

1. *Měkké maximum* je funkce  $f(\mathbf{x}) = \ln(e^{x_1} + \dots + e^{x_n})$ , kde  $\mathbf{x} \in \mathbb{R}^n$ .
- (a) Spočítejte derivaci a Hessián funkce  $f$ .
- (b) Pro  $n = 2$  rozhodněte, zda je funkce  $f$  konvexní.

**Řešení:**

Derivaci spočítáme pomocí řetízkového pravidla. Pišme  $f(\mathbf{x}) = g(h(\mathbf{x}))$ , kde  $h(\mathbf{x}) = e^{x_1} + \dots + e^{x_n}$  a  $g(y) = \ln y$ . Platí

$$f'(\mathbf{x}) = g'(h(\mathbf{x}))h'(\mathbf{x}).$$

Dostaneme  $g'(y) = \frac{1}{y}$  a  $\frac{\partial h}{\partial x_i} = e^{x_i}$ , tedy  $h'(\mathbf{x}) = [e^{x_1} \dots e^{x_n}] \in \mathbb{R}^{1 \times n}$ . Tak dostaneme

$$f'(\mathbf{x}) = \frac{1}{e^{x_1} + \dots + e^{x_n}} [e^{x_1} \dots e^{x_n}].$$

Označme si pro jednoduchost

$$f_i := \frac{\partial f}{\partial x_i} = \frac{e^{x_i}}{e^{x_1} + \dots + e^{x_n}}.$$

Druhé parciální derivace jsou

$$\frac{\partial^2 f}{\partial x_j \partial x_i} = \frac{\partial f_i}{\partial x_j} = \begin{cases} -\frac{e^{x_i} e^{x_j}}{(e^{x_1} + \dots + e^{x_n})^2} & i \neq j, \\ \frac{e^{x_i}}{e^{x_1} + \dots + e^{x_n}} - \frac{e^{x_i} e^{x_j}}{(e^{x_1} + \dots + e^{x_n})^2} & i = j. \end{cases}$$

To lze dále zjednodušit, pokud zavedeme značení

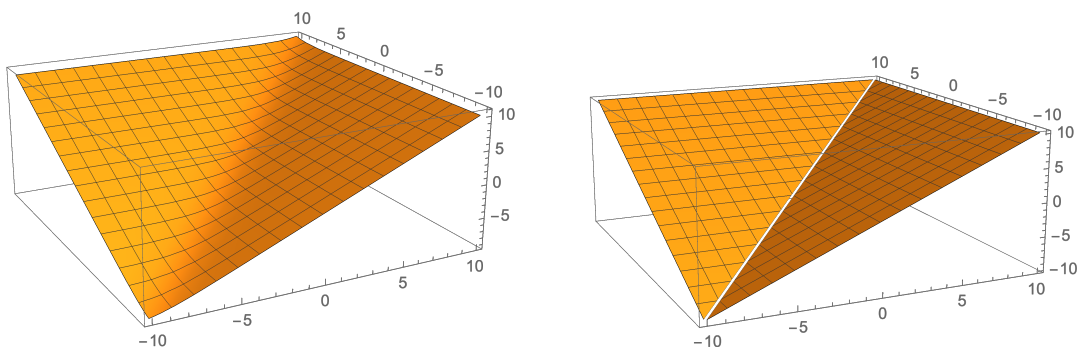
$$\delta_{ij} = \begin{cases} 1 & i = j \\ 0 & i \neq j. \end{cases}$$

Potom totiž platí

$$\frac{\partial^2 f}{\partial x_j \partial x_i} = f_i \delta_{ij} - f_i f_j, \quad i, j = 1, \dots, n,$$

což jsou právě složky Hessiánu  $f''(\mathbf{x}) \in \mathbb{R}^{n \times n}$ .

Předpokládejme, že  $n = 2$ . Na obrázku jsou funkce  $f$  a funkce  $\max(x_1, x_2)$ :



Ukážeme, že  $f''(\mathbf{x})$  je pozitivně semidefinitní matice, což je ekvivalentní konvexitě funkce  $f$ . Chceme tedy ověřit, že platí  $\mathbf{x}^\top f''(\mathbf{x})\mathbf{x} \geq 0$  pro každé  $\mathbf{x} \in \mathbb{R}^2$ . Platí

$$\mathbf{x}^\top f''(\mathbf{x})\mathbf{x} = [x_1 \ x_2] \begin{bmatrix} f_1 - f_1^2 & -f_1 f_2 \\ -f_1 f_2 & f_2 - f_2^2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = f_1 x_1^2 + f_2 x_2^2 - (f_1 x_1 + f_2 x_2)^2.$$

Protože platí  $f_1 + f_2 = 1$ ,  $f_1, f_2 > 0$  a funkce  $\varphi(z) = z^2$  je konvexní, dostaneme

$$f_1 x_1^2 + f_2 x_2^2 \geq (f_1 x_1 + f_2 x_2)^2.$$

Tudíž  $\mathbf{x}^\top f''(\mathbf{x})\mathbf{x} \geq 0$ .

2. Hledáme neznámé parametry  $\mathbf{x} = (x_1, x_2) \in \mathbb{R}^2$  nelineárního regresního modelu

$$p(t) = \frac{x_1 t}{x_2 + t}, \quad t \in \mathbb{R},$$

na základě dat  $(t_1, y_1), \dots, (t_7, y_7) \in \mathbb{R}^2$ .

- Formulujte odpovídající úlohu nelineárních nejmenších čtverců.
- Jak vypadá krok Gauss-Newtonovy (GN) metody?
- Jak vypadá krok Levenberg-Marquardtovy (LM) metody?
- Jak vypadá krok Newtonovy metody?

### Řešení:

Definujeme nejprve jednotlivá rezidua modelu pro  $i = 1, \dots, 7$ ,

$$g_i(\mathbf{x}) = y_i - p(t_i) = y_i - \frac{x_1 t_i}{x_2 + t_i}$$

a dále klademe  $\mathbf{g} = (g_1, \dots, g_7): \mathbb{R}^2 \rightarrow \mathbb{R}^7$ . Úloha nelineárních nejmenších čtverců je

$$\text{Minimalizuj} \quad f(\mathbf{x}) := \|\mathbf{g}(\mathbf{x})\|^2 = \sum_{i=1}^7 g_i(\mathbf{x})^2, \quad \mathbf{x} \in \mathbb{R}^2.$$

Jacobiho matice (derivace) zobrazení  $\mathbf{g}$  v bodě  $\mathbf{x}$  je matice  $\mathbf{g}'(\mathbf{x}) \in \mathbb{R}^{7 \times 2}$ , která má v  $i$ -tém řádku parciální derivace

$$\frac{\partial g_i}{\partial x_1} = -\frac{t_i}{x_2 + t_i}, \quad \frac{\partial g_i}{\partial x_2} = \frac{x_1 t_i}{(x_2 + t_i)^2}.$$

Předpokládejme dále, že má matice  $\mathbf{g}'(\mathbf{x})$  plnou sloupcovou hodnotu, neboli  $\text{rank } \mathbf{g}'(\mathbf{x}) = 2$ . Potom je iterace GN metody tvaru

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \left[ \mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}'(\mathbf{x}_k) \right]^{-1} \mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}(\mathbf{x}_k).$$

Krok LM metody je

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \left[ \mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}'(\mathbf{x}_k) + \mu_k \mathbf{I} \right]^{-1} \mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}(\mathbf{x}_k),$$

kde  $\mu_k > 0$  je regularizační parametr. Pro malá  $\mu_k$  tak dostaneme přibližně GN iteraci, což může pomoci urychlit konvergenci v blízkém okolí hledaného optima. Pro velká  $\mu_k$  je naopak krok LM iterace přibližně iterací gradientní metody, neboť derivace funkce  $f$  je  $f'(\mathbf{x}) = 2\mathbf{g}(\mathbf{x})^\top \mathbf{g}'(\mathbf{x})$  a platí,

$$\mathbf{x}_{k+1} \approx \mathbf{x}_k - \mu_k \mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}(\mathbf{x}_k) = \mathbf{x}_k - \frac{1}{2} \mu_k f'(\mathbf{x}_k)^\top.$$

To nám umožňuje docílit robustnosti (spolehlivosti pro počáteční odhady daleko od optima). Newtonova metoda použitá na minimalizaci funkce  $f$  vyžaduje Hessián funkce  $f$ , který lze vyjádřit jako

$$f''(\mathbf{x}) = 2\mathbf{g}'(\mathbf{x})^\top \mathbf{g}'(\mathbf{x}) + 2 \sum_{i=1}^7 g_i(\mathbf{x}) g_i''(\mathbf{x}).$$

Iterace Newtonovy metody je

$$\mathbf{x}_{k+1} = \mathbf{x}_k - f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^\top.$$

Newtonova metoda konverguje kvadraticky k lokálnímu minimu v jeho blízkém okolí, ovšem vyžaduje navíc výpočet Hessiánu a není typicky robustní vůči počátečním iteracím daleko od hledaného optima.