

Zobecněná metoda nejmenších čtverců

- pozorovatelné: $\mathbf{y} = (y_1, y_2, \dots, y_J)^T \quad J \times 1$
- teoretický model: $\mathbf{y} = \mathbf{y}(\boldsymbol{\theta})$
- parametry: $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_M)^T \quad M \times 1$
- zpravidla $M < J$
- **apriorní informace:**
 - odhad vektoru parametrů: $\boldsymbol{\xi} = (\xi_1, \xi_2, \dots, \xi_M)^T \quad M \times 1$
 - kovarianční matice: $A_{i,j} = \text{cov}(\xi_i, \xi_j) \quad M \times M$

- apriorní hustota pravděpodobnosti: $f(\boldsymbol{\theta} | \boldsymbol{\xi}, \mathbf{A}) \propto \exp \left[-\frac{1}{2} (\boldsymbol{\xi} - \boldsymbol{\theta})^T \mathbf{A}^{-1} (\boldsymbol{\xi} - \boldsymbol{\theta}) \right]$

- **posteriorní informace:**
 - naměřená data: $\boldsymbol{\eta} = (\eta_1, \eta_2, \dots, \eta_N)^T \quad N \times 1$
 - kovarianční matice: $B_{i,j} = \text{cov}(\eta_i, \eta_j) \quad N \times N$

- věrohodnost: $P(\boldsymbol{\eta} | \mathbf{y}(\boldsymbol{\theta}), \mathbf{B}) \propto \exp \left[-\frac{1}{2} (\boldsymbol{\eta} - \mathbf{y}(\boldsymbol{\theta}))^T \mathbf{B}^{-1} (\boldsymbol{\eta} - \mathbf{y}(\boldsymbol{\theta})) \right]$

Zobecněná metoda nejmenších čtverců

- **posteriorní hustota pravděpodobnosti:**

$$f(\boldsymbol{\theta}|\boldsymbol{\eta}, \boldsymbol{B}, \boldsymbol{\xi}, \boldsymbol{A}) \propto P(\boldsymbol{\eta}|\boldsymbol{y}(\boldsymbol{\theta}), \boldsymbol{B})f(\boldsymbol{\theta}|\boldsymbol{\xi}, \boldsymbol{A})$$

$$f(\boldsymbol{\theta}|\boldsymbol{\eta}, \boldsymbol{B}, \boldsymbol{\xi}, \boldsymbol{A}) \propto \exp \left[-\frac{1}{2} (\boldsymbol{\eta} - \boldsymbol{y}(\boldsymbol{\theta}))^T \boldsymbol{B}^{-1} (\boldsymbol{\eta} - \boldsymbol{y}(\boldsymbol{\theta})) - \frac{1}{2} (\boldsymbol{\xi} - \boldsymbol{\theta})^T \boldsymbol{A}^{-1} (\boldsymbol{\xi} - \boldsymbol{\theta}) \right]$$

$$\ln f = -\frac{1}{2} (\boldsymbol{\eta} - \boldsymbol{y}(\boldsymbol{\theta}))^T \boldsymbol{B}^{-1} (\boldsymbol{\eta} - \boldsymbol{y}(\boldsymbol{\theta})) - \frac{1}{2} (\boldsymbol{\xi} - \boldsymbol{\theta})^T \boldsymbol{A}^{-1} (\boldsymbol{\xi} - \boldsymbol{\theta}) + K$$

- pokud jsou odhady parametrů $\boldsymbol{\xi}$ a naměřené hodnoty $\boldsymbol{\eta}$ nezávislé:

$$\ln f = -\frac{1}{2} \sum_{i=1}^N \frac{(\eta_i - y_i(\boldsymbol{\theta}))^2}{\sigma_{\eta_i}^2} - \frac{1}{2} \sum_{j=1}^M \frac{(\xi_j - \theta_j)^2}{\sigma_{\xi_j}^2} + K$$

Fit histogramu

$$x_1, x_2, \dots, x_N \quad f(x|\theta) \quad \theta = (\theta_1, \theta_2, \dots, \theta_M)$$

• místo $x_1, x_2, \dots, x_N \rightarrow$ histogram K binů $\mathbf{n} = (n_1, n_2, \dots, n_K)$

• pravděpodobnost, že výsledek padne do i -tého binu $P_i = \int_{x_i - \frac{\Delta}{2}}^{x_i + \frac{\Delta}{2}} f(x|\theta) dx$


• očekávaná hodnota v i -tém binu: $v_i(\theta) = NP_i = N \int_{x_i - \frac{\Delta}{2}}^{x_i + \frac{\Delta}{2}} f(x|\theta) dx$

• věrohodnost (multinomické rozdělení):



$$L(\theta) = P(\mathbf{n}|\nu) = \frac{N!}{n_1!n_2!\dots n_K!} \left(\frac{\nu_1(\theta)}{N}\right)^{n_1} \dots \left(\frac{\nu_K(\theta)}{N}\right)^{n_K}$$

$$\ln L(\theta) = \sum_{i=1}^K n_i \ln [\nu_i(\theta)] + \ln \left(\frac{N!}{n_1!n_2!\dots n_K!} \right) - N \ln N$$

posteriorní hustota pravděpodobnosti: $f(\theta|\mathbf{n}) \propto L(\theta)f(\theta)$




Příklad – difrakce na štěrbině



$$I = I_0 \left(\frac{\sin u}{u} \right)^2$$

$$u = \frac{1}{2} kb\phi = \frac{b\phi}{\lambda} \quad \phi \in \langle -\phi_0, \phi_0 \rangle$$

Příklad – difrakce na šterbině



$$I = I_0 \left(\frac{\sin u}{u} \right)^2 \quad u = \frac{1}{2} kb\phi = \frac{b\phi}{\lambda} \quad \phi \in \langle -\phi_0, \phi_0 \rangle$$

• normalizace: $\frac{1}{\xi} = \int_{-\phi_0}^{\phi_0} I(\phi) d\phi$

$$I = \xi(b) \left(\frac{\sin u(b)}{u(b)} \right)^2$$


$$\nu_i(\theta) = \nu_i(b) = N \int_{\phi_i - \frac{\Delta}{2}}^{\phi_i + \frac{\Delta}{2}} \xi(b) \left(\frac{\sin \left(\frac{1}{2} kb\phi \right)}{\frac{1}{2} kb\phi} \right)^2 d\phi \approx N \xi(b) \left(\frac{\sin \left(\frac{1}{2} kb\phi_i \right)}{\frac{1}{2} kb\phi_i} \right)^2 \Delta$$

$$\ln L = \sum_{i=1}^K n_i \ln \nu_i(b) = \sum_{i=1}^K n_i \ln (\xi(b)) + 2 \sum_{i=1}^K n_i \ln \left(\sin \left(\frac{1}{2} kb\phi_i \right) \right) - 2 \sum_{i=1}^K n_i \ln \left(\frac{1}{2} kb\phi_i \right) + N \ln(N \Delta)$$

$$\sigma_b \approx \left(- \frac{d^2 \ln L}{db^2} \Big|_{b=b_0} \right)^{-\frac{1}{2}}$$



Příklad – difrakce na šterbině

$$\ln L = \sum_{i=1}^K n_i \ln \nu_i(b) = \sum_{i=1}^K n_i \ln(\xi(b)) + 2 \sum_{i=1}^K \ln \left(\sin \left(\frac{1}{2} kb \phi_i \right) \right) - 2 \sum_{i=1}^K n_i \ln \left(\frac{1}{2} kb \phi_i \right) + N \ln(N \Delta)$$



Příklad – difrakce na šěrbině

$$\frac{n_i - I(\phi_i)}{\sqrt{n_i}}$$



Testování hypotéz

- hypotéza H
 - naměřená data D
- věrohodnost, tj. pravděpodobnost,
že naměříme data D
pokud hypotéza H platí apriorní víra v pravdivost hypotézy H

posteriorní víra
v pravdivost
hypotézy H

$$\longrightarrow P(H|D, I) = \frac{P(D|H, I)P(H|I)}{P(D|I)}$$


normovací člen
pravděpodobnost, že naměříme data D

- použití zákona celkové pravděpodobnosti $P(D|I) = P(D|H, I)P(H|I) + P(D|\bar{H}, I)P(\bar{H}, I)$

$$P(H|D, I) = \frac{P(D|H, I)P(H|I)}{P(D|H, I)P(H|I) + P(D|\bar{H}, I)P(\bar{H}, I)}$$

Dvě alternativní hypotézy

- hypotéza A: veličina $y = 0$
- hypotéza B: veličina y je nějaká konstanta λ




poměr věrohodností poměr apriorních pravděpodobností

poměr
posteriorních
pravděpodobností

$$\frac{P(A|D, I)}{P(B|D, I)} = \frac{P(D|A, I) P(A, I)}{P(D|B, I) P(B, I)}$$

- věrohodnost pro hypotézu B: $P(D|B, I) = \int P(D, \lambda|B, I) d\lambda = \int P(D|\lambda, B, I) f(\lambda|B, I) d\lambda$

- apriorní hustota pravděpodobnosti parametru λ : $f(\lambda|B, I) = \begin{cases} \frac{1}{\lambda_{max} - \lambda_{min}} & \lambda \in \langle \lambda_{min}, \lambda_{max} \rangle \\ 0 & \text{jinak} \end{cases}$



$$P(D|\lambda, B, I) = P(D|\lambda_0, B, I) \exp \left[-\frac{(\lambda - \lambda_0)^2}{2\sigma_\lambda^2} \right]$$

Dvě alternativní hypotézy

- hypotéza A: veličina $y = 0$
- hypotéza B: veličina y je nějaká konstanta λ

poměr věrohodností poměr apriorních pravděpodobností


poměr
posteriorních
pravděpodobností

$$\frac{P(A|D, I)}{P(B|D, I)} = \frac{P(D|A, I) P(A, I)}{P(D|B, I) P(B, I)}$$

- věrohodnost pro hypotézu B: $P(D|B, I) = \frac{1}{\lambda_{max} - \lambda_{min}} \int_{\lambda_{min}}^{\lambda_{max}} P(D|\lambda, B, I) d\lambda$

• po dosazení:

$$P(D|B, I) = \frac{P(D|\lambda_0, B, I) \sqrt{2\pi\sigma_\lambda}}{\lambda_{max} - \lambda_{min}}$$



$$P(D|\lambda, B, I) = P(D|\lambda_0, B, I) \exp \left[-\frac{(\lambda - \lambda_0)^2}{2\sigma_\lambda^2} \right]$$

Dvě alternativní hypotézy

- hypotéza A: veličina $y = 0$
- hypotéza B: veličina y je nějaká konstanta λ

poměr apriorních pravděpodobností

poměr věrohodností

poměr
posteriorních
pravděpodobností

$$\frac{P(A|D, I)}{P(B|D, I)} = \frac{P(A, I)}{P(B, I)} \frac{P(D|A, I)}{P(D|\lambda_0, B, I)} \frac{\lambda_{max} - \lambda_{min}}{\sqrt{2\pi}\sigma_\lambda}$$


- pokud je $P(A, I) = P(B, I)$

$$P(D|A, I) \approx P(D|\lambda_0, B, I)$$

$$\sigma_\lambda \ll \lambda_{max} - \lambda_{min}$$

} preferujeme hypotézu A

↑ Ockhamův člen
(penalizační faktor
pro hypotézu B)



$$P(D|\lambda, B, I) = P(D|\lambda_0, B, I) \exp \left[-\frac{(\lambda - \lambda_0)^2}{2\sigma_\lambda^2} \right]$$

Dvě alternativní hypotézy

- hypotéza A: veličina $y = 0$
- hypotéza B: veličina y je nějaká konstanta λ

poměr apriorních pravděpodobností

poměr věrohodností

poměr
posteriorních
pravděpodobností

$$\frac{P(A|D, I)}{P(B|D, I)} = \frac{P(A, I)}{P(B, I)} \frac{P(D|A, I)}{P(D|\lambda_0, B, I)} \frac{\lambda_{max} - \lambda_{min}}{\sqrt{2\pi}\sigma_\lambda}$$


- pokud je $P(A, I) = P(B, I)$

$$P(D|A, I) \ll P(D|\lambda_0, B, I)$$

$$\sigma_\lambda \ll \lambda_{max} - \lambda_{min}$$

preferujeme hypotézu B
tj. hypotéza s více parametry
musí vést k výrazně lepšímu
souhlasu s experimentem

Ockhamův člen
(penalizační faktor
pro hypotézu B)



$$P(D|\lambda, B, I) = P(D|\lambda_0, B, I) \exp \left[-\frac{(\lambda - \lambda_0)^2}{2\sigma_\lambda^2} \right]$$

Dvě alternativní hypotézy

- hypotéza A: veličina y je nějaká konstanta μ
- hypotéza B: veličina y je nějaká konstanta λ

poměr apriorních pravděpodobností



poměr věrohodností

poměr
posteriorních
pravděpodobností

$$\frac{P(A|D, I)}{P(B|D, I)} = \frac{P(A, I)}{P(B, I)} \frac{P(D|\mu_0, A, I)}{P(D|\lambda_0, B, I)} \frac{\lambda_{max} - \lambda_{min}}{\mu_{max} - \mu_{min}} \frac{\sigma_\mu}{\sigma_\lambda}$$

$$P(D|\lambda, B, I) = P(D|\lambda_0, B, I) \exp \left[-\frac{(\lambda - \lambda_0)^2}{2\sigma_\lambda^2} \right]$$

$$P(D|\mu, B, I) = P(D|\mu_0, B, I) \exp \left[-\frac{(\mu - \mu_0)^2}{2\sigma_\mu^2} \right]$$



Dvě alternativní hypotézy

- hypotéza A: veličina y je nějaká konstanta μ
- hypotéza B: veličina y je nějaká konstanta λ

poměr apriorních pravděpodobností

poměr věrohodností

poměr
posteriorních
pravděpodobností

$$\frac{P(A|D, I)}{P(B|D, I)} = \frac{P(A, I)}{P(B, I)} \frac{P(D|\mu_0, A, I)}{P(D|\lambda_0, B, I)} \frac{\lambda_{max} - \lambda_{min}}{\mu_{max} - \mu_{min}} \frac{\sigma_\mu}{\sigma_\lambda}$$

- pokud je $P(A, I) = P(B, I)$

$$P(D|\mu_0, A, I) = P(D|\lambda_0, B, I)$$

$$\mu_{max} - \mu_{min} = \lambda_{max} - \lambda_{min}$$

$$\frac{P(A|D, I)}{P(B|D, I)} = \frac{P(A, I)}{P(B, I)} \frac{P(D|\mu_0, A, I)}{P(D|\lambda_0, B, I)} \frac{\sigma_\mu}{\sigma_\lambda}$$

- pokud je $P(A, I) = P(B, I)$

$$P(D|\mu_0, A, I) = P(D|\lambda_0, B, I)$$

$$\sigma_\mu = \sigma_\lambda$$

$$\frac{P(A|D, I)}{P(B|D, I)} = \frac{P(A, I)}{P(B, I)} \frac{P(D|\mu_0, A, I)}{P(D|\lambda_0, B, I)} \frac{\lambda_{max} - \lambda_{min}}{\mu_{max} - \mu_{min}}$$