

3

Técnicas de Apoio à Decisão

O termo *Técnicas de Apoio à Decisão* refere-se ao agrupamento de métodos cujas finalidades apontam para o auxílio em tomada de decisão por parte de especialistas. São, pela própria definição, genéricas o suficiente para serem aplicadas em uma enorme quantidade de problemas e, por isso, serão utilizadas no problema-alvo deste trabalho. Dentre as técnicas utilizadas, estão as baseadas em Inteligência Computacional e as baseadas em estatística.

A Inteligência Computacional, por sua vez, é um ramo da Ciência da Computação que compreende um conjunto de técnicas que se inspiram em comportamentos observados na natureza, como aprendizagem, percepção e evolução, para resolver problemas de forma "inteligente". Dentre as técnicas mais conhecidas, estão os Algoritmos Genéticos, as Redes Neurais Artificiais e a Lógica Nebulosa.

3.1

Algoritmos Genéticos

Os Algoritmos Genéticos, sugeridos inicialmente em [21], situam-se na classe dos métodos evolutivos, baseados em populações de potenciais soluções de um problema. Métodos dessa natureza se mostram interessantes na resolução de problemas complexos de otimização porque demandam pouco conhecimento matemático ou analítico do problema em questão, além de serem funcionais para problemas descontínuos. Além disso, sua natureza estocástica confere aos métodos evolutivos a qualidade de serem menos suscetíveis ao aprisionamento em ótimos locais. Contudo, o tempo de convergência costuma ser bem mais elevado que o tempo gasto por métodos de otimização baseados em gradiente, devido ao alto número de avaliações da função objetivo. Portanto, os algoritmos genéticos são mais adequados para a busca de uma solução aceitável, que não necessariamente seja uma solução ótima, mas que sirva de guia para a solução de um problema complexo de otimização.

Os Algoritmos Genéticos são um dos principais modelos pertencentes à computação evolutiva e são inspirados no princípio evolutivo de Charles Darwin. São tipicamente utilizados para resolver problemas de otimização de

funções reais definidas em um espaço de busca S , constituído por todas as possíveis soluções para um problema particular. Sendo assim, a função a ser otimizada representa uma medida da aptidão do indivíduo, segundo o conceito de aptidão de Darwin.

Dependendo das peculiaridades do problema, as soluções (elementos do conjunto S) podem ser representadas por vetores de números binários, inteiros, reais, ou estruturas mais complexas.

Na prática, a finalidade principal de um algoritmo genético é, então, buscar eficientemente no espaço de busca S soluções que estejam de acordo com a função objetivo do problema. Vale ressaltar que essas soluções não precisam ser necessariamente ótimas, devido à grande demanda de tempo que seria necessária. Contudo, as soluções devem ser, ao mínimo, satisfatórias.

O projeto de um algoritmo genético parte da forma ou representação das soluções admissíveis no conjunto S . Uma boa representação deve garantir que qualquer vetor de entrada pertença a S e que, idealmente, não existe elemento representável que não pertença a S . Neste trabalho, esta questão não é tão fundamental, pois o algoritmo genético adotado necessita trabalhar apenas com funções reais, isto é, o domínio é real. Logo, representações sofisticadas não serão necessárias.

Uma vez escolhida a representação vetorial dos elementos de S , gera-se uma amostragem aleatória, conhecida como população inicial. Após avaliada a população inicial do algoritmo genético, inicia-se o processo evolutivo, no qual os indivíduos são submetidos a quatro etapas básicas: seleção, cruzamento, mutação e, novamente, a avaliação. Na seleção, ocorre o favorecimento dos mais aptos, de forma probabilística. Em outras palavras, cada indivíduo da população tem uma probabilidade de seleção diretamente proporcional à sua aptidão.

Operadores são aplicados aos vetores selecionados, de modo a provocar a referida evolução. Os principais operadores genéticos são o cruzamento, que consiste em recombinar o material genético de dois indivíduos a fim de criar dois novos, e a mutação, incumbida em aplicar modificações aleatórias em um ou mais elementos do vetor representativo do indivíduo. Sendo assim, o operador de mutação é responsável pela exploração do espaço de busca e o operador de cruzamento é responsável por tirar proveito de um determinado subespaço de busca. Busca-se, assim, equilíbrio adequado entre essas duas características.

Por fim, o ciclo conclui-se com a avaliação dos novos indivíduos gerados pelos operadores genéticos. Tais ciclos, conhecidos como gerações, são repetidos até atingir um critério de parada. Normalmente, este critério é baseado no

número total de ciclos, ou, alternativamente, no tempo total de otimização.

3.2

Métodos Monte Carlo

Métodos Monte Carlo são uma classe de algoritmos computacionais que dependem de repetição de amostragens aleatórias para calcular resultados. São freqüentemente usados na simulação de sistemas físicos e matemáticos, sobretudo com cenários apoiados sob incertezas. São métodos mais adequados para o cálculo em computador e tendem a ser utilizados quando é inviável calcular um resultado exato com um algoritmo determinístico ou quando este necessita de informações pouco conhecidas mas que, entretanto, podem ser modeladas como variáveis aleatórias [11].

Além disso, são especialmente úteis para a simulação de sistemas com muitos graus de liberdade acoplados, como fluidos, materiais desordenados, sólidos fortemente acoplados e estruturas celulares. Adicionalmente, são usados para fenômenos com incerteza significativa nos parâmetros, tais como o cálculo de risco no negócio. Já foram usados amplamente em Eletromagnetismo, inclusive para modelar problemas sob incertezas [22, 23, 24, 25].

A técnica foi nomeada com inspiração no cassino Monte Carlo, um local de jogo famoso em Mônaco. O termo foi cunhado em 1940 por físicos que trabalham em projetos de armas nucleares em Los Alamos National Laboratory.

Basicamente, as técnicas de amostragem Monte-Carlo resumem-se em:

- Definir um domínio para as variáveis de entrada.

Amostrar valores de entrada baseando-se nas distribuições das variáveis aleatórias do problema e seus respectivos domínios.

- Fazer um cálculo determinístico envolvendo as amostras.

- Agregar os resultados e computar estatísticas em cima destes.

Existem diversas técnicas de amostragem que podem ser utilizadas [11]. Contudo, a técnica de amostragem conhecida como LHS (*Latin Hypercube Sampling*, [26]) fora adotada neste trabalho, por ter se mostrado capaz de apresentar soluções convergentes com menos amostras que outros métodos, tornando-se especialmente útil para problemas com muitas incertezas. Outros métodos têm mostrado necessidade de maior quantidade de amostras levando,

então, a um maior número de cálculos determinísticos envolvidos e, por isso, maior custo computacional.

O cálculo determinístico citado, contudo, não tem nenhuma relação com a técnica de simulação adotada, sendo aquele apenas decorrente do modelo físico do problema em questão. Neste trabalho, este modelo é, portanto, uma função matemática que relaciona os parâmetros constituintes do meio de propagação (tal como permissividade elétrica, temperatura média, frequência de propagação, entre outras) com atenuação de propagação e impedância de linha. Esta função, por sua vez, foi obtida no capítulo 2, através de cálculos teóricos e modelagem computacional.