

## Sequentiell linjärprogrammering (SLP)

Iterativ lösningsmetod för olinjär optimering med bivillkor.

Problem:  $\min f(x)$

$$(P) \quad \text{då } g_i(x) \leq 0, \quad i=1, \dots, m$$

där både  $f \in C^1$  och alla  $g_i \in C^1$ .

(Likhetsvillkor kan också hanteras.)

Metodprincip:

- linjärapproximera målfunktionen och bivillkorsfunktionerna med första ordningens Taylor-utvecklingar,
- Lös linjärapproximerade problem,
- inkludera explicita steglängdsrestriktioner för att förhindra att linjärapproximationerna används alltför långt bort från punkterna där de skapats (och där de därför kan vara opålitliga),
- använd en strafffunktion för att mäta målfunktionsvärde och grad av otillåtenhet tillsammans

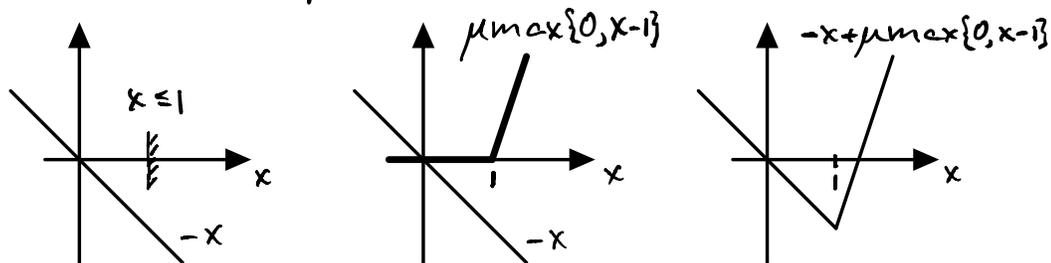
Låt  $\mu > 0$  vara en straffparameter.

Betrakta den exakta strafffunktionen  
 $F_\epsilon: \mathbb{R}^n \rightarrow \mathbb{R}$  med

$$F_\epsilon(x) = f(x) + \mu \sum_{i=1}^m \max\{0, g_i(x)\}.$$

Observera att  $F_\epsilon(x)$  inte är differentierbar  
 i punkter där  $g_i(x) = 0$  gäller för något  $i$ .

Enkelt exempel: betrakta  $\min -x$  då  $x \leq 1$



Med ett tillräckligt stort värde på  $\mu$   
 gäller att det obegränsade problemet  
 $\min_{x \in \mathbb{R}^n} F_\epsilon(x)$  är ekvivalent med (P).

(Om  $f$  och alla  $g_i$  är konvexa funktioner  
 så gäller att  $\mu$  är tillräckligt stort  
 om  $\mu$  är minst lika stort som den  
 största optima KKT-multiplikatorn.)

Problemet  $\min_{x \in \mathbb{R}^n} F_\epsilon(x)$  kan skrivas som

$$\min f(x) + \mu \sum_{i=1}^m y_i$$

$$\text{då } g_i(x) \leq y_i, \quad i=1, \dots, m$$

$$y_i \geq 0, \quad i=1, \dots, m,$$

ts pga minimeringen förs  $g_i := \max\{0, g_i(x)\}$ .

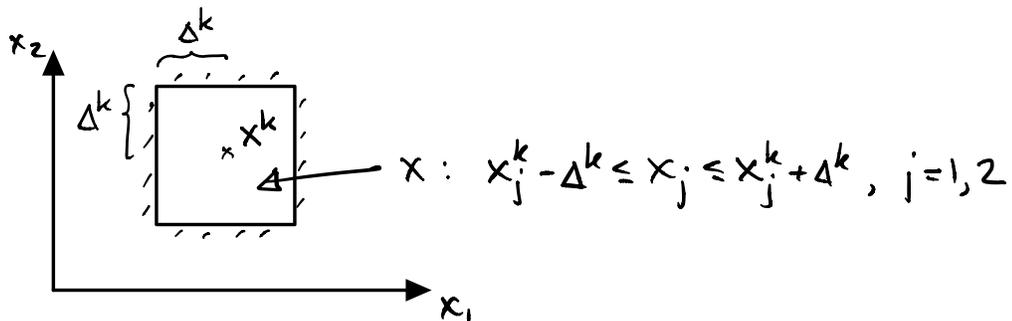
Betrakta en iterationspunkt  $x^k$ .

Linjäropproximera  $f$  och alla  $g_i$  i  $x^k$  och konstruera den linjäriserade strafffunktioner  $F_{EL} : \mathbb{R}^n \rightarrow \mathbb{R}$  med

$$F_{EL}(x) = f(x^k) + f'(x^k)^T(x - x^k) + \mu \sum_{i=1}^m \max\{0, g_i(x^k) + \nabla g_i(x^k)^T(x - x^k)\}.$$

Approximationerna är tillräckligt tillförlitliga endast i en liten omgivning till  $x^k$ , varför en steglängdsbegränsning (eng. trust region) införs. Beräkningsmässigt är det lämpligast om begränsningen beskrivs av enkla linjära villkor, varför max-normen används:

$\|x - x^k\|_\infty \leq \Delta^k \Leftrightarrow -\Delta^k \leq x_j - x_j^k \leq \Delta^k, j=1, \dots, n,$   
där  $\Delta^k > 0$  är en parameter.



Den linjäriserade strafffunktionen minimeras därefter över det område som definieras av steglängdsbegränsningen.

Analogt med omskrivningen ovan kan detta problem skrivas som

$$\begin{aligned} \min & f(x^k) + \nabla f(x^k)^T(x-x^k) + \mu \sum_{i=1}^m y_i \\ \text{då } & g_i(x^k) + \nabla g_i(x^k)^T(x-x^k) \leq y_i, \quad i=1, \dots, m \\ (\text{LP}) \quad & -\Delta_k \leq x_j - x_j^k \leq \Delta_k, \quad j=1, \dots, h \\ & y_i \geq 0, \quad i=1, \dots, m, \end{aligned}$$

vilket är ett linjärt optimeringsproblem som utgör en (lokal) approximation av (P). (LP) har alltid en tillåten lösning, eftersom  $y_i, i=1, \dots, m$ , fungerar som artificiella variabler, och ett begränsat optimum, pga steglängdsbegränsningen.

Om något  $g_i(x)$  är icke-konvext så kan variablerna  $y_i, i=1, \dots, m$ , vara nödvändiga för att säkerställa att (LP) är tillåtet, även om (P) är tillåtet. Ett triviellt exempel på detta:  $g(x) = 1 - x^2$  ger  $\{x \mid g(x) \leq 0\} = \{x \mid x \leq -1 \text{ eller } x \geq 1\}$ , men om  $g(x)$  linjäriseras i  $x=0$  så får  $\{x \mid g(0) + g'(0)(x-0) \leq 0\} = \{x \mid 1 + 0(0-0) \leq 0\} = \emptyset$ .

Om däremot alla  $g_i$  är konvexa så

gäller att  $g_i(x^k) + \alpha g_i(x^k)^T(x-x^k) \leq g(x)$ ,  $i=1, \dots, m$ ,  
 varför (LP) då alltid är tillåtet med  
 alla  $s_i=0$ , givet att (P) är tillåtet. Dock  
 behöver inte därför  $s_i=0$ ,  $i=1, \dots, m$ , gälla i  
 ett optimum i (LP).

Man kan visa ett om  $\mu$  är tillräckligt  
 stor så är  $x^k$  optimal i (LP) [dvs  
 linjäringspunkter är själva optimala i  
 det linjäriserade problemet] om  
 $x^k$  är en KKT-punkt för (P).

Iterativ metod:

Låt  $\bar{x}^k \neq x^k$  vara optimal i (LP).

Definiera  $\Delta F_{E_k} = F_E(x^k) - F_E(\bar{x}^k)$  [= förbättring  
 i värde på strafffunktionen].

Definiera  $\Delta F_{EL_k} = \underbrace{F_{E_k}(x^k)}_{= F_E(x^k)} - \underbrace{F_{E_k}(\bar{x}^k)}_{= \text{prediktion av } F_E(\bar{x}^k)}$  [= förbättring  
 i värde på den linjäriserade straff-  
 funktionen = en prediktion av  $\Delta F_{E_k}$ ].

Relationen mellan  $\Delta F_{E_k}$  och  $\Delta F_{EL_k}$  styr  
 hur  $x^{k+1}$  väljs och  $\Delta^k$  förändras.

Olika fall:

om  $\Delta F_{E_k}$  avviker mycket från  $\Delta F_{EL_k} \rightarrow$   
 låt  $x^{k+1} = x^k$  och minska  $\Delta^k$

om  $\Delta F_{E_h}$  avviker lite från  $\Delta F_{EL_h} \rightarrow$   
Låt  $x^{k+1} = \bar{x}^k$  och behåll  $\Delta^k$

om  $\Delta F_{E_h}$  avviker mycket lite från  $\Delta F_{EL_h} \rightarrow$   
Låt  $x^{k+1} = \bar{x}^k$  och öka  $\Delta^k$

(Vad som betraktas som stora och små avvikelser mellan  $\Delta F_{E_h}$  och  $\Delta F_{EL_h}$  är algoritmparametrar och lämpliga val av värden på dem är problemberoende. Värden på  $\Delta^0$  och hur mycket  $\Delta^k$  minskar eller ökar är också algoritmparametrar och val av lämpliga värden på dem är också problemberoende. Värden på  $\Delta^k$  förändras typiskt mha en enkel strategi, som tex genom halveringar och fördubblingar.)