



CT 820 Teoria de Sistemas e Otimização Fuzzy
Introdução e Aplicações



Programação Não Linear

Modelo programação não linear (PNL)

$$\begin{array}{ll} \min & f(x) \\ \text{sa} & x \in D \subset \mathbb{R}^n \end{array} \quad \text{restrito}$$


$$\begin{array}{ll} \min & f(x) \\ \text{sa} & x \in D = \mathbb{R}^n \end{array} \quad \text{irrestrito}$$

I- programação não linear irrestrita

$$\begin{array}{ll} \min & f(x) \\ \text{sa} & x \in \mathbf{D} = \mathbf{R}^n \end{array}$$


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



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

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



$$m = 12$$




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




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


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
 $x^* \in [x^{hi}, x^{lo}]$

Busca unidimensional (número de ouro)

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

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

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

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 $f(x^1) > f(x^2)$; 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;

Busca unidimensional: intervalo inicial

- Intervalo inicial

- tal que $x^* \in [x^{lo}, x^{hi}] \rightarrow$ 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 $f(x^{lo})$

- $\{x^{lo}, x^{mid}, x^{hi}\} \rightarrow x^* \in [x^{hi}, x^{lo}]$

Intervalo inicial: algoritmo

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 sem restrições

- Vetor gradiente

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

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

- Matriz Hessiana

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

Exemplo: regressão não linear

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

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

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

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

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

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

$$x = (x_1, x_2)$$

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

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

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

Aproximações usando série de Taylor

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

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

1ª ordem

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

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

2ª ordem

Gradiente e ótimo local

- Condição necessária (de 1ª ordem)
 - x^t é um ponto estacionário de f se $\nabla f(x^t) = 0$
 - ótimo local de uma função suave: ponto estacionário

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

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

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

⇓

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

Hessianas e ótimos locais

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

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

Δx direção que melhora f em x^t

■ Condições de 2ª ordem




– necessárias

- 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

– suficientes



- x^t ponto estacionário f , $H(x^t)$ positiva definida $\rightarrow x^t$ mínimo local de f
- x^t ponto estacionário f , $H(x^t)$ negativa definida $\rightarrow x^t$ máximo local de f

Pontos estacionários





Convexidade e otimalidade global

- Função convexa



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

▪ Função côncava



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

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

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

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

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

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

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

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

Condições suficientes: otimalidade global

- 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

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^* mínimo global

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

Exemplo: se $f(x)$ é convexa, então

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

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

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

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



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

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

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


- Fazendo $\lambda = 1$ e derivando com relação à Δx_i

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


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

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

Newton



Gradiente



- algoritmo Newton 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: $\Delta x^{t+1} = -D_t \nabla f(x^t)$
- 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

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


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

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

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

(- min, + max)

BFGS



Algoritmo de Nelder-Mead


- Não utiliza derivadas
- Mantém $(n + 1)$ soluções candidatas
- Baseia-se nos conceitos de:
 - reflexão
 - expansão
 - contração
 - encolhimento

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


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

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

n –ésimo centróide




encolhimento



II- programação não linear restrita

$$\begin{array}{ll} \min & f(x) \\ \text{sa} & x \in D \subset \mathbb{R}^n \end{array}$$


Exemplo: localização e alocação



Distribuidores: 17

Regiões: 650 agrupando 24.000 clientes

$i = \text{distribuidor}, i = 1, \dots, 17$
 $j = \text{região}, j = 1, \dots, 650$



$d_j = \text{número de viagens/ano para entregas à } j\text{-ésima região}$

- Minimizar custo de transporte
 - minimizar número de viagens (w_{ij}) de $i \rightarrow j$
 - minimizar distância entre i e j

- Modelo PNL

$$\min \sum_{i=1}^{17} \sum_{j=1}^{650} w_{ij} \sqrt{(x_i - h_j)^2 + (y_i - h_j)^2}$$

$$\text{sa } \sum_{i=1}^{17} w_{ij} = d_j, \quad j = 1, \dots, 650$$

$$w_{ij} \geq 0, \quad i = 1, \dots, 17; j = 1, \dots, 650$$

Modelos convexos

$$\min f(x)$$

$$\text{sa } g_i(x) \geq a_i, i = 1, \dots, I$$

$$h_j(x) \leq b_j, j = 1, \dots, J$$

$$l_k(x) = c_k, k = 1, \dots, K$$


$f(x)$ convexa

$g_i(x)$ côncava $\forall i$

$h_j(x)$ convexa $\forall j$

$l_k(x)$ linear $\forall k$



$$\begin{aligned}
 \min \quad & (x_1 - 3)^2 + (x_2 - 3)^2 \\
 \text{sa} \quad & 3x_1 + 5x_2 \leq 15 \\
 & 5x_1 + 2x_2 \leq 10 \\
 & x_1, x_2 \geq 0
 \end{aligned}$$



$$\begin{aligned}
 \max \quad & 3w_1 - w_2 + 8\ln w_1 \\
 \text{sa} \quad & 4w_1^2 - w_1w_2 + w_2^2 \leq 100 \\
 & w_1 + w_2 = 4 \\
 & w_1, w_2 \geq 0
 \end{aligned}$$



■ Função objetivo

$$f(w_1, w_2) = 3w_1 - w_2 + 8\ln w_1$$





■ Restrições principais


$$h(w_1, w_2) = 4w_1^2 - w_1w_2 + w_2^2 \leq 100$$



$$l(w_1, w_2) = w_1 + w_2 = 4$$



$$\begin{aligned}
 \max \quad & 3w_1 - w_2 + 8\ln w_1 \\
 \text{sa} \quad & 4w_1^2 - w_1w_2 + w_2^2 \leq 100 \\
 & w_1 + w_2 = 4 \\
 & w_1, w_2 \geq 0
 \end{aligned}$$



Propriedade de modelos convexos

Se a função objetivo do modelo é convexa e as restrições produzem um conjunto convexo factível, então toda solução ótima local é uma solução ótima global.

$$\left. \begin{array}{l} g_i(\mathbf{x}) \text{ côncava } \quad \forall i \\ h_j(\mathbf{x}) \text{ convexa } \quad \forall j \\ l_k(\mathbf{x}) \text{ linear } \quad \forall k \end{array} \right\} \Rightarrow \text{Conjunto convexo}$$
$$f \text{ convexa (côncava)} \Rightarrow \text{Função unimodal}$$

Método dos multiplicadores de Lagrange

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

$$\text{sa} \quad g_i(x) = b_i \\ i = 1, \dots, m$$

Restrições igualdade

$$L(x, v) = f(x) + \sum_{i=1}^m v_i [b_i - g_i(x)]$$

Função Lagrangeana

v_i = multiplicador de Lagrange associado à restrição i

Pontos estacionários da função Lagrangeana

(x^*, v^*) é um ponto estacionário de $L(x, v)$ se $\nabla L(x^*, v^*) = 0$:

$$\nabla f(x^*) = \sum_{i=1}^m v_i^* \nabla g_i(x^*) \quad \text{ou} \quad \sum_{i=1}^m \frac{\partial g_i}{\partial x_j} v_i = \frac{\partial f}{\partial x_j}, \quad \forall j$$

$$g_i(x^*) = b_i, \quad \forall i$$

Se (x^*, v^*) é um ponto estacionário de $L(x, v)$ e x^* é uma solução ótima irrestrita de $L(x, v)$, então x^* é uma solução ótima do modelo original com restrições de igualdade.

Exemplo

$$\begin{aligned} \min \quad & 6x_1^2 + 4x_2^2 + x_3^2 \\ \text{sa} \quad & 24x_1 + 24x_2 = 360 \\ & x_3 = 1 \end{aligned}$$

$$L(x, v) = 6x_1^2 + 4x_2^2 + x_3^2 + v_1[360 - 24x_1 - 24x_2] + v_2[1 - x_3]$$

$$\nabla f(x) = (12x_1, 8x_2, 2x_3)$$

$$\nabla g_1(x) = (24, 24, 0)$$

$$\nabla g_2(x) = (0, 0, 1)$$

$$24v_1 = 12x_1$$

$$24v_1 = 8x_2$$

$$1v_2 = 2x_3$$

$$24x_1 + 24x_2 = 360$$

$$1x_3 = 1$$

$$L(x, v) = 6x_1^2 + 4x_2^2 + x_3^2 - 72x_1 - 72x_2 - 2x_3 + 1082 \quad \text{convexa}$$

⇓

$$(x_1^*, x_2^*, x_3^*, v_1^*, v_2^*) = (6, 9, 1, 3, 2) \Rightarrow \text{mínimo de } L(x, v)$$

Interpretação multiplicadores de Lagrange

- v_i = variação valor ótimo f quando b_i aumenta de 1 unidade
- v_i = variável dual

$$v_i^* = \frac{\partial L}{\partial b_i}$$

- Limitações
 - condições de estacionariedade difíceis de resolver
 - restrições de desigualdade aumenta a complexidade
 - soluções ótimas globais somente para modelos tratáveis

Caso geral: condições de Karush-Kuhn-Tucker

- Forma geral PNL diferenciáveis

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

$$\begin{aligned} \text{sa} \quad & g_i(x) \geq b_i, \quad \forall i \in G \\ & g_i(x) \leq b_i, \quad \forall i \in L \\ & g_i(x) = b_i, \quad \forall i \in E \end{aligned}$$

f, g_i : funções diferenciáveis

G, L, E : conjuntos de índices

Folgas complementares

$$v_i[b_i - g_i(x)] = 0 \quad \text{para todas desigualdades } i$$

■ Sinais dos multiplicadores

objetivo	$i \text{ é } \leq$	$i \text{ é } \geq$	$i \text{ é } =$
min	$v_i \leq 0$	$v_i \geq 0$	irrestrito
max	$v_i \geq 0$	$v_i \leq 0$	irrestrito

Condições de Karush-Kuhn-Tucker

- Solução (x, v) satisfaz as condições de KKT se:

- f, g_i são funções diferenciáveis
- condições das folgas complementares
- restrições no sinais dos multiplicadores
- restrições primais
- equação dos gradientes

$$\sum_i \nabla g_i(x) v_i = \nabla f(x)$$

- Ponto de KKT
 - qualquer x para o qual $\exists v$ que satisfaça as condições KKT

Característica da direção de busca Δx

$$f(x + \Delta x) \approx f(x) + \nabla f(x)\Delta x$$

objetivo	$\nabla f(x)\Delta x > 0$	$\nabla f(x)\Delta x < 0$
min	não melhora	melhora
max	melhora	não melhora

(14.23)

$\nabla f(x)\Delta x = 0 \Rightarrow$ necessitamos de mais informação

Factibilidade da direção de busca Δx

$$g_i(x + \Delta x) \approx g_i(x) + \nabla g_i(x)\Delta x$$

$$\nabla g_i(x)\Delta x \begin{cases} \geq 0 & \text{restrições } \geq \textit{ativas} \\ \leq 0 & \text{restrições } \leq \textit{ativas} \\ = 0 & \text{todas restrições } = \end{cases} \quad (14.24)$$

Condições suficientes de KKT

- As condições de KKT fornecem um teste de primeira ordem para determinar a ausência de direções factíveis que melhoram o valor da função objetivo
- Isto é, x é um ponto de KKT se e somente se não existe uma direção Δx em x que satisfaz as condições de primeira ordem (14.23) e (14.24)



- Condições KKT são suficientes para ótimo local, isto é:
 - se x é um ponto de KKT, então x é ótimo local
- Se modelo de PNL é convexo:
 - condições de KKT são suficientes para ótimo global


Condições necessárias de KKT

- Necessidade:
 - se x é uma solução ótima, então x satisfaz KKT

- Solução ótima local é um ponto de KKT se:
 - todas as restrições são lineares
 - gradientes das restrições ativas no ponto ótimo local são LI (qualificação de restrição)


Exemplo

$$\begin{aligned} \min & (x_1 - 3)^2 + (x_2 - 3)^2 \\ \text{sa} & 3x_1 + 5x_2 \leq 15 \\ & 5x_1 + 2x_2 \leq 10 \\ & x_1, x_2 \geq 0 \end{aligned}$$



Exemplo

$$\begin{aligned} \min \quad & x_1^2 + 4x_2 \\ \text{sa} \quad & (x_1 - 1)^2 + x_2^2 \leq 1 \\ & (x_1 + 1)^2 + x_2^2 \leq 1 \end{aligned}$$



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.