

Sekventiell kvadratisk programmering

Problem: $\min f(x)$

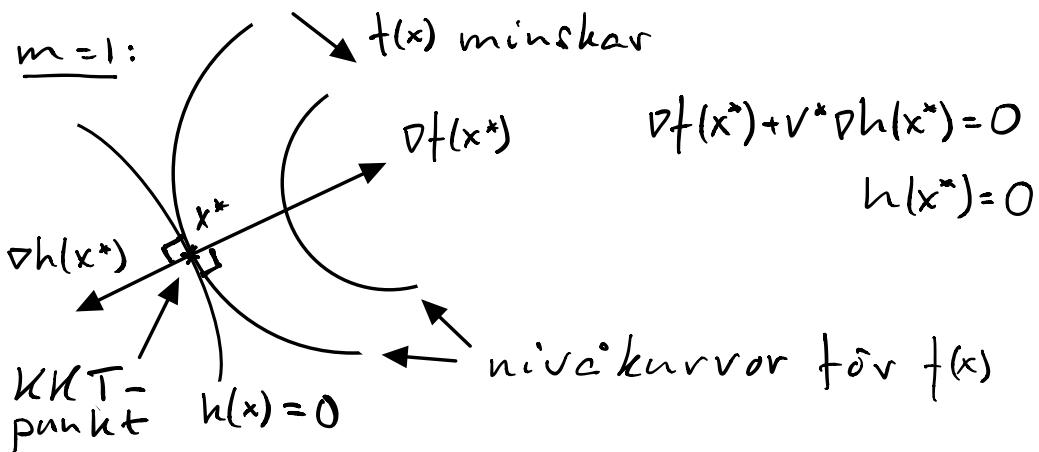
$$(P) \quad \text{d}c^{\circ} h_i(x) = 0, i=1, \dots, m \mid v_i$$

(Olikhetsvillkor kan också hanteras.)

Ett globalt minimum till problemet finns bland dess KKT-punkter. (Givet att problemet uppfyller något lämpligt regularitetskrav.) Om problemet är icke-konvex så kan det bland KKT-punkterna även finnas punkter som är lokala, men inte globala, minima, och även punkter som inte ens är lokala minima (utan lokala maxima eller "sadelpunkter").

KKT-villkoren för (P):

$$\begin{cases} \nabla f(x) + \sum_{i=1}^m v_i \nabla h_i(x) = 0 \\ h_i(x) = 0, \quad i=1, \dots, m \end{cases}$$



Låt $h(x) = (h_1(x), \dots, h_m(x))^T$ och låt $v \in \mathbb{R}^m$ vara vektorer av Lagrange-multiplikatorer för villkoren $h(x) = 0$. Lagrange-funktionen är då $L(x, v) = f(x) + v^T h(x) = f(x) + \sum_{i=1}^m v_i h_i(x)$.

Men $\nabla f(x) + \sum_{i=1}^m v_i \nabla h_i(x) = \nabla_x L(x, v)$ och $h(x) = \nabla_v L(x, v)$, varför KKT-villkoren kan skrivas som

$$\begin{cases} \nabla_x L(x, v) = 0 \\ \nabla_v L(x, v) = 0 \end{cases} \text{ eller som } \nabla L(x, v) = 0.$$

Alltså sammanfaller KKT-punkter med stationära punkter till Lagrange-funktionen $L(x, v)$!

För att finna en stationär punkt till Lagrange-funktionen kan Newtons metod användas! Eftersom Lagrange-multiplikatorer även kan betraktas som dualvariabler så får en primal-dual metod.

Givet en iterationspunkt (x^k, v^k) .

En andra ordningens Taylor-utveckling ger att

$$L(x, v) \approx L(x^k, v^k) + \nabla L(x^k, v^k)^T (x - x^k) + \frac{1}{2} (v - v^k)^T \nabla^2 L(x^k, v^k) (v - v^k)$$

$$\Rightarrow \nabla L(x, v) \approx \nabla L(x^k, v^k) + \nabla^2 L(x^k, v^k) \begin{pmatrix} x - x^k \\ v - v^k \end{pmatrix}$$

$$HL = 0 \Rightarrow \nabla^2 L(x^k, v^k) \begin{pmatrix} x - x^k \\ v - v^k \end{pmatrix} = -\nabla L(x^k, v^k)$$

Linjärt ekuationsystem i x och v !

$$\text{Här är } \nabla^2 L(x^k, v^k) = \begin{pmatrix} \nabla_{xx}^2 L(x^k, v^k) & \nabla_{xv}^2 L(x^k, v^k) \\ \nabla_{vx}^2 L(x^k, v^k) & \nabla_{vv}^2 L(x^k, v^k) \end{pmatrix}$$

med

$$\nabla_{xx}^2 L(x^k, v^k) = D^2 f(x^k) + \sum_{i=1}^m v_i^k \nabla^2 h_i(x^k)$$

$$\nabla_{xv}^2 L(x^k, v^k) = \nabla_{vx}^2 L(x^k, v^k) = \nabla h(x^k)^T = (\nabla h_1(x^k), \dots, \nabla h_m(x^k))$$

$$\nabla_{vv}^2 L(x^k, v^k) = 0$$

$$\text{och } \nabla L(x^k, v^k) = \begin{pmatrix} \nabla_x L(x^k, v^k) \\ \nabla_v L(x^k, v^k) \end{pmatrix} = \begin{pmatrix} \nabla f(x) + \sum_{i=1}^m v_i^k \nabla h_i(x^k) \\ h(x^k) \end{pmatrix}.$$

Alltså för systemet

$$\begin{cases} \nabla_{xx}^2 L(x^k, v^k)(x - x^k) + \nabla h(x^k)^T(v - v^k) = -(\nabla f(x^k) + \sum_{i=1}^m v_i^k \nabla h_i(x^k)) \\ \nabla h(x^k)(x - x^k) = -h(x^k), \end{cases}$$

eller med $d = x - x^k$,

$$\begin{cases} \nabla_{xx}^2 L(x^k, v^k) d + \nabla h(x^k)^T v = -\nabla f(x^k) \\ \nabla h(x^k) d = -h(x^k). \end{cases}$$

Låt (d^k, v^*) vara en lösning till detta system.

Om $d^k = 0$ gäller så är (x^k, v^k) en KKT-punkt för (P). Annars är nästa iterationspunkt i Newtons metod på problemet att

finna en stationär punkt till $L(x, v)$ som $(x^{k+1}, v^{k+1}) = (x^k + d^k, v^*)$.

Genom att skriva systemet som

$$\begin{cases} \nabla f(x^k) + \nabla_{xx}^2 L(x^k, v^k) d + \sum_{i=1}^m v_i \nabla h_i(x^k) = 0 \\ h_i(x^k) + \nabla h_i(x^k)^T d = 0, \quad i=1, \dots, m \end{cases}$$

inseras dock att det är KKT-villkoren för det kvadratiska optimeringsproblemets

$$\min q(d) = f(x^k) + \nabla f(x^k)^T d + \frac{1}{2} d^T \nabla_{xx}^2 L(x^k, v^k) d$$

$$(QP) \quad d \geq 0, \quad h_i(x^k) + \nabla h_i(x^k)^T d = 0, \quad i=1, \dots, m, \quad | v_i |$$

varför näste iterationspunkt alltså istället kan beräknas genom att lösa (QP). [Inkrementet d^k utgör primärt optimum till (QP), medan v^* är de optimala värdena på dualvariablerna för de linjäriserade villkoren i (QP).] Notera att målfunktionen i (QP) är kvadratisk medan villkoren är linjära, och vidare utgör linjärapproximationer (första ordningens Taylor-utvecklingar) av villkoren i (P). Vidare kan målfunktionen skrivas ut som

$$q(d) = f(x^k) + \nabla f(x^k)^T d + \frac{1}{2} d^T \nabla^2 f(x^k) d + \frac{1}{2} d^T \left(\sum_{i=1}^m v_i^k \nabla^2 h_i(x^k) \right) d,$$

där de tre första termerna utgör en kvadratisk approximation av $f(x^k)$ (en andre ordningens Taylor-utveckling), medan den sista, kvadratiska, termen innehåller bivillkorfunktionernas Hessianer i x^k , ihopviktade med v_i^k , $i=1,\dots,m$, och därmed beskriver bivillkorens kurvatur (kröhning) i x^k . (QP) innehåller alltså information från andre ordningens approximationer av både målfunktion och bivillkor, men bidraget från andre ordningens termer hanteras på olika sätt.

Newton's metod på problemet att finna en stationär punkt till $L(x,v)$ konvergerer till en KKT-punkt om startpunkten (x^0, v^0) ligger tilräckligt nära KKT-punkten. När KKT-punkten fär kvadratisk konvergens.

En möjlig komplikation i metoden är att (QP) kan bli otillåtet. Detta kan dock enkelt åtgärdas genom att i (P) införa artificiella variabler med

mycket höga kostnader, varigenom (QP) alltid kommer att ha en tillåten lösning.

Om (P) innehåller olikhetsvillkor så kommer de i (QP) approximeras med linjäriserade olikhetsvillkor (och motsvarande dualvariabler kommer att bli teckenbegränsade).

Hur gerantere global konvergens till en KKT-punkt, dvs konvergens till en KKT-punkt avsett startpunkt?

Introducera en strafffunktion som mäter både målfunktionsvärdet och total otillåtenhet, samt läss till linjesökningar med denna!

Låt l,-strafffunktion $F_\epsilon: \mathbb{R}^n \rightarrow \mathbb{R}$ ges av

$$F_\epsilon(x) = f(x) + \mu \sum_{i=1}^m |h_i(x)|$$

där $\mu > 0$ och tillräckligt stor.

Observera att F_ϵ inte är differentierbar i punkter där $h_i(x) = 0$ gäller för något i .

Observera också att F_ϵ beror av endast de primale variablerna, x .

Givet den primale iterationspunkten x^k , görs linjesömninjen min $F_E(x^k + \lambda d^k)$, som $\lambda \geq 0$

ger $\lambda = \gamma_k$. Man kan visa att d^k är en autogonderichtning för F_E från x^k , varför $\gamma_k > 0$ gäller. Nästa primale iterationspunkt ges av $x^{k+1} = x^k + \gamma_k d^k$, med $F_E(x^{k+1}) < F_E(x^k)$. Nästa duala iterationspunkt ges som tidigare som $v^{k+1} = v^*$ [från duallösningen till (QP)].

Om (P) innehåller olikhetsvillkor, $g_i(x) \leq 0$, $i=1, \dots, m$, så ges ℓ_1 -strafffunktionen istället av $F_E(x) = f(x) + \mu \sum_{i=1}^m \max\{0, g_i(x)\}$.

(Man kan självklart även hantera en kombination av likhets- och olikhetsvillkor.)

Utvägningar:

Problemet (P) är konvext om f är konvex och

- för fallet likhetsvillkor: alla h_i är affina
- för fallet olikhetsvillkor: alla g_i är konvexa.

Da blir (QP) alltid ett konvext optimeringsproblem och det är typiskt mittligt beräkningskrävande. (Det är

väsentligen lika svärlöst som ett linjärprogrammeringsproblem av motsvarande storlek.) Om däremot (P) är ett icke-konvext problem (vilket är vanligt i tillämpningar) så kan matrisen $\nabla_{xx}^2 L(x^k, v^k)$ bli indefinit, varigenom (QP) blir icke-konvext och beräkningskrävande. Ett vanligt sätt att åtgärda detta är att ersätta $\nabla_{xx}^2 L(x^k, v^k)$ med $\nabla_{xx}^2 L(x^k, v^k) + \nu I$, där $\nu > 0$ är en parameter som väljs större än bellopet av det mest negativa egenvärdet till $\nabla_{xx}^2 L(x^k, v^k)$. Däriigenom blir $\nabla_{xx}^2 L(x^k, v^k) + \nu I$ positivt definit och (QP) konvext. (Jämför Newton-Marguerat metoden!)

Ofta är det beräkningskrävande att finna matrisen $\nabla_{xx}^2 L(x^k, v^k)$. Det är dock vanligt att den approximeras och uppdateras enligt en kvasi-Newton strategi, som t.ex BFGS.