

11. cvičení

Úloha 1 (MLE společně)

Máme náhodný výběr $X_1, \dots, X_n \sim \text{Geom}(p)$, jako parametr nás zajímá $\vartheta = p$. Navrhněte bodový odhad ϑ metodou maximální věrohodnosti.

Úloha 2 (Opět mince)

Hodíme 100krát spravedlivou mincí. Kolikrát nám v průměru padne orel? Pomocí CLV dále odhadněte pravděpodobnost, že padne více než 60 orlů.

Úloha 3

Němci vyrábějí tanky s pořadovými čísly $1, \dots, N$ pro neznámé N . Ukořistíme k z nich a vidíme pořadová čísla X_1, \dots, X_k , tj. rovnoměrně náhodnou k -prvkovou podmnožinu $\{1, \dots, N\}$. Necht' $M = \max(X_1, \dots, X_k)$.

- Ukažte, že $P(M = m) = \frac{\binom{m-1}{k-1}}{\binom{N}{k}}$ pro $m \in \{k, \dots, N\}$.
- Připomeňte si, že M je MLE pro N (ukazovali jsme na přednášce).
- Spočtete $\mathbb{E}(M) = \frac{k(N+1)}{k+1}$. Může se hodit hockey-stick identity: $\sum_{m=k}^N \binom{m}{k} = \binom{N+1}{k+1}$. Pak si připomeňte, jak z toho plyne nestranný odhad $\hat{N}_{unbiased} = \frac{k+1}{k} M - 1$ (**Pozor: na přednášce bylo místo -1 napsáno $-\frac{k+1}{k}$ — to byla chyba.**)

Úloha 4 (MLE once more)

Máme náhodný výběr $X_1, \dots, X_n \sim N(\mu, 1)$ – data na vstupu x_1, \dots, x_n tedy pochází z normální distribuce s neznámým středem μ , ale známou směrodatnou odchylkou 1.

- Napište věrohodnostní (likelihood) funkci $p_\theta(x)$; později se může hodit pracovat s funkcí $\log p_\theta(x)$, které se říká log-likelihood.
- Derivací spočtete $\hat{\mu}_{MLE}$, mělo by vyjít $\hat{\mu}_{MLE} = \frac{1}{n} \sum_{i=1}^n x_i$.
- Ověřte, že $\hat{\mu}_{MLE}$ je nestranný.
- Přesvědčte se, že kdyby směrodatná odchylka nebyla 1, ale byl to jakýkoliv (nám známý) parametr σ^2 , $\hat{\mu}_{MLE}$ by vyšlo úplně stejně; volba $\sigma^2 = 1$ jen zjednodušuje výpočet.

Úloha 5 (Nestranný \neq dobrý)

Najděte příklad nějakého nestranného estimátoru (třeba pro problémy z předchozích úloh), který je zjevně hodně špatný.

Tahák

- Centrální limitní věta:** Označme $Y_n = ((X_1 + \dots + X_n) - n\mu)/(\sqrt{n} \cdot \sigma)$. Pak $Y_n \xrightarrow{d} N(0, 1)$. Neboli

$$\lim_{n \rightarrow \infty} F_{Y_n}(x) = \Phi(x) \quad \text{pro každé } x \in \mathbb{R}.$$

- Na počítání $\Phi(x)$: <https://t.ly/JRQ2>
- Zkoumáme posloupnost n.n.v. se stejným rozdělením, např. $\text{Geom}(\theta)$, $U(0, \theta)$, kde θ je parametr.
- Zapisujeme $X_1, \dots, X_n \sim F_\theta$, tzv. náhodný výběr z F_θ (model s parametrem).
- Naměříme $X_1 = x_1, \dots$, chceme odhadnout θ .
- $\hat{\theta}$... nějaká metoda jak odhadnout θ pomocí naměřených dat (hodnot X_1, \dots, X_n). Angl. *estimator* – jeden získaný odhad je *estimate*, ten značíme $\hat{\theta}$.
- $L(\theta; x_1, \dots, x_n) = P[X_1 = x_1 \wedge \dots \wedge X_n = x_n]$... pravd. pozorovaných dat závislá na parametru θ .
- nebo $L(\dots) = f_{X_1, \dots, X_n}(x_1, \dots, x_n)$... hustota pravděpodobnosti ...

- $\ell(\theta; x_1, \dots, x_n) = \log L(\dots)$... pro snazší výpočty.
- *Odhad metodou maximální věrohodnosti (Maximal Likelihood)* hledáme θ , pro které je maximální $L(\theta; x_1, \dots, x_n)$, resp. $\ell(\dots)$. Obvykle pomocí derivací funkce L , resp. ℓ .
- bias (vychýlení): $\mathbb{E}(\hat{\Theta} - \theta)$... θ skutečný parametr, $\hat{\Theta}$ náš odhad (náhodná veličina, protože závisí na naměřených datech)
- odhad je nevychýlený/nestranný/unbiased: bias = 0
- odhad je asymptoticky nevychýlený: bias konverguje k 0, neboli $\mathbb{E}(\hat{\Theta}) \rightarrow \theta$
- odhad je konzistentní: $\hat{\Theta}$ konverguje k 0 v pravděpodobnosti: pro všechna $\varepsilon > 0$: $P(|\hat{\Theta} - \theta| > \varepsilon) \rightarrow 0$
- MSE (mean square error, střední kvadratická odchylka): $\mathbb{E}((\hat{\Theta} - \theta)^2)$
- Věta: $\text{MSE} = \text{bias}^2 + \text{var}(\hat{\Theta})$.