



EA 044 Planejamento e Análise de Sistemas de Produção

Algoritmos Numéricos 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**

- otimização (branch and bound, discrete dynamic programming, SA)
- heurísticos (A, A*, outros)

- **Aplicações:** KBS, seqüenciamento de produção, busca internet, etc.

- **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?

2

Busca em Otimização

- **Solução de um modelo de otimização**

- 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**

- melhoram soluções factíveis ao longo de direções factíveis
- baseiam-se em informações sobre a vizinhança da solução corrente
- vizinhanças dão uma natureza local às soluções

- **Vizinhança**

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

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

$\|\mathbf{x}\|$ norma (comprimento) de \mathbf{x}

- **Ponto interior**

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

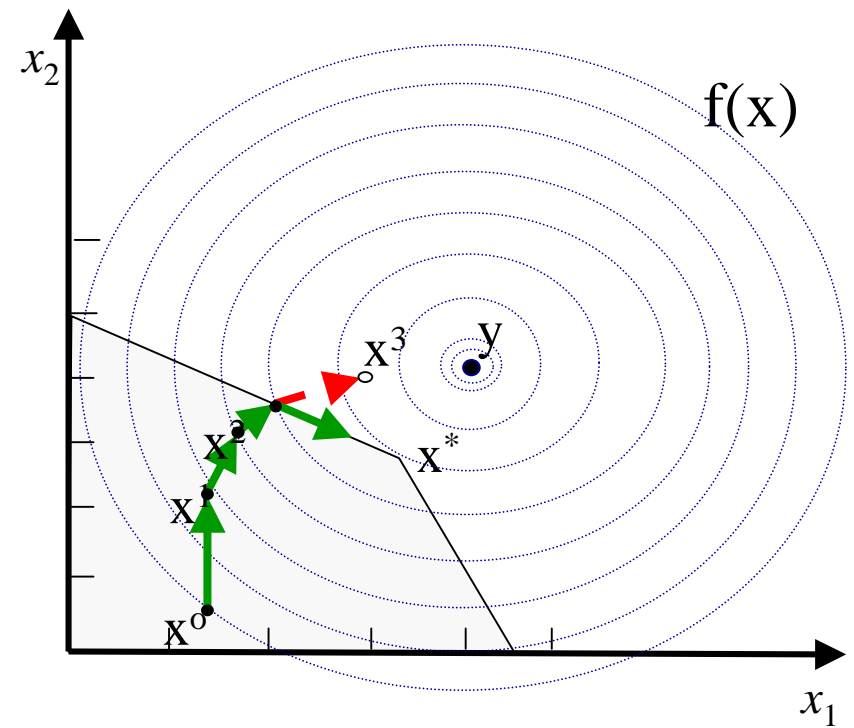
\Downarrow

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

Algoritmos numéricos de busca

$$\begin{aligned} \min & \quad (x_1 - 4)^2 + (x_2 - 4)^2 \\ \text{sujeito a} & \quad 1.7 x_1 + 3.0 x_2 \leq 15 \\ & \quad 2.2 x_1 + 0.9 x_2 \leq 10 \\ & \quad x_1, x_2 \geq 0 \end{aligned}$$

procedimentos que se iniciam em uma solução factível para um modelo de otimização e prosseguem ao longo de uma trajetória formada por pontos factíveis que sempre melhoram o valor da função objetivo.



$$x^{t+1} \leftarrow x^t + \lambda \Delta x \quad \Rightarrow \quad f(x^{t+1}) \leq f(x^t) \quad \lambda > 0$$

- Problemas de maximização


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

- Problemas de minimização

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

- Ótimo local pode ser ótimo global
- Modelos mais tratáveis: ótimo local \equiv ótimo global
- Em geral ótimo local não é global
 - executar algoritmos de busca independentes
 - melhor solução local \equiv solução ótima
 - ótimo aproximado, heurístico

Exemplo: problema de alocação




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


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

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

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

$f(x_1, x_2)$






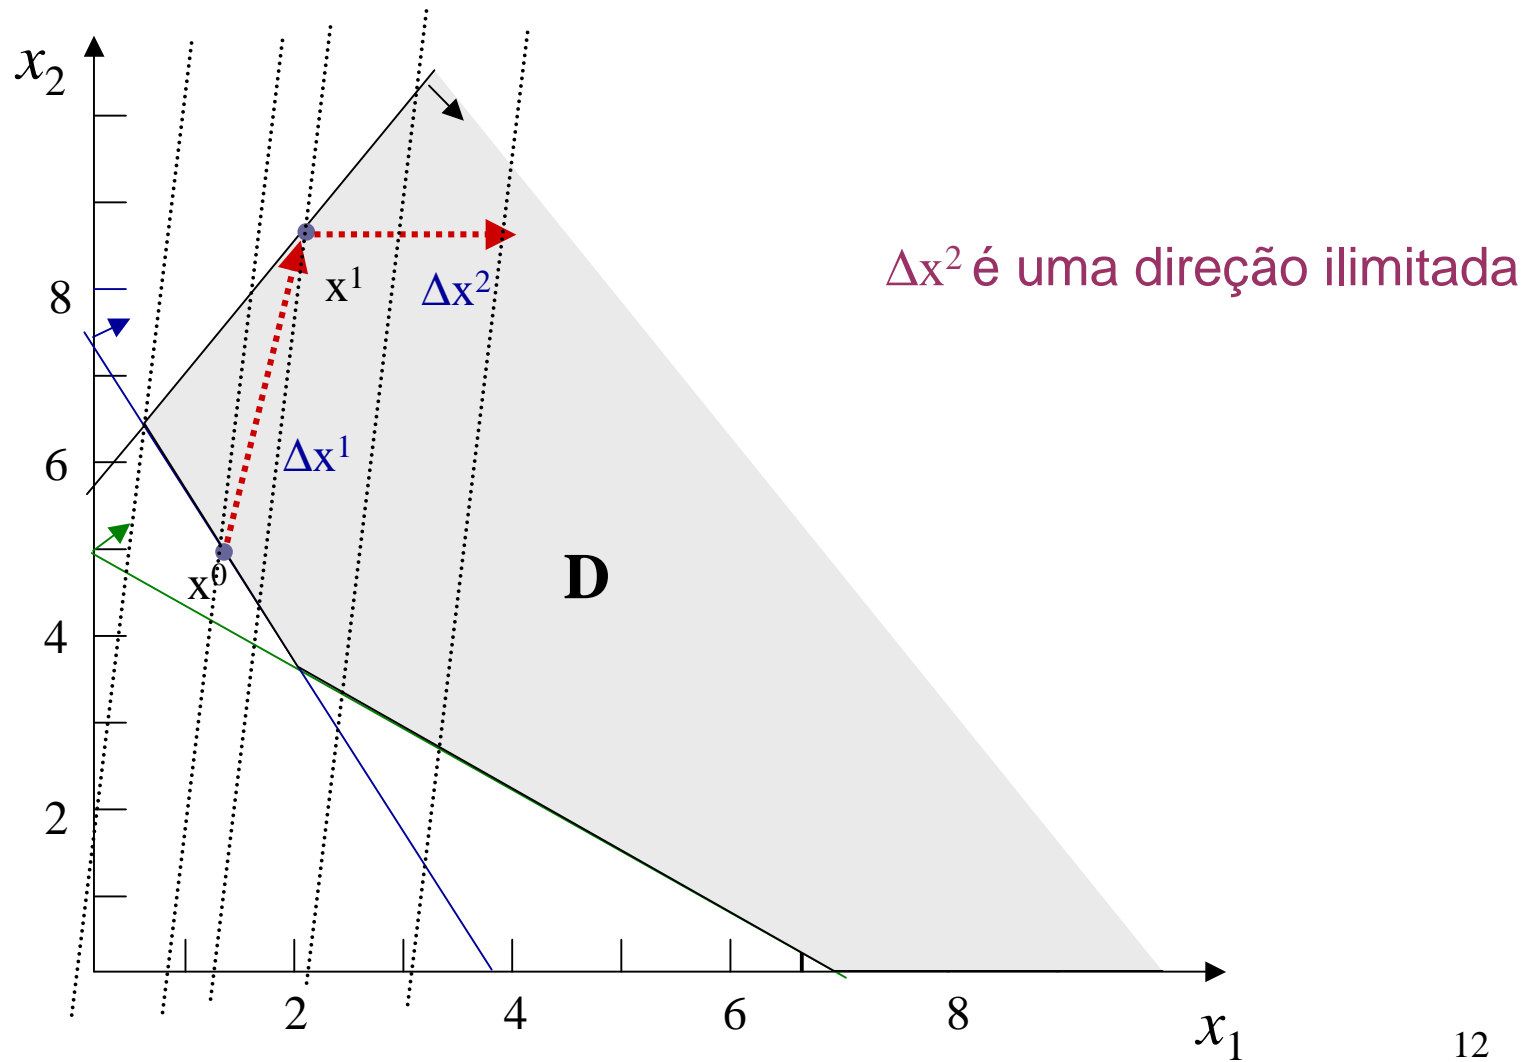
Direção Factível

Δx é uma direção factível em x^t se $x^t + \lambda \Delta x \in D$, $\lambda > 0$ e suf. pequeno.

λ = passo na direção Δx



Modelos ilimitados



Condições algébricas: melhor direção

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

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

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

$\nabla f(\mathbf{x})' \Delta \mathbf{x} > 0$ melhora para *maximizar*

$\nabla f(\mathbf{x})' \Delta \mathbf{x} < 0$ melhora para *minimizar*

Se escolhemos $\Delta \mathbf{x} = \nabla f(\mathbf{x})$, $\nabla f(\mathbf{x}) \neq 0$:

$\nabla f(\mathbf{x})' \nabla f(\mathbf{x}) > 0$ em geral (nem sempre) melhora para *maximizar*

Se escolhemos $\Delta \mathbf{x} = -\nabla f(\mathbf{x})$

$\nabla f(\mathbf{x})' \nabla f(\mathbf{x}) < 0$ em geral (nem sempre) 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: com solução factível x^0 , $t \leftarrow 0$;




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

Passo 2 **Passo**: se existir limites para valor de λ para o qual a função objetivo melhora, mantendo a factibilidade na direção Δx , então escolher o maior valor λ^{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





Condições algébricas: factibilidade

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

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



D é convexo

- Ótimos locais são ótimos globais para funções objetivo unimodais e quando os problemas não tem restrições
- Ótimos locais são ótimos globais quando a função objetivo é unimodal e as restrições formam um conjunto convexo
 - modelos lineares
 - modelos 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 a Fase I termina com soma = 0, ir para o passo 3 pois a solução original é factível. Se $\text{sum} > 0$, parar: modelo original é infactível. Caso contrário, repetir Fase 1 com diferentes valores iniciais.
- 3 - **Fase II**: Construir solução inicial factível para o problema original eliminando as componentes artificiais do ótimo da Fase I.

Método de duas fases: exemplo

- Modelo da Refinaria de Petrolinea

$$\begin{aligned} \min \quad & 20x_1 + 15x_2 \\ \text{sujeito a} \quad & 0.3x_1 + 0.4x_2 \geq 2.0 \\ & 0.4x_1 + 0.2x_2 \geq 1.5 \\ & 0.2x_1 + 0.3x_2 \geq 0.5 \\ & x_1 \leq 9 \\ & x_2 \leq 6 \\ & x_1, x_2 \geq 0 \end{aligned}$$

- Escolhendo: $x_1 = x_2 = 0$
- Viola todas as três restrições principais

- **Modelo Artificial**

$$\begin{aligned}
 \min \quad & x_3 + x_4 + x_5 \\
 \text{sujeito a} \quad & 0.3x_1 + 0.4x_2 + x_3 \geq 2.0 \\
 & 0.4x_1 + 0.2x_2 + x_4 \geq 1.5 \\
 & 0.2x_1 + 0.3x_2 + x_5 \geq 0.5 \\
 & x_1 \leq 9 \\
 & x_2 \leq 6 \\
 & x_1, x_2 \geq 0
 \end{aligned}$$

- **Fase I:** depois de fixar variáveis do problema original nos valores escolhidos, inicializar as variáveis artificiais atribuindo-as 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 $\Rightarrow (4 \ 4)$ **solução inicial para Fase II**

Método Big-M

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

1 - **Teste I:** Se Big-M termina em uma solução local com todas as variáveis artificiais nulas, então os 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 o multiplicador M não é grande o suficiente, nada se pode dizer. Repetir algoritmo ou com valor M maior, ou com outra solução inicial.

Método Big-M: exemplo

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

sujeito a $0.3x_1 + 0.4x_2 + x_3 \geq 2.0$

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

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

$$x_1 \leq 9$$

$$x_2 \leq 6$$

$$x_1, x_2 \geq 0$$

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

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

Observação

Este material refere-se às notas de aula do curso EA 044 Planejamento e Análise de Sistemas de Produção da Faculdade de Engenharia Elétrica e de Computação da Unicamp. 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.