

## Stručné shrnutí semináře 11

**Interpolace funkčních závislostí (fitování).** Studujeme chování veličiny  $y$  v závislosti na  $x$ , máme tedy k dispozici  $n$  dvojic  $(x_i, y_i)$  ... např. naměřená data. Nejistotu nezávislé veličiny  $x$  považujeme obvykle za zanedbatelnou vůči nejistotě závislé veličiny  $y$ .

Předpokládáme nějaký konkrétní tvar funkční závislosti  $y=f(x)$  a chceme posoudit jeho platnost, resp. získat hodnoty parametrů této závislosti. K tomu lze využít **metodu nejmenších čtverců**, která spočívá v minimalizaci veličiny

$$\chi^2(\alpha, \beta, \gamma, \dots) = \sum_{i=1}^N \frac{(f(x_i | \alpha, \beta, \gamma, \dots) - y_i)^2}{\sigma_{y_i}^2}$$

Hodnoty hledaných parametrů jsou ty, které minimalizují  $\chi^2$ .

Je-li  $f(x)$  **lineární** funkcí parametrů  $\alpha, \beta, \chi, \dots$ , lze pro problém minimalizace  $\chi^2$  nalézt **analytické** řešení a hovoříme o **lineární regresi**. Některé nelineární funkce lze linearizovat (exponenciálu lze zlogaritmovat).

V ostatních případech analytické řešení nemáme a minimum  $\chi^2$  je nutno hledat **numericky**. Pak jde o **nelineární regresi**, iterativní numerický proces, který je nutno uživatelsky kontrolovat. Pro složitější  $f(x)$  často velice záleží na počáteční volbě parametrů  $\alpha, \beta, \chi, \dots$ . Při nevhodné volbě parametrů může algoritmus uvíznout v lokálním minimu  $\chi^2$ , a tak dospět k nesprávnému výsledku.

Náhodné poznámky a rady:

- Většinou jsou fyzikální veličiny spojité funkce.  $f(x)$  je pak tedy také spojitá funkce (tj. čára v grafu). (Neboli: naměřené body nejsou závislost. Ale využíváme je ke konstrukci té hledané závislosti.)
- Je rozdíl mezi vyhlažováním (tj. interpolování po částech pomocí polynomů – např. metodou *spline*) a výše popsanou regresí. Protože ve fyzice obvykle známe tvar hledané funkce  $f(x)$ , proto se ho vždy snažíme použít při fitování. Interpolace pomocí *spline* sice může být v grafu hezké vodítko pro oko, ale nemá žádný fyzikální význam.
- Některé algoritmy, veličiny nebo charakteristiky mohou mít v různých programech odlišnou implementaci či definici. Vždy je dobré se přesvědčit, jak je to v daném programu zadefinováno. Obecně vždy byste měli mít jistotu, že program dělá právě a jenom to, co chcete, aby dělal.
- Obvykle program umí znázornit chybové úsečky (nejistoty fitovaných dat), a často je i umí zohlednit (jako váhy jednotlivých bodů) při výpočtu hodnot hledaných parametrů funkce  $f(x)$ . To ale ještě neznamená, že je umí promítnout také do nejistot těch získaných parametrů. Zpravidla tomu tak není. Ke správnému započtení by totiž byly potřeba dodatečné předpoklady o charakteru nejistot fitovaných dat (např. že jsou normálně rozděleny, jak jsou korelovány, apod.).
- Fit přímkou je sice častý případ lineární regrese, nicméně lineární regrese je obecnější pojem – jde o fitování jakoukoliv funkcí  $f(x; \alpha, \beta, \chi, \dots)$ , která je lineární kombinací svých parametrů  $\alpha, \beta, \chi, \dots$  (např. polynom  $n$ -tého stupně proměnné  $x$ ), tj. vede na lineární problém řešitelný analyticky. Někdy lidé nesprávně hovoří o lineární regresi, když mají na mysli fit lineární závislostí (přímkou), a o nelineární regresi, když mají na mysli fit nelineární funkcí (např. parabolou).
- Reziduální analýza a další nástroje (statistické charakteristiky) mohou pomoci posoudit, jak je zvolený model vhodný.