



CT 820 Teoria de Sistemas e Otimização Fuzzy  
Introdução e Aplicações



## 2.2-Métodos de Busca em Otimização

# Introdução e motivação

- Algoritmos de busca
  - não informados (depth-first, breadth-first, variações)
  - informados (hill-climbing, beam search, best-first)
- Características dos algoritmos de busca
  - exatos (*branch and bound, discrete dynamic programming*)
  - heurísticos (A, A\*, outros )
  - metaheurísticas (algoritmos genéticos, PSA, SA, sistemas imunes, ACO)

## ■ Aplicações

- KBS
- programação de produção
- busca internet
- GIS
- 

## ■ Questões

- busca é a melhor maneira de resolver o problema?
  - quais algoritmos de busca resolvem o problema?
  - qual algoritmo é o mais eficiente para um dado problema?

# Busca em otimização

- Solução de um modelo de otimização
  - é uma escolha para os valores das variáveis de decisão
  - em geral uma solução é um vetor do  $\mathbb{R}^n$
- Características dos algoritmos de busca
  - melhora soluções factíveis ao longo de direcções factíveis
  - usa informação sobre a vizinhança da solução corrente
  - vizinhança  $\Rightarrow$  natureza local às soluções

- Vizinhança

$$N_\varepsilon(x) = \{y : \|y - x\| < \varepsilon\}, \quad x \in \mathbb{R}^n, \varepsilon > 0$$

$$\|x\| = \sqrt{(x_1^2 + x_2^2 + \dots + x_n^2)}$$

$\|x\|$  : norma (comprimento) de  $x$

- Ponto interior

$$S \subseteq \mathbb{R}^n, \quad x \in S \text{ interior se } \exists N_\varepsilon(x) \subset S$$

⇓

$$\exists \varepsilon > 0 \mid \|y - x\| < \varepsilon \Rightarrow y \in S$$

# Algoritmos numéricos de busca

1. iniciar com uma solução factível


$$x = x^0 \in D$$

2. prosseguir ao longo de direção factível  $\Delta x$

$$x^{t+1} \leftarrow x^t + \lambda \Delta x, \quad x^{t+1} \in D$$

⇓

$$f(x^{t+1}) \leq f(x^t)$$



min	$(x_1 - 4)^2 + (x_2 - 4)^2$
sa	$1.7 x_1 + 3.0 x_2 \leq 15$
	$2.2 x_1 + 0.9 x_2 \leq 10$
	$x_1, x_2 \geq 0$

6

■ Problemas de maximização


$$\begin{array}{l} \max f(x) \\ \text{sa } x \in D \end{array} \quad \Rightarrow \quad f(x^*) \geq f(x) \quad \begin{cases} \forall x \in (D \cap N_\varepsilon(x)) & \text{local} \\ \forall x \in D & \text{global} \end{cases}$$

■ Problemas de minimização

$$\begin{array}{l} \min f(x) \\ \text{sa } x \in D \end{array} \quad \Rightarrow \quad f(x^*) \leq f(x) \quad \begin{cases} \forall x \in (D \cap N_\varepsilon(x)) & \text{local} \\ \forall x \in D & \text{global} \end{cases}$$

- Ótimo local pode ser ótimo global
- Modelos tratáveis: ótimo local  $\equiv$  ótimo global
- Em geral ótimo local não é global
- O que fazer ?
  - executar algoritmos de busca independentes
  - declarar melhor solução  $\equiv$  solução ótima
  - ótimo aproximado (heurísticas)

# Exemplo: problema de alocação




$$\max f(x_1, x_2) = \frac{60}{1 + (x_1 + 1)^2 + (x_2 - 3)^2} + \frac{20}{1 + (x_1 - 1)^2 + (x_2 - 3)^2} + \frac{30}{1 + (x_1)^2 + (x_2 + 4)^2}$$


$$\text{s.a. } (x_1 + 1)^2 + (x_2 - 3)^2 \geq 0.25$$

$$(x_1 - 1)^2 + (x_2 - 3)^2 \geq 0.25$$

$$(x_1)^2 + (x_2 + 4)^2 \geq 0.25$$


$f(x_1, x_2)$






# Direção factível

- $\Delta x$  é uma direção factível em  $x^t$  se:
  - $x^t + \lambda \Delta x \in D$ ,  $\lambda > 0$  suficientemente pequeno
  - $\lambda =$  passo na direção  $\Delta x$



# Modelos ilimitados



# Melhor direção: condições algébricas

Gradiente de  $f(x)$  em  $x$  :  $\nabla f(x) = (\partial f / \partial x_1 \dots \partial f / \partial x_j \dots \partial f / \partial x_n)$

$$f(x^t + \lambda \Delta x) \approx f(x^t) + \lambda \nabla f(x^t)' \Delta x = f(x^t) + \lambda \sum_{j=1}^n \left( \frac{\partial f}{\partial x_j} \right) \Delta x_j$$

$$\Delta f = \lambda \nabla f(x^t)' \Delta x$$

$\nabla f(x)' \Delta x > 0 \Rightarrow$  melhora para *maximizar*

$\nabla f(x)' \Delta x < 0 \Rightarrow$  melhora para *minimizar*

Se  $\Delta x = \nabla f(x)$  e  $\nabla f(x) \neq 0$  então

$\nabla f(x)' \nabla f(x) > 0$  em geral melhora para *maximizar*

Se  $\Delta x = -\nabla f(x)$  e  $\nabla f(x) \neq 0$  então

$\nabla f(x)' \nabla f(x) < 0$  em geral melhora para *minimizar*

Nota : 1) por convenção consideraremos vetores colunas

2) ' denota transposto (às vezes denotado também por T)

3) para simplificar notação às vezes omitimos ' ou T

# Algoritmo busca local


Passo 0 Inicialização: escolher uma solução factível  $x^0$ ,  $t \leftarrow 0$ ;




Passo 1 Direção e otimalidade: construir direção factível  $\Delta x^{t+1}$  em  $x^t$ ;  
se não existir direção factível, então parar;  $x^t$  é um ótimo local;

Passo 2 Passo: se existir limites para valor de  $\lambda$  para o qual a função objetivo melhora, mantendo a factibilidade na direção  $\Delta x$ , então escolher o maior valor  $\lambda^{t+1}$ ; senão parar, o modelo é ilimitado;

Passo 4 Avanço: determinar nova solução  $x^{t+1} = x^t + \lambda \Delta x^{t+1}$ ;  $t = t + 1$ ;  
ir para o Passo 1;

# Exemplo: problema de alocação





# Factibilidade: condições algébricas:

- Caso linear

$$a'x = \sum_{j=1}^n a_j x_j \geq b; \Delta x \text{ factível} \Leftrightarrow a' \Delta x = \sum_{j=1}^n a_j \Delta x_j \geq 0$$

$$a'x = \sum_{j=1}^n a_j x_j \leq b; \Delta x \text{ factível} \Leftrightarrow a' \Delta x = \sum_{j=1}^n a_j \Delta x_j \leq 0$$

$$a'x = \sum_{j=1}^n a_j x_j = b; \Delta x \text{ factível} \Leftrightarrow a' \Delta x = \sum_{j=1}^n a_j \Delta x_j = 0$$


- Restrições ativas

# Unimodalidade e convexidade


- **Tratabilidade**
  - conveniência para análise de um modelo
- **Características importantes do modelo**
  - convexidade
  - unimodalidade

# Funções unimodais

$\forall x^1, x^2, f(x^2)$  melhor que  $f(x^1) \Rightarrow \Delta x = x^2 - x^1$  melhora em  $x^1$




não unimodal para max e min




unimodal para max  
não unimodal para min<sub>21</sub>

# Conjuntos convexos


$$\forall x^1, x^2 \in D, x^1 + \lambda (x^2 - x^1) \in D, 0 \leq \lambda \leq 1$$




Convexo



Não convexos



- Todas restrições lineares  $\Rightarrow$  conjunto (espaço) factível convexo



- Ótimo local é ótimo global para:
  - função objetivo unimodal
  - modelos sem restrições
  
- Ótimo local é ótimo global para:
  - função objetivo unimodal
  - modelos com restrições que formam um conjunto convexo
    - modelos lineares
    - modelos lineares quadráticos

# Soluções factíveis iniciais

- Método de duas fases

0 - Modelo artificial: escolher uma solução inicial conveniente para o modelo original e construir modelo da Fase I adicionando (subtraindo) variáveis artificiais não negativas em cada uma das restrições violadas;

1 - Fase I: Atribuir valores para as variáveis artificiais para obter uma solução inicial factível para o modelo artificial. Resolver problema de minimizar a soma das variáveis artificiais;

2 - Teste de factibilidade: se Fase I termina com  $soma = 0$ , ir para o passo 3, a solução original é factível. Se  $soma > 0$ , parar: modelo original é infactível. Caso contrário, repetir Fase I com solução inicial diferente;

3 - Fase II: Construir solução inicial factível para o problema original eliminando as componentes artificiais da solução ótima da Fase I.

# Método de duas fases: exemplo

- Modelo da Refinaria de Gabriel

$$\begin{array}{ll} \min & 20x_1 + 15x_2 \\ \text{sa} & 0.3x_1 + 0.4x_2 \geq 2.0 \\ & 0.4x_1 + 0.2x_2 \geq 1.5 \\ & 0.2x_1 + 0.3x_2 \geq 0.5 \\ & x_1 \leq 9 \\ & x_2 \leq 6 \\ & x_1, x_2 \geq 0 \end{array}$$

Escolha  $x_1 = x_2 = 0$

Viola as três primeiras restrições principais

■ Modelo artificial

$$\begin{array}{ll} \min & x_3 + x_4 + x_5 \\ \text{sa} & 0.3x_1 + 0.4x_2 + x_3 \geq 2.0 \\ & 0.4x_1 + 0.2x_2 + x_4 \geq 1.5 \\ & 0.2x_1 + 0.3x_2 + x_5 \geq 0.5 \\ & x_1 \leq 9 \\ & x_2 \leq 6 \\ & x_1, x_2 \geq 0 \end{array}$$

Fase I: depois de fixar variáveis do problema original nos valores escolhidos, inicializar as variáveis artificiais atribuindo os menores valores necessários para obter factibilidade

$$\begin{aligned}0.3 (0) + 0.4 (0) + x_3 &\geq 2 &\Rightarrow x_3 = 2 \\0.4 (0) + 0.2 (0) + x_4 &\geq 1.5 &\Rightarrow x_4 = 1.5 \\0.2 (0) + 0.3 (0) + x_5 &\geq 0.5 &\Rightarrow x_5 = 0.5\end{aligned}$$

Solução da Fase I: ( 4 4 0 0 0 ) factível

Solução inicial para Fase II :  $x^0 = ( 4 4 )$

## ■ Método Big-M

1 - Modelo auxiliar:  $\max f - M$  ( soma das variáveis artificiais )  
 $\min f + M$  ( soma das variáveis artificiais )

- 1 - Teste I: Se Big-M termina em uma solução local com todas as variáveis artificiais nulas, então as componentes restantes constituem uma solução ótima para o problema original;
- 2 - Teste II: se M é suficientemente grande e Big-M termina em um solução ótima global com alguma variável artificial positiva, então o problema original é infactível
- 3 - Teste III: se M é suficientemente grande e Big-M termina em um solução ótima local, com alguma variável artificial positiva, ou M não é grande o suficiente, nada se pode dizer. Repetir algoritmo ou com valor M maior, ou com outra solução inicial.

# Big-M: exemplo

$$\min \quad 20x_1 + 15x_2 + M(x_3 + x_4 + x_5)$$

$$\text{sa} \quad 0.3x_1 + 0.4x_2 + x_3 \geq 2.0$$

$$0.4x_1 + 0.2x_2 + x_4 \geq 1.5$$

$$0.2x_1 + 0.3x_2 + x_5 \geq 0.5$$

$$x_1 \leq 9$$

$$x_2 \leq 6$$

$$x_1, x_2 \geq 0$$

$$x^o = (0 \ 0 \ 2 \ 1.5 \ 0.5)$$

$$M = 10.000 \Rightarrow x^* = (2 \ 3.5 \ 0 \ 0 \ 0)$$

## Observação

Este material refere-se às notas de aula do curso CT 820 Teoria de Sistemas e Otimização Fuzzy: Introdução e Aplicações da Faculdade de Engenharia Elétrica e de Computação da Unicamp e do Centro Federal de Educação Tecnológica do Estado de Minas Gerais. Não substitui o livro texto, as referências recomendadas e nem as aulas expositivas. Este material não pode ser reproduzido sem autorização prévia dos autores. Quando autorizado, seu uso é exclusivo para atividades de ensino e pesquisa em instituições sem fins lucrativos.