

OBEČNĚ:

 $f_1(x|\theta) / f_2(t|\theta)$ závisí na θ ; $f_1(x|\theta)$... sdružená hustota \mathcal{X}

$$X_i \sim \text{Alt}(p) \Rightarrow \text{sdružená hustota: } \prod_{i=1}^N p^{x_i} (1-p)^{1-x_i}$$

$$T(\mathcal{X}) = \sum_{i=1}^N X_i \sim \text{Bin}(N, p)$$

$$X_i \dots \text{Bernoulliho pokusy} \Rightarrow X_i \sim \text{Bin}(1, p)$$

 $f_2(t|\theta)$... hustota $T(\mathcal{X})$

KONKRÉTNĚ:

$$f_1(x|p) = \prod_{i=1}^N p^{x_i} (1-p)^{1-x_i} \dots \text{sdružená hustota } \mathcal{X}$$

$$f_2(t|p) = \binom{N}{t} p^t (1-p)^{N-t} \dots \text{hustota } T(\mathcal{X}) = \sum_{i=1}^N X_i \dots \quad \boxed{t = \sum_{i=1}^N x_i}$$

$$\begin{aligned} \frac{f_1(x|p)}{f_2(t|p)} &= \frac{\prod_{i=1}^N p^{x_i} (1-p)^{1-x_i}}{\binom{N}{t} p^t (1-p)^{N-t}} \\ &= \frac{p^{\sum_{i=1}^N x_i} (1-p)^{\sum_{i=1}^N (1-x_i)}}{\binom{N}{t} p^t (1-p)^{N-t}} = \frac{p^{\sum_{i=1}^N x_i} (1-p)^{\sum_{i=1}^N 1 - \sum_{i=1}^N x_i}}{\binom{N}{t} p^t (1-p)^{N-t}} \\ &= \frac{p^{\sum_{i=1}^N x_i} (1-p)^{N - \sum_{i=1}^N x_i}}{\binom{N}{t} p^t (1-p)^{N-t}} = \frac{p^{\sum_{i=1}^N x_i} (1-p)^{N-t}}{\binom{N}{t} p^t (1-p)^{N-t}} = \frac{1}{\binom{N}{t}} = \frac{1}{\binom{N}{\sum_{i=1}^N x_i}} \dots \text{nezávisí na } p \rightarrow \end{aligned}$$

$\rightarrow T(\mathcal{X}) = \sum_{i=1}^N X_i$ je postačující statistika pro parametr p .

Poznámka: Speciálním případem statistiky je testovací statistika.

• Příklady statistik: \bar{X} , S_n^2 , S_{n-1}^2 , $Z_W = \frac{X/(N-p)}{\sqrt{p(1-p)/N}}$, $T_W = \frac{\bar{X} - \mu_0}{s} \sqrt{n}$,

$$Z_W = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n}, \text{ apod.}$$

OBEČNĚ:

$f_1(x|\theta) / f_2(t|\theta)$ nezávisí na θ ; $f_1(x|\theta)$... sdružená hustota X
 $f_2(t|\theta)$... hustota $T(X)$

KONKRÉTNĚ:

$f_1(x|\mu) / f_2(t|\mu)$ nezávisí na μ ; $f_1(x|\mu)$... sdružená hustota X , $X_i \sim N(\mu, \sigma^2)$
 $f_2(t|\mu)$... hustota $T(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n x_i \sim N(\mu, \frac{\sigma^2}{n})$

$$f_1(x|\mu) = \prod_{i=1}^n f(x_i|\mu) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}}$$

$$f_2(t|\mu) = \frac{1}{\sqrt{\frac{2\pi\sigma^2}{n}}} e^{-\frac{n(\bar{x}-\mu)^2}{2\sigma^2}} = \sqrt{\frac{n}{2\pi\sigma^2}} e^{-\frac{n(\bar{x}-\mu)^2}{2\sigma^2}}$$

$$\frac{f_1(x|\mu)}{f_2(t|\mu)} = \frac{\prod_{i=1}^n (2\pi\sigma^2)^{-\frac{1}{2}} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}}}{n^{\frac{1}{2}} (2\pi\sigma^2)^{-\frac{1}{2}} e^{-\frac{n(\bar{x}-\mu)^2}{2\sigma^2}}} = \frac{(2\pi\sigma^2)^{-\frac{n}{2}}}{n^{\frac{1}{2}} (2\pi\sigma^2)^{-\frac{1}{2}}} \cdot e^{-\frac{\sum (x_i-\mu)^2}{2\sigma^2}} \cdot e^{\frac{n(\bar{x}-\mu)^2}{2\sigma^2}} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{-\frac{n}{2} + \frac{1}{2}} \cdot e^{\frac{-\sum (x_i-\mu)^2 + n(\bar{x}-\mu)^2}{2\sigma^2}} = n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{\frac{-\sum (x_i^2 - 2x_i\mu + \mu^2) + n(\bar{x}^2 - 2\bar{x}\mu + \mu^2)}{2\sigma^2}}$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{\frac{-\sum x_i^2 + 2\mu\sum x_i - \sum \mu^2 + n\bar{x}^2 - 2\mu n\bar{x} + n\mu^2}{2\sigma^2}} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{\frac{-\sum x_i^2 + 2\mu n\bar{x} - n\mu^2 + n\bar{x}^2 - 2\mu n\bar{x} + n\mu^2}{2\sigma^2}} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{\frac{-\sum x_i^2 + n\bar{x}^2}{2\sigma^2}} = n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{\frac{-\sum x_i^2 + n\bar{x}^2 + n\bar{x}^2 - n\bar{x}^2}{2\sigma^2}} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{-\frac{1}{2\sigma^2} (\sum x_i^2 - 2n\bar{x}^2 + n\bar{x}^2)} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{-\frac{1}{2\sigma^2} (\sum x_i^2 - 2n\bar{x} \frac{1}{n} \sum x_i + n\bar{x}^2)} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{-\frac{1}{2\sigma^2} (\sum x_i^2 - 2\bar{x} \sum x_i + \sum \bar{x}^2)} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{-\frac{1}{2\sigma^2} \sum (x_i^2 - 2\bar{x}x_i + \bar{x}^2)} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{\frac{1-n}{2}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \bar{x})^2} =$$

$$= n^{-\frac{1}{2}} (2\pi\sigma^2)^{-\frac{n-1}{2}} e^{-\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{2\sigma^2}} \dots \text{nezávisí na } \mu \longrightarrow T(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \text{ je}$$

postupující statistika pro parametru μ .

3.3

Monotonní poměr věrohodnosti pro parametry p binomického rozdělení

Nechť $X \sim \text{Bin}(N, p)$, kde $\Theta = p$. Fce věrohodnosti je definována jako

$$L(p|x) = p^x (1-p)^{N-x}$$

kde $X = \sum_{i=1}^N x_i$, $x = (x_1, \dots, x_N)^T$. Poměr věrohodnosti $L(p_2|x) / L(p_1|x)$ má podobu tvaru

$$\begin{aligned} \frac{L(p_2|x)}{L(p_1|x)} &= \frac{p_2^x (1-p_2)^{N-x}}{p_1^x (1-p_1)^{N-x}} = \frac{p_2^x (1-p_2)^N (1-p_2)^{-x}}{p_1^x (1-p_1)^N (1-p_1)^{-x}} = \\ &= \frac{p_2^x (1-p_1)^x (1-p_2)^N}{p_1^x (1-p_2)^x (1-p_1)^N} = \underbrace{\left(\frac{p_2}{p_1}\right)^x}_{>1} \underbrace{\left(\frac{1-p_1}{1-p_2}\right)^x}_{>1} \underbrace{\left(\frac{1-p_2}{1-p_1}\right)^N}_{\text{konstanta} < 1} \end{aligned}$$

Při pevném zvolení p_1, p_2 ($0 < p_1 < p_2 < 1$) a N je poměr věrohodnosti monotonní (rostoucí) funkcí statistiky $x = \sum_{i=1}^N x_i$.

$N \leftarrow \dots$

$p_2 \leftarrow \dots$

$x \leftarrow 1, 2, \dots, N \dots \text{opa } x$

$p_1 \leftarrow 0.49, 0.47, \dots, 0.01 \dots \text{ krok animace}$

$\text{lbin} \leftarrow \text{function}(x, N, p) \{ L(p|x) \}$

$\text{opts} \leftarrow \text{ani.options}()$

$\text{ani.record}(\dots)$

$\text{saveLatex}(\text{for}(i \text{ in } 1:\text{length}(p1)) \{$

$L \leftarrow \frac{L(p_2|x)}{L(p_1[i]|x)}$

$\text{plot}(x, L, \text{xlab} = \dots)$

$\text{mtext}(\text{expression}(L(p[2], x) / L(p[1], x)), \text{side} = \dots, \text{line} = \dots)$

$\text{mtext}('x', \dots)$

$\text{mtext}(\text{bquote}(\text{paste}(N == .(N), 'i', p[1] == .(p1[i]), 'i', p[2] == .(p_2))), \text{side} = \dots, \text{line} = \dots)$

$\}$

3.4

Samostatná úvaha.

Monotónní poměr věrohodnosti pro parametry μ normálního rozdělení (σ^2 známe)

Nechť $X \sim N(\mu, \sigma^2)$, kde $\sigma^2 > 0$ je známý rozptyl. Fce věrohodnosti je definována jako

$$L((\mu, \sigma^2)^T | x) = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2}$$

Poměr věrohodnosti $L((\mu_2, \sigma^2)^T | x) / L((\mu_1, \sigma^2)^T | x)$ má potom tvar

$$\begin{aligned} \frac{L((\mu_2, \sigma^2)^T | x)}{L((\mu_1, \sigma^2)^T | x)} &= \frac{\frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu_2)^2}}{\frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu_1)^2}} = e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i^2 - 2\mu_2 x_i + \mu_2^2) + \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i^2 - 2\mu_1 x_i + \mu_1^2)} \\ &= e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i^2 - 2\mu_2 x_i + \mu_2^2 - x_i^2 + 2\mu_1 x_i - \mu_1^2)} = \\ &= e^{-\frac{1}{2\sigma^2} (-2\mu_2 \sum_{i=1}^n x_i + n\mu_2^2 + 2\mu_1 \sum_{i=1}^n x_i - n\mu_1^2)} = \\ &= e^{-\frac{1}{2\sigma^2} (n(\mu_2^2 - \mu_1^2) - 2n\bar{x}(\mu_2 - \mu_1))} = \\ &= e^{\underbrace{\frac{n(\mu_2 - \mu_1)}{2\sigma^2}}_{\text{konstanta } > 0 \text{ pokud } \mu_1 < \mu_2}} \underbrace{\left(2\bar{x} - (\mu_2 + \mu_1)\right)}_{\text{konstanta}} \quad (*) \end{aligned}$$

rostoucí / klesající

Δ rostoucím \bar{x} poroste celý výraz

Při pevně zvoleném μ_1, μ_2 ($\mu_1 < \mu_2$) je poměr věrohodnosti monotónní funkcí statistiky

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i.$$

sigma ← ...

mu2 ← ...

mu1 ← -0.01, -0.03, ..., -0.49 ... krok animace

m ← -0.7, -0.68, ..., 0, 0.02, ..., 0.5 ... \bar{x} ... sa x

lpomer ← function(m, mu1, mu2, sigma, n) { (*)}

opts ← ...

ani.record(...)

save Latex (for(i in 1:length(mu1)) {

L ← lpomer(...)

plot(m, L, xlab = "", ...)

mtext(expression(...), side = ..., line = ...) ... sa y

mtext(expression(bar(x)), side = ..., line = ...) ... sa x; \bar{x}

mtext(hquote(paste(mu[1] == .(mu1[i]), ... ,
sigma^2 == .(sigma^2), sep = ")), side = ...)

}