

Otimização de Redes

Simulated Annealing & Tabu Search

Prof. Lucas S. Batista

lusoba@ufmg.br

www.ppgce.ufmg.br/~lusoba

Universidade Federal de Minas Gerais
Escola de Engenharia

Sumário

1 Problema de Otimização

- Definição Geral

2 Simulated Annealing

- Conceitos Gerais e Implementação

3 Tabu Search

- Conceitos Gerais e Implementação

Problema de Otimização Mono-objetivo

- Formulação geral:

$$\min_{\mathbf{x}} f(\mathbf{x}) \in \mathbb{R}, \quad \mathbf{x} \in \mathcal{F}$$

$$\mathcal{X} = \{\mathbf{x} = (x_1, x_2, \dots, x_n), \quad x_i \in \mathcal{D}_i\}$$

$$\mathcal{F} = \begin{cases} g_i(\mathbf{x}) \leq 0; & i = 1, \dots, p \\ h_j(\mathbf{x}) = 0; & j = 1, \dots, q \\ \mathbf{x} \in \mathcal{X} \end{cases}$$

Sumário

1 Problema de Otimização

- ## ● Definição Geral

2 Simulated Annealing

- ## ● Conceitos Gerais e Implementação

3 Tabu Search

- ## ● Conceitos Gerais e Implementação

Introdução

- *Simulated Annealing* (SA) foi proposto por três pesquisadores da IBM em 1982 (S. Kirkpatrick, C.D. Gelatt and M.P. Vecchi, 1983).
 - Na ocasião estavam tentando resolver um problema de disposição ótima de componentes eletrônicos em uma placa de circuitos.

Introdução

- SA é uma metaheurística de busca local usada para tratar problemas de otimização discreta e, em menor escalar, contínua.
 - Sua principal característica é a habilidade de escapar de mínimos locais, através da aceitação de “movimentos” de piora da qualidade da solução.
 - Tornou-se muito popular na década de 90 devido à fácil implementação e propriedades de convergência atrativas.

História e Motivação

- SA é inspirado no processo de “recozimento” físico de sólidos:
 - Um sólido é aquecido e, em seguida, resfriado em estágios, lentamente, até atingir a configuração cristalina mais regular possível (i.e., estado de menor energia), a qual é livre de defeitos.
- SA estabelece uma conexão entre esse tipo de comportamento termodinâmico e o processo de busca por mínimos globais de problemas de otimização discreta.

Funcionamento do Algoritmo

- Em cada iteração do SA, duas soluções candidatas são comparadas (a atual e a modificada):
 - soluções melhoradas são sempre aceitas;
 - uma parcela das soluções inferiores é aceita, com o intuito de escapar de ótimos locais.
- A probabilidade de aceitação de soluções inferiores depende do parâmetro “temperatura”, o qual é usualmente não-crescente ao longo das iterações.
- À medida que o parâmetro “temperatura” tende a zero, movimentos de piora ocorrem com menor frequência e o método converge para um ótimo local, que pode ou não ser global.

Funcionamento do Algoritmo

- Assuma as seguintes definições¹:
 - Ω : espaço de soluções (conjunto de todas as soluções possíveis);
 - $f : \Omega \rightarrow \mathbb{R}$: uma função objetivo definida em Ω ;
 - $\mathcal{N}(\mathbf{x})$: função de vizinhança da solução $\mathbf{x} \in \Omega$;
 - \mathbf{x}^* : mínimo global, i.e., $\mathbf{x}^* \in \Omega$ tal que $f(\mathbf{x}^*) \leq f(\mathbf{x})$, $\forall \mathbf{x} \in \Omega$.

¹A menos que seja dito o contrário, será considerado o SA para problemas de optimização discreta.

Funcionamento do Algoritmo

- Evolução geral do SA:
 - Começa a busca a partir de uma solução inicial $x \in \Omega$;
 - Uma nova solução candidata $x' \in \mathcal{N}(x)$ é gerada;
 - Emprega-se o critério de aceitação de Metropolis (1953), que modela como um sistema termodinâmico move-se do estado corrente, $x \in \Omega$, para um novo estado, $x' \in \Omega$, de menor energia.

Funcionamento do Algoritmo

- A probabilidade de aceitação da solução candidata, \mathbf{x}' , como a alternativa corrente é dada por:

$$P\{\mathbf{x}'\} = \begin{cases} \exp[-(f(\mathbf{x}') - f(\mathbf{x}))/t_k] & \text{se } f(\mathbf{x}') - f(\mathbf{x}) > 0 \\ 1 & \text{se } f(\mathbf{x}') - f(\mathbf{x}) \leq 0 \end{cases}$$

em que t_k é o parâmetro temperatura no estágio k , tal que:

$$t_k > 0 \quad \forall k \quad \text{e} \quad \lim_{k \rightarrow \infty} t_k = 0.$$

- Note que em altas temperaturas, $\exp[-(f(\mathbf{x}') - f(\mathbf{x}))/t_k] \rightarrow 1$, e em baixas, $\exp[-(f(\mathbf{x}') - f(\mathbf{x}))/t_k] \rightarrow 0$.

Funcionamento do Algoritmo

- A regra de redução da temperatura possui a seguinte forma:
 - Regra geométrica (amplamente aceita, muito simples)

$$t_{k+1} = \alpha t_k, \quad \alpha \text{ é uma constante menor que } 1.$$

- Regra adaptativa (mais efetiva)

$$t_{k+1} = \alpha(t_k) t_k$$

$$t_{k+1} = \left(1 - t_k \frac{\Delta(t_k)}{\sigma^2(t_k)}\right) t_k, \quad t_{k+1} = \min \left(D_0, \frac{E_k}{\bar{E}_k}\right) t_k, \quad \text{etc.}$$

em que $\sigma^2(t_k)$ é o desvio padrão das soluções aceitas no estágio k , $\Delta(t_k)$ depende da regra adaptativa definida, $D_0 \in [0.5, 0.9]$, E_k é o menor $f(\cdot)$ aceito durante o estágio k e \bar{E}_k é o valor médio de todas as soluções aceitas no o estágio k .

Pseudocódigo do Algoritmo

Algoritmo 1: Simulated Annealing

```
1 Defina um contador  $k = 0$ ;  
2 Defina uma temperatura inicial  $t_k \geq 0$ ;  
3 Defina  $T_k$  (função que controla a variação da temperatura);  
4 Defina  $M_k$  (no. de iterações executadas na temperatura  $t_k$ );  
5 Selecione uma solução inicial  $\mathbf{x} \in \Omega$ ;  
6 while critério de parada não alcançado do  
7   Defina o contador  $m = 0$ ;  
8   while  $m \leq M_k$  do  
9     Gere uma solução  $\mathbf{x}' \in \mathcal{N}(\mathbf{x})$ ;  
10    Calcule  $\Delta E = f(\mathbf{x}') - f(\mathbf{x})$ ;  
11    if  $\Delta E \leq 0$  then  
12       $\mathbf{x} \leftarrow \mathbf{x}'$ ;  
13    else  
14       $\mathbf{x} \leftarrow \mathbf{x}'$  com probabilidade  $\exp(-\Delta E/t_k)$ ;  
15     $m \leftarrow m + 1$ ;  
16   $t_{k+1} \leftarrow T_k(t_k)$ ;  
17   $k \leftarrow k + 1$ ;
```

Considerações Práticas

- Algumas escolhas são fortemente dependentes do problema, e influenciam diretamente a eficiência do SA:
 - função objetivo;
 - mapeamento das soluções candidatas;
 - função de vizinhança;
 - “tamanho” da vizinhança².

²Alguns autores sugerem a implementação do SA com busca em vizinhança variável. Resultados numéricos sugerem um aumento do desempenho do método.

Considerações Práticas

- Definição da temperatura inicial t_0 :
 - realize 100 perturbações em x_0 , e obtenha o valor médio $\overline{\Delta E}$;
 - escolha uma taxa de aceitação inicial τ_0 , e.g., $\tau_0 = 0.5$ ou $\tau_0 = 0.2$;
 - deduza t_0 a partir da relação $\exp(-\Delta E/t_0) = \tau_0$.
- Critério para alteração da temperatura:
 - $12n$ perturbações aceitas, ou $100n$ perturbações testadas.
- Regra de redução da temperatura:
 - $t_{k+1} = 0.9t_k$
- Critério de parada do método:
 - 03 estágios sucessivos de temperatura sem melhora.

Extensão para Problemas Contínuos

- A maioria das aplicações com SA são para problemas discretos, entretanto, existem algumas para tratar problemas contínuos.
- A principal dificuldade relaciona-se com a modelagem da “discretização” do espaço de busca.
- Inúmeros trabalhos discutem as propriedades de convergência do SA aplicado a problemas contínuos de otimização global.

Extensão para Problemas Contínuos

Simulated Annealing para problemas contínuos:

- 1 Geração de novas soluções:

$$\mathbf{x}' = \mathbf{x} + \boldsymbol{\delta}, \text{ em que } \boldsymbol{\delta} = \sigma(\mathbf{x}^{ub} - \mathbf{x}^{lb}) \mathcal{D}(0, 1), \mathcal{D}(0, 1) = 2rand(n, 1) - 1$$

- 2 As n variáveis são modificadas em grupos de $p \cong n/3$:

$$\mathbf{x}' = \mathbf{x} + H\boldsymbol{\delta}, \text{ em que } H \text{ é uma matriz diagonal com 1s nas posições a serem modificadas.}$$

- 3 Regra de atualização de σ :

$$\begin{aligned} \text{se } A_k > 0.2, \sigma &= 2\sigma; \\ \text{se } A_k < 0.05, \sigma &= 0.5\sigma; \\ \text{em que } A_k &\text{ é a taxa de aceitação no estágio } k. \end{aligned}$$

- 4 O desvio padrão inicial é $\sigma = 0.25$, sendo atualizado ao fim de cada estágio de temperatura.

Vantagens e Desvantagens do Método

- Vantagens:

- Geralmente encontra uma solução de boa qualidade;
- Sua aplicação e adaptação é muito flexível;
- Possui fácil implementação.

- Desvantagens:

- Alto número de parâmetros de controle;
- O ajuste de parâmetros é dependente do problema;
- O custo computacional pode ser alto em algumas aplicações.

Sumário

1 Problema de Otimização

- Definição Geral

2 Simulated Annealing

- Conceitos Gerais e Implementação

3 Tabu Search

- Conceitos Gerais e Implementação

Introdução

- *Tabu Search* (TS) foi proposta por Fred Glover (1986) para a solução de problemas de otimização combinatória.
- Assim como o SA, TS é considerada uma metaheurística, i.e., uma estratégia geral para guiar e controlar heurísticas subordinadas especializadas.
- Tornou-se muito popular na década de 90 principalmente por:
 - apresentar grande efetividade,
 - determinar soluções muito próximas do ótimo global, e
 - lidar com problemas de grande escala.

Introdução

- O princípio básico da TS consiste na aplicação de busca local (“local search” - LS) e na aceitação de movimentos de piora da qualidade da solução.
- Um mecanismo de “memória”³ (chamado *tabu list*) é usado para evitar revisitação de soluções conhecidas.

³Conceito chave relacionado à teoria de inteligência artificial.

Espaço de Busca e Estrutura de Vizinhança

- Assuma as seguintes definições⁴:

- Ω : espaço de soluções (conjunto de todas as soluções possíveis);
- $f : \Omega \rightarrow \mathbb{R}$: uma função objetivo definida em Ω ;
- $\mathcal{N}(\mathbf{x})$: função de vizinhança da solução $\mathbf{x} \in \Omega$;
- \mathbf{x}^* : mínimo global, i.e., $\mathbf{x}^* \in \Omega$ tal que $f(\mathbf{x}^*) \leq f(\mathbf{x})$, $\forall \mathbf{x} \in \Omega$.

⁴A menos que seja dito o contrário, será considerado o TS para problemas de otimização discreta.

Espaço de Busca e Estrutura de Vizinhança

- O domínio de busca pode ser mapeado de diferentes formas para um mesmo problema.
 - Uma escolha mal sucedida dessa representação pode comprometer muito o desempenho do método.
 - Por exemplo, em muitos casos pode ser desejável/necessário pesquisar em regiões infactíveis.
- De forma similar, em geral existem inúmeras estruturas de vizinhança possíveis para um mesmo mapeamento do domínio de busca.
- A definição do espaço de busca e da estrutura de vizinhança representa o passo mais crítico no projeto de qualquer TS.

Tabus

- *Tabus* são usados para evitar operações cíclicas, i.e., a revisitação de soluções.
- Essa “inteligência” é implementada por meio de listas tabus que armazenam *movimentos tabus*.
- Esse mecanismo permite ao TS escapar de ótimos locais e, simultaneamente, a explorar regiões ainda não visitadas.

Tabus

- Múltiplas listas tabus podem ser utilizadas simultaneamente, e em alguns casos são aconselhadas, e.g., quando diferentes tipos de movimentos são empregados para pesquisar a vizinhança.
- Listas tabus de tamanho fixo frequentemente não previnem revisitações:
 - Recomenda-se variar o comprimento das listas durante a busca;
 - Outra opção é a geração aleatória da “duração” tabu de cada movimento.

Critérios de Aspiração

- *Tabus* são, algumas vezes, muitos fortes!
 - Eles podem proibir movimentos atrativos, mesmo quando não há risco de revisitação, ou podem levar à estagnação do método.
- São necessárias então técnicas que permitam revogar os tabus! Essas estratégias são chamadas *critérios de aspiração*.
 - Em geral, um movimento é aceito (mesmo sendo tabu) se ele resulta em uma solução melhor do que a melhor alternativa conhecida.

Pseudocódigo do Algoritmo

- \mathbf{x} , a solução corrente;
- \mathbf{x}^* , a melhor solução conhecida;
- f^* , o valor de $f(\mathbf{x}^*)$;
- $\mathcal{N}(\mathbf{x})$, a vizinhança de \mathbf{x} ;
- $\tilde{\mathcal{N}}(\mathbf{x})$, o subconjunto admissível de $\mathcal{N}(\mathbf{x})$ ⁵;
- T , a lista tabu.

Algoritmo 2: Tabu Search

- 1 Selecione uma solução inicial $\mathbf{x}_0 \in \Omega$;
 - 2 Defina $\mathbf{x} \leftarrow \mathbf{x}_0$, $\mathbf{x}^* \leftarrow \mathbf{x}_0$, $f^* \leftarrow f(\mathbf{x}_0)$, $T \leftarrow \emptyset$;
 - 3 **while** critério de parada não alcançado **do**
 - 4 Determine $\mathbf{x} = \arg \min_{\mathbf{x}' \in \tilde{\mathcal{N}}(\mathbf{x})} f(\mathbf{x}')$;
 - 5 **if** $f(\mathbf{x}) < f^*$ **then** $\mathbf{x}^* \leftarrow \mathbf{x}$, $f^* \leftarrow f(\mathbf{x})$;
 - 6 Atualize a lista tabu T (delete entradas antigas se necessário);
-

⁵Conjunto não-tabu ou aceito por aspiração.

Busca Local

- A busca local, $\mathbf{x} = \arg \min_{\mathbf{x}' \in \tilde{\mathcal{N}}(\mathbf{x})} f(\mathbf{x}')$, pode ser implementada de diferentes formas:
 - *best improvement*;
 - *first improvement*;
 - TS probabilístico e listas candidatas.

Busca Local

- Visando minimizar o custo computacional, é frequente a presença de um TS probabilístico e listas candidatas.
 - No TS probabilístico, uma amostra aleatória $\mathcal{N}'(\mathbf{x}) \subset \mathcal{N}(\mathbf{x})$ substitui o conjunto completo $\mathcal{N}(\mathbf{x})$.
 - Essa aleatoriedade na busca minimiza problemas de revisitação;
 - As listas tabus podem ser menores;
 - Soluções “excelentes” podem ser perdidas!
 - Listas candidatas “contornam” a limitação anterior, a partir da geração de um subconjunto $\mathcal{N}'(\mathbf{x})$ mais promissor.

Critérios de Parada do Algoritmo

- Os critérios de parada mais comuns no TS são:
 - máximo número de iterações;
 - máximo custo computacional;
 - número específico de iterações sem melhora;
 - determinação de um limiar preestabelecido para $f(\cdot)$.

Elementos Adicionais

- Intensificação:

- busca local intensa, aplicada de tempos em tempos, usando uma lista candidata, uma estrutura de vizinhança variável, ou um subconjunto de vizinhança mais amplo (no caso do TS probabilístico).

- Diversificação:

- busca exploratória por regiões não investigadas;
- *restart diversification* – promove a inserção, na solução atual, de alguns movimentos raramente usados até a iteração corrente, e reinicia a busca a partir dessa alternativa;
- *continuous diversification* – emprega “memória de frequência” durante a evolução do algoritmo para polarizar a utilização de movimentos pouco explorados.

Elementos Adicionais

- Presença de soluções inviáveis:
 - a eliminação de todas as soluções inviáveis pode restringir muito o espaço de busca, e levar a soluções finais ruins;
 - técnicas de relaxação das restrições ampliam o domínio de busca que, geralmente, poderá ser explorado com uma estrutura de vizinhança mais simples;
 - essas técnicas são facilmente implementadas por meio da adição de funções penalidade ponderadas à função objetivo.

Elementos Adicionais

- Modelos de aproximação local:
 - a avaliação de $f(\cdot)$ de alguns problemas é proibitiva;
 - visando minimizar os custos, pode-se avaliar soluções vizinhas usando uma função objetivo aproximada, $\tilde{f}(\cdot)$, de baixo custo;
 - após a exploração dessa vizinhança, e a identificação de um subconjunto promissor de soluções, estas são avaliadas no objetivo original $f(\cdot)$ para se determinar a melhor alternativa.

Literatura Especializada

-  M. Gendreau, J.-Y. Potvin (eds.), *Handbook of Metaheuristics*, Springer, 2nd ed., 2010.
-  J. Dréo, P. Siarry, A. Pétrowski, E. Taillard, *Metaheuristics for Hard Optimization: Methods and Case Studies*, Springer, 2006.