

**PQI-5884 - Programação Inteira Mista aplicada à
Otimização de Processos
3º Período 2023**

Data	Atividade	Conteúdo
14/set	Aula 1	Introdução, formulação, classes, representação
21/set	Aula 2	Condições de otimalidade
28/set	Aula 3	Condições KKT, multiplicadores
06/out*	Aula 4	Otimização irrestrita
19/out	Aula 5	LP
26/out	Aula 6	NLP
09/out	Aula 7	MILP
16/nov	Aula 8	MILP, problemas clássicos
23/nov	Aula 9	MILP, problema de scheduling
30/nov	Aula 10	MINLP, problema de síntese
07/dez	-	Apresentações

Conceitos Básicos de Otimalidade



Problema NLP

$$\begin{array}{ll}
 \min & f(\underline{x}) & \text{função objetivo escalar} \\
 \text{s.a.:} & \underline{h}(\underline{x}) = 0 & m \text{ equações} \\
 & \underline{g}(\underline{x}) \leq 0 & r \text{ inequações} \\
 & \underline{x} \in \mathcal{R}^n & n \text{ variáveis contínuas}
 \end{array}
 \left. \vphantom{\begin{array}{l} \\ \\ \\ \end{array}} \right\} \text{restrições}$$


Região viável do problema:

$$\text{Espaço } F = \{\underline{x} \mid \underline{x} \in \mathcal{R}^n, \underline{h}(\underline{x}) = 0, \underline{g}(\underline{x}) \leq 0\}$$

$f(\underline{x})$ é função convexa?
F é um espaço convexo?



Convexidade de função em intervalo, exemplos em \mathbb{R}^1



Hessiano de $f(\underline{x})$:

$$\underline{\underline{H}}(f) = \begin{bmatrix} \frac{\partial f}{\partial x_1 x_1} & \frac{\partial f}{\partial x_1 x_2} & \cdots & \frac{\partial f}{\partial x_1 x_n} \\ \frac{\partial f}{\partial x_2 x_1} & \frac{\partial f}{\partial x_2 x_2} & \cdots & \frac{\partial f}{\partial x_2 x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f}{\partial x_n x_1} & \frac{\partial f}{\partial x_n x_2} & \cdots & \frac{\partial f}{\partial x_n x_n} \end{bmatrix}$$

matriz quadrada simétrica


Sinal de uma matriz quadrada



Matriz \underline{H}	Condição	Autovalores
Positiva definida	$\underline{x}^T \cdot \underline{H} \cdot \underline{x} > 0$, para $\forall \underline{x} \neq 0$	$\alpha_i > 0$
Positiva semi-definida	$\underline{x}^T \cdot \underline{H} \cdot \underline{x} \geq 0$, para $\forall \underline{x} \neq 0$	$\alpha_i \geq 0$
Negativa definida	$\underline{x}^T \cdot \underline{H} \cdot \underline{x} < 0$, para $\forall \underline{x} \neq 0$	$\alpha_i < 0$
Negativa semi-definida	$\underline{x}^T \cdot \underline{H} \cdot \underline{x} \leq 0$, para $\forall \underline{x} \neq 0$	$\alpha_i \leq 0$
Indefinida		

$$f(\underline{x}) = x_1^2 - x_1 \cdot x_2 + x_2^2$$


$$H = \begin{bmatrix} 2 & -1 \\ -1 & 2 \end{bmatrix}$$

$$\alpha = \{1, 3\}$$






Convexidade de espaço, exemplos em \mathbb{R}^2




Convexo





Não convexo


Importante: Se $\underline{h}(\underline{x}) = 0$ é linear e $\underline{g}(\underline{x}) \leq 0$ é convexa (linear ou não linear), então F é uma região viável convexa.

Região Viável (exemplo 1)



$$\begin{aligned} &\min f(x_1, x_2) \\ &\text{s.a.: } h = 0 \\ &\quad g_1 \leq 0 \\ &\quad g_2 \leq 0 \end{aligned}$$





II.3. CONDIÇÕES DE OTIMALIDADE

II.3.1. PROBLEMA DE OTIMIZAÇÃO SEM RESTRIÇÕES

Seja o problema de otimização:

$$\begin{aligned} \min & f(\underline{x}) \\ \text{sujeito a: } & \underline{x} \in \mathcal{R}^n \end{aligned}$$

Condição necessária para um mínimo local \underline{x}^*

$$\nabla f(\underline{x}^*) = \underline{0}$$

Condição suficiente para um mínimo local \underline{x}^*

$\underline{H}(f(\underline{x}^*))$ deve ser positiva definida

II.3.2. PROBLEMA DE OTIMIZAÇÃO COM RESTRIÇÕES DE IGUALDADE

Seja o problema de otimização:

$$\begin{array}{ll} \min & f(\underline{x}) \\ \text{sujeito a:} & \underline{h}(\underline{x}) = 0 \quad m \text{ equações} \\ & \underline{x} \in \mathfrak{R}^n \end{array}$$

Condições necessárias para um mínimo local \underline{x}^*

$$\nabla f(\underline{x}^*) + \sum_{j=1}^m \lambda_j \cdot \nabla h_j(\underline{x}^*) = 0 \quad \text{dependência linear de gradientes}$$

$$\underline{h}(\underline{x}^*) = 0 \quad \text{viabilidade}$$


Condição suficiente para um mínimo local \underline{x}^*

$\underline{H}_{xx}(L(\underline{x}^*, \underline{\lambda}))$ deve ser positiva definida

sendo $L(\underline{x}, \underline{\lambda}) = f(\underline{x}) + \sum \lambda_j \cdot h_j(\underline{x})$ a função Lagrangeano

Exemplo de dependência linear de gradientes:

$$\begin{array}{l} \min f(x_1, x_2) \\ \text{s.a.: } h = 0 \end{array}$$



II.3.3. PROBLEMA DE OTIMIZAÇÃO COM RESTRIÇÕES DE DESIGUALDADE

Seja o problema de otimização:

$$\begin{array}{ll} \min & f(\underline{x}) \\ \text{sujeito a:} & g(\underline{x}) \leq 0 \quad r \text{ inequações} \\ & \underline{x} \in \mathfrak{R}^n \end{array}$$

Condições necessárias para um mínimo local \underline{x}^*

$$\nabla f(\underline{x}^*) + \sum_{j=1}^r \mu_j \cdot \nabla g_j(\underline{x}^*) = 0 \quad \text{dependência linear de gradientes}$$


$$g(\underline{x}^*) \leq 0 \quad \text{viabilidade}$$


$$\mu_j \cdot g_j(\underline{x}^*) = 0 \quad \mu_j \geq 0 \quad \text{complementariedade}$$

Condição suficiente para um mínimo local \underline{x}^*

$H_{xx}(L(\underline{x}^*, \underline{\mu}))$ deve ser positiva definida

sendo $L(\underline{x}, \underline{\mu}) = f(\underline{x}) + \sum \mu_j \cdot g_j(\underline{x})$ a função Lagrangeano





Condições KKT (Karush-Kuhn-Tucker)

1- Dependência linear dos gradientes

$$\nabla f(\underline{x}) + \sum_{j=1}^m \lambda_j \cdot \nabla h_j(\underline{x}) + \sum_{j=1}^r \mu_j \cdot \nabla g_j(\underline{x}) = 0$$

λ_j : multiplicadores de Lagrange

μ_j : multiplicadores de Kuhn-Tucker

2 - Viabilidade das restrições

$$h_j(\underline{x}) = 0 \quad 1 \leq j \leq m$$

$$g_j(\underline{x}) \leq 0 \quad 1 \leq j \leq r$$

3 - Condições de complementaridade

$$\mu_j \cdot g_j(\underline{x}) = 0 \quad 1 \leq j \leq r$$

$$\mu_j \geq 0$$

sistema não-linear de
 $n + m + r$ equações e variáveis

Solução:
ponto KKT (mínimo local)

verificar convexidade