

4

Ajuste Automático do Conhecimento Multitemporal

Neste capítulo, será apresentado um método para ajustar automaticamente os parâmetros relativos ao conhecimento multitemporal utilizando algoritmos genéticos. Desta forma, a próxima seção tratará de introduzir os conceitos relacionados aos algoritmos genéticos. Posteriormente, será ilustrada a interação de algoritmos genéticos com o procedimento de interpretação para aquisição do conhecimento multitemporal.

A próxima seção é dirigida ao leitor pouco familiarizado com os fundamentos de algoritmos genéticos.

4.1.

Algoritmos genéticos

Nos últimos anos, algoritmos genéticos têm sido aplicados em problemas de otimização complexos que envolvem dificuldade para formulação matemática, grande número de regras e condições e/ou múltiplas soluções a considerar (Bac & Perov, 1993; Lee et al., 2003; Mohamed & Aoued, 2005; Nascimento & Pires, 1997; Schmiedle et al., 2002; Shaaban et al., 2001).

Algoritmo genético (AG) é um modelo de inteligência computacional fundamentado na biologia. Inspirado, mais especificamente, nos processos pelos quais as espécies se reproduzem gerando descendentes mais adaptados ao ambiente para solução de problemas.

De acordo com a teoria de evolução das espécies de Charles Darwin (1859), também conhecida por teoria Darwiniana, uma população sujeita a um ambiente qualquer, sofrerá influências deste, de tal forma que os mais aptos terão maior expectativa de sobreviver a tal ambiente. Desta forma, a cada geração haverá uma população mais adaptada ao ambiente em questão.

Baseado na teoria da evolução (Darwin, 1859), John H. Holland propôs os algoritmos genéticos em 1975 (Holland, 1975). O método emprega um processo

adaptativo e paralelo de busca de soluções em problemas complexos. O aprendizado é visto como uma competição dentro de uma população de soluções evolutivas, candidatas à solução do problema.

A idéia básica é de buscar a solução ótima para um problema partindo de uma população inicial que representa um conjunto inicial de candidatos à solução. A partir do cruzamento de indivíduos selecionados aleatoriamente privilegiando os mais aptos, chega-se a uma nova geração. As soluções na população tendem a melhorar geração após geração, até que se chegue ao objetivo, expresso no critério de parada da evolução. Em geral, o resultado corresponde ao melhor indivíduo da população final.

Em relação às técnicas de busca convencionais, algoritmos genéticos diferem nos seguintes pontos:

- A procura pela solução para o problema é uma busca paralela, ou seja, é feita sobre um conjunto de pontos (possíveis soluções) simultaneamente, e não sobre um único ponto, tornando-o indicado em problemas com grande espaço de busca (grande número de soluções). Assim, o custo computacional para encontrar a solução diminui e reduz o risco da solução recair sobre um máximo (ou mínimo) local;
- A única exigência é o conhecimento do valor da função de custo (ou objetivo) de cada ponto. Não há necessidade de qualquer outra informação, ou heurística, dependente do problema. Portanto, é relativamente mais fácil de ser utilizado em problemas de difícil formulação matemática.

Os algoritmos genéticos usam operadores estocásticos e não regras determinísticas para guiar uma busca altamente exploratória e estruturada, onde informações acumuladas nas iterações (gerações) anteriores são usadas para direcionar essa busca.

Uma solução possível para o problema é denominada indivíduo ou cromossomo que é constituído por genes. Cada gene representa uma característica do problema, ou seja, uma variável a ser encontrada. Um conjunto destes indivíduos é uma população. A figura 8 mostra um esquema geral do funcionamento de algoritmos genéticos.

Inicialmente, uma população é gerada. Geralmente, a população inicial é determinada por um conjunto aleatório de indivíduos dentre os existentes no espaço de busca. Então a cada indivíduo é associado um valor de avaliação que

determinará o quão adequado é o indivíduo para o problema. Em seguida, uma parte da população é selecionada privilegiando os indivíduos mais aptos para a produção de novos indivíduos a partir de operadores genéticos. Estes novos indivíduos substituem os indivíduos menos aptos da população anterior gerando uma nova geração. Assim, outras gerações são produzidas da mesma forma até que o critério de parada seja satisfeito. Na última geração, o melhor indivíduo da população é indicado como solução para o problema.

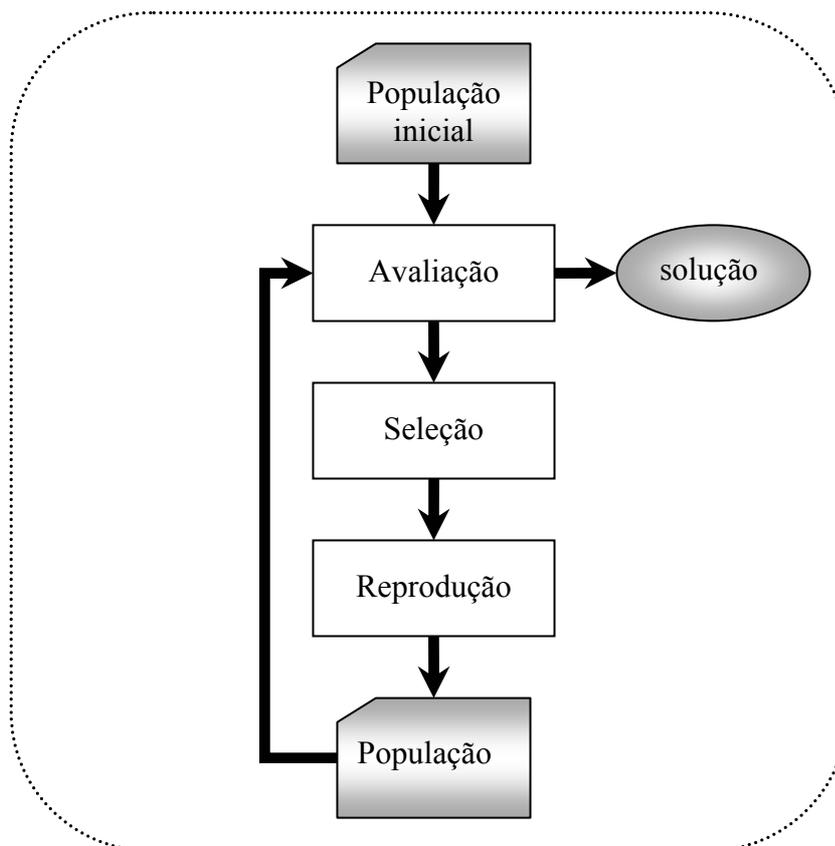


Figura 8 – Representação gráfica de algoritmos genéticos.

Sendo assim, o procedimento geral de algoritmos genéticos pode ser dado pela seguinte forma:

Procedimento algoritmo genético;

início

ajuste o tempo $\tau = 0$;

inicia a população $P(\tau)$;

enquanto a condição de parada não for satisfeita faça:

```
início
  avalie cada membro da população  $P(\tau)$ ;
  selecione membros da população  $P(\tau)$  com base na avaliação;
  produza os descendentes destes membros;
  substitua os piores membros de  $P(\tau)$ ;
  ajuste o tempo  $\tau = \tau + 1$ ;
fim;
fim.
```

Os operadores genéticos básicos são o crossover e a mutação descritos abaixo:

- Crossover simples: este se dá pela aproximação dos cromossomos de dois indivíduos (pais), que trocam entre si partes de seus genes. Primeiramente, um ponto de corte é escolhido com probabilidade uniforme sobre o comprimento do cromossomo, sendo, então, os genes correspondentes permutados (ver ilustração na figura 9). Isso resulta em dois novos indivíduos que guardam características de seus pais. Este é o principal operador genético, pois atua cruzando soluções anteriores fazendo com que novas gerações permaneçam com características desejáveis de gerações anteriores.
- Mutação: ocorre alterando aleatoriamente um gene de um indivíduo selecionado. A mutação consiste em perturbações na cadeia de um cromossomo dando origem a uma nova cadeia, que guardará parte da informação do indivíduo original. Esta alteração ocorre de forma que cada gene do cromossomo “pai” é um candidato à mutação, de forma que a seleção é determinada pela probabilidade de mutação (ver ilustração na figura 10). Este operador é essencial para o processo de iterações genéticas, pois evita que o processo iterativo fique estagnado dentro de um mínimo local, introduzindo diversidade na população.

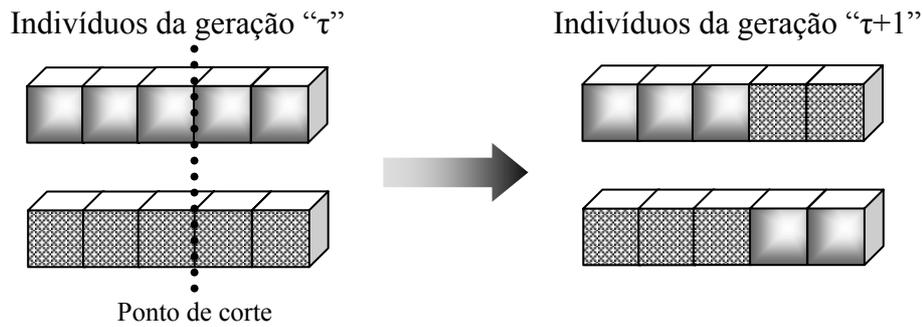


Figura 9 – Crossover simples.

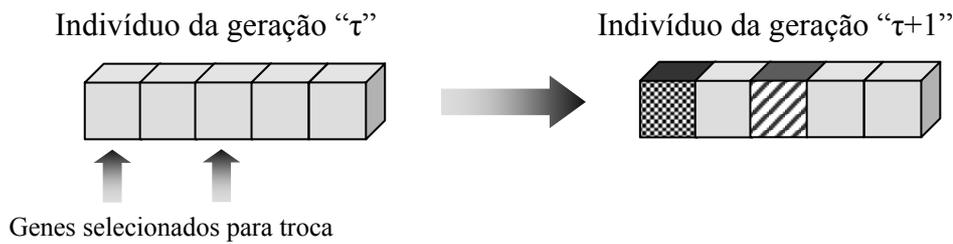


Figura 10 – Mutação.

Existem outros operadores variantes do crossover e mutação. Os que também são utilizados no presente trabalho são:

- Crossover aritmético: este se diferencia do crossover simples pela combinação linear dos indivíduos pais. Desta forma, dado que foram selecionados os indivíduos P_1 e P_2 para reprodução, seus descendentes F_1 e F_2 resultam, respectivamente, da equação 18 e da equação 19:

$$F_1 = a \cdot P_1 + (1 - a) \cdot P_2 \quad \text{Equação 18}$$

$$F_2 = a \cdot P_2 + (1 - a) \cdot P_1 \quad \text{Equação 19}$$

onde a é um número aleatório no intervalo $[0,1]$.

- Creep: atua na busca de uma solução próxima da resultante através de ajustes aleatórios em ambas as direções (limite superior e inferior). Assim, se um indivíduo P é formado por x e y , seu descende F é dado pela equação 20:

$$P = (x,y) \rightarrow F = (x \pm \Delta x, y \pm \Delta y) \quad \text{Equação 20}$$

onde Δ é um ajuste pequeno ou grande.

Estes algoritmos não resolvem problemas a partir de algum modelo lógico. Ao contrário, geram populações de indivíduos candidatos e as estimulam a evoluir para soluções melhores por um processo que imita a evolução biológica. Os indivíduos menos aptos segundo suas respectivas avaliações tendem a se extinguir, enquanto que aqueles que se mostram mais promissores em resolver o problema sobrevivem e se reproduzem construindo novas soluções.

Estudos mais amplos e detalhados sobre algoritmos genéticos podem ser encontrados em Davis (1990), Goldberg (1989), Koza (1992), Michalewicz (1994) e Pacheco (2004).

4.2.

Ajuste automático do conhecimento multitemporal através de algoritmos genéticos

O conhecimento multitemporal, neste trabalho, é definido por um conjunto de valores de possibilidades de ocorrerem mudanças de classes dentro de um determinado intervalo de tempo. Em Mota (2004a), onde o uso dos diagramas de transição de estado foi proposto, a busca dos valores de possibilidade de transição é manual através de um processo de tentativa-e-erro. Este método de ajuste mostrou-se lento além de não prover segurança de que os valores encontrados são adequados. Um dos objetivos deste trabalho é analisar uma metodologia automática para busca do conhecimento multitemporal pelo uso de algoritmos genéticos. Adotou-se o uso destes algoritmos tendo em vista que o número total de parâmetros a serem otimizados é limitado superiormente pelo quadrado do número de classes da legenda, e pode, portanto, dependendo da aplicação, ser intratável por métodos convencionais.

Nesta aplicação, cada indivíduo é definido por um vetor de números reais, de modo que cada vetor representa um conjunto de valores possíveis para as possibilidades de transição de classes da legenda. Deste modo, cada posição do vetor ou cromossomo representa uma possibilidade cujos valores devem ser encontrados.

Primeiramente, o especialista da região analisada define as transições impossíveis. Estas transições têm possibilidade nula, então seus valores recebem o valor “0”. Dado um objeto da classe ω_i , a permanência deste objeto em ω_i ,

situação mais provável, recebe imediatamente 1 como valor de possibilidade. Os demais valores de possibilidade de transição constituem o indivíduo ou cromossomo em AG.

A figura 11 exemplifica a representação física de um indivíduo. Seja um problema de interpretação com três classes e conhecimento multitemporal, com um determinado intervalo de tempo, representado pelo diagrama de transição da figura 11a. Um valor p_{ij} refere-se ao valor de possibilidade de transição da classe ω_i para a classe ω_j . Como os valores p_{11} , p_{22} e p_{33} correspondem às possibilidades de não ocorrer mudança de classe, são iguais a 1 e, por isso, não são encontrados pelo AG e, conseqüentemente, não são representados pelo indivíduo. Os demais valores de possibilidade, quando há transição, constituem o indivíduo (vide figura 11b).

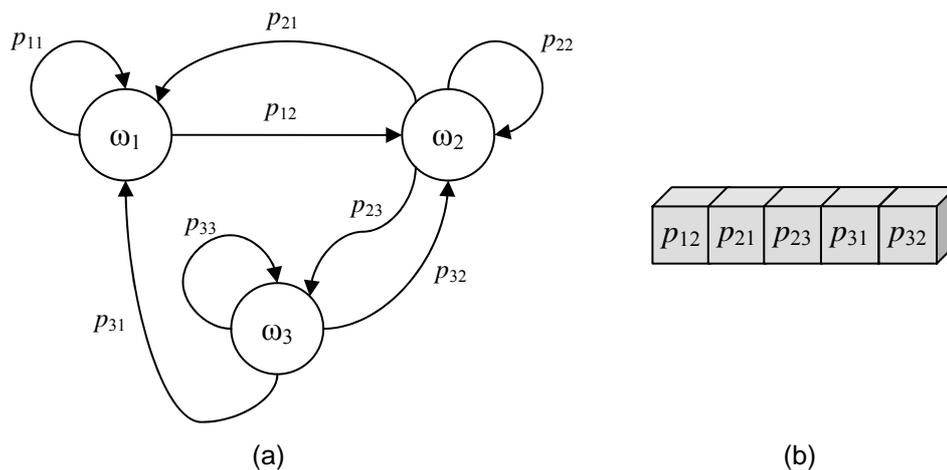


Figura 11 – Representação física de um indivíduo.

A população inicial é obtida através da geração aleatória de indivíduos, obedecendo a condições de limite previamente estabelecidas, neste caso, no intervalo $[0,1]$. A função de avaliação, neste trabalho, é definida como a taxa média de reconhecimento das classes apresentada pela equação 21.

$$A = \frac{\sum_{j=1}^n \Gamma_j}{n}$$

Equação 21

onde n é o número de classes da legenda e Γ_j é a taxa de reconhecimento da classe ω_j definida pela equação 22.

$$\Gamma_j = \frac{C_j}{n_j} \quad \text{Equação 22}$$

onde C_j é o número de objetos atribuídos corretamente à classe ω_j pelo procedimento de interpretação e n_j é o número real de objetos pertencentes à classe ω_j .

Neste caso, a função de avaliação poderia ser dada também pela taxa de reconhecimento global de objetos. Optou-se por adotar a taxa média para que a interpretação, ao utilizar os valores indicados pelo AG, não tenha tendência a classificar predominantemente as classes que possuem o maior número de objetos.

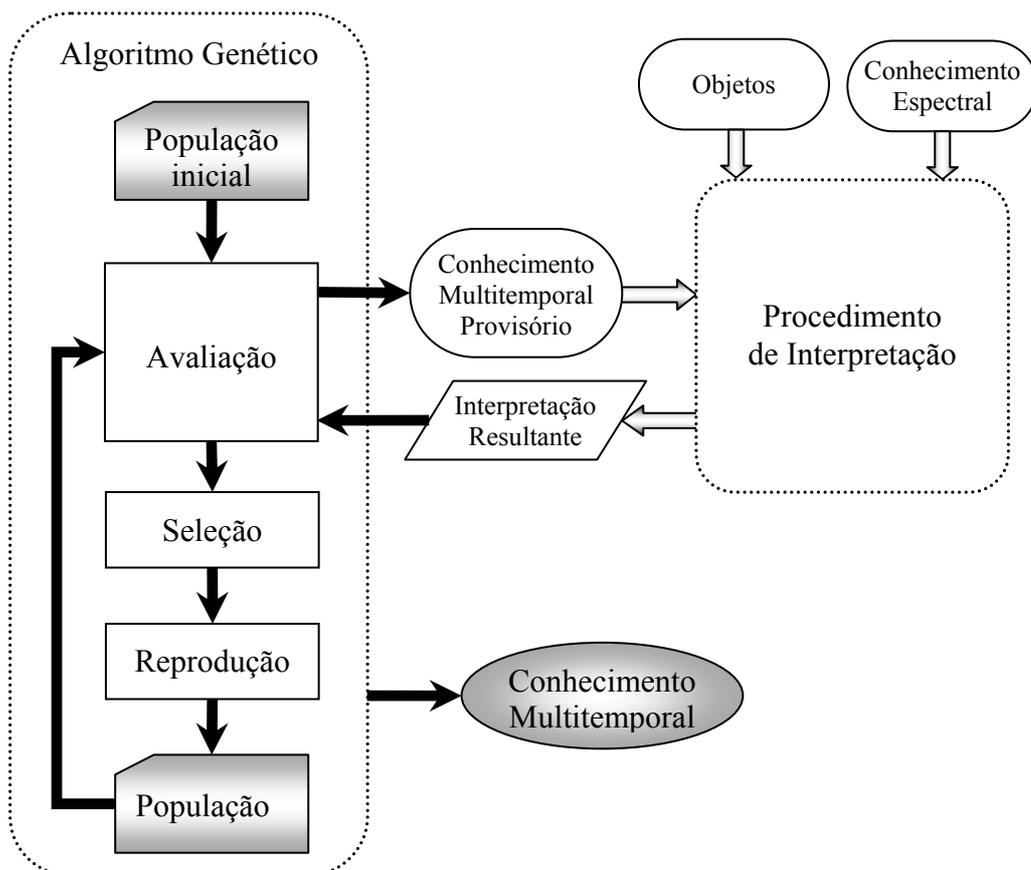


Figura 12 – Ajuste do conhecimento multitemporal para o processo de interpretação automática utilizando algoritmos genéticos.

Assim sendo, o processo de avaliação de cada indivíduo inicia-se classificando cada objeto de uma imagem utilizando os respectivos valores de possibilidade e, então, é calculada a média aritmética das taxas de reconhecimentos por classe baseando-se na classificação de referência.

Após a seleção de indivíduos privilegiando os mais aptos, estes são reproduzidos através de operadores genéticos para criação da nova geração de indivíduos. A técnica utilizada para determinar o critério de substituição dos indivíduos é a troca parcial da população, denominada steady state, que gera M novos indivíduos, onde M é menor que o tamanho da população, e substitui os M piores indivíduos da população da geração corrente. Esta técnica garante, portanto, a preservação dos melhores indivíduos e que a população seguinte tenha, no mínimo, soluções tão aptas quanto a corrente.