

# PA081: Programování numerických výpočtů

## 10. Modelování experimentálních dat, metoda nejmenších čtverců

Aleš Křenek

jaro 2011

# Modelování experimentálních dat

- ▶ v experimentu naměříme v bodech  $x_i$  hodnoty  $y_i$ 
  - ▶  $x$  může být libovolná veličina: čas, napětí, poloha, ...
- ▶ chování systému popisujeme modelem  $y = \mathbf{M}(x)$
- ▶ model závisí na sadě parametrů  $a_i$ , tj.


$$y = \mathbf{M}(x, a_1, \dots, a_M)$$

- ▶ hledáme takové hodnoty  $a_i$ , pro něž model odpovídá nejlépe experimentu

# Modelování experimentálních dat

## Příklad

- ▶ radioaktivní rozpad  $N = N_0 e^{-\frac{t \ln 2}{T}}$
- ▶  $N$  je počet atomů ve vzorku ( $N_0$  v čase  $t = 0$ ),  $T$  poločas rozpadu



# Metoda nejmenších čtverců

## Odvození

- ▶ „Jaká je pravděpodobnost, že konkrétní sada parametrů  $a_i$  je správná?“
  - ▶ špatně položená otázka
  - ▶ neexistuje „náhodná veličina modelů“
  - ▶ naopak, náhodnou veličinou jsou měřená data zatížená chybou
- ▶ tedy „Při daných parametrech  $a_i$ , jaká je pravděpodobnost měření  $(x_i, y_i)$ ?“

# Metoda nejmenších čtverců

## Odvození

- ▶ „Jaká je pravděpodobnost, že konkrétní sada parametrů  $a_i$  je správná?“
  - ▶ špatně položená otázka
  - ▶ neexistuje „náhodná veličina modelů“
  - ▶ naopak, náhodnou veličinou jsou měřená data zatížená chybou
- ▶ tedy „Při daných parametrech  $a_i$ , jaká je pravděpodobnost měření  $(x_i, y_i)$ ?“
  - ▶ nulová, je-li  $y$  spojitá veličina
  - ▶ musíme přidat „plus/minus odchylka měření  $\Delta y$ “
- ▶ model považujeme za správný, maximalizuje-li tuto pravděpodobnost
  - ▶ i tak je to velmi intuitivní konstrukce

# Metoda nejmenších čtverců

## Odvození

- předpokládáme normální rozložení chyby měření
- pravděpodobnost výskytu dané sady měření

$$\prod e^{-\frac{1}{2} \left( \frac{y_i - \mathbf{M}(x_i)}{\sigma} \right)^2} \Delta y$$

- maximalizace odpovídá minimalizaci logaritmu, tj.

$$\left( \sum \frac{(y_i - \mathbf{M}(x_i))^2}{2\sigma^2} \right) - N \ln \Delta y$$

- $N, \sigma, \Delta y$  jsou konstanty

# Metoda nejmenších čtverců

## Poznámky

- ▶ rozložení chyby všech měření nemusí být stejné
  - ▶ používá se modifikovaná funkce

$$\chi^2 = \sum \frac{(y_i - \mathbf{M}(x_i))^2}{2\sigma_i^2}$$

# Metoda nejmenších čtverců

## Poznámky

- ▶ rozložení chyby všech měření nemusí být stejné
  - ▶ používá se modifikovaná funkce

$$\chi^2 = \sum \frac{(y_i - \mathbf{M}(x_i))^2}{2\sigma_i^2}$$

- ▶ rozložení chyby nemusí být normální
  - ▶ počet měření v jednom bodě bývá příliš malý
  - ▶ zatížení chybou typu „někdo kopl do váhy“
  - ▶ metoda je na takové chyby nepřiměřeně citlivá
  - ▶ tzv. robustní statistiky

# Metoda nejmenších čtverců

## Poznámky

- ▶ rozložení chyby všech měření nemusí být stejné

- ▶ používá se modifikovaná funkce

$$\chi^2 = \sum \frac{(y_i - \mathbf{M}(x_i))^2}{2\sigma_i^2}$$

- ▶ rozložení chyby nemusí být normální

- ▶ počet měření v jednom bodě bývá příliš malý
  - ▶ zatížení chybou typu „někdo kopl do váhy“
  - ▶ metoda je na takové chyby nepřiměřeně citlivá
  - ▶ tzv. robustní statistiky


- ▶ systematická chyba

- ▶ např. špatně kalibrovaný přístroj, závislost na související veličině

# Metoda nejmenších čtverců

## Zhodnocení vypočtených parametrů

- ▶ minimalizací  $\chi^2$  se téměř vždy hodnot  $a_i$  dopočítáme
- ▶ nevypovídá to ještě nic o kvalitě modelu
- ▶ např. lineární model radioaktivního rozpadu



# Metoda nejmenších čtverců

## Zhodnocení vypočtených parametrů

- ▶ „chi by eye“ nebo seriozní statistické zhodnocení
- ▶ hodnotíme pomocí *regularizované gamma funkce*
  - ▶ funkce konkrétního  $\chi^2$  a počtu stupňů volnosti ( $N - M$ )

$$Q\left(\frac{N - M}{2}, \frac{\chi^2}{2}\right)$$

- ▶ viz např. [http://en.wikipedia.org/wiki/Incomplete\\_gamma\\_function](http://en.wikipedia.org/wiki/Incomplete_gamma_function)
- ▶ pravděpodobnost, že zcela náhodně vybraný vzorek  $(x_i, y_i)$  dá větší hodnotu  $\chi^2$
- ▶ čím větší tím lepší
  - ▶  $Q > 0.1$  je v pořádku
  - ▶  $Q \in [0.001, 0.1]$  je podezřelé, ale stále přijatelné, není-li distribuce chyb měření zcela normální, resp. je mírně podceněná
  - ▶  $Q < 0.001$  znamená špatný model nebo zcela nesmyslné měření

# Lineární regrese

- ▶ data prokládáme přímkou  $a + bx = 0$
- ▶ obecnější než se zdá na první pohled
  - ▶ data  $(x, y)$  lze předem libovolně (nelineárně) transformovat na  $(x', y')$
- ▶ minimalizovaná funkce

$$\chi^2(a, b) = \sum \frac{(y_i - a - bx_i)^2}{2\sigma_i^2}$$

- ▶ minimum v bodě nulových prvních derivací

$$0 = \frac{\partial \chi^2}{\partial a} = -2 \sum \frac{y_i - a - bx_i}{\sigma_i^2}$$

$$0 = \frac{\partial \chi^2}{\partial b} = -2 \sum \frac{x_i(y_i - a - bx_i)}{\sigma_i^2}$$

# Lineární regrese

- ▶ vhodným vyjádřením faktorů  $S, S_x, S_y, S_{xx}, S_{xy}$ 
  - ▶ součty zlomků konstruovaných z  $x_i, y_i, \sigma_i$
  - ▶ vše jsou to tady konstanty
- ▶ řešíme systém lineárních rovnic

$$Sa + S_x b = S_y$$

$$S_x a + S_{xx} b = S_{xy}$$

- ▶ získáme řešení, ale nevíme nic o jeho kvalitě
  - ▶ odhad podle grafu nebo výpočet  $Q$
  - ▶ uvedená lineární regrese na radioaktivní rozpad začíná být přijatelná až když připustíme  $\sigma_i > 1.6$

# Obecný model

- ▶  $\mathbf{M}(x, a_1, \dots, a_M)$  je nelineární funkce v  $a_i$ 
  - ▶ nelinearity v  $x$  by nevadila, viz dále
- ▶ výpočet minimálního  $\chi$  standardními optimalizačními metodami
- ▶ existují speciální varianty právě pro tvar funkce

$$\chi^2(a_1, \dots, a_M) = \sum \frac{(y_i - \mathbf{M}(x_i, a_1, \dots, a_M))^2}{2\sigma_i^2}$$

- ▶ včetně verzí s dostupnými prvními i druhými derivacemi
- ▶ díky speciálnímu použití další triky
- ▶ konkrétní metody
  - ▶ Levenberg-Marquardt
  - ▶ Moré
- ▶ např. NAG library

# Lineární modely

- ▶ model  $\mathbf{M}(x, \alpha_1, \dots, \alpha_M)$  je lineární kombinace

$$\mathbf{M}(x, \alpha_1, \dots, \alpha_M) = \sum \alpha_j X_j(x)$$

- ▶ linearita ve smyslu parametrů modelu  $\alpha_j$
- ▶ základní funkce  $X_j$  mohou být jakékoli
  - ▶ pro výhodnocení modelu se použijí jen jejich konkrétní hodnoty v bodech  $x_i$
- ▶ opět minimalizujeme  $\chi^2$
- ▶ definujeme matici **A** a vektor **b**

$$A_{ij} = \frac{X_j(x_i)}{\sigma_i} \quad b_i = \frac{y_i}{\sigma_i}$$

# Lineární modely

- ▶ derivováním dostáváme  $M$  rovnic pro  $k = 1, \dots, M$

$$0 = \sum_i \frac{1}{\sigma_i^2} \left( y_i - \sum_j a_j X_j(x_i) \right) X_k(x_i)$$

- ▶ po úpravách v maticovém vyjádření

$$(A^T A) \mathbf{a} = A^T \mathbf{b}$$

- ▶ řešení bývá citlivé na zaokrouhlovací chyby
- ▶ preferovaná technika je QR rozklad

# Lineární modely

## Rozklad na singulární hodnoty

- ▶ model nemusí být dokonalý, mohou se objevit téměř lineární závislosti
  - ▶ některé základní funkce nebo jejich kombinace jsou pro danou datovou sadu irrelevantní
- ▶ vede na téměř singulární matici
  - ▶ standardní metody inklinují k velkým hodnotám irrelevantních parametrů
- ▶ SVD dokáže tyto problémy identifikovat
- ▶ algoritmus přímo hledá nejbližší řešení, tj. minimalizuje


$$|\mathbf{A}\mathbf{a} - \mathbf{b}|^2$$

- ▶ zároveň detekuje problematické funkce

# Lineární modely

## Rozklad na singulární hodnoty

- ▶ stejná data, kvadratické a kubická funkce



# Lineární modely

- ▶ tabulka singulárních hodnot pro různé řády polynomu

řád	$\sigma_i$					
1	5.18	537.24				
2	39654.25	3.51	134.10			
3	31922200.00	66338.90	564.94	25.73		
4	2685350000.00	4133810.00	19913.70	272.78	99.50	

- ▶ koeficienty u  $x^n$  pro  $n > 4$  jsou téměř nulové

# Vícerozměrná data

- ▶ místo dvojic  $(x_i, y_i)$  máme  $(\mathbf{x}_i, y_i)$ 
  - ▶  $\mathbf{x}$  je  $k$ -rozměrný vektor
- ▶ model  $\mathbf{M}$  je funkce  $\mathbb{R}^k \rightarrow \mathbb{R}$
- ▶ jinak se nic nemění
  - ▶ minimalizujeme vůči parametrům
  - ▶ základní funkce se pouze vyhodnocují v  $\mathbf{x}_i$
  - ▶ není třeba derivovat podle složek  $\mathbf{x}_i$