

3 Otimização Aplicada a Reconstituição de Acidentes

3.1. Otimização

A otimização é uma metodologia empregada para minimizar ou maximizar uma função e geralmente são utilizados em problemas onde existam funções de várias variáveis, devido a sua complexidade e elevado número de parâmetros e condições associados.

Tendo como objetivo a minimização de uma função utilizando um método de otimização, onde se incluem como restrições as equações diferenciais que descrevem o seu comportamento no tempo, tem-se um problema de controle ótimo e, resolvendo a cada passo o problema de otimização, este pode ser aplicado a um sistema dinâmico não-linear.

3.1.1. Exemplos de metodologias de otimização

- Programação Linear – visa a maximização ou minimização de uma função objetivo linear. As restrições são expressas por equações e inequações lineares de ordem zero;
- Programação Dinâmica – método utilizado para se fazer uma seqüência de decisões interrelacionadas, de forma a determinar a combinação de decisões que maximize a efetividade de um sistema;
- Otimização de Fluxos em Rede – abordagem baseada na representação de problemas de otimização através de redes;
- Método das Direções Conjugadas (Powell) – garante a minimização de

funções quadráticas de mais de duas dimensões em um número finito de passos. A combinação de direções e o descarte de direções anteriores propicia velocidade de convergência ao método;

- Método do gradiente – utiliza não somente os valores da função como também o gradiente da função na localidade analisada;
- Algoritmo Genético – flexível no que diz respeito à utilização em casos similares aos problemas dinâmicos, sem que sejam necessárias mudanças significativas no algoritmo.

Dos métodos citados, o escolhido foi o Algoritmo Genético, tendo em vista o fato deste método ter sido utilizado com sucesso na tese de MARTINS, G.N.. No trabalho citado, o simulador do AG utilizou um modelo rígido para a estrutura dos veículos envolvidos no choque. Este trabalho tem por objetivo substituir este modelo de estrutura rígida pelo modelo de veículos flexíveis desenvolvido por DE CARVALHO, F. A. e resumidamente exposto no Capítulo 2.

O Algoritmo Genético é caracterizado pela geração de valores aleatórios e pela evolução destes valores, o que se dá de forma análoga à Teoria Evolutiva de Darwin.

Principais conceitos aplicados em algoritmos genéticos:

- gene – valor a ser otimizado;
- cromossomo – vetor com os parâmetros que se pretende otimizar;
- população – grupo de cromossomos;
- tamanho da população (PopulationSize) – número de cromossomos de cada geração;
- geração (Generation) – o momento em que se encontra a evolução;
- função avaliação – responsável por estabelecer índice representativo da probabilidade de perpetuação de um cromossomo;
- cruzamento (CrossoverFcn) – combinação dos valores dos vetores de forma a gerar novos cromossomos;

- mutação (MutationFcn) – troca aleatoriamente um ou mais valores de um ou mais cromossomos escolhidos aleatoriamente;
- elitismo e steady state (EliteCount')– manutenção dos melhores cromossomos para a geração seguinte;
- critério de parada – determinação do valor mínimo ou máximo na função de avaliação o qual define a decisão de parada;
- soluções inválidas – soluções fora das restrições do problema.

3.1.2.

Aplicação do algoritmo genético à reconstituição de acidentes

Foram estabelecidos os critérios para uma “cooperação” adequada entre o otimizador e o simulador. Quanto melhor a avaliação de um cromossomo, mais provavelmente ele passará as suas informações para as gerações seguintes. Portanto, ao se escolher a função de avaliação, deve-se ater tanto à preocupação de bem diferenciar entre um bom cromossomo e um mau cromossomo, quanto à de simplicidade em sua formulação, pois uma excessiva complexidade aumentaria o risco de se formularem hipóteses inválidas.

Outra necessidade é a definição das variáveis que o algoritmo deverá trabalhar em busca da solução ótima. Quanto mais fatores a se otimizar existirem, mais amplo será o universo de busca do problema e portanto mais lentamente se dará a convergência ao ponto ótimo.

As entradas (genes) do algoritmo serão:

- velocidades iniciais;
- posições iniciais;
- atitudes iniciais;
- local da colisão;
- partes colididas dos veículos.

Em uma análise futura ainda pretende-se incluir fatores que deverão ser otimizados pelo algoritmo, como:

- valor do coeficiente de atrito;

- valor do coeficiente de restituição;
- valor do coeficiente de interpenetração.

Os limites e/ou a média e distribuição probabilística destes fatores serão dados de entrada do usuário/especialista. Com isso, apesar do grande número de parâmetros a serem otimizados, o universo de busca será limitado. Quanto mais informações reais o analista tiver, será de se esperar uma convergência mais rápida do algoritmo ao ótimo global.

Como o algoritmo genético é baseado em um processo estocástico, as posições dos veículos não podem ser definidas em coordenadas globais. Esta impossibilidade é devida ao fato de que inicialmente o otimizador gera valores independentes entre si.

Observa-se que a Figura 12 representa o problema que está sendo tratado. Neste modelo, as variáveis x e y do ponto final da área colidida do veículo 2 (x_{fb} e y_{fb}) não são colocadas na figura, tendo em vista o fato de serem obtidas a partir da geometria da área colidida, não sendo portanto escolhidas pelo AG.

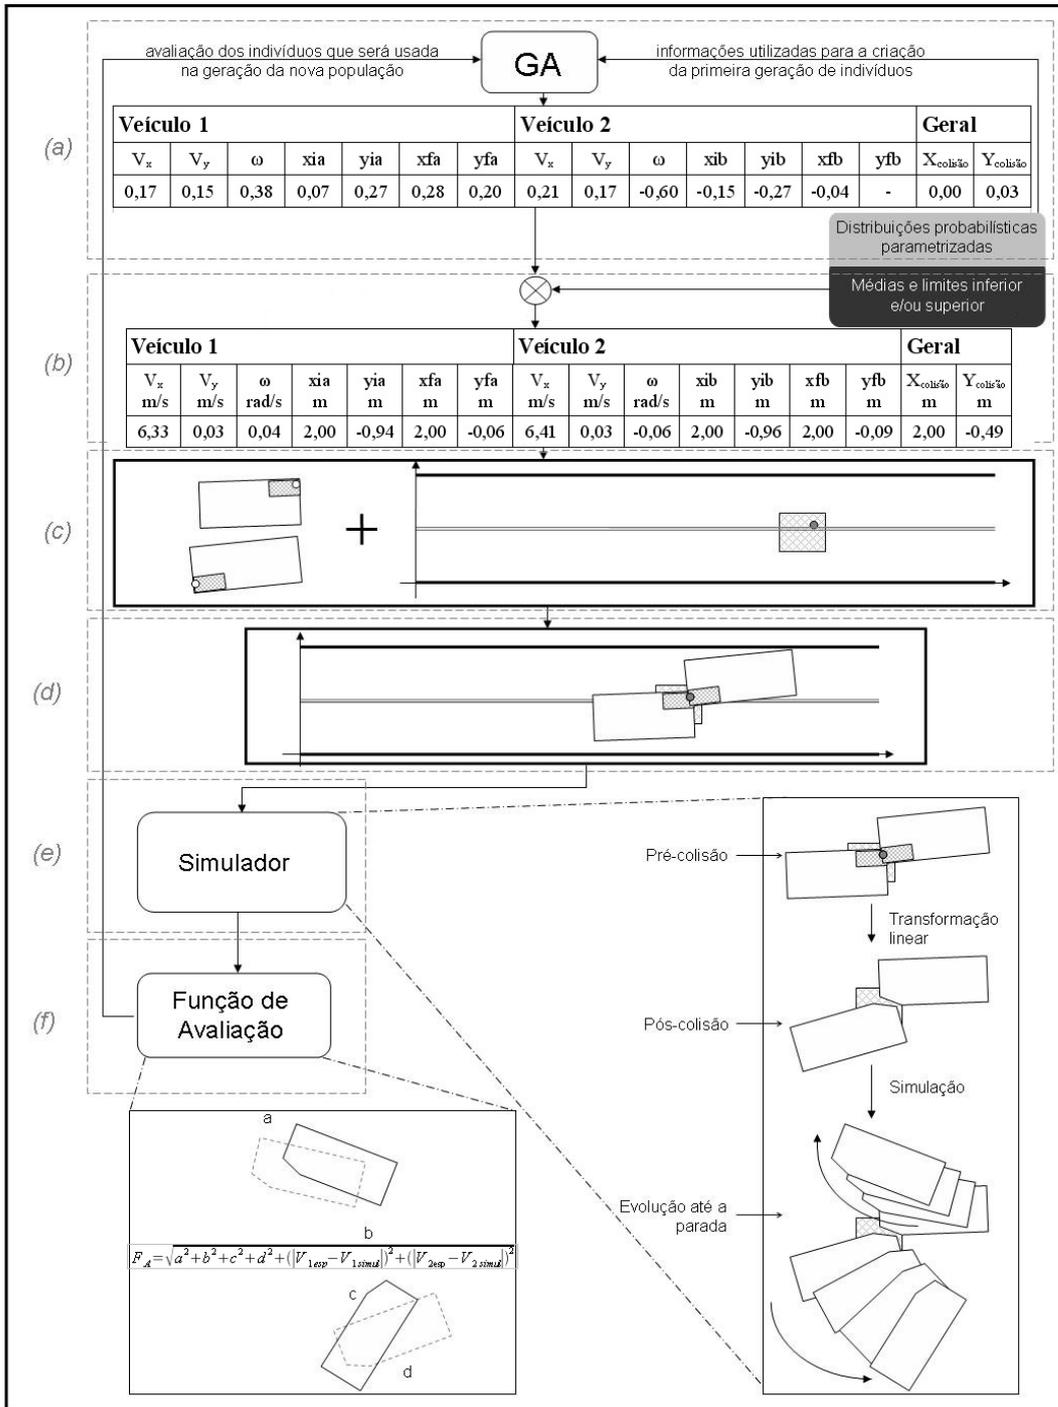


Figura 12 – Detalhamento do Algoritmo Genético conjugado ao programa de simulação.

As variáveis apresentadas na Figura 12 são as seguintes:

$X_{\text{colisão}}$ é a abscissa do local da colisão;

$Y_{\text{colisão}}$ é a ordenada do local da colisão;

V_x é a componente x da velocidade pré-choque;

V_y é a componente y da velocidade pré-choque;

ω é a velocidade angular pré-choque;

x_{ia} é a abscissa do ponto inicial da colisão do veículo 1;

y_{ia} é a ordenada do ponto inicial da colisão do veículo 1;

x_{fa} é abscissa do ponto final da colisão do veículo 1;

y_{fa} é a ordenada do ponto final da colisão do veículo 1;

x_{ib} é a abscissa do ponto inicial da colisão do veículo 2;

y_{fb} é a ordenada do ponto inicial da colisão do veículo 2.

Etapas para utilização do modelo:

1. Entrar com os limites inferior e superior das variáveis a serem tratadas e os parâmetros constantes da colisão e as características de interação (atrito pneu-solo, coeficiente de interpenetração ...)
2. Entrar com as posições-alvo finais, ou seja, aquelas conhecidas da cena do acidente, também denominadas posições reais.
3. O algoritmo genético irá então “criar” a primeira população através de geração aleatória de valores para as variáveis
4. A cena do acidente será montada, ou seja, através da definição do ângulo de cada veículo, das partes colididas e do local da colisão, os veículos serão colocados em posição de colisão. Esta será então simulada e as posições finais dos veículos serão comparadas com aquela fornecida pelo usuário na etapa 2.
5. Através de cada função de avaliação, cada cromossomo terá suas chances de se reproduzir, ou seja, de misturar seus valores com o de

outro cromossomo. Para tanto, os cromossomos com melhores funções de avaliação, que neste caso nada mais são que funções de menores magnitudes (mais próximas de zero), terão maiores chances de se reproduzirem.

6. Outra forma é utilizada para criar cromossomos para a nova geração: a mutação. Esta escolhe aleatoriamente, e normalmente a taxas muito baixas (em torno de 5%), cromossomos que não se cruzarão com nenhum outro, mas terão somente algumas de suas características alteradas aleatoriamente (dentro dos limites iniciais) e serão colocados desta forma na nova geração. Estes cromossomos são responsáveis pela procura do mínimo global.
7. A última forma é utilizada na criação de novas gerações: a perpetuação dos melhores cromossomos. Este número também pode ser alterado pelo usuário e garante que as melhores combinações de genes (valores) até um dado momento não será perdida na mistura com outros cromossomos.
8. Através dos três pontos anteriores tem-se a nova população ou geração. Com esta nova população retorna-se à etapa 4 e se recomeça o processo para uma nova geração. Assim sucessivamente até que algum critério de parada seja alcançado, a saber:
 - Limite inferior da função de avaliação (FitnessLimit);
 - Número máximo de gerações (Generations);
 - Limite máximo de tempo em estagnação - a quantidade de segundos que o programa ficará calculando sem achar um cromossomo melhor que aquele dito como o atual melhor (StallTimeLimit);
 - Limite máximo de gerações em estagnação. Análogo ao anterior, somente tendo como critério o número de gerações, e não o tempo (StallGenLimit).

Na Figura 13 encontra-se o fluxograma relativo ao procedimento de otimização.

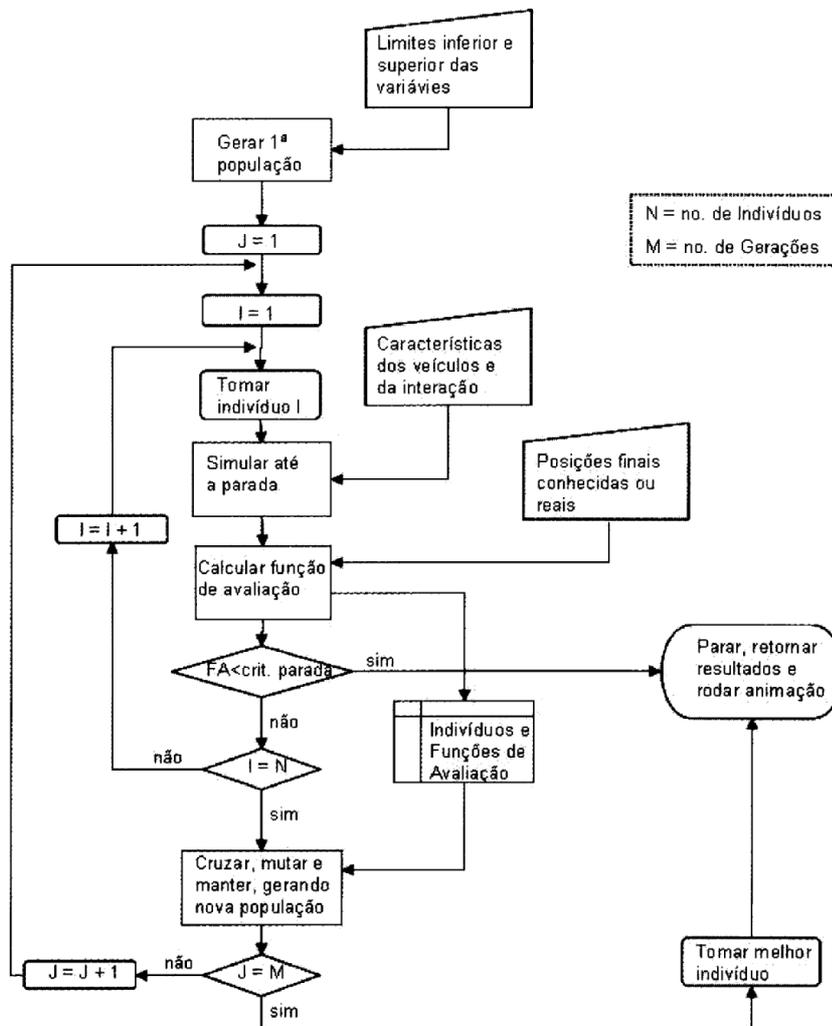


Figura 13 – Fluxograma do procedimento de otimização.