuir para a formação de um ou mais indivíduos da população seguinte.

Existem basicamente os seguintes métodos: troca de toda a população, troca de toda a população com elitismo, onde os cromossomas são substituídos mas o cromossoma mais apto permanece na geração seguinte, e a troca parcial da população, onde a critério do usuário, os “n” melhores indivíduos da população corrente são copiados para a população seguinte (Goldberg, 1989; Koza, 1992; Michalewicz, 1996).

5.6.2. Crossover

Depois da seleção de genitores ocorre o processo de crossover (Goldberg, 1989; Koza, 1992; Michalewicz, 1996) que consiste na recombinação de material genético entre indivíduos da população. Pares de indivíduos são escolhidos na população baseados na aptidão, e é feita a troca de fragmentos entre os pares de genitores o percentual destes indivíduos da população que sofreram o processo é definido pela taxa de *crossover*. Este operador pode, ainda, ser utilizado de várias maneiras; as mais utilizadas são (:

- Um-ponto: foi o tipo de *crossover* utilizado no trabalho. Neste formato é escolhido um ponto de cruzamento e a partir deste ponto as

informações genéticas dos pais serão trocadas. As informações anteriores a este ponto em um dos pais são ligadas às informações posteriores à este ponto no outro pai, como é mostrado no exemplo da figura 4 abaixo.

- Multi-pontos: é uma generalização desta idéia de troca de material genético através de pontos, onde muitos pontos de cruzamento podem ser utilizados.
- Uniforme: não utiliza pontos de cruzamento, mas determina, através de um parâmetro global, qual a probabilidade de cada variável ser trocada entre os pais.

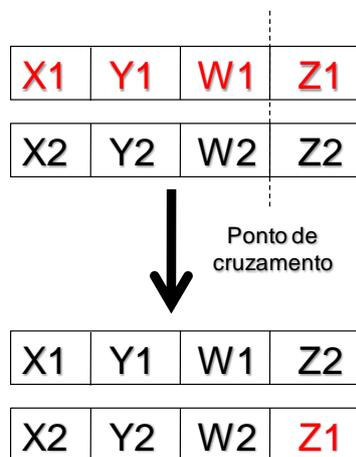


Figura 4 – Operador de *Crossover* de um ponto

5.6.3. Mutação

Após o *crossover*, os indivíduos estão sujeitos à mutação. A mutação utilizada neste trabalho foi à mutação uniforme no qual um gene é substituído por um número aleatório (conforme exemplificado na figura 5). O processo é controlado por um parâmetro fixo, que indica a probabilidade de um gene sofrer mutação. Existem ainda outros tipos de mutação tais como: a mutação baseada na posição, a mutação baseada na ordem e a mutação de mistura (Davis, 1991). A mutação utilizada neste trabalho foi a mutação uniforme no qual um gene é substituído por um número aleatório (conforme exemplificado na figura 5 a seguir).

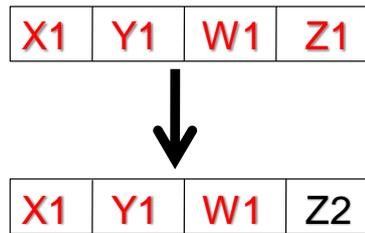


Figura 5 – Operador de Mutação

O *crossover* é o acelerador do processo de busca e tira proveito das soluções mais promissoras, já a mutação é operador exploratório que dispersa a população pelo espaço de busca.

5.6.4. Parâmetros da Evolução

Os parâmetros que mais influenciam o desempenho do algoritmo genético são:

- **Tamanho da População:** afeta o desempenho global e a eficiência dos Algoritmos Genéticos. Uma população muito pequena oferece uma pequena cobertura do espaço de busca (prejudica a diversidade), causando uma queda no desempenho. Uma população suficientemente grande fornece uma melhor cobertura do domínio do problema e previne a convergência prematura para soluções locais. Entretanto, com uma grande população tornam-se necessários recursos computacionais maiores, ou um tempo maior de processamento do problema. Logo, deve-se buscar um ponto de equilíbrio no que diz respeito ao tamanho escolhido para a população.
- **Taxa de Crossover:** probabilidade de um indivíduo ser recombinado com outro. Quanto maior for esta taxa, mais rapidamente novas estruturas serão introduzidas na população. Entretanto, isto pode gerar um efeito indesejável, pois a maior parte da população será substituída, causando assim perda de variedade genética, podendo ocorrer perda de estruturas de alta aptidão e convergência a uma população com indivíduos extremamente parecidos (convergência para um máximo local ou mínimo local), indivíduos estes de solução boa ou não. Com um valor baixo, o algoritmo pode-se tornar lento e até não convergir para uma resposta aceitável.

- **Taxa de Mutação:** probabilidade do conteúdo de um gene de um cromossomo ser alterado. A mutação previne que uma dada população fique estagnada em pequenos espaços restritos de busca (perda de diversidade), além de possibilitar que se chegue a qualquer ponto do espaço de busca. Porém deve-se evitar uma taxa de mutação muito alta, uma vez que esta pode tornar a busca essencialmente aleatória, prejudicando fortemente a convergência para uma solução ótima.
- **Intervalo de Geração:** controla a porcentagem da população que será substituída durante a próxima geração (substituição total, substituição com elitismo, substituição dos piores indivíduos da população atual, substituição parcial da população sem duplicatas). Esse número de indivíduos substituídos também é conhecido como gap.
- **Número de gerações:** representa o número total de ciclos de evolução de um Algoritmo Genético, sendo este um dos critérios de parada do algoritmo genético. Um número de gerações muito pequeno causa uma queda no desempenho, por outro lado um valor grande implicará um tempo maior de processamento, mas fornece uma melhor cobertura do domínio do problema.
- **Critérios de Parada:** O critério de parada do algoritmo genético pode variar de acordo com a opção do usuário. Uma das formas é definir uma quantidade de gerações que devem ser geradas, outra forma é aplicá-lo até que se encontre uma população onde os indivíduos tenham a função de avaliação que se deseja alcançar.