

Základy matematické statistiky

(1)

Problém: máme řadu nějakých pozorování (hodnot), předpokládáme, že všechna pozorování mohou mít různou nějakou náhodnou veličinu.

Ukolem je najít něco o té meziříčné veličině - jaké má pravděpodobnostní rozdíly mimo složení nějaké charakteristiky, např. střední hodnotu, rozptyl.

Náhodná veličina je kvantitativním ohodnocením nějakého náhodného jevu, může mít několik množství mnoha hodnot (např. počet obyvatel v kanceláře) - takové veličiny nazýváme diskrétní, měla bych hodnotu x nějakého konkrétního či nekonkrétního intervalu (např. teplota) - takové veličiny jsou kontinuální.

Rozdílení náhodné veličiny - charakterizuje se např. distribuční funkcií, která se definuje jako $F(x) = P(X \leq x)$.

V diskrétním případě, kdy veličina má jistá hodnota x_1, x_2, \dots , se dá charakterizovat systémem pravděpodobnosti $p_i = P(X = x_i)$, $i=1, 2, \dots$, kde $\sum_{i=1}^{\infty} p_i = 1$. Platí $F(x) = \sum_{\{i : x_i \leq x\}} p_i$. Pravděpodobnosti p_i

se mohou nazývat diskrétní hustotou.

Kontinuální náhodné veličiny jsou charakterizovány hustotou, což je funkce $f(x)$ taková, že platí: $f(x) \geq 0$, $f(x) \leq 1$, $\int_{-\infty}^{\infty} f(x) dx = 1$,

$$F(x) = \int_{-\infty}^x f(t) dt.$$

Další charakteristiky:

Střední hodnota - je typický průměr, kdežto blíže k mohoucí hodnoty mohoucí veličiny (je mítou polohy).

$$\text{diskrétní relativa: } E(X) = \sum_{i=1}^{\infty} x_i P(X=x_i)$$

$$\text{prostá relativa: } E(X) = \int x f(x) dx.$$

Rozptyl - popisuje odlehlosť hodnot mohoucí veličiny od její střední hodnoty (je mítou mierka).

vnáci se σ^2 mimo $\text{var}(X)$

$$\text{definice: } \text{var}(X) = E(X - EX)^2$$

$$\text{platí: } \text{var}(X) = EX^2 - (EX)^2$$

$$\text{příklad: } EX^2 = \sum_i x_i^2 P(X=x_i) \text{ v diskrétním případě}$$

$$EX^2 = \int x^2 f(x) dx \text{ ve prostém případě}$$

Median \tilde{x} - je "prostřední" hodnota

$$\text{platí: } F(\tilde{x}) = \frac{1}{2}, \text{ tj. } P(X < \tilde{x}) = P(X \geq \tilde{x}) = \frac{1}{2}$$

(pro prostá relativa to platí nejen, pro diskrétní skoro)

Modus \hat{x} - je nejpravidelnější hodnota

$$\text{platí: } f(\hat{x}) = \max_x \{f(x)\} \text{ pro prostá rozdělení}$$

$$P(X=\hat{x}) = \max_i P(X=x_i)$$

Příklady diskrétních rozdělení:

Allurálové (0-1): $X = 0, 1$, $P(X=1)=p$, $P(X=0)=1-p$

$$EX = 1 \cdot p + 0 \cdot (1-p) = p$$

$$EX^2 = 1^2 \cdot p + 0^2 \cdot (1-p) = p$$

$$\text{var } X = EX^2 - (EX)^2 = p - p^2 = p(1-p)$$

příklad: hod minci

$X = 1$ když padne "pravda" } obou stranodiskomnosti $\frac{1}{2}$
 $X = 0$ -" " "nev"

Binomické: $X = 0, 1, \dots, n$; $P(X=k) = \binom{n}{k} p^k (1-p)^{n-k}$

p je parametr rozdělení, $0 < p < 1$

$$EX = p, \text{ var } X = mp$$

příklad: počet "výpěšek" v postupnosti m nezávislých pokusů,
 k nichž každý málo záleží i s pravděpodobností p ,
 $P(\text{výpěška}) = p$, $P(\text{nevýpěška}) = 1-p$

Poissonovo: $X = 0, 1, \dots$, $P(X=k) = e^{-\lambda} \frac{\lambda^k}{k!}$, $\lambda > 0$ je parametr

$$EX = \lambda, \text{ var } X = \lambda$$

je limitním případem binomické, když $\lim_{n \rightarrow \infty} np = \lambda$

(4)

geometrické: $X = 0, 1, \dots$, $P(X=k) = p(1-p)^k$

$$EX = \frac{1-p}{p}, \quad \text{var } X = \frac{1-p}{p^2}$$

příklad: modelování "doby cíbiny" na první místo úspěchu

rovnoramenné: $X = 1, 2, \dots, m$; $P(X=k) = \frac{1}{m}$

$$EX = \frac{m+1}{2}, \quad \text{var } X = \frac{m^2-1}{12}$$

příklad: hod kódům $X = 1, 2, \dots, 6$, $P(X=k) = \frac{1}{6}$

Příklady rozdílných modelů

rovnoramenné $R(a, b)$: $X \in (a, b)$, $f(x) = \frac{1}{b-a}$

$$EX = \frac{a+b}{2}, \quad \text{var } X = \frac{(b-a)^2}{12}$$

exponentiální: $X \in (0, \infty)$, $f(x) = \lambda e^{-\lambda x}$, $\lambda > 0$ je parametr

$$EX = \frac{1}{\lambda}, \quad \text{var } X = \frac{1}{\lambda^2}$$

používá se v teorii spolehlivosti, teorii konstrukční obsluhy

My se budeme nejčastěji setkávat s následujícími modely:

normální $N(\mu, \sigma^2)$: $X \in (-\infty, \infty)$, $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$

μ, σ jsou parametry, $\sigma > 0$

$$EX = \mu, \quad \text{var } X = \sigma^2$$

(5)

Normované' normální rozdělení: $X \in (-\infty, \infty)$, $f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$

$$EX=0, \text{ var } X=1$$

chi'-kvadratické rozdělení χ_m^2 ($s m$ stupni volnosti): $X \in (0, \infty)$

$$f(x) = \frac{1}{2^{m/2} \Gamma(\frac{m}{2})} x^{\frac{m}{2}-1} e^{-x/2}$$

Ude $\Gamma(a) = \int_0^\infty x^{a-1} e^{-x} dx$ pro $a > 0$ je Γ -funkce

$$\text{platí: } \Gamma(a+1) = a\Gamma(a), \quad \Gamma(\frac{1}{2}) = \sqrt{\pi}$$

$$EX=m, \text{ var } X=2m$$

Plati' (v důsledku něj o transformaci náhodných veličin):

použi X_1, X_2, \dots, X_m meravise' náhodné veličiny a
která má' rozdělení $N(0,1)$, pak $U = X_1^2 + \dots + X_m^2$

má' rozdělení χ_m^2

Gudendorfova rozdělení t_n (t -rozdělení s m stupni volnosti).

$$X \in (-\infty, \infty)$$

$$f(x) = \frac{\Gamma(\frac{m+1}{2})}{\Gamma(\frac{m}{2}) \sqrt{m}} \left(1 + \frac{x^2}{m}\right)^{-\frac{m+1}{2}}$$

$$EX=0, \text{ var } X=\frac{m}{n-2} \text{ pro } n>2$$

Plati': použi X a U meravise' náhodné veličiny, $X \sim N(0,1)$,

$$U \sim \chi_m^2, \text{ pak veličina } T = \frac{X}{\sqrt{\frac{U}{m}}} \text{ má' rozdělení } t_m.$$

Fisherovo rozdělení F_{m_1, m_2} (F -rozdělení s m_1 a m_2 stejnou hodnotou).

$$X \in (0, \infty)$$

$$f_{m_1, m_2}(x) = \frac{\Gamma(\frac{m_1+m_2}{2})}{\Gamma(\frac{m_1}{2})\Gamma(\frac{m_2}{2})} \left(\frac{m_1}{m_2}\right)^{m_1/2} x^{m_1/2-1} \left(1 + \frac{m_1}{m_2}\right)^{-\frac{m_1+m_2}{2}}$$

$$EX = \frac{m_2}{m_2-2} \quad \text{pro } m_2 > 2$$

$$\text{var } X = \frac{2m_2^2(m_1+m_2-2)}{m_1(m_2-2)(m_2-4)} \quad \text{pro } m_2 > 4$$

Plati: pro - li U a V nezávislé náhodné veličiny, $U \sim \chi_m^2$,

$$V \sim \chi_n^2, \text{ pak } F = \frac{\frac{U}{m}}{\frac{V}{n}} \text{ má rozdělení } F_{m, n}.$$

Tento krok lze dleto rozdělení menšího říba se považovat, díve byz
uvádění se statistických tabulek, dnes se kontrolní hodnoty
vyčítají na počítači.

Důležité je poznam, kde a da' které rozdělení použit.

Budeme potřebovat klasické kvantily nebo kritické hodnoty lze to
rozdělení (opět jen se tabulkami).

Kvantil rozdělení je hodnota α_d , po kterou platí $P(U < \alpha_d) = \alpha$.

(U je náhodná veličina s lze to rozdělením).

Kritická hodnota rozdělení je hodnota α_d , po kterou $P(X > \alpha_d) = \alpha$
(X je náh. veličina s lze to rozdělením).

Vzťah mezi kritickou hodnotou a kvantilem této soudění je tedy

$$K_d = \mu_{1-\alpha}.$$

Je ale třeba dál pozor:

- 1) po méněm soudění se referují k původním definicím kritické hodnoty a absolutní hodnoty
- 2) kvantily a kritické hodnoty se v statistické literatuře obvykle označují stejnými symboly
- 3) v některých tabulkách se uvažuje kvantil, a jiné kritické hodnoty

Je tedy třeba vidět důkladně číslo celého, nejen nečetné!

Nesouvislost mezi hodnotami několika veličin.

Veličiny X_1, \dots, X_n jsou nezávislé, jestliže platí $F(x_1, \dots, x_n) = F_1(x_1) \dots F_n(x_n)$, kde $F(x_1, \dots, x_n) = P(X_1 < x_1, \dots, X_n < x_n)$ je soudružina distribuční funkce, $F_i(x_i) = P(X_i < x_i)$ jsou marginalní distribuční funkce jednotlivých veličin (musí to platit pro každou n a někdy možné hodnoty x_1, \dots, x_n).

$$\text{Jinak: } f(x_1, \dots, x_n) = f_1(x_1) \dots f_n(x_n)$$

$$\text{Důsledek: } E(X_1, \dots, X_n) = E(X_1) \dots E(X_n)$$

$$\text{var}(X_1 + \dots + X_n) = \text{var}(X_1) + \dots + \text{var}(X_n)$$

$$\text{cov}(X_i, X_j) = E(X_i - EX_i)(X_j - EX_j) = 0 \text{ pro různá } i, j$$

Máhodržný rýber je postupnost marginalních nezávislých máhodržných veličin se stejným souděním.

Používe mnohy statistického metoda předpokládá normální rozdělení, ale lze toto předpokladu nelze vždy s jistotou ověřit. Díky tomu mohou vzniknout i následující. Odečít? Platí tedy centrální limitní věta.

Nechť $X_1, X_2, \dots, X_n, \dots$ jsou nezávislé stejně rozdělené náhodné veličiny, $E X_i = \mu < \infty$, $\text{var } X_i = \sigma^2 < \infty$ pro všechna i . Považme $Y_m = \sum_{k=1}^m X_k$. Pak pro distribuci fce $F_m(x)$ náhodné veličiny $Y_m^* = \frac{Y_m - E(Y_m)}{\sqrt{\text{var } Y_m}}$ platí

$$\lim_{m \rightarrow \infty} F_m(x) = \Phi(x), \text{ kde } \Phi(x) \text{ je dist. fce rozdělení } N(0, 1).$$

neboť:
$$\frac{\sum_{k=1}^m X_k - m\mu}{\sqrt{m\sigma^2}} \xrightarrow[m \rightarrow \infty]{} Z \sim N(0, 1) \text{ v distribuci}$$

tedy xlomek rozdělení n :
$$\frac{\frac{1}{n} \sum_{k=1}^n X_k - \mu}{\sqrt{\frac{\sigma^2}{n}}} \xrightarrow[n \rightarrow \infty]{} Z \sim N(0, 1)$$

Je-li rozdělení $N(0, 1)$ má $N(\mu, \sigma^2)$ a mognal:

nechť $X \sim N(0, 1)$, pak $Y = \sigma X + \mu \sim N(\mu, \sigma^2)$

nechť $X \sim N(\mu, \sigma^2)$, pak $Y = \frac{X-\mu}{\sigma} \sim N(0, 1)$

Centrální limitní věta pak vlastně říká, že alespoň v průměru

$$\bar{X}_m = \frac{1}{m} \sum_{k=1}^m X_k \text{ má asymptotický normální rozdělení } N\left(\mu, \frac{\sigma^2}{m}\right),$$

i když veličiny X_k normální rozdělení nemají.

Další krok, když máme někdy dorozumět sicej jde o podrobnosti, je
zákon velkých čísel. Existuje ne 2 podobnosti:

Galy'ský zákon velkých čísel: Nechť X_1, X_2, \dots jsou pozitivní měřivé mimožné
 veličiny, $EX_i = \mu < \infty$, $\text{var } X_i = \sigma^2 < \infty$ pro všechna i . Pak

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} \mu \quad (\text{konečný podle pravidelností}).$$

Znamená to, že po libovolné $\varepsilon > 0$ platí $\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| < \varepsilon) = 1$.

Gilny'ský zákon velkých čísel: Nechť X_1, X_2, \dots jsou měřivé mimožné
 veličiny s linným srovnáníem, $EX_i = \mu < \infty$, $\text{var } X_i = \sigma^2 < \infty$. Pak

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow \mu \text{ plato jistě, tj: } P(\lim_{n \rightarrow \infty} \bar{X}_n = \mu) = 1.$$

Náhodný výber z normálního rozdělení $N(\mu, \sigma^2)$

postupnost X_1, \dots, X_m nazýváme náhodnými veličinami,
když má rozdělení $N(\mu, \sigma^2)$
(v paci to bude mpozorování hodnoty)

Budoucí odhad parametrů:

$$\hat{\mu} = \bar{X} = \frac{1}{m} \sum_{i=1}^m X_i$$

odhad je nestanový, tj: $E\bar{X} = \mu$ (d. $E\bar{X} = \frac{1}{m} \sum_{i=1}^m E X_i = \frac{1}{m} \sum_{i=1}^m \mu = \mu$)

konsistentní, tj: $\bar{X} = \frac{1}{m} \sum_{i=1}^m X_i \rightarrow \mu$ podle náhoda
veličin ēise

maximální náhodný (xálem nebudeme definoval)

má rozdělení $N\left(\mu, \frac{\sigma^2}{m}\right)$ ($\text{var } \bar{X} = \frac{1}{m^2} \sum_{i=1}^m \text{var } X_i = \frac{m\sigma^2}{m^2} = \frac{\sigma^2}{m}$)

$$\hat{\sigma}^2 = S^2 = \frac{1}{m-1} \sum_{i=1}^m (X_i - \bar{X})^2 \quad (= \frac{1}{m-1} \left(\sum_{i=1}^m X_i^2 - m(\bar{X})^2 \right))$$

odhad je nestanový, tj: $ES^2 = \sigma^2$

konsistentní, tj: $S^2 \rightarrow \sigma^2$

není maximální náhodný

veličina $\frac{(m-1)S^2}{\sigma^2}$ má rozdělení χ^2_{m-1}

$$\text{platí } \frac{(m-1)S^2}{\sigma^2} = \sum_{i=1}^m \underbrace{\left(\frac{X_i - \bar{X}}{\sigma} \right)^2}_{\text{jde o veličinu mající rozdělení } N(0,1)}$$

násau ale řeč významné, protože je počet stupnic
volnosti $m-1$ a ne m .

\bar{X} a S^2 jsou nezávislé

Neleží-li hodnota parametru se soudou mohouceho s velkou pravděpodobností, v nějakém intervalu kolem reálé hodnoty jeho obhodové. Může se uvažovat i o tom, jak všechnou počítat chance.

Nejpravděpodobnější pěsík: Interval prohlášení počtu (mezního) pro
krámitum σ^2 .

Krámitu nejakej je $\alpha \in (0,1)$. - mělo by být male, např. $\alpha = 0,05$
hledáme a, b tak, aby platilo

tedy $P(a < \mu) = 1 - \alpha$ } jednostranné intervaly prohlášení

nebo $P(\mu < b) = 1 - \alpha$

nebo $P(a < \mu < b) = 1 - \alpha$ obousměrný

$1 - \alpha$ je koeficient prohlášení (confidence)

vyjdeme k obhodové \bar{X} , normujeme ho na $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$

platí $P\left(\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < u_{1-\alpha}\right) = 1 - \alpha$, kde $u_{1-\alpha}$ je hraniční hodnota $N(0, 1)$

platí $1 - \alpha = P\left(\bar{X} - \mu < \frac{\sigma}{\sqrt{n}} u_{1-\alpha}\right) = \underbrace{P\left(\bar{X} - \frac{\sigma}{\sqrt{n}} u_{1-\alpha} < \mu\right)}_{\alpha}$

Definice hraničí: Nechť Y je náhodná veličina s distribucí fci F . Hranice x_α , po kterou $F(x_\alpha) = P(Y < x_\alpha) = \alpha$, se nazývá α -hraničí počtu (mezního) rozdělení.

Hraničí mezních rozdělení se mají vztahy k tabulkám.

(12)

podstatě: $P\left(\mu < \bar{X} + \underbrace{\mu_{1-\alpha} \frac{\sigma}{\sqrt{n}}}_{\delta}\right) = P\left(-\mu_{1-\alpha} \frac{\sigma}{\sqrt{n}} < \bar{X} - \mu\right) =$

$$P\left(-\mu_{1-\alpha} < \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}\right) = 1 - P\left(\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < -\mu_{1-\alpha}\right) =$$

$$= 1 - \Phi(-\mu_{1-\alpha}) = 1 - [1 - \Phi(\mu_{1-\alpha})] = \Phi(\mu_{1-\alpha}) = 1 - \alpha$$

Φ je distribuční funkce $N(0,1)$

platí po ní $\Phi(-a) = 1 - \Phi(a)$, protože rozdělení je symetrické
obousměrný interval bude mít měnu $(\bar{X} - \mu_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + \mu_{1-\alpha/2} \frac{\sigma}{\sqrt{n}})$

$$P\left(\bar{X} - \mu_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + \mu_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}\right) =$$

$$= P\left(-\mu_{1-\alpha/2} < \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < \mu_{1-\alpha/2}\right) = \Phi(\mu_{1-\alpha/2}) - \Phi(-\mu_{1-\alpha/2}) =$$

$$= 1 - \alpha/2 - (1 - (1 - \alpha/2)) = 1 - \alpha$$

Interval prodeklivosti pro μ s pravou stranou σ^2

Když σ^2 neznáme, nahradíme ho jeho odhadem s^2 a

použijeme výraz $\frac{\bar{X} - \mu}{\frac{s}{\sqrt{n}}}$, ten však ale nebude mít
normální rozdělení.

platí:

$$\frac{\bar{X} - \mu}{\frac{s}{\sqrt{n}}} = \frac{\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}}{\sqrt{\frac{(n-1)s^2}{m-1}}} = \frac{Y}{\sqrt{\frac{\chi^2_{m-1}}{m-1}}}, \text{ kde } Y \sim N(0,1)$$

$$Y \sim \chi^2_{m-1}$$

takže $\frac{\bar{X} - \mu}{\frac{s}{\sqrt{n}}} \sim t_{m-1}$

Intervaly pravděpodobnosti budou zpravidla rozdílné, pouze měla být stejná.
 α normálního rozdělení se používají kvantily $t_{m-1, \alpha}$ Studentova
 t -rozdělení.

Intervaly pravděpodobnosti pro σ^2

vydělíme σ^2 ohradenou s^2 a σ^2 dobra, nebo víc, nebo $\frac{(m-1)s^2}{\sigma^2} \sim \chi^2_{m-1}$

pak $P\left(\frac{(m-1)s^2}{\sigma^2} < \chi^2_{m-1, 1-\alpha}\right) = 1-\alpha$, když $\chi^2_{m-1, 1-\alpha}$ je kvantil

$$\text{a dobrá } P\left(\frac{(m-1)s^2}{\chi^2_{m-1, 1-\alpha}} < \sigma^2\right) = 1-\alpha$$

$$\text{podobně } P\left(\sigma^2 < \frac{(m-1)s^2}{\chi^2_{m-1, \alpha}}\right) = 1-\alpha$$

$$\text{a obousměrně } P\left(\frac{(m-1)s^2}{\chi^2_{m-1, 1-\alpha/2}} < \sigma^2 < \frac{(m-1)s^2}{\chi^2_{m-1, \alpha/2}}\right) = 1-\alpha.$$