

2006–05–15

Optimering, fortsättning

en dimension, utan bivillkor:

Problem:

$$\min_{x \in \mathbb{R}} f(x), \quad f: \mathbb{R} \rightarrow \mathbb{R}$$

Metoder:

1. Gyllene snittet.
2. Polynomapproximation. Populär i modern programvara.

Konvergerar om f är konvex. Illustration (fig24). p_2 är interpolationspolynom av grad 2, genom $f(x_1)$, $f(x_2)$, $f(x_3)$. Minimera $p_2(x)$ är enkelt. Låt x_4 vara $p_2(x)$:s minpunkt och byt x_4 mot någon gammal punkt så att minimum ligger i intervallet som bestäms av de tre punkterna. I exemplet i figuren fotsätter vi alltså med x_2, x_4, x_3 .

3. Newtons metod för att lösa $f'(x) = 0$, dvs $x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$, $k = 0, 1, \dots$ Kräver andraderivator.

4. Modifierad Newton:

$$x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_0)}, k = 0, 1, \dots$$

2:a derivatan eller en approximation av densamma beräknas *bara* i startpunkten.

5. Sekantmetoden:

$$x_{k+1} = x_k - \frac{f'(x_k)(x_k - x_{k-1})}{f'(x_k) - f'(x_{k-1})}, k = 1, 2, \dots$$

Endast förstaderivator, två startapproximationer.

Flerdimensionell optimering utan bivillkor

$$\min f(\mathbf{x}): \quad f: \mathbb{R}^n \rightarrow \mathbb{R}$$

Sökmetoder: $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{d}_k$ där α_k är en steglängd och \mathbf{d}_k är sökriktning. Anta först att \mathbf{d}_k är bestämd (hur kommer vi tala om senare). Vi vill då bestämma α_k , dvs hur långt ska vi gå längs sökriktningen?

Att bestämma α_k är en-dimensionell optimering, s.k. linjesökning. Linjesökningsproblem:

$$(P_L) \quad \min_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{d}_k)$$

Tidigare metoder 1–5 för endimensionell optimering kan användas.

I specialfallet f kvadratisk, dvs

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T H \mathbf{x} + \mathbf{c}^T \mathbf{x}$$

kan vi visa formeln för optimal steglängd:

$$\alpha_k = -\frac{\nabla f(\mathbf{x}_k)^T \mathbf{d}_k}{\mathbf{d}_k^T H \mathbf{d}_k}$$

Bevis.

$$\min_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{d}_k) = \min_{\alpha} g(\alpha)$$

$$g(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{d}_k)$$

$$g'(\alpha) = \nabla f(\mathbf{x}_k + \alpha \mathbf{d}_k)^T \mathbf{d}_k$$

$$\begin{aligned} f \text{ kvadratisk} &\implies \nabla f(\mathbf{x}_k + \alpha \mathbf{d}_k) = H(\mathbf{x}_k + \alpha \mathbf{d}_k) + \mathbf{c} = \\ &= H\mathbf{x}_k + \mathbf{c} + \alpha H\mathbf{d}_k = \nabla f(\mathbf{x}_k) + \alpha H\mathbf{d}_k = \nabla f(\mathbf{x}_k) + \alpha H\mathbf{d}_k \\ g'(\alpha) = 0 &\implies (\nabla f(\mathbf{x}_k) + \alpha H\mathbf{d}_k)^T \mathbf{d}_k = 0 \end{aligned}$$

Lös ut α :

$$\alpha = -\frac{\nabla f(\mathbf{x}_k)^T \mathbf{d}_k}{\mathbf{d}_k^T H \mathbf{d}_k}$$

□

Val av sökriktning d_k :

1. Steepest descent, $\mathbf{d}_k = -\nabla f(\mathbf{x}_k)$.
2. Newtons metod på $\nabla f(\mathbf{x}) = \mathbf{0}$, dvs \mathbf{d}_k som lösning till ekvationssystemet

$$H(\mathbf{x}_k) \mathbf{d}_k = -\nabla f(\mathbf{x}_k)$$

3. Kvasi-Newton:

$$B_k \mathbf{d}_k = -\nabla f(\mathbf{x}_k)$$

där B_k är approximation av $H(\mathbf{x}_k)$, exempelvist Broydens uppdatering.

4. Konjugerad gradient (ej på tentan)

$$\mathbf{d}_k = -\nabla f(\mathbf{x}_k) + \beta_k \mathbf{d}_k$$

“metod med minne”.

$$\beta_k = \frac{\|\nabla f(\mathbf{x}_k)\|_2^2}{\|\nabla f(\mathbf{x}_{k-1})\|_2^2}$$

Egenskap: Om f är kvadratisk så blir sökriktningarna konjugerat ortogonala:

$$\mathbf{d}_k^T H \mathbf{d}_j = 0, \quad k \neq j$$

EXEMPEL:

$$\min_{\mathbf{x} \in \mathbb{R}^2} 5x_1^2 + x_1 x_2 + \frac{1}{2} x_2^2 - x_1$$

$$\nabla f = \begin{pmatrix} 10x_1 + x_2 - 1 \\ x_1 + x_2 \end{pmatrix}, \quad H = \begin{pmatrix} 10 & 1 \\ 1 & 1 \end{pmatrix}$$

Steepest descent:

$$\mathbf{x}^{[0]} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \quad \nabla f(\mathbf{x}^{[0]}) = \begin{pmatrix} -1 \\ 0 \end{pmatrix}, \quad \mathbf{d}^{[0]} = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$$

$$\alpha_0 = -\frac{\nabla f(\mathbf{x}^{[0]})^T \mathbf{d}^{[0]}}{(\mathbf{d}^{[0]})^T H \mathbf{d}^{[0]}} = \frac{1}{10}$$

$$\mathbf{x}^{[1]} = \mathbf{x}^{[0]} + \alpha_0 \mathbf{d}^{[0]} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} + \frac{1}{10} \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 0.1 \\ 0 \end{pmatrix}$$

$$\nabla f(\mathbf{x}^{[1]}) = \begin{pmatrix} 0 \\ 0.1 \end{pmatrix}, \quad \mathbf{d}^{[1]} = \begin{pmatrix} 0 \\ -0.1 \end{pmatrix}$$

$$\alpha_1 = -\frac{\nabla f(\mathbf{x}^{[1]})^T \mathbf{d}^{[1]}}{(\mathbf{d}^{[1]})^T H \mathbf{d}^{[1]}} = \dots = 1$$

$$\mathbf{x}^{[2]} = \mathbf{x}^{[1]} + \alpha \mathbf{d}^{[1]} = \begin{pmatrix} 0.1 \\ 0 \end{pmatrix} + \begin{pmatrix} 0 \\ -0.1 \end{pmatrix} = \begin{pmatrix} 0.1 \\ -0.1 \end{pmatrix}$$

Konjugerad gradient

$$\mathbf{x}^{[0]} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \quad \mathbf{x}^{[1]} = \begin{pmatrix} 0.1 \\ 0 \end{pmatrix}, \quad \nabla f(\mathbf{x}^{[1]}) = \begin{pmatrix} 0 \\ 0.1 \end{pmatrix}$$

$$\beta_1 = \frac{\|\nabla f(\mathbf{x}^{[1]})\|^2}{\|\nabla f(\mathbf{x}^{[0]})\|^2} = 0.01$$

$$\mathbf{d}^{[1]} = -\nabla f(\mathbf{x}^{[1]}) + \beta_1 \mathbf{d}^{[0]} = \begin{pmatrix} 0 \\ -0.1 \end{pmatrix} + 0.01 \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 0.01 \\ -0.1 \end{pmatrix}$$

$$\alpha_1 = \frac{-\nabla f(\mathbf{x}^{[1]})^T \mathbf{d}^{[1]}}{(\mathbf{d}^{[1]})^T H \mathbf{d}^{[1]}} = \frac{10}{9}$$

$$\mathbf{x}^{[2]} = \mathbf{x}^{[1]} + \alpha_1 \mathbf{d}^{[1]} = \dots = \frac{1}{9} \begin{pmatrix} 1 \\ -1 \end{pmatrix} = \mathbf{x}^*$$

Icke-linjära minsta-kvadrat-problem, Heath 6.4

$$\mathbf{f}(\mathbf{x}) = \mathbf{0}; \quad \mathbf{f}: \mathbb{R}^m \rightarrow \mathbb{R}^n, m > n$$

Vi har ett överbestämt system av icke-linjära ekvationer. Minsta-kvadrat-lösning:

$$\min_{\mathbf{x}} \|\mathbf{f}(\mathbf{x})\|_2$$

Stegvis linjärisering som vid Newtons metod. Taylorutveckling kring en approximation \mathbf{x}_k :

$$\mathbf{f}(\mathbf{x}) \approx \mathbf{f}(\mathbf{x}_k) + \mathcal{J}(\mathbf{x}_k)(\mathbf{x} - \mathbf{x}_k)$$

Linjär modell:

$$\min_{\mathbf{x}} \|\mathbf{f}(\mathbf{x})\|_2 \approx \min_{\mathbf{x}} \|\mathbf{f}(\mathbf{x}_k) + \mathcal{J}(\mathbf{x}_k)(\mathbf{x} - \mathbf{x}_k)\|_2$$

Detta är ett *linjärt* minsta-kvadrat-problem som alltså ska lösas i varje iteration.

Gauss-Newton metod: $\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{d}_k$, $\mathcal{J}(\mathbf{x}_k)\mathbf{d}_k = -\mathbf{f}(\mathbf{x}_k)$. Ser ut som Newtons metod, men innebördens i det ekvationssystemet är helt annorlunda: lösning av linjärt minsta-kvadratproblem medan i vanlig Newton är det lösning av ett linjärt ekvationssystem.

Typisk tillämpning Anpassning av icke-linjär modell till mätdata.

EXEMPEL $\psi(\mathbf{x}, t) = x_1 + x_2 e^{-x_3 t}$, (t_i, ψ_i) uppmätta värden, $i = 1, \dots, m$. Överbestämt system om $m > 3$. $f_i = \psi(\mathbf{x}, t_i) - \psi_i$ med

$$\mathbf{f} = \begin{pmatrix} f_1 \\ \vdots \\ f_m \end{pmatrix}, \quad \mathbf{f}(\mathbf{x}) = \mathbf{0}, \min_{\mathbf{x}} \|\mathbf{f}(\mathbf{x})\|_2$$

EXEMPEL. Byråkratisk tillväxtmodell, dagsproduktion av EU-papper (kilo A4).

$$\begin{array}{ccccccccc} t & = & 0 & 1 & 2.5 & 3 & 3.5 & 4 & 5 & 6 \\ Y & = & 4 & 8 & 54 & 76 & 78 & 66 & 75 & 130 \end{array}$$

Modell: $Y = a e^{qt} + b e^{-(t-t_0)^2}$: exponentiell tillväxt med superponerad topp vid extrem händelse (Maastricht-avtalet).

a) Anta $q = 0.5$ och $t_0 = 3$. Bestäm a och b med linjär minsta-kvadrat.

Lösning:

$$A = \begin{pmatrix} | & | & | \\ e^{0.5 t_i} & t_i & e^{-(t_i - 3)^2} \\ | & | & | \end{pmatrix}, \quad \mathbf{Y} = \begin{pmatrix} 4 \\ 8 \\ \vdots \\ 130 \end{pmatrix}$$

$$A \begin{pmatrix} a \\ b \end{pmatrix} = \mathbf{Y}$$

b) Icke-linjär minsta-kvadrat alla 4 parametrarna, sätt upp problemet med Gauss-Newton metod. Residual:

$$f_i = a e^{qt_i} + b e^{-(t_i - t_0)^2} - Y_i$$

Jakobianen:

$$\mathcal{J} = \begin{pmatrix} | & | & | & | \\ e^{qt_i} & t_i a e^{qt_i} & e^{-(t_i - t_0)^2} & 2(t_i - t_0) b e^{-(t_i - t_0)^2} \\ | & | & | & | \end{pmatrix}$$

$$\mathbf{x} = \begin{pmatrix} a \\ q \\ b \\ t_0 \end{pmatrix}$$

Gauss-Newton

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{d}_k \\ \mathcal{J}(\mathbf{x}_k) \mathbf{d}_k = -\mathbf{f}(\mathbf{x}_k) \end{cases}$$

\mathbf{x}_0 kan tas från linjära modellen.