

Teoretická odvození pro zkoušku z předmětu KPST

1. Nezávislost náhodných jevů $P(A|B) = P(A) \Leftrightarrow P(A \cap B) = P(A)P(B)$

$$P(A) = P(A|B) = \frac{P(A \cap B)}{P(B)} \Rightarrow P(A \cap B) = P(A)P(B)$$

2. Bayesova věta $P(A|B) = \frac{P(B|A)P(A)}{P(B|A)P(A) + P(B|\bar{A})P(\bar{A})}$

$$\begin{aligned} P(A|B) &= \frac{P(A \cap B)}{P(B)} \text{ a zároveň } P(B|A) = \frac{P(A \cap B)}{P(A)} \Rightarrow \\ P(A|B) &= \frac{P(B|A)P(A)}{P(B)} \\ P(B) &= P(B|A)P(A) + P(B|\bar{A})P(\bar{A}) \Rightarrow \\ P(A|B) &= \frac{P(B|A)P(A)}{P(B|A)P(A) + P(B|\bar{A})P(\bar{A})} \end{aligned}$$

s využitím věty o úplné pravděpodobnosti

3. Vlastnosti střední hodnoty $\mathbb{E}(a + bX) = a + b\mathbb{E}X$

$$\begin{aligned} \mathbb{E}(a + bX) &= \sum_{i=1}^k (a + bX_i)p_i = \sum_{i=1}^k (ap_i + bX_i p_i) = \sum_{i=1}^k ap_i + \sum_{i=1}^k bX_i p_i = \\ &= a \sum_{i=1}^k p_i + b \sum_{i=1}^k X_i p_i = a + b(E)X \end{aligned}$$

4. Vlastnosti rozptylu $\mathbb{V}\text{ar}(a + bX) = b^2\mathbb{V}\text{ar}X$

$$\begin{aligned} \mathbb{V}\text{ar}(a + bX) &= \sum_{i=1}^2 (a + bX_i - (E)(a + bX))^2 p_i = \sum_{i=1}^2 (a + bX_i - (a + b(E)X))^2 p_i = \\ &= \sum_{i=1}^2 (b(X_i - (E)X))^2 p_i = b^2 \sum_{i=1}^2 (X_i - (E)X)^2 p_i = b^2\mathbb{V}\text{ar}X \end{aligned}$$

5. Dva tvary rozptylu $\mathbb{V}\text{ar}X = \mathbb{E}(X_i - \mathbb{E}X)^2 = \mathbb{E}X^2 - (\mathbb{E}X)^2$

$$\begin{aligned} \sum_{i=1}^k (X_i - \mathbb{E}X)^2 p_i &= \sum_{i=1}^k (X_i^2 - 2X_i \mathbb{E}X + (\mathbb{E}X)^2) p_i = \sum_{i=1}^k X_i^2 p_i - 2\mathbb{E}X \sum_{i=1}^k X_i p_i + (\mathbb{E}X)^2 \sum_{i=1}^k p_i = \\ &= \mathbb{E}X^2 - 2(\mathbb{E}X)^2 + (\mathbb{E}X)^2 = \mathbb{E}X^2 - (\mathbb{E}X)^2 \end{aligned}$$

6. Vlastnosti výběrové šikmosti $\text{Skew}X = \frac{1}{n} \sum_{i=1}^n Z_i^3$, kde $Z_i = \frac{X_i - \bar{X}}{\text{sd}X}$
 počítá se přes Z-skóry a pro ně platí

$$\begin{aligned} ZX_i &= \frac{X_i - \bar{X}}{\text{sd}X} \\ \text{pro } Y_i &= a + bX \text{ dostávám } ZY_i = \frac{Y_i - \bar{Y}}{\text{sd}Y} \\ ZY_i &= \frac{a + bX_i - \bar{a} + b\bar{X}}{\text{sd}(a + bX)} = \frac{a + bX_i - a + b\bar{X}}{b\text{sd}X} = \frac{b(X_i - \bar{X})}{b\text{sd}X} = ZX_i \end{aligned}$$

Z-skóry tedy vychází stejně pro proměnnou X i Y a tedy pro ně musí vycházet stejně i šikmost

7. Střední hodnota binomického rozdělení $B(n, p)$ s parametry $n = 3, p = 1/2$ je $\mathbb{E}X = np$

$$\begin{aligned} \mathbb{E}X &= \sum_{k=0}^n kP(X = k) = \sum_{k=0}^n k \binom{n}{k} p^k (1-p)^{n-k} \\ \mathbb{E}X &= 0 \binom{3}{0} \left(\frac{1}{2}\right)^0 \left(1 - \left(\frac{1}{2}\right)\right)^{3-0} + 1 \binom{3}{1} \left(\frac{1}{2}\right)^1 \left(1 - \left(\frac{1}{2}\right)\right)^{3-1} + \\ &\quad + 2 \binom{3}{2} \left(\frac{1}{2}\right)^2 \left(1 - \left(\frac{1}{2}\right)\right)^{3-2} + 3 \binom{3}{3} \left(\frac{1}{2}\right)^3 \left(1 - \left(\frac{1}{2}\right)\right)^{3-3} = \\ &= 0 + 3 \left(\frac{1}{2}\right)^3 + 2 \times 3 \left(\frac{1}{2}\right)^3 + 3 \left(\frac{1}{2}\right)^3 = \frac{3+6+3}{8} = \frac{3}{2} = np \end{aligned}$$

8. Interval spolehlivosti pro průměr vychází z $\bar{X} \sim N(\mu, \sigma^2/n)$

$$\begin{aligned} Z &= \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1) \\ \text{Chceme} \quad P(\mu \in CI) &= P(LL \leq \mu \leq UL) = 1 - \alpha \\ \text{Víme} \quad P(q(\alpha/2) \leq Z \leq q(1 - \alpha/2)) &= 1 - \alpha; \text{ a } q(\alpha/2) = -q(1 - \alpha/2) \\ P(-q(1 - \alpha/2)) &\leq \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \leq q(1 - \alpha/2)) = \\ &= P(-q(1 - \alpha/2)\sigma/\sqrt{n} - \bar{X} \leq -\mu \leq q(1 - \alpha/2)\sigma/\sqrt{n} - \bar{X}) = \\ &= P(-q(1 - \alpha/2)\sigma/\sqrt{n} - \bar{X} \leq -\mu \leq q(1 - \alpha/2)\sigma/\sqrt{n} - \bar{X}) = \\ &= P(\bar{X} + q(1 - \alpha/2)\sigma/\sqrt{n} \geq \bar{X} - \mu \geq q(1 - \alpha/2)\sigma/\sqrt{n}) \\ LL &= \bar{X} - \mu \geq q(1 - \alpha/2)\sigma/\sqrt{n} \\ UL &= \bar{X} + \mu \geq q(1 - \alpha/2)\sigma/\sqrt{n} \end{aligned}$$

kde $q(1 - \alpha/2)$ je kvantil standardního normálního rozdělení

9. Spojitost mezi jednovýběrovým t-testem a intervalem spolehlivosti pro průměr:
 testová statistika pro jednovýběrový t-test je $T = \frac{\bar{X} - \mu_0}{\text{sd}X} \sqrt{n}$,
 tato statistika má za platnosti nulové hypotézy t -rozdělení o $n - 1$ stupních volnosti,
 nulovou hypotézu (při oboustranné alternativě) zamítáme, pokud $|T| \geq qt_{n-1}(1 - \alpha/2)$,
 kde $qt_{n-1}(1 - \alpha/2)$ je kvantil t -rozdělení o $n - 1$ stupních volnosti,
 meze intervalu spolehlivosti pro průměr při neznámém rozptylu jsou

$$\begin{aligned} LL &= \bar{X} - \mu \geq qt_{n-1}(1 - \alpha/2) \text{sd}X / \sqrt{n} \\ UL &= \bar{X} + \mu \geq qt_{n-1}(1 - \alpha/2) \text{sd}X / \sqrt{n} \end{aligned}$$

z testové statistiky lze odvodit, že nulovou hypotézu zamítáme, když

$$\begin{aligned} T &= \frac{\bar{X} - \mu_0}{\text{sd}X} \sqrt{n} \geq qt_{n-1}(1 - \alpha/2) \Rightarrow \bar{X} - \mu_0 \geq qt_{n-1}(1 - \alpha/2) \frac{\text{sd}X}{\sqrt{n}} \Rightarrow \\ \mu_0 &\leq \bar{X} - qt_{n-1}(1 - \alpha/2) \frac{\text{sd}X}{\sqrt{n}} \\ &\quad \text{nebo} \\ -T &= \frac{\mu_0 - \bar{X}}{\text{sd}X} \sqrt{n} \geq qt_{n-1}(1 - \alpha/2) \Rightarrow \mu_0 - \bar{X} \geq qt_{n-1}(1 - \alpha/2) \frac{\text{sd}X}{\sqrt{n}} \Rightarrow \\ \mu_0 &\geq \bar{X} + qt_{n-1}(1 - \alpha/2) \frac{\text{sd}X}{\sqrt{n}} \end{aligned}$$

tedy když μ_0 je mimo meze intervalu spolehlivosti

10. Rozklad součtu čtverců u analýzy rozptylu, tj. rozklad celkové variability na variabilitu

vysvětlenou a nevysvětlenou

$$\begin{aligned}
 SST &= \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_{..})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_{i.} + \bar{X}_{i.}\bar{X}_{..})^2 = \\
 &= \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_{i.})^2 + 2 \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_{i.})(\bar{X}_{i.} - \bar{X}_{..}) + \sum_{i=1}^k n_i (\bar{X}_{i.} - \bar{X}_{..})^2 = \\
 &= \sum_{i=1}^k n_i (\bar{X}_{i.} - \bar{X}_{..})^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_{i.})^2 = \\
 &= SSA + SSe
 \end{aligned}$$

jelikož platí, že

$$\begin{aligned}
 \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_{i.})(\bar{X}_{i.} - \bar{X}_{..}) &= \sum_{i=1}^k \sum_{j=1}^{n_i} (X_{ij}\bar{X}_{i.} - X_{ij}\bar{X}_{..} - \bar{X}_{i.}^2 + \bar{X}_{i.}\bar{X}_{..}) = \\
 &= \sum_{i=1}^k \bar{X}_{i.} \sum_{j=1}^{n_i} X_{ij} - \bar{X}_{..} \sum_{i=1}^k \sum_{j=1}^{n_i} X_{ij} - \sum_{i=1}^k \bar{X}_{i.}^2 \sum_{j=1}^{n_i} 1 + \bar{X}_{..} \sum_{i=1}^k \bar{X}_{i.} \sum_{j=1}^{n_i} 1 = \\
 &= \sum_{i=1}^k \bar{X}_{i.} n_i \bar{X}_{i.} - \bar{X}_{..} n \bar{X}_{..} - \sum_{i=1}^k n_i \bar{X}_{i.}^2 + \bar{X}_{..} \sum_{i=1}^k n_i \bar{X}_{i.} = \\
 &= \sum_{i=1}^k n_i \bar{X}_{i.}^2 - n \bar{X}_{..}^2 - \sum_{i=1}^k n_i \bar{X}_{i.}^2 + n \bar{X}_{..}^2 = 0
 \end{aligned}$$

11. odvození regresních koeficientů v jednoduché lineární regrese
metoda nejmenších čtverců, hledáme $\min \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$

$$\begin{aligned}
 \min_{b_0, b_1} \sum_{i=1}^n (Y_i - (b_0 + b_1 X_i))^2 & \\
 \text{derivace podle } b_0 & \\
 \frac{\partial}{\partial b_0} \sum_{i=1}^n (Y_i - (b_0 + b_1 X_i))^2 &= \sum_{i=1}^n -2(Y_i - b_0 - b_1 X_i) \\
 \text{derivace podle } b_1 & \\
 \frac{\partial}{\partial b_1} \sum_{i=1}^n (Y_i - (b_0 + b_1 X_i))^2 &= \sum_{i=1}^n -2(Y_i - b_0 - b_1 X_i) X_i
 \end{aligned}$$

položíme rovno nule

$$\begin{aligned}
\sum_{i=1}^n -2(Y_i - b_0 - b_1 X_i) &= 0 \\
2n\bar{Y} - 2nb_0 - 2b_1 \sum_{i=1}^n X_i &= 0 \\
b_0 &= \frac{2n\bar{Y} - 2nb_1\bar{X}}{2n} \\
b_0 &= \bar{Y} - b_1\bar{X} \\
\sum_{i=1}^n -2(Y_i - b_0 - b_1 X_i)X_i &= 0 \\
-2 \sum_{i=1}^n Y_i X_i + 2b_0 \sum_{i=1}^n X_i + 2b_1 \sum_{i=1}^n X_i^2 &= 0 \\
&\text{dosadím za } b_0 \\
-2 \sum_{i=1}^n Y_i X_i + 2(\bar{Y} - b_1\bar{X}) \sum_{i=1}^n X_i + 2b_1 \sum_{i=1}^n X_i^2 &= 0 \\
-2 \sum_{i=1}^n Y_i X_i + 2\bar{Y} \sum_{i=1}^n X_i - 2b_1\bar{X} \sum_{i=1}^n X_i + 2b_1 \sum_{i=1}^n X_i^2 &= 0 \\
\sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y} &= b_1 \left(\sum_{i=1}^n X_i^2 - n\bar{X}^2 \right) \\
b_1 &= \frac{\sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y}}{\sum_{i=1}^n X_i^2 - n\bar{X}^2}
\end{aligned}$$

12. odvojení očekávané četnosti v χ^2 -testu nezávislosti z definice nezávislosti $P(A \cap B) = P(A)P(B)$

$$P(A_1) = \frac{\sum_{j=1}^c X_{1j}}{n} = \frac{n_{1.}}{n}$$

$$P(B_1) = \frac{\sum_{i=1}^r X_{i1}}{n} = \frac{n_{.1}}{n}$$

očkávaná četnost 1. políčka tabulky (se souřadnicemi)1, 1

$$\frac{n_{1.}}{n} \frac{n_{.1}}{n} n = \frac{n_{1.} n_{.1}}{n}$$