

Základy matematické statistiky

Problém: máme řadu nějakých pozorování (hodnot), předpokládáme, že vznikla pozorovánímu nebo měřením nějaké náhodné veličiny.

Úkolem je zjistit něco o té neznámé veličině - jaké má pravděpodobnostní rozdělení nebo alespoň nějaké charakteristiky, např. střední hodnota, rozptyl.

Náhodná veličina je kvantitativní ohodnocení nějakého náhodného jevu, může nabývat buď konečné nebo spočítané množiny hodnot (např. počet oh na haci' kostce) - takové veličiny nazýváme diskrétní, nebo i nekonečné nebo spočítané intervalu (např. teplota) - takové veličiny jsou spojité.

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

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

se někdy nazývají diskrétní hustota.

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

Dalsi charakteristiky:

Střední hodnota - je hypotetický průměr, kolem kterého kolísají hodnoty náhodné veličiny (je měrou polohy).

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

spojitá veličina: $E(X) = \int_{-\infty}^{\infty} x f(x) dx$

Rozptyl - popisuje rozdělenosti hodnot náhodné veličiny od její střední hodnoty (je měrou měřítka).

značí se σ^2 nebo $var(X)$

definice: $var(X) = E(X - EX)^2$

platí: $var(X) = EX^2 - (EX)^2$

přitom $EX^2 = \sum_i x_i^2 P(X=x_i)$ v diskrétním případě

$EX^2 = \int x^2 f(x) dx$ v spojitém případě

Medián \tilde{x} - je "pro střední" hodnota

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

(pro spojité veličiny to platí přibližně, pro diskrétní přesně)

Modus \hat{x} - je nejpravděpodobnější hodnota

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

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

Příklady diskrétních rozdělání:

Alternativní (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 mince

$X = 1$ když padne "pravá" } oba s pravděpodobností $\frac{1}{2}$
 $X = 0$ -"- "levá" }

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

p je parametr rozdělání, $0 < p < 1$

$$EX = p, \text{ var } X = mp(1-p)$$

příklad: počet "úspěchů" v posloupnosti m nezávislých pokusů, k může každý měřit pomocí úspěchu nebo neúspěchu,

$$P(\text{úspěch}) = p, P(\text{neúspěch}) = 1-p$$

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

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

je limitním případem binomického, když $\lim_{m \rightarrow \infty} mp = \pi$

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

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

příklad: rozdělení "doby čekání" na první výsle "úspěchu"

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

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

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

Příklady spojitého rozdělení

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

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

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

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

používá se v teorii spolehlivosti, teorii hromadné obsluhy

My se budeme nejčastěji zabývat o následujícími rozděleními:

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, $\sigma > 0$

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

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

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

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

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

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

Plati' (o důležitou řadu o transformaci náhodných veličin):

jestli X_1, X_2, \dots, X_m nezávislé náhodné veličiny a každá má rozdělení $N(0, 1)$, pak $U = X_1^2 + \dots + X_m^2$

má rozdělení χ_m^2

Studentovo rozdělení t_m (t -rozdělení s m stupni volnosti):

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

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

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

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

$U \sim \chi_m^2$, pak veličina $T = \frac{X}{\sqrt{\frac{U}{m}}}$ má rozdělení t_m .

Fisherovo rozdění F_{m_1, m_2} (F-rozdění s m_1 a m_2 stupni volnosti).

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

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

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

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

Plati: jsou-li U a V nezávislé náhodné veličiny, $U \sim \chi^2_{m_1}$,
 $V \sim \chi^2_{m_2}$, pak $F = \frac{\frac{U}{m_1}}{\frac{V}{m_2}}$ má rozdění F_{m_1, m_2} .

Trasy hustot těchto rozdění není třeba se paratovat, dříve byly uváděny ve statistických tabulkách, dnes se konkrétní hodnoty vypočítou na počítači.

Důležitá je poznat, kde se dá které rozdění použít.

Budeme potřebovat hlavní kvantily nebo kritické hodnoty těchto rozdění (opět jsou v tabulkách).

Kvantil rozdění je hodnota α_α , pro kterou platí $P(U < \alpha_\alpha) = \alpha$.

(U je náhodná veličina s tímto rozděním).

Kritická hodnota rozdění je hodnota α_α , pro kterou $P(X > \alpha_\alpha) = \alpha$

(X je náh. veličina s tímto rozděním).

Veliká mexi kritické hodnotou a kvantilem této rozdělení je tedy

$$x_\alpha = \mu_{1-\alpha}$$

Je ale třeba dát pozor:

- 1) pro některá rozdělení se veličiny v předchozích definicích berou v absolutní hodnotě
- 2) kvantily a kritické hodnoty se ve statistické literatuře obvykle označí stejnými symboly
- 3) v některých tabulkách se uvádějí kvantily, a jiným kritické hodnoty

Je tedy třeba mít důkladně číst celý text, nejen vzorce!

Nezávislost náhodných veličin.

Veličiny X_1, \dots, X_n jsou nezávislé, jedliže 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 sdružená distribuční fce,
 $F_i(x_i) = P(X_i < x_i)$ jsou marginální distribuční fce jednotlivých veličin
 (musí to platit pro každé n a všechny možné hodnoty x_1, \dots, x_n).

jinak: $f(x_1, \dots, x_n) = f_1(x_1) \dots f_n(x_n)$

Důsledky: $E(X_1 \dots X_n) = E(X_1) \dots E(X_n)$

$$var(X_1 + \dots + X_n) = var(X_1) + \dots + var(X_n)$$

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

Náhodný vektor je posloupnost navzájem nezávislých náhodných veličin se stejným rozdělením.

Povídky mnoha statistických metod předpokládá normální rozdělení, ale tento předpoklad nebyla nikdy a není splněn. Proto jsou někdy a někdy používány. Proč? Platí tzv. Centrální limitní věta:

Necht $X_1, X_2, \dots, X_m, \dots$ jsou nezávislé stejné rozdělení náhodné veličiny, $E X_i = \mu < \infty$, $var X_i = \sigma^2 < \infty$ pro všechna i . Položíme $Y_m = \sum_{k=1}^m X_k$. Pak pro distribuční fci $F_m(x)$ náhodné veličiny $Y_m^* = \frac{Y_m - E(Y_m)}{\sqrt{var Y_m}}$ platí

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

neboli: $\frac{\sum_{k=1}^m X_k - m\mu}{\sqrt{m\sigma^2}} \xrightarrow{m \rightarrow \infty} \zeta \sim N(0, 1)$ a distribuci

když kromě uplatíme m : $\frac{\frac{1}{m} \sum_{k=1}^m X_k - \mu}{\sqrt{\frac{\sigma^2}{m}}} \xrightarrow{m \rightarrow \infty} \zeta \sim N(0, 1)$

Převod rozdělení $N(0, 1)$ na $N(\mu, \sigma^2)$ a naopak:

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

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

Centrální limitní věta pak vlastně říká, že aritmetické průměry

$\bar{X}_m = \frac{1}{m} \sum_{k=1}^m X_k$ mají asymptoticky normální rozdělení $N(\mu, \frac{\sigma^2}{m})$,

i když veličiny X_k normální rozdělení nemají.

Dalsi trik, ktery mam nikdy dorozuji osidit predpoklady, ze zakon velkych cisel. Existuje ve 2 podobach:

Glady zakon velkych cisel: Necht X_1, X_2, \dots jsou po dvou nesavisle nastrojeni velicity, $EX_i = \mu < \infty$, $var X_i = \sigma^2 < \infty$ po vsechna i . Pak $\bar{X}_m = \frac{1}{m} \sum_{i=1}^m X_i \xrightarrow{P} \mu$ (konverguje podle pravdepodobnosti).

Knamena to, ze po libovolni $\epsilon > 0$ plati $\lim_{m \rightarrow \infty} P(|\bar{X}_m - \mu| < \epsilon) = 1$.

Slabij zakon velkych cisel: Necht X_1, X_2, \dots jsou nesavisle nastrojeni velicity s kyma rozdilenim, $EX_i = \mu < \infty$, $var X_i = \sigma^2 < \infty$. Pak $\bar{X}_m = \frac{1}{m} \sum_{i=1}^m X_i \rightarrow \mu$ skoro jiste, tj: $P(\lim_{m \rightarrow \infty} \bar{X}_m = \mu) = 1$.

Cím ze kapitoly matematická statistika

- a) odhady charakteristik náhodných veličin (střední hodnota, rozptyl, ...)
odhady bodové nebo intervalové
a vlastnosti těchto odhadů (nestranne, maximálně účinné, ...)
 - b) odhady parametrů rozdělení
 - c) testy hypotéz o parametrech rozdělení
 - d) testy dobré shody a předpokladových rozdělení
 - e) testy nezávislosti
 - f) parametry dvou nebo více výběrů
 - g) regrese
 - h) plánování experimentů
- atd.

Literatura: J. Anděl: *Statistické metody*, MATFYZ PRESS, Praha 1998

K. Kváča, J. Uhlířan: *Pravděpodobnost a matematická statistika*
MATFYZ PRESS, Praha 1997

Náhodný vzorek & normální rozdělení $N(\mu, \sigma^2)$

postupnost X_1, \dots, X_n navzájem nezávislých náhodných veličin,
každá má rozdělení $N(\mu, \sigma^2)$

(μ může být budou naprovozané hodnoty)

Bodyové odhady parametrů:

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

odhad je nestkanný, tj: $E\bar{X} = \mu$ (důl. $E\bar{X} = \frac{1}{n} \sum_{i=1}^n EX_i = \frac{1}{n} \sum_{i=1}^n \mu = \mu$)

konzistentní, tj: $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow \mu$ podle zákona
veliké čísel

maximálně věrohodný (kolem nebudeme definovat)

má rozdělení $N(\mu, \frac{\sigma^2}{n})$

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

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

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

není maximálně věrohodný

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

$$\text{plati' } \frac{(n-1)S^2}{\sigma^2} = \sum_{i=1}^n \underbrace{\left(\frac{X_i - \bar{X}}{\sigma}\right)^2}$$

tyto veličiny mají rozdělení $N(0,1)$

nijaké ale všechny nezávislé, proto je počet stupňů
volnosti $n-1$ a ne n .

\bar{X} a S^2 jsou nezávislé

Skutečné hodnoty parametru se budou nacházet s velkou pravděpodobností v nějakém intervalu kolem svých bodových odhadů. Měkké se učí podle toho, jak velkou jst chceme.

Nejjednodušší případ: Interval spolehlivosti pro μ (normální) při známém σ^2 .

vzdáme nějaké $\alpha \in (0,1)$ - mělo by být malé, např. $\alpha = 0,05$

hledáme a, b tak, aby platilo

$$\left. \begin{array}{l} \text{buď } P(a < \mu) = 1 - \alpha \\ \text{nebo } P(\mu < b) = 1 - \alpha \\ \text{nebo } P(a < \mu < b) = 1 - \alpha \end{array} \right\} \begin{array}{l} \text{jednosměrné intervaly spolehlivosti} \\ \text{obousměrný} \end{array}$$

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

vydeme se odhadu \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 kvantil rozdělení $N(0,1)$

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

Definice kvantilu: Necht Y je náhodná veličina s distribuční fci F . Hodnota x_α , po které $F(x_\alpha) = P(Y < x_\alpha) = \alpha$, se nazývá α -kvantilem příslušného rozdělení.

Kvantily známých rozdělení se najdou v tabulkách.

podobně:
$$P(\mu < \bar{X} + \underbrace{\mu_{1-\alpha}}_{\text{d}} \frac{\sigma}{\sqrt{n}}) = P(-\mu_{1-\alpha} \frac{\sigma}{\sqrt{n}} < \bar{X} - \mu) =$$

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

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

Φ je distribuční fce $N(0,1)$

platí pro ni $\Phi(-u) = 1 - \Phi(u)$, protože rozdělení je symetrické
obousměrný interval bude mít meze $(\bar{X} - \mu_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + \mu_{1-\alpha/2} \frac{\sigma}{\sqrt{n}})$

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

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

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

Interval spolehlivosti pro μ při neznámém σ^2

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

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

platí:
$$\frac{\bar{X} - \mu}{\frac{s}{\sqrt{n}}} = \frac{\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}}{\sqrt{\frac{(n-1)S^2}{\sigma^2}} \cdot \frac{1}{\sqrt{n-1}}} = \frac{Y}{\sqrt{\frac{\chi^2}{n-1}}}$$
, kde $Y \sim N(0,1)$

$$\chi^2 \sim \chi^2_{n-1}$$

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

Intervaly spolehlivosti budou vypadat stejně, pouze místo kvantilů u_α normálního rozdělení se použijí kvantily $t_{m-1, \alpha}$ Studentova t -rozdělení:

Interval spolehlivosti pro σ^2

vycházíme z vztahu S^2 a σ^2 toho, že víme, že $\frac{(m-1)S^2}{\sigma^2} \sim \chi^2_{m-1}$

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

z toho $P\left(\frac{(m-1)S^2}{\chi^2_{m-1, 1-\alpha}} < \sigma^2\right) = 1-\alpha$

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

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

Obecně je ve statistice třeba vyřešit otázku, jak velký rozsah výběru je třeba, aby tyto vztahy byly dostatečně přesné (a je to obléhání).

V data miningu to není tak důležitá, protože rozsah dat, která jsou k dispozici, je obvykle hodně velký.

Testy hypotéz o parametrech μ normálního rozdělení

Hypotéza = nějaké tvrzení o hodnotě parametru, např.:

- $H: \mu = \mu_0$... jednoduchá hypotéza
- $H: \mu \geq \mu_0$ } složená hypotéza
- $H: \mu \leq \mu_0$ }

alternativa = možnost, že kterou považujeme α případy, že hypotéza neplatí, např.

- $A: \mu = \mu_1$... jednoduchá alternativa
- $A: \mu \neq \mu_0$... složená alternativa, dvoustranná
- $A: \mu > \mu_0$ } složená alternativa jednostranná
- $A: \mu < \mu_0$ }

testuje se např. $H: \mu = \mu_0$ proti $A: \mu \neq \mu_0$

nebo $H: \mu \geq \mu_0$ proti $A: \mu < \mu_0$ atd.

Každé při testování je buď: hypotézu zamítneme

nebo: hypotézu nemítneme

můžeme se, že hypotézu přijímáme nebo že platí

každé je vždy nějakou nějakou chybou

chyba 1. druhu ... zamítneme hypotézu, ačkoli je pravdivá

chyba 2. druhu ... nemítneme hypotézu, ačkoli pravdivá není

krácíme $P(\text{chyba 1. druhu}) = \alpha$

$P(\text{chyba 2. druhu}) = \beta$

Ideální by bylo, kdyby se daly obě tyto podmínky současně minimalizovat, nebo předem zvolit tak malé, jak bychom si přáli - to se ale obvykle nedá splnit (např. při kmenování a rozleptání). Obecně obvyklý postup je: zvolit se d dostatečně malé, ale nepřehnaně malé.

(např. $\alpha = 0,05$ nebo $\alpha = 0,01$)

při tomto α se konstruuje test tak, aby se byla co nejvíce d... hladina významnosti testu

test hypotéz se opět redukuje na nějaké kritické upřesnění a porovnání hodnot, podle-li do tzv. kritického oboru, hypotéza se zamítá, podle-li mimo kritický obor, hypotéza se nezamítá.

Test $H: \mu = \mu_0$ při známém rozptylu σ^2

jednostranný test $H: \mu = \mu_0$ proti $A: \mu > \mu_0$

test se redukuje na odhadu \bar{X}

velké hodnoty \bar{X} budou svědčit ve prospěch alternativní hypotézy kritický obor bude $\bar{X} \geq k$, kde k musíme nějak určit

pomocí transformací $T = \frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ na přednosti H

platí: $P(T \geq u'_\alpha) = \alpha$, kde u'_α je kritická hodnota rozdělení $N(0, 1)$

(to je definice)

tedy $\alpha = P\left(\frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \geq u'_\alpha\right) = P\left(\bar{X} \geq \underbrace{\mu_0 + \frac{\sigma}{\sqrt{n}} u'_\alpha}_{\text{hledané } k}\right)$

je to zároveň test $H: \mu \leq \mu_0$ proti $A: \mu > \mu_0$

$\bar{X} \geq \mu_0 + \frac{\sigma}{\sqrt{n}} u'_\alpha$ je kritický obor, hypotéza se zamítá

nebo $\bar{X} < \mu_0 + \frac{\sigma}{\sqrt{n}} u'_\alpha$ se nezamítá

je-li $\mu = \mu_0$ (H platí), máme $\mu > \bar{X} - \frac{\sigma}{\sqrt{n}} u'_\alpha$

$$P(\mu > \bar{X} - \frac{\sigma}{\sqrt{n}} u'_\alpha) = 1 - \alpha$$

je tedy $(\bar{X} - \frac{\sigma}{\sqrt{n}} u'_\alpha, \infty)$ interval spolehlivosti pro μ .

vztah mezi kritickou hodnotou a kvantilem:

$$P(X < u_\alpha) = \alpha \quad \text{kvantile}$$

$$P(X \geq u'_\alpha) = \alpha \quad \text{kritická hodnota}$$

$$\text{platí } u'_\alpha = u_{1-\alpha}, \text{ neboť } P(X \geq u_{1-\alpha}) = 1 - P(X < u_{1-\alpha}) = 1 - (1 - \alpha) = \alpha$$

Hypotéza se tedy dá ekvivalentně testovat pomocí intervalu spolehlivosti. podobně test $H: \mu = \mu_0$ proti $A: \mu < \mu_0$.

obousměrný test $H: \mu = \mu_0$ proti $\mu \neq \mu_0$ má kritický obor:

$$|\bar{X} - \mu_0| \geq k$$

$$k \text{ se určí ze podmínky, že } P\left(\frac{|\bar{X} - \mu_0|}{\frac{\sigma}{\sqrt{n}}} \geq u'_{\alpha/2}\right) =$$

$$= P\left(\frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \geq u'_{\alpha/2}\right) + P\left(-\frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \leq -u'_{\alpha/2}\right) = \alpha/2 + \alpha/2 = \alpha$$

$$\text{tedy } |\bar{X} - \mu_0| \geq \frac{\sigma}{\sqrt{n}} u'_{\alpha/2}$$

obvyklý výjádření kritického obou je, že se hodnota

$$T = \frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} \text{ porovná přímo s kritickou hodnotou rozdílů}$$

Testy pro H: $\mu = \mu_0$ při neznámém σ^2

vezme se $T = \frac{\bar{X} - \mu_0}{\frac{s}{\sqrt{n}}} \sim t_{n-1}$ na platnosti hypotézy

odvodi se stejně, jen kritické hodnoty se nabídnou krit. hodnotami t-rozdělení

např. H: $\mu = \mu_0$ proti A: $\mu \neq \mu_0$ se namítá, když

$$T = \frac{|\bar{X} - \mu_0|}{\frac{s}{\sqrt{n}}} \geq t_{n-1, \alpha}$$

Test $\sigma^2 = \sigma_0^2$

test H: $\sigma^2 = \sigma_0^2$ proti A: $\sigma^2 > \sigma_0^2$

H se namítá, když $\frac{(n-1)S^2}{\sigma_0^2} \geq \chi^2_{n-1, \alpha}$

test H: $\sigma^2 = \sigma_0^2$ proti A: $\sigma^2 \neq \sigma_0^2$

H se namítá, když $\frac{(n-1)S^2}{\sigma_0^2} \geq \chi^2_{n-1, \alpha/2}$

nebo $\frac{(n-1)S^2}{\sigma_0^2} \leq \chi^2_{n-1, 1-\alpha/2}$

test H: $\sigma^2 = \sigma_0^2$ proti A: $\sigma^2 < \sigma_0^2$

H se namítá, když $\frac{(n-1)S^2}{\sigma_0^2} \leq \chi^2_{n-1, 1-\alpha}$

P-hodnota

Každá se používá ať s rozdílnými výpočtovými technickými, spíše tabulkami
by to bylo nereálnější.

P-hodnota je významná hodnota, při které bychom ještě hypotézu neměli.

Některé přirozené vztahy pro tabulkové hodnoty

Normální rozdělení:

hustota: $\varphi(u) = \varphi(-u)$

distr. fce: $\Phi(u) = 1 - \Phi(-u)$

kvantil: definice $\Phi(u_\alpha) = \alpha$ platí $u_\alpha = -u_{1-\alpha}$

důkaz: $\alpha = P(U < u_\alpha) = P(U > -u_\alpha)$ ze symetrie

$$= 1 - P(U < -u_\alpha)$$

$$\Rightarrow P(U < -u_\alpha) = 1 - \alpha \Rightarrow -u_\alpha = u_{1-\alpha}$$

kritická hodnota: definice $P(U \geq u'_\alpha) = \alpha$

platí $u'_\alpha = -u'_{1-\alpha}$ (důkaz stejný)

platí $u'_\alpha = u_{1-\alpha}$ dle: $\alpha = P(U \geq u'_\alpha) = 1 - P(U < u'_\alpha)$

$$\Rightarrow P(U < u'_\alpha) = 1 - \alpha \Rightarrow u'_\alpha = u_{1-\alpha}$$

χ^2 -rozdělení:

není symetrické

kvantil: $P(X < \chi^2_{m, \alpha}) = \alpha$

kritická hodnota: $P(X \geq \chi^2'_{m, \alpha}) = \alpha$

} definice

platí: $\chi^2_{m, \alpha} = \chi^2'_{m, 1-\alpha}$

t -rozdělení:

hustota: $f_m(t) = f_m(-t)$

distr. fce: $F_m(t) = 1 - F_m(-t)$

kvantil: definice $P(X < t_{m,d}) = d$

platí $t_{m,d} = -t_{m,1-d}$

kritická hodnota: definice: $P(|X| \geq t'_{m,d}) = d$

platí: $t'_{m,d} = t_{m,1-d/2}$

F -rozdělení:

není symetrické

kvantil: def. $P(X < f_{m_1, m_2; d}) = d$

platí: $f_{m_1, m_2; d} = \frac{1}{f_{m_2, m_1; 1-d}}$

kritická hodnota: def. $P(X \geq f'_{m_1, m_2; d}) = d$

platí: $f'_{m_1, m_2; d} = f_{m_1, m_2; 1-d}$

$$f'_{m_1, m_2; d} = \frac{1}{f'_{m_2, m_1; 1-d}}$$

dh: necht $X_1 \sim \chi^2_{m_1}$, $X_2 \sim \chi^2_{m_2}$, nezávislé

$$P\left(\frac{\frac{X_1}{m_1}}{\frac{X_2}{m_2}} \geq f'_{m_1, m_2; d}\right) = d = P\left(\frac{\frac{X_2}{m_2}}{\frac{X_1}{m_1}} \geq f'_{m_2, m_1; d}\right)$$

$$1 - \alpha = P\left(\frac{\frac{x_2}{m_2}}{\frac{x_1}{m_1}} < \frac{1}{f'_{m_1, m_2, \alpha}}\right) = 1 - P\left(\frac{\frac{x_2}{m_2}}{\frac{x_1}{m_1}} \geq \frac{1}{f'_{m_1, m_2, \alpha}}\right)$$

$$\Rightarrow P\left(\frac{\frac{x_2}{m_2}}{\frac{x_1}{m_1}} \geq \frac{1}{f'_{m_1, m_2, \alpha}}\right) = 1 - \alpha$$

$$\Rightarrow \frac{1}{f'_{m_1, m_2, \alpha}} = f'_{m_2, m_1, 1-\alpha}$$

Odhad početníku počtu pozorování

maxim se o "přijatelnou" délku intervalu spolehlivosti (1-α)%-ní interval spolehlivosti pro μ při známém σ²:

$$\bar{x} - \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2} < \mu < \bar{x} + \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2} \quad u_{1-\alpha/2} \text{ je kvantil}$$

délka intervalu je $\frac{2\sigma}{\sqrt{n}} u_{1-\alpha/2}$

je obvyklé je omezit nejvyšším možným směrodatnou odchylkou,

tj. $\frac{2\sigma}{\sqrt{n}} u_{1-\alpha/2} \leq k\sigma$, kde k se zvolím

nebo $\sqrt{n} \geq \frac{2}{k} u_{1-\alpha/2}$

Např. pro k=2 to znamená: chci interval délky nejvýše dvojnásobku směrodatné odchylky, tj. střední hodnota bude $\bar{x} \pm \sigma$. K tomu potřebujeme $n = u_{1-\alpha/2}^2$ pozorování.

pro α=0,05 je $u_{1-\alpha/2} = u_{0,975} = 1,96$, tj. n=4

existují k tomu tabule