

Método de Lagrangiano aumentado (LA)

Esquema de penalidade externa.

↳ instável numericamente.

↳ p_k cresce muito...

Método de LA pode ser visto como uma melhoria "prática" do esquema de penalidade.

Dois estratégias são adotadas para evitar p_k crescer muito:

→ 1) Penalizar $h(x) + a$ e $(g(x) + b)_+$ ao invés de $h(x)$ e $g(x)_+$.

→ 2) Só aumentar p_k se a inviabilidade não diminuir.

Obs.: não vamos pedir que x^k seja minimizador global do subproblema, apenas que seja ponto estacionário (amble o $\nabla F.O.$)

Penalização com deslocamento

Penalidade externa "pura":

$$SP(\rho_k): \min f(x) + \frac{\rho_k}{2} [\|h(x)\|^2 + \|g(x)_+\|^2]$$

(subproblema irrestrito)

Resolver $SP(\rho_k)$ significa calcular x^k tq.

$$\nabla f(x^k) + \sum_{i=1}^m [\rho_k h_i(x^k)] \nabla h_i(x^k) + \sum_{j=1}^p [\rho_k g_j(x^k)_+] \nabla g_j(x^k) = 0.$$

As expressões $\rho_k h_i(x^k)$ e $\rho_k g_j(x^k)_+$ são aproximações dos multiplicadores de Lagrange.

Vamos considerar as estimativas

deslocadas $\rho_k h_i(x^k)_+ \bar{\lambda}_i^k$ e

$(\rho_k g_j(x^k)_+ \bar{\mu}_j^k)_+$, onde $\bar{\lambda}^k$ e $\bar{\mu}^k$ estarão limitados (dentro de um compacto).

Seja que, considerando a função

$$L_p(x, \bar{\lambda}, \bar{\mu}) = f(x) + \frac{\rho}{2} \left[\left\| h(x) + \frac{\bar{\lambda}}{\rho} \right\|^2 + \left\| \left(g(x) + \frac{\bar{\mu}}{\rho} \right)_+ \right\|^2 \right],$$

derivando obtemos

$$\nabla_x L_p(x, \bar{\lambda}, \bar{\mu}) = \nabla f(x) + \sum_{i=1}^m (\rho h_i(x) + \bar{\lambda}_i) \nabla h_i(x) + \sum_{j=1}^p (\rho g_j(x) + \bar{\mu}_j)_+ \nabla g_j(x).$$

Seja que pontos x^k estacionários de $L_{p_k}(x, \bar{\lambda}^k, \bar{\mu}^k)$ são associados aos multiplicadores com deslocamento.

O subproblema do método de Lagrangiano aumentado é

$$\min_x L_{p_k}(x, \bar{\lambda}^k, \bar{\mu}^k).$$

Obs. se $\bar{\lambda}^k = 0$ e $\bar{\mu}^k = 0$, então o método

se reduz à penalidade externa "pura".

Obs: a função $L_p(x, \bar{\lambda}, \bar{\mu})$ é chamada Lagrangiano aumentado, daí vem o nome do método!

Obs: a função Lagrangiano é

$$L(x, \lambda, \mu) = f(x) + \sum_{i=1}^m \lambda_i h_i(x) + \sum_{j=1}^p \mu_j g_j(x)$$

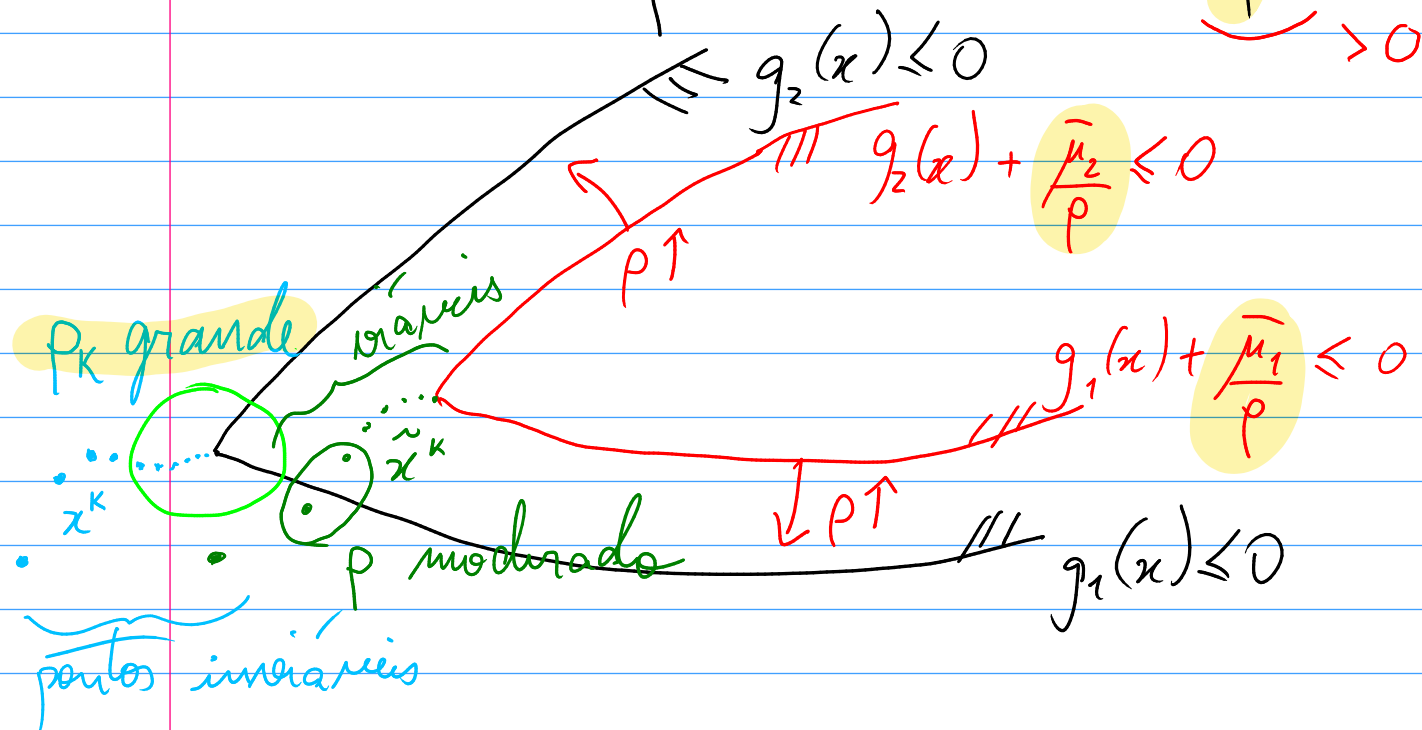
(Em KKT, temos $\nabla_x L(x, \lambda, \mu) = 0$)

Veja que


$$\begin{aligned} \nabla_x L(x, \lambda, \mu) &= \nabla f(x) + \sum_{i=1}^m \lambda_i \nabla h_i(x) + \sum_{j=1}^p \mu_j \nabla g_j(x) \\ &= \nabla_x L_0(x, \lambda, \mu) \end{aligned}$$

Interpretação geométrica do deslocamento

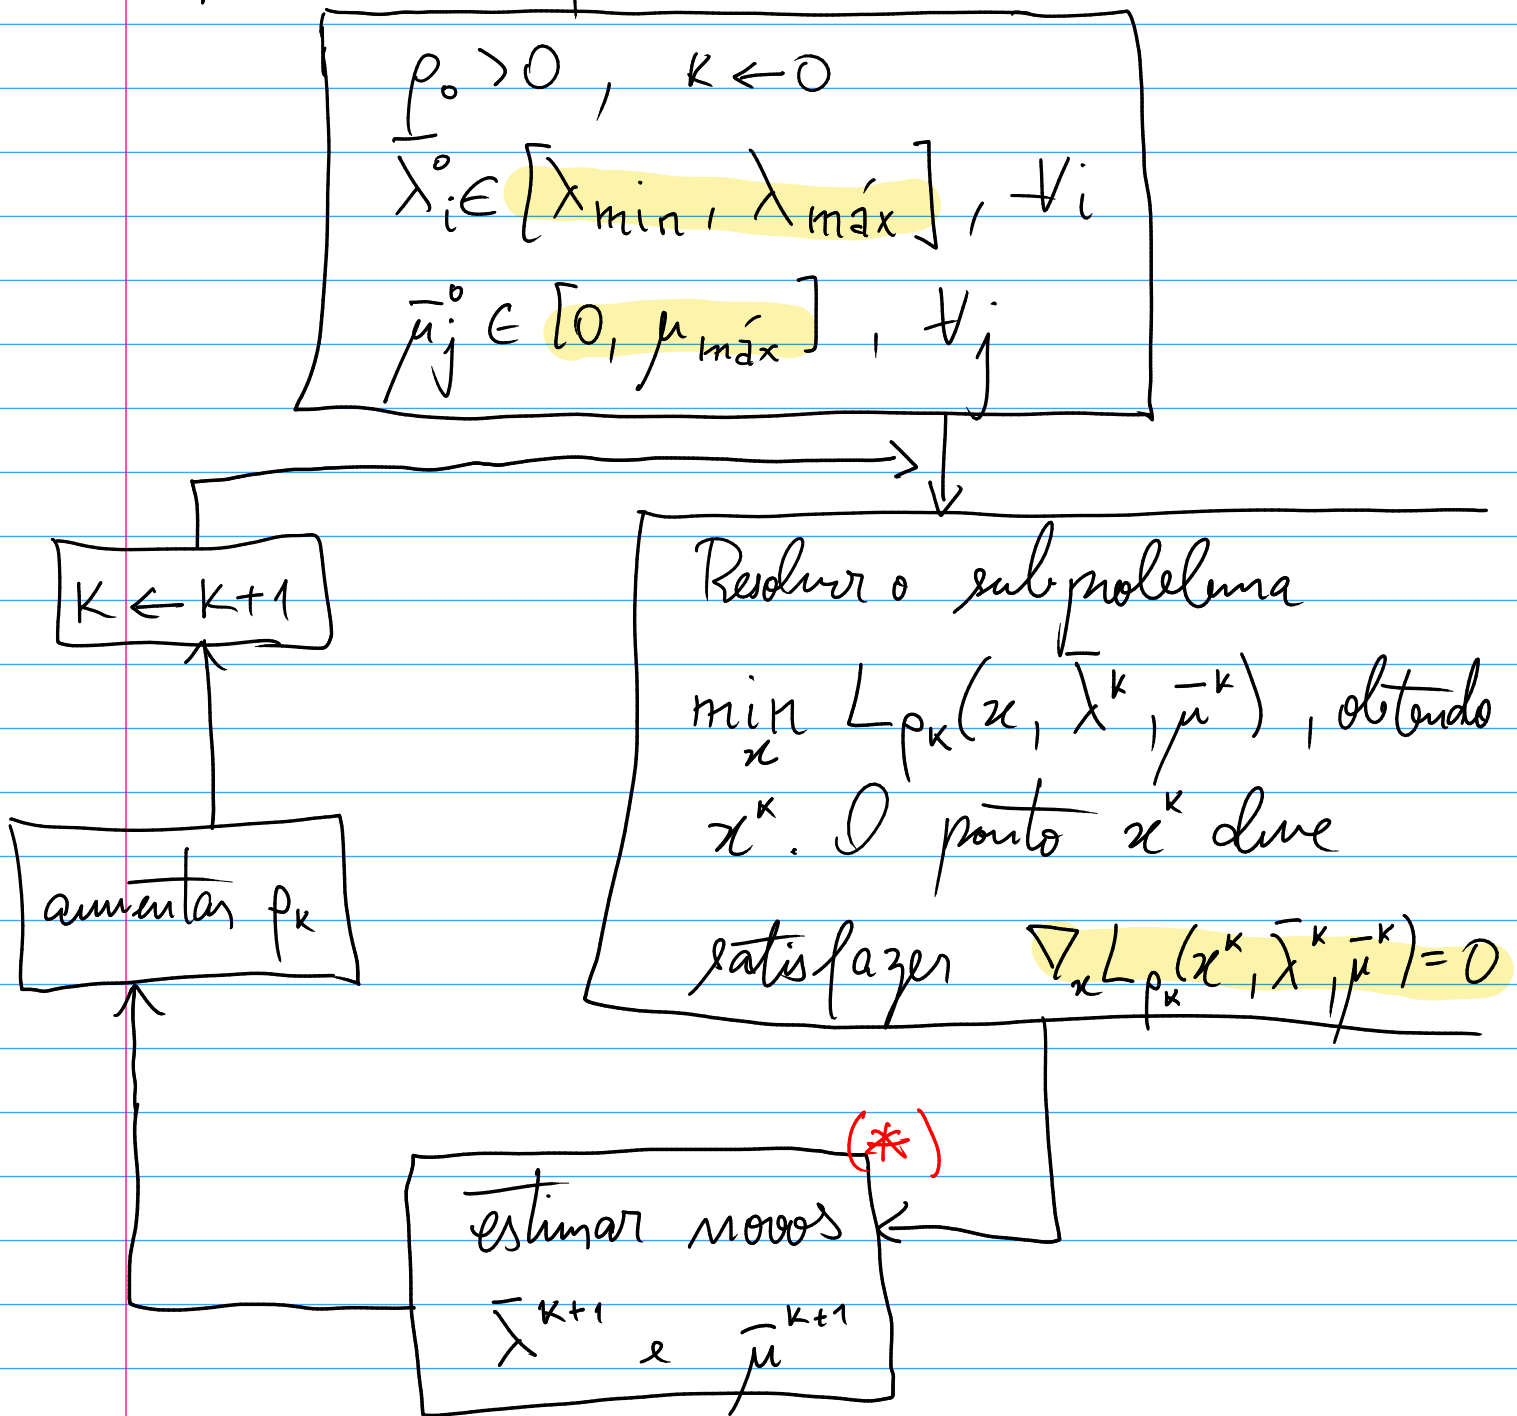
$$h(x) + \frac{\bar{\lambda}}{\rho} \quad , \quad g(x) + \frac{\bar{\mu}}{\rho} > 0$$



- Penalidade "pura" (sem deslocamento)
- com deslocamento



Esquema de penalidade com deslocamento



Quem são $\bar{\lambda}^{k+1}$ e $\bar{\mu}^{k+1}$ adequados?

Deja que, ao resolver o subproblema, temos

$$\nabla_x L_{\rho_k}(x^k, \bar{\lambda}^k, \bar{\mu}^k) = \nabla f(x^k) + \sum_{i=1}^m (\rho_k h_i(x^k) + \bar{\lambda}_i^k) \nabla h_i(x^k) + \sum_{j=1}^p (\rho_k g_j(x^k) + \bar{\mu}_j^k) \nabla g_j(x^k) = 0$$

Para esta expressão, é natural considerar

$$\tilde{\lambda}_i^{k+1} = \rho_k h_i(x^k) + \bar{\lambda}_i^k \quad \text{e} \quad \tilde{\mu}_j^{k+1} = (\rho_k g_j(x^k) + \bar{\mu}_j^k)_+ \geq 0$$

As novas $\tilde{\lambda}_i^{k+1}$ e $\tilde{\mu}_j^{k+1}$ serão as projeções de $\tilde{\lambda}_i^{k+1}$ e $\tilde{\mu}_j^{k+1}$ nos intervalos $[\lambda_{\min}, \lambda_{\max}]$ e $[0, \mu_{\max}]$.

Assim,

$$\rightarrow \bar{\lambda}_i^{k+1} = \max \{ \lambda_{\min}, \min [\lambda_{\max}, \rho_k h_i(x^k) + \bar{\lambda}_i^k] \}.$$

Exercício:

(i) verifique que $\bar{\lambda}_i^{k+1} \in [\lambda_{\min}, \lambda_{\max}]$, e logo $\{ \bar{\lambda}_i^{k+1} \}$ é limitada.

(ii) verifique que, se

$$\rho_k h_i(x^k) + \bar{\lambda}_i^k \in [\lambda_{\min}, \lambda_{\max}] \quad \text{então}$$

$$\bar{\lambda}_i^{k+1} = \rho_k h_i(x^k) + \bar{\lambda}_i^k.$$

Analogamente,

$$\rightarrow \bar{\mu}_j^{k+1} = \max \{ 0, \min \{ \mu_{\max}, \rho_k g_j(x^k) + \bar{\mu}_j^k \} \}$$


Essas expressões são implementadas no pacote ALGENCAN.

Obs: A medida que λ_{\min} , λ_{\max} e μ_{\max} (parâmetros do método) são escolhidos ≈ 0 , o método se assemelha ao esquema de penalidade sem deslocamento.

Na prática, escolhemos esses parâmetros grandes. Por exemplo, em ALGENCAN, o padrão é $\lambda_{\min} = -10^{20}$, $\lambda_{\max} = \mu_{\max} = 10^{20}$.

Exemplo: P: $\min_x x$

$$\text{s.a. } x \geq 0. \quad (-x \leq 0)$$



$x^* = 0$ (minimizador global)

Aplicando o esquema de penalidade interna para:

$$SP(\rho_k): \min_x x + \frac{\rho_k}{2} \max\{0, -x\}^2$$


$$f(x) + \frac{\rho_k}{2} \max\{0, g(x)\}^2$$

Suponha que $x \leq 0$. Então

$$\max\{0, -x\} = -x \quad (\geq 0)$$

Assim, neste caso,

$$SP(\rho_k): \min_x x + \frac{\rho_k}{2} x^2.$$




Resolvendo:

$$1 + \rho_k x^k = 0 \Leftrightarrow x^k = -\frac{1}{\rho_k}$$

Veja que x^k de fato é < 0 . Assim, x^k é a solução de $SP(\rho_k)$ no caso geral.

Observe que $x^k \rightarrow 0$. (solução de P).

Observe também $x^k = -\frac{1}{\rho_k}$ nunca é igual a $x^* = 0$ (ρ_k deve crescer para aproximar x^*).



x^k externo ao conj. viável.

Aplicando penalidade com deslocamento:

$$SP(\rho_k) = \min_x x + \frac{\rho_k}{2} \max\{0, -x + \frac{\bar{\mu}^k}{\rho_k}\}^2$$

Dados iniciais: $\bar{\mu}^0 = 0$, $\rho_0 = 1$

Iteração 0: (k=0)

$$SP(\rho_k): \min_x x + \frac{1}{2} \max\{0, -x\}^2$$

(esse é o mesmo problema da penalidade pura).

$$\text{Assim, } x^0 = -\frac{1}{\rho_0} = -1.$$

Poramos com x^0 ? ρ_0 NÃO, pois $\tilde{\mu}$ é KKT.

Iteração 1: (k=1)

$$\tilde{\mu}^1 = \rho_0 g(x^0) + \bar{\mu}^0 = 1 \cdot (-(-1)) + 0 = 1.$$

Imagine que $\mu_{\max} > 1$ (p.ex., 10^{20}).

$$\bar{\mu}^1 = \max\{0, \min\{10^{20}, \tilde{\mu}^1\}\}$$

$$= \max\{0, \min\{10^{20}, 1\}\}$$

$$= \max\{0, 1\}$$

$$\Rightarrow \boxed{\bar{\mu}^1 = 1}.$$

Atualizamos também $\rho_1 = 10\rho_0 = 10$.

Subproblema (k=1)

$$SP(\rho_1): \min_x x + \frac{10}{2} \max\{0, -x + \frac{1}{10}\}^2$$

Suponha que $-x + \frac{1}{10} > 0$. Assim,

$$SP(\rho_1): \min_x x + 5 \left(-x + \frac{1}{10}\right)^2$$

Resolvendo:

$$1 + 10 \left(-x + \frac{1}{10}\right) (-1) = 0$$

$$\Rightarrow \cancel{1} + 10x^1 - \cancel{1} = 0 \quad \Rightarrow x^1 = 0.$$

Verificando os parâmetros, ou seja, se x^1 é KKT:

$$\nabla f(x^1) + \bar{\mu}^1 \nabla g_1(x^1) = 0 \quad g(x) = -x$$
$$\bar{\mu}^1 \geq 0$$
$$\bar{\mu}^1 g(x^1) = 0$$

→ $1 + 1(-1) = 0 \quad \checkmark$

$$\bar{\mu}^1 = 1 \geq 0 \quad \checkmark$$

$$\bar{\mu}^1 \cdot g(x^1) = 1(-0) = 0 \quad \checkmark$$

Assim, x^1 é ponto KKT do problema original P, e logo o método para com 2 iterações!

Em particular, o uso do deslocamento impede p_k crescer.

Exemplo executado no pacote ALGENCAN

- Com deslocamento ($\mu_{max} = 10^{20}$)


```

out penalt objective infeas infeas norm norm |Grad| inner Newton
ite function ibilty +compl graLag point infeas totit forKKT
0 1.000D+00 0.D+00 0.D+00 1.D+00 1.D+00 0.D+00 0 0 0
1 1.D+01 -1.000D-01 1.D-01 1.D-01 0.D+00 1.D-01 1.D-01 4C 0 0
2 1.D+01 0.000D+00 0.D+00 0.D+00 0.D+00 0.D+00 0.D+00 5C 0 0

Flag of ALGENCAN: Solution was found.
    
```

2 iterações

ρ_k pequeno



$\min\{\mu^k, -g(x^k)\}$
 (viabilidade + complementaridade)

- Sem deslocamento ($\mu_{max} = 0$)


\hookrightarrow = penalidade externa pura (precisão parada = 10^{-8})

```

out penalt objective infeas infeas norm norm |Grad| inner Newton
ite function ibilty +compl graLag point infeas totit forKKT
0 1.000D+00 0.D+00 0.D+00 1.D+00 1.D+00 0.D+00 0 0 0
1 1.D+01 -1.000D-01 1.D-01 1.D-01 0.D+00 1.D-01 1.D-01 4C 0 0
2 1.D+01 -1.000D-01 1.D-01 1.D-01 0.D+00 1.D-01 1.D-01 4C 0 0
3 1.D+02 -1.000D-02 1.D-02 1.D-02 4.D-16 1.D-02 1.D-02 5C 0 0
4 1.D+02 -1.000D-02 1.D-02 1.D-02 4.D-16 1.D-02 1.D-02 5C 0 0
5 1.D+03 -1.000D-03 1.D-03 1.D-03 9.D-16 1.D-03 1.D-03 6C 0 0
6 1.D+03 -1.000D-03 1.D-03 1.D-03 9.D-16 1.D-03 1.D-03 6C 0 0
7 1.D+04 -1.000D-04 1.D-04 1.D-04 4.D-16 1.D-04 1.D-04 7C 0 0
8 1.D+04 -1.000D-04 1.D-04 1.D-04 4.D-16 1.D-04 1.D-04 7C 0 0
9 1.D+05 -1.000D-05 1.D-05 1.D-05 1.D-16 1.D-05 1.D-05 8C 0 0

out penalt objective infeas infeas norm norm |Grad| inner Newton
ite function ibilty +compl graLag point infeas totit forKKT
10 1.D+05 -1.000D-05 1.D-05 1.D-05 1.D-16 1.D-05 1.D-05 8C 0 0
11 1.D+06 -1.000D-06 1.D-06 1.D-06 1.D-15 1.D-06 1.D-06 9C 0 0
12 1.D+06 -1.000D-06 1.D-06 1.D-06 1.D-15 1.D-06 1.D-06 9C 0 0
13 1.D+07 -1.000D-07 1.D-07 1.D-07 0.D+00 1.D-07 1.D-07 10C 0 0
14 1.D+07 -1.000D-07 1.D-07 1.D-07 0.D+00 1.D-07 1.D-07 10C 0 0
15 1.D+08 -1.000D-08 1.D-08 1.D-08 3.D-16 1.D-08 1.D-08 11C 0 0

Flag of ALGENCAN: Solution was found.
    
```



ρ_k aumenta muito!

$\mu^{15} = -\frac{1}{10^8} < 0$

Controle de viabilidade / admissibilidade

Queremos tentar crescer ρ ... Oimos a estratégia de penalizar restrições com deslocamento. Uma segunda estratégia é aumentar ρ apenas se a inviabilidade não melhora de uma iteração para outra.

→ $\phi(x) = \|h(x)\|_2^2 + \|g(x)_+\|_2^2 \rightarrow$ poderíamos usar ϕ no teste, mas não é a forma adotada por ALGENCAN. Usamos a norma $\|\cdot\|_\infty$:
 $\|z\|_\infty = \max \{ |z_1|, \dots, |z_m| \}$

• Viabilidade do iterando x^k :

→ $\max \{ \|h(x^k)\|_\infty, \|g(x^k)_+\|_\infty \}$.

• Complementaridade: $\mu_j^k g_j(x^k) \approx 0$?

Seja que $\mu_j g_j(x) = 0, g(x) \leq 0$ ($\mu \geq 0$)

$$\Leftrightarrow V_j = \min \{ \mu_j, -g_j(x) \} = 0$$

(mínimo coord. a coord.)

De fato, suponha que $\mu_j g_j(x) = 0$ e $g_j(x) \leq 0$. Se fosse $V_j > 0$ então $\mu_j > 0$ e $-g_j(x) > 0$. Assim, $\mu_j g_j(x) < 0$, uma contradição. Se fosse $V_j < 0$ então, em particular, $-g_j(x) < 0 \Rightarrow g_j(x) > 0$, uma contradição.

Reciprocamente, suponha $V_j = 0$. Assim, $(\mu_j = 0 \text{ e } -g_j(x) \geq 0)$ ou $(\mu_j > 0 \text{ e } -g_j(x) = 0)$. No primeiro caso, $\mu_j g_j(x) = 0$ e $-g_j(x) \geq 0 \Rightarrow g_j(x) \leq 0$. No segundo caso $\mu_j g_j(x) = \mu_j (-g_j(x)) = 0$ e $-g_j(x) = 0 \Rightarrow g_j(x) \leq 0$.

Esta forma $V_j = 0$ engloba a completude e a viabilidade das desigualdades $g_j(x) \leq 0$. Daí, o teste do acréscimo de p fica:

(**)

Se $k=0$ (primeira iteração) ou
 $\max \{ \|h(x^k)\|_\infty, \|V^k\|_\infty \}$ \leq ρ $\left\{ \begin{array}{l} \text{viabilidade } g(x) \leq 0 \\ + \text{ complement.} \end{array} \right.$

\rightarrow $\text{viabilid. } h(x)=0 \leq \rho \max \{ \|h(x^{k-1})\|_\infty, \|V^{k-1}\|_\infty \}$

então $\rho_{k+1} = \rho_k$ (não aumentamos ρ). Caso

contrário, $\rho_{k+1} = 10 \rho_k$.

• $\rho \in [0, 1)$: parâmetro.

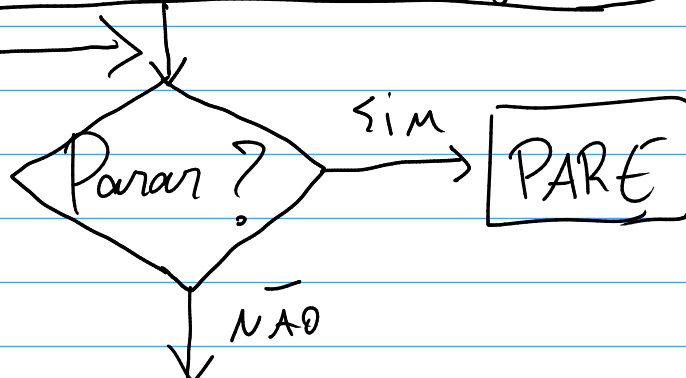
• $V^k = \min \{ \bar{\mu}^k, -g(x^k) \}$.

Método de Lagrangiano aumentado (ALGENCAN)

$$\rho_0 > 0, \beta \in [0, 1), x^0 \in \mathbb{R}^n,$$

$$\bar{\lambda}_i^0 \in [\lambda_{\min}, \lambda_{\max}], \forall i$$

$$\bar{\mu}_j^0 \in [0, \mu_{\max}], \forall j; \{\epsilon_k\} \downarrow 0$$



Resolver o subproblema

$$\min_x f(x) + \frac{\rho_k}{2} \left[\|h(x) + \frac{\bar{\lambda}^k}{\rho_k}\|^2 + \|(g(x) + \frac{\bar{\mu}^k}{\rho_k})_+\|^2 \right]$$

obtendo o iterando x^k . O ponto x^k

$$\text{deve satisfazer } \|\nabla_x L_{\rho_k}(x^k, \bar{\lambda}^k, \bar{\mu}^k)\|_{\infty} \leq \epsilon_k$$

$$k \leftarrow k+1$$

Atualize ρ segundo o critério (**)

Atualizar multiplicadores projetados:

$$\bar{\lambda}^{k+1} = \max\{\lambda_{\min}, \min\{\lambda_{\max}, \rho_k h(x^k) + \bar{\lambda}^k\}\}$$

$$\bar{\mu}^{k+1} = \max\{0, \min\{\mu_{\max}, \rho_k g(x^k) + \bar{\mu}^k\}\}$$

Critério de parada: paramos quando x^k é \approx KKT do problema original

$P: \min_x f(x)$ s.a. $h(x)=0, g(x) \leq 0$.

Parâmetro: $\epsilon_{opt} > 0$: precisão de parada.

$$\left\| \nabla f(x^k) + \sum_{i=1}^m \lambda_i^k \nabla h_i(x^k) + \sum_{j=1}^p \mu_j^k \nabla g_j(x^k) \right\| \leq \epsilon_{opt}$$

$$\left| \min \{ \mu_j^k, -g_j(x^k) \} \right| \leq \epsilon_{opt}, \forall j, \mu_j^k \geq 0, \forall j.$$

$$\|h(x^k)\|_{\infty} \leq \epsilon_{opt}, \|g(x^k)_+\|_{\infty} \leq \epsilon_{opt}$$

• Padrão: $\epsilon_{opt} = 10^{-8}$

$$\lambda^k = \rho_k h(x^k) + \bar{\lambda}^k, \quad \mu^k = (\rho_k g(x^k) + \bar{\mu}^k)_+$$

```
Min (x[1] - 2.0) ^ 2.0 + (x[2] - 1.0) ^ 2.0
Subject to
x[1] + x[2] ≤ 2.0
(x[1] ^ 2.0 - x[2]) - 0.0 ≤ 0
```

$\max \{ \|h(x^k)\|_{\infty}, \|v^k\|_{\infty} \}$

ite	penalt	objective function	infeas ibility	scaled obj-funct	scaled infeas	infeas +compl	norm graLag	Grad infeas	inner totit	Newton forKKT
0		5.000D+00	0.D+00	1.250D+00	0.D+00	0.D+00	1.D+00	0.D+00	0	0
1	1.D+01	9.827D-01	1.D-02	2.457D-01	1.D-02	1.D-02	3.D-09	4.D-02	8C	0
2	1.D+01	9.996D-01	4.D-04	2.499D-01	4.D-04	4.D-04	3.D-07	7.D-04	10C	0
3	1.D+01	1.000D+00	1.D-05	2.500D-01	1.D-05	1.D-05	1.D-06	1.D-05	11C	0
4	1.D+01	1.000D+00	3.D-07	2.500D-01	3.D-07	3.D-07	5.D-10	3.D-07	12C	0
5	1.D+01	1.000D+00	1.D-08	2.500D-01	1.D-08	1.D-08	8.D-14	1.D-08	13C	0

Flag of ALGENCAN: Solution was found.

ρ não aumenta