

## 2006–05–16

### Icke linjär minsta kvadrat

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

Sätt  $\mathbf{d}_k = \mathbf{x} - \mathbf{x}_k$

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

(Överbestämt linjärt system, löses i minsta-kvadrat-mening.)

Gauss-Newton's metod:

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{d}_k \\ \mathcal{J}(\mathbf{x}_k) \mathbf{d}_k = -\mathbf{f}(\mathbf{x}_k) \end{cases}, \quad k = 0, 1, \dots$$

Lokalt konvergent.

En populär metod i programvara är Levenberg-Marquardt's metod som är *globalt* konvergent (kommer ej på tentan).

$\min_{\mathbf{x}} \|\mathbf{f}(\mathbf{x})\|_2$  approximeras med linjär model med steglängdskontroll.

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

Detta är ekvivalent med (visas inte) att lösa:

$$(\mathcal{J}(\mathbf{x}_k)^T \mathcal{J}(\mathbf{x}_k) + \mu I) \mathbf{d} = -\mathcal{J}(\mathbf{x}_k)^T \mathbf{f}(\mathbf{x}_k)$$

Man kan dämpa steglängden genom att välja ett stort  $\mu > 0$ : väljs så att  $\|\mathbf{d}\|_2 \leq \Delta$ .

ANMÄRKNING. För  $\mu = 0$  är detta normalekvationerna. Men inte så illa konditionerade om  $\mu > 0$ . Vi gör alltså en reguljärisering.

Levenberg-Marquardt's metod är alltså:

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

I praktiken får man pröva sig fram till ett  $\mu$  så att  $\|\mathbf{d}\|_2 \leq \Delta$ , exempelvis genom intervallhalvering.

**Tvåpunkts randvärdesproblem**, Heath 10.

$$(RVP) \quad \begin{cases} \alpha y'' + \beta y' + \gamma y = f(t), & 0 \leq t \leq 1 \\ y(0) = c_1, & y(1) = c_2 \end{cases}$$

$y(t)$  sökt funktion,  $f(t), \alpha, \beta, \gamma, c_1, c_2$  är givna.

**Metod 1:** Differensapproximation av differenskvoterna ger approximation till  $y(t)$  i diskreta punkter (fig25). Låt  $f_i = f(t_i)$ . Centraldifferens ger linjärt ekvationsystem:

$$\begin{cases} \frac{\alpha}{h^2}(y_{i-1} - 2y_i + y_{i+1}) + \frac{\beta}{2h}(y_{i+1} - y_{i-1}) + \gamma y_i = f_i, & i = 2, \dots, n-1 \\ y_1 = c_1, & y_n = c_2 \end{cases}$$

På matrisform, multiplicera med  $h^2$ .

$$\begin{pmatrix} \ddots & & & & & & & & \\ \ddots & \ddots & & & & & & & \\ \ddots & & \alpha - \frac{\beta h}{2} & & & & & & \\ \ddots & & & -2\alpha + \gamma h^2 & & & & & \\ \ddots & & & & \alpha + \frac{\beta h}{2} & & & & \\ & & & & & \ddots & & & \\ & & & & & & \ddots & & \\ & & & & & & & \ddots & \\ & & & & & & & & \mathbf{0} \\ \mathbf{0} & & & & & & & & \end{pmatrix} \begin{pmatrix} y_2 \\ y_3 \\ \vdots \\ y_{n-1} \end{pmatrix} = \begin{pmatrix} h^2 f_2 - c_1 \left( \alpha - \frac{\beta h}{2} \right) \\ h^2 f_3 \\ \vdots \\ h^2 f_i \\ \vdots \\ h^2 f_{n-2} \\ h^2 f_{n-1} - c_2 \left( \alpha + \frac{\beta h}{2} \right) \end{pmatrix}$$

Tridiagonalt, lätt att lösa.

**Metod 2**, inskjutning. Skriv om (RVP) till (BVP).

$$y_1 = y$$

$$y_2 = y'$$

$$\begin{cases} y_1' = y_2 \\ y_2' = \frac{1}{\alpha} [-\beta y_2 - \gamma y_1 + f(t)] \\ y_1(0) = c_2 \\ y_2(0) = s \end{cases}$$

där  $s$  är en okänd parameter. Välj nu  $s$  så att lösningen

$$y_1(1, s) = c_2$$

dvs vi löser det givna (RVP) om vi väljer  $s$  rätt. Vi ska alltså lösa ekvationen

$$q(s) \equiv y_1(1, s) = c_2$$

Metoder för ekvationslösning får användas.

EXEMPEL. Sekantmetoden:  $s_{k+1} = s_k - \frac{[y_1(1, s_k) - c_2](s_k - s_{k-1})}{y_1(1, s_k) - y_1(1, s_{k-1})}$ ,  $k = 1, 2, \dots$

Två startvärden (provskott):  $s_0, s_1$ .

EXEMPEL. Inskjutning. (fig26).

$$(RVP) \begin{cases} EI \frac{y''}{(1+(y')^2)^{\frac{3}{2}}} = Py - \frac{w x^2}{2} \\ y(0) = 0 \\ y'(L) = 0 \end{cases}$$

Inskjutning:  $y_1 = y$ ,  $y_2 = y'$ :

$$\begin{cases} y_1' = y_2 \\ y_2' = f(x, y, y') \text{ från givna problemet} \\ y_1(0) = 0 \\ y_2(0) = s \end{cases}$$

Ekvation:  $q(s) = y_2(L, s) = 0$ . Sekantmetoden:

$$s_{k+1} = s_k - \frac{y_2(L, s_k)}{y_2(L, s_k) - y_2(L, s_{k-1})}$$

ANMÄRKNING. I varje iteration av sekantmetoden får vi lösa ODE-problemet med t.ex. `ode45` i `MALTBAB`.

EXEMPEL (tentauppgift) Undersök om algoritmen

$$y = a \cdot x + b$$

är stabil i ett IEEE-system. Vi antar att  $a, x$  och  $b$  är lagrade flyttal i datorn.

$$\text{fl}(a \cdot x) = (1 + \varepsilon_1)(a \cdot x)$$

där  $|\varepsilon_1| \leq \mu$ .

$$\text{fl}(a \cdot x + b) = (1 + \varepsilon_2)[(1 + \varepsilon_1)(a \cdot x) + b]$$

Är algoritmen stabil? Bakåttelet ska vara litet. Vi ska hitta  $\hat{a}, \hat{x}, \hat{b}$  så att

$$\text{fl}(a \cdot x + b) = \hat{a} \cdot \hat{x} + \hat{b}$$

Vi har

$$\text{fl}(a \cdot x + b) = (1 + \varepsilon_2) a \cdot (1 + \varepsilon_1) x + (1 + \varepsilon_2) b = \hat{a} \cdot \hat{x} + \hat{b}$$

$$\frac{\hat{a} - a}{a} = \varepsilon_2$$

$$\left| \frac{\hat{a} - a}{a} \right| \leq \mu$$

På samma sätt för  $\hat{x}$  och  $\hat{b}$ . Algoritmen är stabil.

UPPGIFT: Visa att den asymptotiska felkonstanten  $C = \frac{1}{2}$  vid dubbelrot (linjär konvergens) hos Newtons metod.

$$f(x_k) \approx f(x^*) + f'(x^*)(x_k - x^*) + \frac{1}{2} f''(x^*)(x_k - x^*)^2 = \frac{1}{2} f''(x^*)(x_k - x^*)^2$$

$$f'(x_k) \approx f'(x^*) + f''(x^*)(x_k - x^*)$$

Newtons metod:

$$x_k - \frac{f(x_k)}{f'(x_k)} = x_k - \frac{\frac{1}{2} f''(x^*)(x_k - x^*)^2}{f''(x^*)(x_k - x^*)} + \dots$$

$$x_{k+1} - x^* = x_k - x^* - \frac{1}{2}(x_k - x^*)$$

$$\frac{x_{k+1} - x^*}{x_k - x^*} \rightarrow 1 - \frac{1}{2} = \frac{1}{2} \quad \text{då } k \rightarrow \infty$$

**Kvasi-Newton**

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{s}_k \\ B_k \mathbf{s}_k = -\mathbf{f}(\mathbf{x}_k) \end{cases}$$

$B_k$  är en approximation av  $\mathcal{J}(\mathbf{x}_k)$ .

Broydens metod:

$$B_{k+1} = B_k + \frac{1}{\|\mathbf{s}_k\|_2^2} [\mathbf{f}(\mathbf{x}_{k+1}) - \mathbf{f}(\mathbf{x}_k) - B_k \mathbf{s}_k] \mathbf{s}_k^T$$

Visa att

1.  $B_{k+1} \mathbf{s}_k = \mathbf{f}(\mathbf{x}_{k+1}) - \mathbf{f}(\mathbf{x}_k)$
2.  $B_{k+1} \mathbf{z} = B_k \mathbf{z}$  då  $\mathbf{z}^T \mathbf{s}_k = 0$

**Bevis. 2:**

$$B_{k+1} \mathbf{z} = B_k \mathbf{z} + \frac{1}{\|\mathbf{s}_k\|_2^2} [\mathbf{f}(\mathbf{x}_{k+1}) - \mathbf{f}(\mathbf{x}_k) - B_k \mathbf{s}_k] \mathbf{s}_k^T \mathbf{z} \implies B_{k+1} \mathbf{z} = B_k \mathbf{z}$$

1:

$$B_{k+1} \mathbf{s}_k = B_k \mathbf{s}_k + \frac{1}{\|\mathbf{s}_k\|_2^2} [\mathbf{f}(\mathbf{x}_{k+1}) - \mathbf{f}(\mathbf{x}_k) - B_k \mathbf{s}_k] \mathbf{s}_k^T \mathbf{s}_k =$$

$$= B_k \mathbf{s}_k + \mathbf{f}(\mathbf{x}_{k+1}) - \mathbf{f}(\mathbf{x}_k) - B_k \mathbf{s}_k = \mathbf{f}(\mathbf{x}_{k+1}) - \mathbf{f}(\mathbf{x}_k). \quad \square$$

1. Visa att  $\|\mathbf{x} \mathbf{y}^T\|_2 = \|\mathbf{x}\|_2 \cdot \|\mathbf{y}\|_2$  för  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ .

Ledning: Matrisnorm + Cauchys olikhet.

2. Visa att varje skalärprodukt  $\langle \cdot, \cdot \rangle \in \mathbb{R}^n$  kan skrivas  $\langle \mathbf{x}, \mathbf{y} \rangle = \mathbf{y}^T A \mathbf{x}$  där  $A$  är symmetrisk, positivt definit.

Ledning:  $\exists$  bas + egenskaper hos skalärprodukt.