



EA 044 Planejamento e Análise de Sistemas de Produção

Programação Não Linear Irrestrita

Modelo Programação Não Linear: PNL

$$\max (\min) \quad f(x)$$

$$\text{s. a.} \quad x \in D \subset \mathbb{R}^n$$

restrito

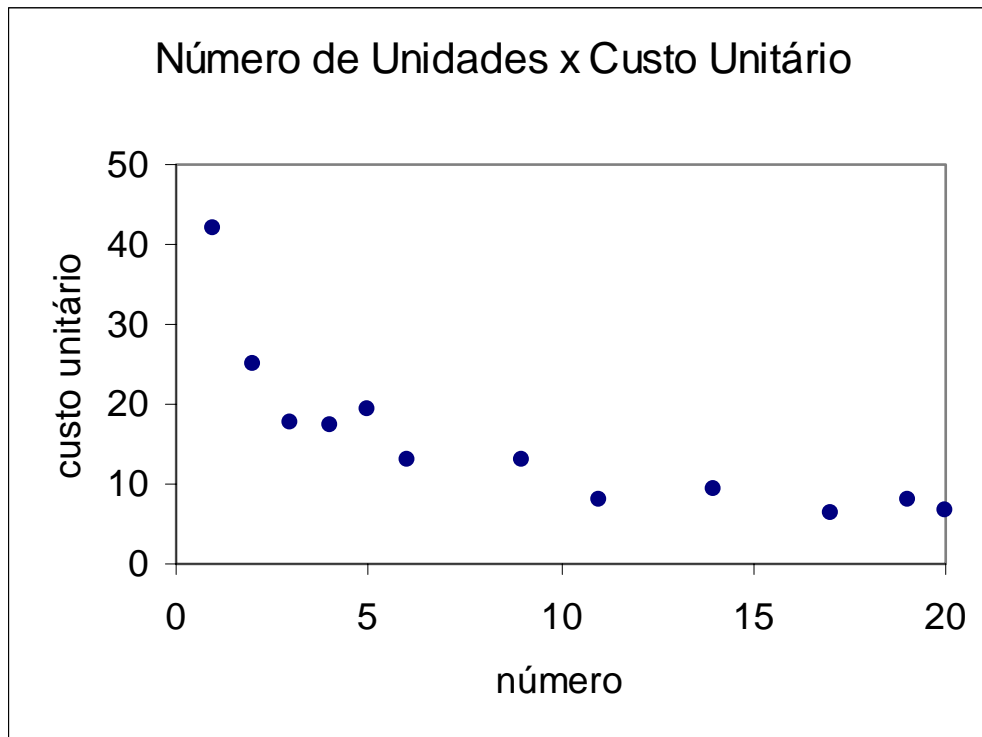
$$\max (\min) \quad f(x)$$

$$\text{s. a.} \quad x \in D = \mathbb{R}^n$$

irrestrito


Exemplo: regressão não linear

| | número | custo | | número | custo | | número | custo |
|---|--------|-------|---|--------|-------|----|--------|-------|
| i | p_i | q_i | i | p_i | q_i | i | p_i | q_i |
| 1 | 19 | 7.9 | 5 | 5 | 19.5 | 9 | 14 | 9.2 |
| 2 | 2 | 25 | 6 | 6 | 13 | 10 | 17 | 6.3 |
| 3 | 9 | 13.1 | 7 | 3 | 17.8 | 11 | 1 | 42.0 |
| 4 | 4 | 17.4 | 8 | 11 | 8.0 | 12 | 20 | 6.6 |



$$q = r(p) = x_1(p)^{x_2}$$


$$\min f(x_1, x_2) = \sum_{i=1}^m [q_i - x_1(p_i)^{x_2}]^2$$



$$m = 12$$




$$x_1^* = 40.69; \quad x_2^* = -0.6024$$




$$q = r(p) = 40.69 p^{-0.6024}$$


Funções Suaves e Derivadas



suave





não contínua



não diferenciável

- função $f(x)$ suave: contínua e diferenciável no domínio de interesse $D \subseteq \mathbb{R}^n$
- modelos de PNL com funções suaves são, geralmente, mais tratáveis
- funções suaves: possuem derivadas \rightarrow possibilitam busca mais eficiente
- derivada : forma analítica pode ser difícil / impossível de ser obtida

Busca Unidimensional



$$x^1 = x^{hi} - \alpha(x^{hi} - x^{lo})$$

$$x^2 = x^{lo} + \alpha(x^{hi} - x^{lo})$$

$$\alpha = 0.618 \text{ (número de ouro)}$$

- $f(x)$ unimodal
- $[x^{hi}, x^{lo}]$ contém x^*

Busca Unidimensional com Número de Ouro

Passo 0 Inicialização: escolher x^{lo} , x^{hi} e tolerância $\varepsilon > 0$. Computar ($\alpha = 0.618$)

$$x^1 \leftarrow x^{hi} - \alpha (x^{hi} - x^{lo})$$

$$x^2 \leftarrow x^{hi} + \alpha (x^{hi} - x^{lo})$$

calcular valor da função $f(x)$ para os quatro pontos; $t \leftarrow 0$;

Passo 1 Parada: se $(x^{hi} - x^{lo}) \leq \varepsilon$, parar: solução ótima aproximada $x^* = 1/2 (x^{hi} - x^{lo})$; senão ir para Passo 2 se $f(x^1)$ é superior a $f(x^2)$; caso contrário ir para o Passo 3;

Passo 2 Esquerdo: estreitar lado esquerdo do intervalo;

$$x^{hi} \leftarrow x^2; \quad x^2 \leftarrow x^1$$

$$x^1 \leftarrow x^{hi} - \alpha (x^{hi} - x^{lo})$$

avaliar $f(x^1)$; $t \leftarrow t + 1$; ir para Passo 1;

Passo 3 Direito: estreitar lado direito do intervalo;

$$x^{lo} \leftarrow x^1; \quad x^1 \leftarrow x^2$$

$$x^2 \leftarrow x^{lo} + \alpha (x^{hi} - x^{lo})$$

avaliar $f(x^2)$; $t \leftarrow t + 1$; ir para Passo 1;

Intervalo Inicial para Busca Unidimensional

- intervalo inicial deve ser tal que $x^* \in [x^{hi}, x^{lo}] \rightarrow$ padrão 3 pontos
- padrão 3 pontos $\{x^{lo}, x^{mid}, x^{hi}\}$, $x^{lo} < x^{mid} < x^{hi}$, $f(x^{mid})$ melhor que $f(x^{hi})$ e $f(x^{lo})$
- padrão 3 pontos $\{x^{lo}, x^{mid}, x^{hi}\} \rightarrow x^* \in [x^{hi}, x^{lo}]$

Passo 0 Inicializa: escolher limitante inferior x^{lo} para x^* e passo $\delta > 0$;

Passo 1 Esquerda ou Direita: se $f(x^{lo} + \delta)$ é superior à $f(x^{lo})$ então $x^{mid} \leftarrow x^{lo} + \delta$; ir para o Passo 2 para busca à direita; caso contrário ótimo está à esquerda; fazer $x^{hi} \leftarrow x^{lo} + \delta$; ir para Passo 3;

Passo 2 Expande: aumentar $\delta \leftarrow 2\delta$; se $f(x^{mid})$ é superior à $f(x^{mid} + \delta)$ então $x^{hi} \leftarrow x^{mid} + \delta$ e parar; $\{x^{lo}, x^{mid}, x^{hi}\}$ fornece padrão 3 pontos; senão $x^{lo} \leftarrow x^{mid}$; $x^{mid} \leftarrow x^{mid} + \delta$; repetir Passo 2;

Passo 3 Reduz: diminuir $\delta \leftarrow \delta/2$; se $f(x^{lo} + \delta)$ é superior à $f(x^{lo})$ então $x^{mid} \leftarrow x^{lo} + \delta$ e parar; $\{x^{lo}, x^{mid}, x^{hi}\}$ fornece padrão 3 pontos; senão $x^{hi} \leftarrow x^{lo} + \delta$; repetir Passo 3;

Condições de Otimalidade

Vetor Gradiente

$\mathbf{x} = (x_1, x_2, \dots, x_n)$; $f : R^n \rightarrow R$ diferenciável em \mathbf{x} :

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

Matriz Hessiana

$$H(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$$

$$x = (x_1, x_2); \quad f(x_1, x_2) = \sum_{i=1}^m [q_i - x_1 (p_i)^{x_2}]^2$$

Exemplo regressão não linear

$$\frac{\partial f}{\partial x_1} = -2 \sum_{i=1}^m (q_i - x_1 p_i^{x_2}) p_i^{x_2}$$

$$\frac{\partial f}{\partial x_2} = -2 \sum_{i=1}^m (q_i - x_1 p_i^{x_2}) x_1 p_i^{x_2} \ln(p_i)$$

$$\frac{\partial f}{\partial x_1^2} = 2 \sum_{i=1}^m p_i^{x_2}$$

$$\frac{\partial f}{\partial x_2^2} = -2 \sum_{i=1}^m \ln^2(p_i) [(q_i - x_1 p_i^{x_2})(x_1 p_i^{x_2}) - (x_1 p_i^{x_2})^2]$$

$$\frac{\partial f}{\partial x_1 \partial x_2} = \frac{\partial f}{\partial x_2 \partial x_1} = -2 \sum_{i=1}^m [(q_i - x_1 p_i^{x_2})(p_i^{x_2}) \ln(p_i) - (p_i^{x_2})(x_1 p_i^{x_2}) \ln(p_i)]$$

$$\hat{\mathbf{x}} = (x_1, x_2) = (33, -0.5)$$

$$\nabla f(33, -0.5) = (\partial f / \partial x_1, \partial f / \partial x_2)_{\hat{\mathbf{x}}} = (-23.07, -174.23)$$

$$H(33, -0.5) = \left[\begin{array}{cc} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} \end{array} \right]_{\hat{\mathbf{x}}} = \begin{bmatrix} 5.77 & 179.65 \\ 179.65 & 11003.12 \end{bmatrix}$$

Aproximação via séries de Taylor

$$f_1(\mathbf{x}^t + \lambda \Delta \mathbf{x}) = f(\mathbf{x}^t) + \lambda \nabla f(\mathbf{x}^t) \Delta \mathbf{x}$$

1a ordem

$$f_1(\mathbf{x}^t + \lambda \Delta \mathbf{x}) = f(\mathbf{x}^t) + \lambda \sum_{j=1}^n \left(\frac{\partial f}{\partial x_j} \right) \Delta x_j$$

$$f_2(\mathbf{x}^t + \lambda \Delta \mathbf{x}) = f(\mathbf{x}^t) + \lambda \nabla f(\mathbf{x}^t) \Delta \mathbf{x} + \frac{\lambda^2}{2} \Delta \mathbf{x} H(\mathbf{x}^t) \Delta \mathbf{x}$$

2a ordem

$$f_2(\mathbf{x}^t + \lambda \Delta \mathbf{x}) = f(\mathbf{x}^t) + \lambda \sum_{j=1}^n \left(\frac{\partial f}{\partial x_j} \right) \Delta x_j + \frac{\lambda^2}{2} \sum_{i=1}^n \sum_{j=1}^n \left(\frac{\partial^2 f}{\partial x_i \partial x_j} \right) \Delta x_i \Delta x_j$$

Gradientes e ótimos locais

condição necessária
de 1a ordem

\mathbf{x}^t é um ponto estacionário de f se $\nabla f(\mathbf{x}^t) = 0$

ótimo local de uma função objetivo suave é um ponto estacionário

$$f(\mathbf{x}^t + \lambda \Delta \mathbf{x}) = f(\mathbf{x}^t) + \lambda \nabla f(\mathbf{x}^t) \Delta \mathbf{x}$$

$$\Delta \mathbf{x} = \pm \nabla f(\mathbf{x}^t) \quad [+ \text{ max}, - \text{ min}]$$

$$f(\mathbf{x}^t + \lambda \Delta \mathbf{x}) = f(\mathbf{x}^t) \pm \lambda \nabla f(\mathbf{x}^t) \nabla f(\mathbf{x}^t)$$



função objetivo melhora a menos que $\nabla f(\mathbf{x}^t) = 0$

Hessianas e ótimos locais

condições de
2a ordem

se x^t é um ponto estacionário de f então $\nabla f(x^t) = 0$; logo

$$\begin{aligned} f(x^t + \lambda \Delta x) &\approx f(x^t) + \lambda \nabla f(x^t) \Delta x + \frac{\lambda^2}{2} \Delta x H(x^t) \Delta x \\ &\approx f(x^t) + 0 + \frac{\lambda^2}{2} \Delta x H(x^t) \Delta x \end{aligned}$$

Δx direção de
melhora em x^t



necessária

x^t mínimo local de f $\rightarrow H(x^t)$ semi-positiva definida

x^t máximo local de f $\rightarrow H(x^t)$ semi-negativa definida

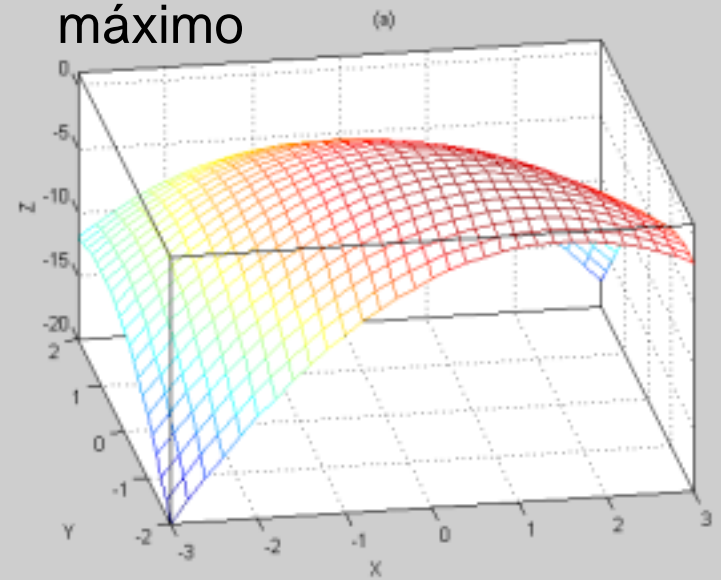
suficiente

x^t ponto estacionário de f e $H(x^t)$ positiva definida $\rightarrow x^t$ mínimo local de f

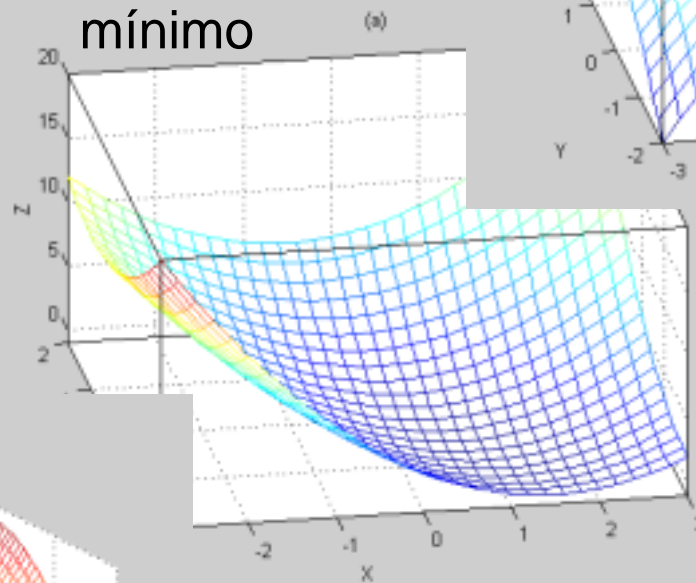
x^t ponto estacionário de f e $H(x^t)$ negativa definida $\rightarrow x^t$ máximo local de f

pontos estacionários exemplos


máximo



mínimo





sela





Convexidade e Otimalidade Global

funções convexas



$$f(x^1 + \lambda(x^2 - x^1)) \leq \lambda f(x^2) + (1 - \lambda)f(x^1); \quad x^1, x^2 \in D; \quad \lambda \in [0, 1]$$

funções côncavas



$$f(x^1 + \lambda(x^2 - x^1)) \geq f(x^1) + \lambda[f(x^2) - f(x^1)]; \quad x^1, x^2 \in D; \quad \lambda \in [0, 1]$$

Funções Convexas e Côncavas

1- se $f(x)$ é convexa então $-f(x)$ é côncava

2- $f(x)$ com segundas derivadas contínuas é convexa se e somente se a matriz Hessiana $H(x)$ é semi-positiva definida em um domínio convexo (aberto); $f(x)$ é côncava se e somente se $H(x)$ é semi-negativa definida.

3- funções lineares são convexas e côncavas

4- se $f(x)$ é côncava, $g(x) = 1/f(x)$ é convexa $\forall x \mid f(x) > 0$
se $f(x)$ é convexa, $g(x) = 1/f(x)$ é côncava $\forall x \mid f(x) < 0$

5- se $g(y)$ é uma função convexa não decrescente e $h(x)$ é convexa, então $f(x) = g(h(x))$ é convexa; se $g(y)$ é uma função côncava não decrescente e $h(x)$ é côncava, então $f(x) = g(h(x))$ é côncava

6- $f(\mathbf{x})$ é convexa se, para $\alpha_i \geq 0$ e $g_i(\mathbf{x})$ convexa, $i = 1, \dots, k$

$$f(\mathbf{x}) = \sum_{i=1}^k \alpha_i g_i(\mathbf{x})$$

7- $f(\mathbf{x})$ formada a partir de máximos de funções convexas é convexa
 $f(\mathbf{x})$ formada a partir do mínimo de funções côncavas é côncava

$$f(\mathbf{x}) = \max_{\mathbf{x}} \{g_i(\mathbf{x}); i = 1, \dots, k\}$$

$$f(\mathbf{x}) = \min_{\mathbf{x}} \{g_i(\mathbf{x}); i = 1, \dots, k\}$$

8- funções convexas (côncavas) são unimodais (o contrário não)

Otimidade Global: Condições Suficientes

- se $f(x)$ é uma função convexa, então todo mínimo local é mínimo global
- se $f(x)$ é uma função côncava, então todo máximo local é máximo global

por exemplo, no caso de mínimo: seja x^* mínimo global e $x^1 \neq x^*$

$$f(x^*) < f(x^1) \Rightarrow \lambda[f(x^*) - f(x^1)] < 0; \quad \forall \lambda > 0$$

$$f[x^1 + \lambda(x^* - x^1)] \leq f(x^1) + \lambda[f(x^*) - f(x^1)] < f(x^1); \quad \lambda \in [0,1]$$

$\Delta x = (x^1 - x^*)$ direção melhora em $x^1, \forall x^1 \in D$



x^* ótimo global

- todo ponto estacionário de uma função convexa suave é um mínimo global
- todo ponto estacionário de uma função côncava suave é um máximo global

por exemplo, se $f(x)$ é convexa, então:

$$f[x^* + \lambda(x - x^*)] \leq f(x^*) + \lambda[f(x) - f(x^*)] \quad \lambda \in (0,1) \quad \text{definição convexidade}$$

$$f[x^* + \lambda(x - x^*)] \approx f(x^*) + \lambda \nabla f(x)(x - x^*) \quad \text{Taylor}$$

$$f(x) - f(x^*) \geq \nabla f(x^*)(x - x^*)$$

$$\nabla f(x^*) = 0 \quad \Rightarrow \quad f(x) - f(x^*) \geq 0 \quad \forall x$$



x^* é mínimo global

Algoritmo (Busca) do Gradiente

Passo 0 Inicialização: com solução inicial x^0 ; tolerância $\varepsilon > 0$; $t \leftarrow 0$;

Passo 1 Gradiente: calcular $\nabla f(x^t)$ em x^t ;

Passo 2 Ponto Estacionário: se $\|\nabla f(x^t)\| \leq \varepsilon$ então parar; x^t é ótimo;

Passo 3 Direção: $\Delta x^{t+1} \leftarrow \pm \nabla f(x^t)$ [+ para max, - para min];


Passo 4 Busca Unidimensional: determinar λ_{t+1} resolvendo



$$\max (\min) f(x^t + \lambda \Delta x^{t+1});$$





Passo 5 Atualizar: $x^{t+1} = x^t + \lambda \Delta x^{t+1}$;

Passo 6 Incrementa: $t = t + 1$; ir para Passo 1;

Algoritmo do Gradiente







Método de Newton

Utiliza informação de segunda ordem

$$f_2(\mathbf{x}^t + \lambda \Delta \mathbf{x}) = f(\mathbf{x}^t) + \lambda \nabla f(\mathbf{x}^t) \Delta \mathbf{x} + \frac{\lambda^2}{2} \Delta \mathbf{x} H(\mathbf{x}^t) \Delta \mathbf{x}$$

$$f_2(\mathbf{x}^t + \lambda \Delta \mathbf{x}) = f(\mathbf{x}^t) + \lambda \sum_{j=1}^n \left(\frac{\partial f}{\partial x_j} \right) \Delta x_j + \frac{\lambda^2}{2} \sum_{i=1}^n \sum_{j=1}^n \left(\frac{\partial^2 f}{\partial x_i \partial x_j} \right) \Delta x_i \Delta x_j$$

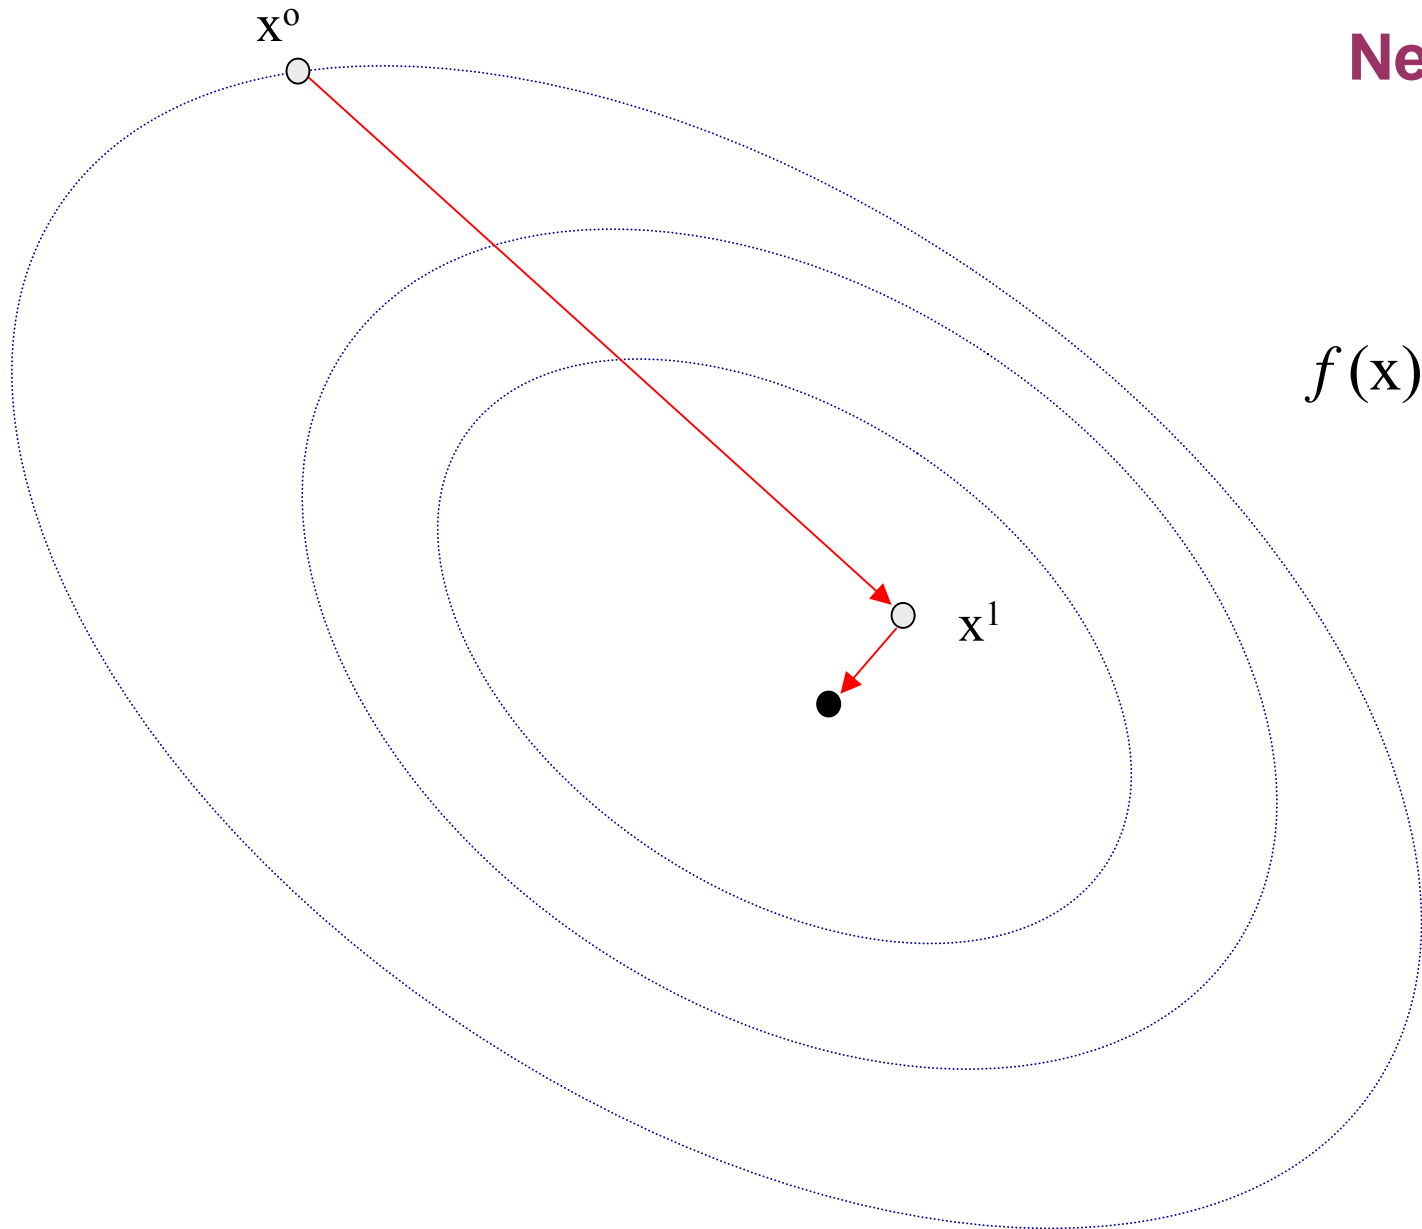
fazendo $\lambda = 1$ e derivando com relação à Δx_i

$$\frac{\partial f_2}{\partial \Delta x_i} = \frac{\partial f}{\partial x_i} + \sum_{j=1}^n \frac{\partial^2 f}{\partial x_i \partial x_j} \Delta x_j, \quad i = 1, \dots, n$$

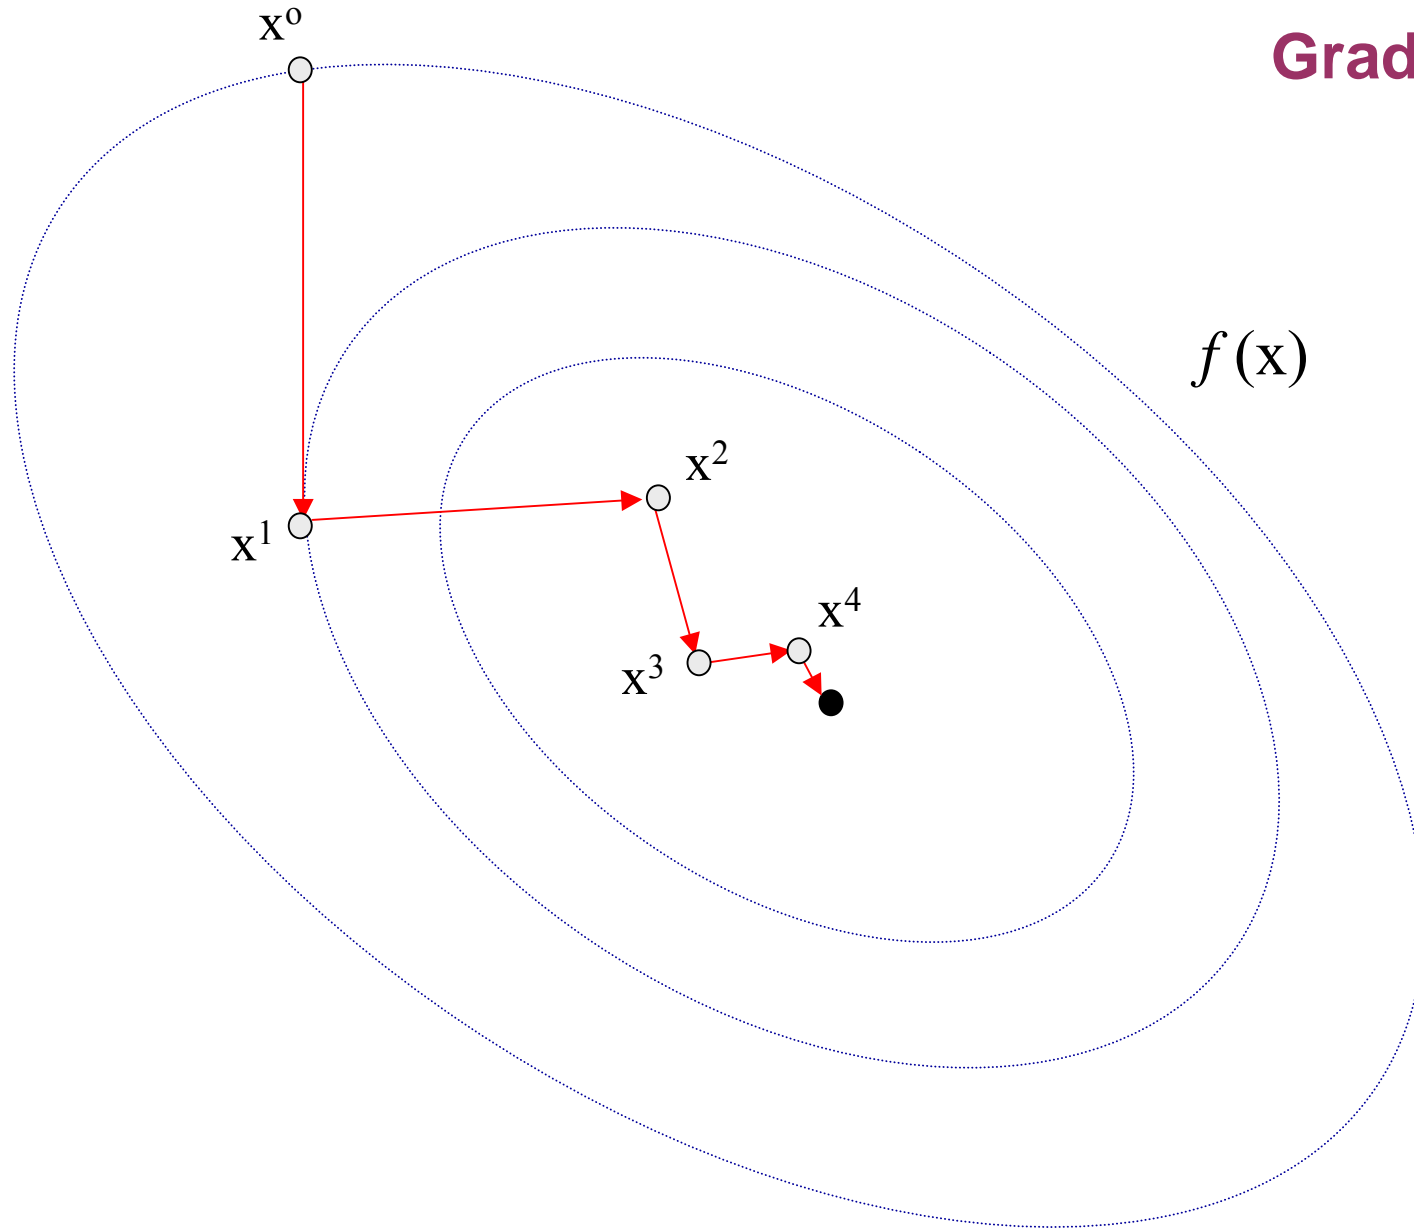
$$\nabla f_2(\Delta \mathbf{x}) = 0 \rightarrow H(\mathbf{x}^t) \Delta \mathbf{x} = -\nabla f(\mathbf{x}^t)$$

$$\nabla f_2(\Delta \mathbf{x}) = \nabla f(\mathbf{x}^t) + H(\mathbf{x}^t) \Delta \mathbf{x}$$

Newton



Gradiente



- algoritmo Newtoniano converge para ótimo local se inicialização é suficientemente próxima do ótimo local
- não há garantia de que a matriz Hessiana seja não singular em todo domínio de interesse
- idéia: combinar gradiente + Newton



- métodos Quase Newtonianos: $\Delta \mathbf{x} = -\mathbf{D}_t \nabla f(\mathbf{x}_t)$
- matriz D aproxima da inversa da Hessiana H^{-1} ao longo da busca
- Hessiana: relacionada com a variação do gradiente:



$$\nabla f(x^{t+1}) - \nabla f(x^t) \approx H(x^t)[x^{t+1} - x^t]$$

Broyden, Fletcher, Goldfarb, Shanno: Método BFGS

$$\Delta \mathbf{x}^{t+1} \leftarrow -D_t \nabla f(\mathbf{x}^t)$$


$$\mathbf{x}^{t+1} \leftarrow \mathbf{x}^t + \lambda_{t+1} \Delta \mathbf{x}^{t+1}$$

$$D_{t+1} \leftarrow D_t + \left(1 + \frac{\mathbf{g}^T D_t \mathbf{g}}{\mathbf{d}^T \mathbf{g}} \right) \frac{\mathbf{d} \mathbf{d}^T}{\mathbf{d}^T \mathbf{g}} - \frac{D_t \mathbf{g} \mathbf{d}^T + \mathbf{d} \mathbf{g}^T D_t}{\mathbf{d}^T \mathbf{g}}$$

$$\mathbf{d} = \mathbf{x}^{t+1} - \mathbf{x}^t \quad \mathbf{g} = \nabla f(\mathbf{x}^{t+1}) - \nabla f(\mathbf{x}^t) \quad D_0 = \pm I$$

(- min, + max)

BFGS



Algoritmo de Nelder-Mead

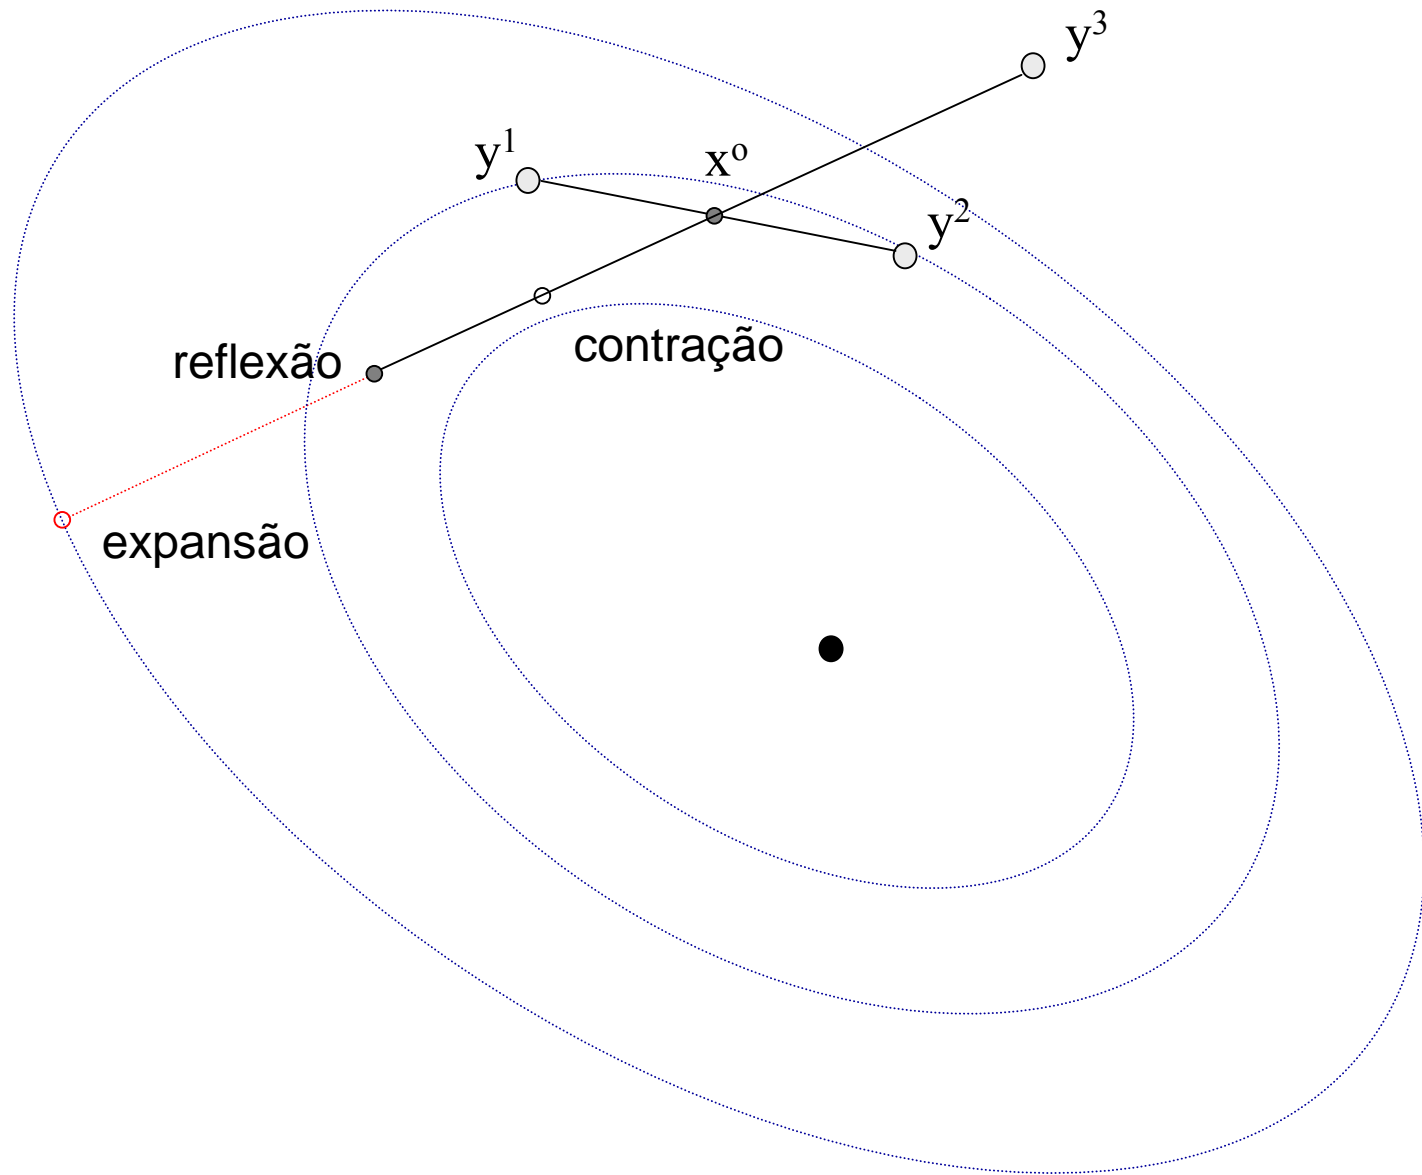
- não utiliza derivadas
- mantém $(n+1)$ soluções candidatas
- baseia-se nos conceitos de:
 - reflexão
 - expansão
 - contração
 - encolhimento

$$\Delta x \equiv x^t - y^{n+1}$$

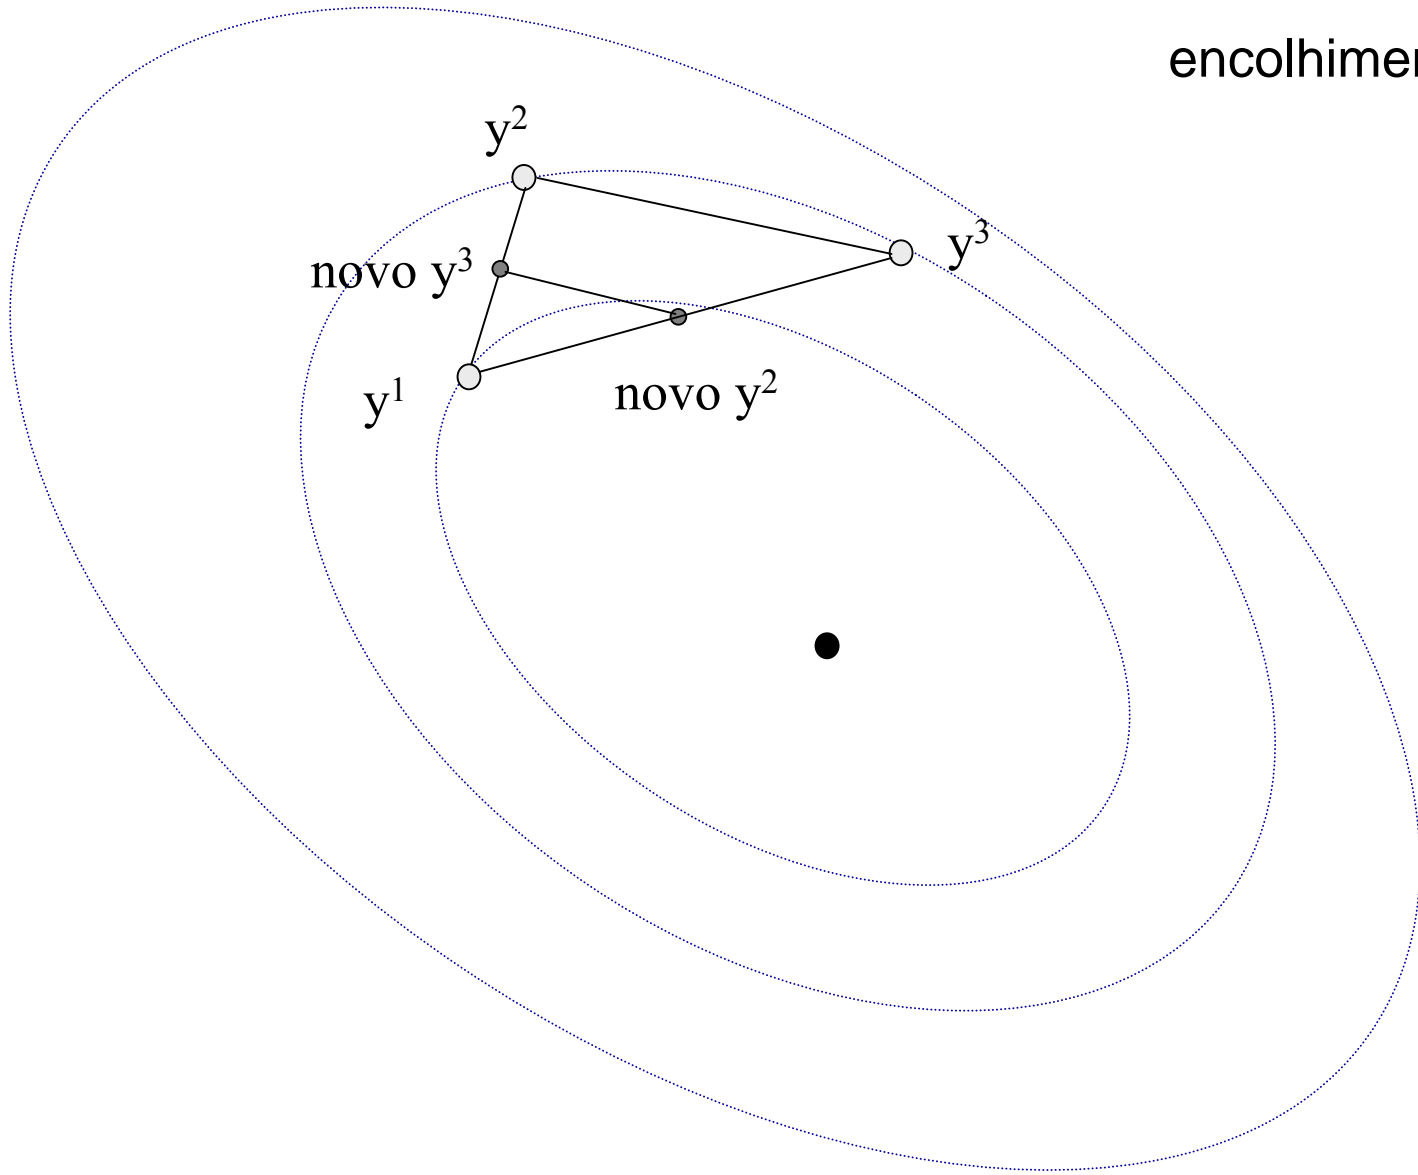
$y^{n+1} \leftarrow$ pior solução entre as $(n+1)$ candidatas

$$x^t \equiv \frac{1}{n} \sum_{i=1}^n y^i$$

n – ésimo centróide



encolhimento



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.