

Přednáška 08a

Od popisné statistiky k matematické statistice

Statistický soubor ... množina statistických jednotek

Měříme jeden nebo více znaků

Typy znaků - nominální ($x_1 = x_2?$)

- ordinální ($x_1 < x_2?$)

- intervalové ... jsme navíc schopni prohodit
řadí $x_1 - x_2$

- poměrové ... nerovnost, řadí, řadí

Nechtě x_1, x_2, \dots, x_n je soubor hodnot, které lze uspořádat, namísto měření na n statistických jednotkách.

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n-1)} \leq x_{(n)}$$

Různé hodnoty nechtě jsou $a_1 < a_2 < \dots < a_m$,
 n_i je počet jednotek s naměřenou hodnotou a_i
(lidské četnosti).

Průměry

① Aritmetický průměr

$$\bar{x} = \frac{1}{n} \left(\sum_{i=1}^n x_i \right) = \frac{1}{n} \left(\sum_{j=1}^m n_j a_j \right)$$

Aritmetický průměr je invariantní vůči afinnímu transformaci

$$y_i = ax_i + b$$

Pak

$$\bar{y} = a\bar{x} + b$$

② Geometrický průměr pro kladná čísla

$$\bar{x}^G = \sqrt[n]{x_1 x_2 \dots x_n}$$

③ Harmonický průměr pro kladná čísla

$$\bar{x}^H = \left\{ \frac{1}{n} \left(\sum_{i=1}^n \frac{1}{x_i} \right) \right\}^{-1}$$

Platí

$$\bar{x}^H \leq \bar{x}^G \leq \bar{x}$$

Median, kvartil, percentil

Median souboru x_1, x_2, \dots, x_n je číslo \tilde{x} takové, že 50% hodnot x_1, x_2, \dots, x_n je $\leq \tilde{x}$ a zbytek hodnoty jsou $> \tilde{x}$. Tímto není \tilde{x} nutně jednoznačné.

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$$

n liché

$$\tilde{x} = x_{\left(\frac{n+1}{2}\right)}$$

n sudé

$$\tilde{x} = \frac{x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)}}{2}$$

Pro $0 < p < 1$ je p -tý kvantil, p -tý percentil číslo x_p takové, že $p\%$ hodnot je $\leq x_p$ a zbylé jsou $> x_p$. Nemá-li takové číslo, bereme ho jako aritmetický průměr dvou po sobě jdoucích

Hodnoty x_i 1 1 2 2 3 3 3 3

$$x_{0,5} = \tilde{x} = \frac{2+3}{2} = 2,5$$

$$x_{0,25} = Q_1 = \text{dolní kvantil je } \frac{1+2}{2} = 1,5$$


$$x_{0,75} = Q_3 = \text{horní kvantil je } \frac{3+3}{2} = 3$$

Modus je hodnota s největší četností $\hat{x} = 3$.

Příklad

a_i	3	4	7	8	9	10	11
m_i	1	1	4	4	6	3	1

Histogram




Kračový graf

$$n = 20, \quad \bar{x} = 8,1, \quad \tilde{x} = \frac{x_{(10)} + x_{(11)}}{2} = \frac{8+9}{2} = 8,5$$

$$x_{0,25} = Q_1 = \frac{x_{(5)} + x_{(6)}}{2} = 7$$

$$x_{0,75} = Q_3 = \frac{x_{(15)} + x_{(16)}}{2} = 9$$

Rozptyl a směrodatná odchylka

Rozptyl
$$s_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$s_x \geq 0$ je směrodatná odchylka

Průměrná odchylka

$$D_x = \frac{1}{n} \sum_{i=1}^n |x_i - \tilde{x}|$$

Věta (a) Funkce $S(t) = \frac{1}{n} \sum_{i=1}^n (x_i - t)^2$ nabývá svého minima pro $t = \bar{x}$.

(b) Funkce $D(t) = \frac{1}{n} \sum_{i=1}^n |x_i - t|$ nabývá svého minima pro $t = \tilde{x}$.

$$a \quad |x_{(2)} - t| + |x_{(n-1)} - t| > |x_{(2)} - \tilde{x}| + |x_{(n-1)} - \tilde{x}|$$

pre $t \notin [x_{(2)}, x_{(n-1)}]$.

ald. Odhad dokážeme, že $D(t)$ má vďaka sčítke minima pre $t = \tilde{x}$.

Nominaľná analýza

Mi počet jednotiek s nominaľným znakom a_i

a_1	a_2	a_3	...	a_k
n_1	n_2	n_3		n_k

$$\sum_{i=1}^k n_i = n$$

Miera variability znaku vyjadruje entropie

$$H_x = - \sum_{i=1}^k \frac{n_i}{n} \ln \left(\frac{n_i}{n} \right)$$

$$k=1 \quad H_x = 0$$

$$k=2 \quad n_1 = n_2$$

$$H_x = - \sum_{i=1}^2 \frac{1}{2} \ln \frac{1}{2} = \ln 2 > 0.$$

Entropie má vďaka sčítke maxima pri stejnej číslnosti znaku:

Hľadáme maximum funkcie

$$H(p_1, \dots, p_k) = - \sum_{i=1}^k p_i \ln p_i$$

-7-

Pa podmínky $\sum_{i=1}^k p_i = 1$ (a samozřejmě $p_i > 0$). Pomocí Lagrangeova multiplikátoru λ

$$\frac{\partial H}{\partial p_i} = -\ln p_i - 1 = \lambda$$

$$p_i = e^{\lambda-1}$$

$$k e^{\lambda-1} = 1$$

$$\lambda = 1 - \ln k$$

$$p_i = \frac{1}{k}$$

V bodě $[\frac{1}{k}, \frac{1}{k}, \dots, \frac{1}{k}]$ má H svého lokálního maxima. Funkci $f(y) = -y \ln y$ lze nejlehčeji rozšířit na $y=0$ tak, aby $\lim_{y \rightarrow 0^+} (-y \ln y) = 0$.

H má na kompaktní množině

$$\left\{ \sum p_i = 1, \quad p_i \geq 0 \right\}$$

svoje maxima, a to musí být v bodě $[\frac{1}{k}, \frac{1}{k}, \dots, \frac{1}{k}]$.

Pravděpodobnost

Stavíme kostku - máme výsledky $1, 2, 3, 4, 5, 6$.

Můžeme mít situace, kdy máme více výsledků \neq nekonečně mnoho:

Operace body mincí - rub a kč u jednoho hodu.

$w_k \in \mathbb{N} \cup \{\infty\}$ kč padne w_k krát v k -tém hodu

Pravděpodobnost

$$P(\omega_k) = \frac{1}{2^k}$$

$$P(\omega_\infty) = 0$$

$$\sum_{k=1}^{\infty} P(\omega_k) = 1.$$

Jerové pole - σ -algebra

Pracujeme se sákladní množinou Ω . Vybrané podmnožiny reprezentují jevy.

Jerové pole na Ω je systém podmnožin \mathcal{A} množiny Ω splňující, že

- $\Omega \in \mathcal{A}$
- $A, B \in \mathcal{A} \Rightarrow A \setminus B \in \mathcal{A}$
- $A_i \in \mathcal{A}, I$ nejryšle spočetná $\Rightarrow \bigcup_{i \in I} A_i \in \mathcal{A}$

\mathcal{A} nazýváme také σ -algebrou.

Důsledky :

- $\emptyset \in \mathcal{A}$ (nemohou být, Ω je jistý jev)
- $A \in \mathcal{A}, A^c = \Omega \setminus A \in \mathcal{A}$ (doplnek)
- $A, B \in \mathcal{A} \Rightarrow A \cap B = A \setminus (\Omega \setminus B) \in \mathcal{A}$

Pravděpodobnostní prostor

je jové pole \mathcal{A} společně s funkcí $P: \mathcal{A} \rightarrow [0,1]$ splňující, že

- (1) $P(\Omega) = 1,$
- (2) A_i jsou dvou disjunktní, I nejryšle spočetná

$$P\left(\bigcup_{i \in I} A_i\right) = \sum_{i \in I} P(A_i)$$

Důsledky:

• $P(A^c) = 1 - P(A)$, $P(\emptyset) = 0$.

•
$$P\left(\bigcup_{i=1}^k A_i\right) = \sum_{i=1}^k P(A_i) - \sum_{1 \leq i < j \leq k} P(A_i \cap A_j)$$

$$+ \sum_{1 \leq i < j < l \leq k} P(A_i \cap A_j \cap A_l) - \dots$$

Věta

(1) Necht' $A_1 \subseteq A_2 \subseteq \dots \subseteq A_n \subseteq \dots \in \mathcal{A}$

Pak
$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \lim_{n \rightarrow \infty} P(A_n)$$

(2) Necht' $A_1 \supseteq A_2 \supseteq A_3 \supseteq \dots \in \mathcal{A}$

Pak
$$P\left(\bigcap_{i=1}^{\infty} A_i\right) = \lim_{n \rightarrow \infty} P(A_n)$$

Důkaz (1)
$$A = \bigcup_{i=1}^{\infty} A_i = A_1 \cup (A_2 \setminus A_1) \cup (A_3 \setminus A_2) \cup \dots$$

Podob

$$P(A) = P(A_1) + \sum_{i=1}^{\infty} P(A_{i+1} \setminus A_i) = P(A_1) + \lim_{n \rightarrow \infty} \sum_{i=1}^n P(A_{i+1} \setminus A_i)$$

$$= P(A_1) + \lim_{n \rightarrow \infty} \{ P(A_2) - P(A_1) + P(A_3) - P(A_2) + \dots + P(A_{n+1}) - P(A_n) \}$$

$$= P(A_1) + \lim_{n \rightarrow \infty} (P(A_{n+1}) - P(A_1)) = \lim_{n \rightarrow \infty} P(A_{n+1}).$$

$$\begin{aligned} (2) \quad P\left(\bigcap_{i=1}^{\infty} A_i\right) &= 1 - P\left(\bigcup_{i=1}^{\infty} (\Omega \setminus A_i)\right) = \\ &= 1 - \lim_{n \rightarrow \infty} P(\Omega \setminus A_n) = 1 - 1 + \lim_{n \rightarrow \infty} P(A_n) \\ &= \lim_{n \rightarrow \infty} P(A_n) \end{aligned}$$

V druhé rovnici jsme použili (1).

Nesámkost jeví A a B

jeví A a B jsou nezávislé nesámké,
jeví

$$P(A \cap B) = P(A) \cdot P(B)$$

Základní předpoklad o pravidelném počtu:
 Ω konečná množina, v níž všech jeví
podmnožin a

$$P(A) = \frac{|A|}{|\Omega|}.$$

Podmiňena' pravdĕpodobnost

H je jím s nenulovou pravdĕpodobností.

Podmiňena' pravdĕpodobnost jím A sa podmiňky H je pravdĕpodobnost

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

Lemma Nechtĕ B je disj. sřednocením jím $B_1 \cup B_2 \cup \dots \cup B_n$. Pak

$$P(A|B) = \sum_{i=1}^n P(A|B_i) P(B_i|B).$$

Speciálně ma $\Omega = B_1 \cup B_2 \cup \dots \cup B_n$ disj.

$$P(A) = \sum P(A|B_i) P(B_i).$$

Důkaz:

$$P(A|B) = \frac{P(A \cap (B_1 \cup \dots \cup B_n))}{P(B_1 \cup \dots \cup B_n)} = \sum_{i=1}^n \frac{P(A \cap B_i)}{P(B)}$$

$$= \sum_{i=1}^n \frac{P(A \cap B_i)}{P(B_i)} \frac{P(B_i)}{P(B)} = \sum_{i=1}^n P(A|B_i) P(B_i|B).$$

Bayesova věta

(A) Bayesův vzorec pro inverzní pravděpodobnost

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

(B) 1. Bayesův vzorec

$$P(A|B) = \frac{P(A) p(B|A)}{p(A) p(B|A) + p(A^c) p(B|A^c)}$$

(C) obecnější verze: Je-li $\Omega = A_1 \cup A_2 \cup \dots \cup A_n$ disjunktivně, pak

$$P(A_i|B) = \frac{p(A_i) p(B|A_i)}{\sum_{j=1}^n p(A_j) p(B|A_j)}$$

Důkaz: (A)

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

(B) a (C) za $P(B)$ dosadíme z lemmatu.

Příklad v předmětu X je úspěšnost 40%,
v předmětu Y je 80%. Každý předmět
v daný den dělal stejný počet studentů.

žalá' je marděpodobně, že student, který uspěl,
dělal předmět X?

A student dělal předmět X

B student u slovníky uspěl

A^c student dělal předmět Y

Víme, že $P(B|A) = 0,4$, $P(B|A^c) = 0,8$.

Dále $P(A) = P(A^c) = 0,5$. Chceme spočítat

$P(A|B)$. Dosazením do vzorce

$$\begin{aligned} P(A|B) &= \frac{p(A) \cdot p(B|A)}{p(A) p(B|A) + p(A^c) p(B|A^c)} \\ &= \frac{0,5 \cdot 0,4}{0,5 \cdot 0,4 + 0,5 \cdot 0,8} = \frac{1}{3} \end{aligned}$$



Nesánilost jeví^o A a B pro $P(B) \neq 0$ je ekvivalentní
s rovností

$$P(A) = P(A|B).$$