

Pravděpodobnost vs. statistika

Teorie pravděpodobnosti

- pracuje s jednou nebo více teoretickými náhodnými veličinami, jejichž rozdělení je známo
- odvozovali jsme charakteristiky těchto rozdělení atd.

Statistika

- pracuje s pozorováními (daty) \iff náhodný výběr z nějakého neznámého rozdělení
- na základě dat se snažíme něco říci o rozdělení, z něhož pocházejí (např. o střední hodnotě apod.)
- někdy pozorujeme více náhodných veličin (více náhodných výběrů) a chceme něco usoudit o jejich vzájemném vztahu

Teorie odhadu

- máme data x_1, \dots, x_n (např. hodnoty výšky studentů)
- považujeme je za **realizaci náhodného výběru** X_1, \dots, X_n z nějakého neznámého rozdělení
- chceme něco usuzovat o charakteristikách tohoto rozdělení (střední hodnota, rozptyl, hustota ...) \rightsquigarrow budeme konstruovat jejich **odhady** (tzv. bodové odhady)
- odhadů je mnoho, chceme vybrat ty „dobré“

Jak by měl vypadat „dobrý odhad“?

- Neměl by mít žádnou systematickou výchylku (v průměru by měl odhadovat to, co chceme odhadovat).
- S přibývajícím počtem pozorování by měl být „přesnější a přesnější“.

Příklad datového souboru

Studie zkoumající účinky nového léku pro snižování krevního tlaku:

id	lék	tlak pred	tlak po	pohl.	váha	...	kuřák
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
103	T	145	120	M	82	...	ano
104	C	155	130	M	97	...	ano
105	T	140	135	Z	74	...	ne
106	C	160	150	M	123	...	ano
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

Dva typy problémů:

- odhady neznámých kvantit \iff **odhady parametrů**
- rozhodování o platnosti nějakého výroku \iff **testování hypotéz**

Formální definice

Definice

Odhadem neznámé charakteristiky θ rozumíme jakoukoli funkci $\hat{\theta}_n$ pozorování X_1, \dots, X_n .

- Odhad $\hat{\theta}_n$ nazýváme **nestranný (nevychýlený)**, pokud $E\hat{\theta}_n = \theta$.
- Odhad $\hat{\theta}_n$ nazýváme **konzistentní**, pokud $\lim_{n \rightarrow \infty} \hat{\theta}_n = \theta$.

Závěr: Rozumné odhady by měly být konzistentní a pokud možno nestranné (ale malá výchylka nevádí).

Už víme: průměr je dobrý odhad střední hodnoty (je nestranný i konzistentní).

Popisné statistiky jako bodové odhady

Teorie


- náhodná veličina X
- hustota f
- střední hodnota EX
- rozptyl $var X$
- medián, kvantily
- pravděpodobnost jevu

Odhady

- data \leftrightarrow realizace náh.výběru
- histogram
- výběrový průměr \bar{X}_n
- výběrový rozptyl S_X^2
- výběrový medián, výběrové kvantily
- relativní četnost případů

Odhad distribuční funkce

Empirická distribuční funkce váhy studentů 1. ročníku PřF (muži a ženy zvlášť).



Odhad distribuční funkce

Problém: X_1, \dots, X_n náhodný výběr, chceme odhadnout distribuční funkci $F(x) = P(X \leq x)$

Empirická distribuční funkce definovaná jako

$$\hat{F}_n(x) = \frac{\#\{i : X_i \leq x\}}{n}$$

- lze ukázat, že má „dobré“ vlastnosti
- hodnota funkce \hat{F}_n v bodě x je odhadem pravděpodobnosti $P[X_i \leq x]$ pomocí relativní četnosti jevu $[X_i \leq x]$

Odhad kovariance a korelace

Problém: náhodný výběr $(X_1, Y_1), \dots, (X_n, Y_n)$ z dvourozměrného rozdělení, chceme odhadnout kovarianci a korelaci znaků X a Y

Výběrová kovariance:

$$S_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

- \bar{X} je výběrový průměr X_1, \dots, X_n
- \bar{Y} je výběrový průměr Y_1, \dots, Y_n
- S_{XY} má stejnou strukturu jako teoretická kovariance, jen střední hodnoty nahrazeny průměry
- S_{XY} je „dobrý“ odhad $cov(X, Y)$

Odhad korelace

Korelace:
$$\rho_{XY} = \frac{\text{cov}(X, Y)}{\sqrt{\text{var } X \text{ var } Y}}$$


Výběrový korelační koeficient

$$r_{XY} = \frac{S_{XY}}{S_X S_Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

- S_X^2 je výběrový rozptyl X_1, \dots, X_n
- S_Y^2 je výběrový rozptyl Y_1, \dots, Y_n
- r_{XY} je „dobrý“ (konzistentní ale ne nestranný) odhad ρ_{XY}

Odhad kovariance a korelace: příklad

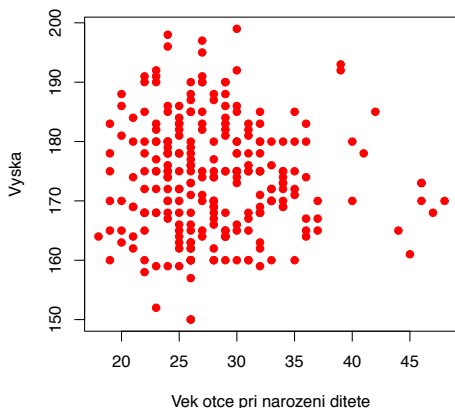
Graf váhy proti výšce ($r_{XY} = 0.72$):



hodnota r_{XY} koresponduje s obrázkem \rightsquigarrow zdá se, že větší výška se pojí s vyšší hmotností

Odhad kovariance a korelace — příklad

Graf výšky proti věku otce při narození dítěte ($r_{XY} = -0.04$):



nic nenaznačuje, že by výška nějak souvisela s věkem otce při narození dítěte

Intervalové odhady

- doted': tzv. bodové odhady (odhadem charakteristiky je číslo)
- nevyjadřuje nic o přesnosti odhadu

Intervalový odhad parametru θ

- interval s náhodnými mezemi, který překryje θ s předepsanou pravděpodobností $1 - \alpha$
- např. 95% interval spolehlivosti, interval na hladině 99% apod.
- konkrétněji si uvedeme **později**

Testování hypotéz – motivační příklad

Příklad: Provádíme průzkum, jaký skutečný objem piva točí v nejmenované hospodě. Zakoupeno bylo 10 piv a jejich objem byl (v litrech):

0.510, 0.462, 0.491, 0.466, 0.461, 0.503, 0.495, 0.488, 0.512, 0.505.

Z pohledu zákazníka bychom chtěli otestovat, zda hostinský netočí pod míru.

Průměr vychází $\bar{X} = 0.4893 < 0.5$. Otázkou je, zda je to vlivem náhody, nebo už se jedná o systematickou výchytku?

Testování hypotéz

Testování hypotéz

- = vyhodnocování pravdivostní hodnoty výroků na základě náhodného výběru (tj. ověřování platnosti nějakého výroku)
- provádíme pomocí **statistických testů**

Hypotéza

- = výrok, o jehož pravdivosti chceme rozhodnout
- **nulová hypotéza** H_0
 - tvrzení o populaci, o jehož platnosti rozhodujeme
 - (není rozdíl, nezávisí, neliší se, ...)
- **alternativní hypotéza** H_1 :
 - alternativa (doplňující možnost) k H_0
 - často tvrzení, které **chceme prokázat**

Testování hypotéz – motivační příklad

Je rozdíl $\bar{X} = 0.4893 < 0.5$ dostatečný na to, abychom mohli tvrdit, že hostinský točí pod míru?

- vezmeme-li přímo výběr se střední hodnotou 0.5 \rightsquigarrow průměr nebude nikdy přesně 0.5, ale neměl by se lišit velmi
- je potřeba zohlednit:
 - ➔ počet pozorování (více dat \rightsquigarrow větší přesnost odhadů)
 - ➔ variabilitu (vysoký rozptyl = větší nejistota)
- vezmeme v úvahu rozdělení $\bar{X} - 0.5$ a z něho zjistíme, jaké hodnoty jsou již „extrémní a málo pravděpodobné“ \rightsquigarrow **statistické testy**

Statistický test

Statistický test = rozhodovací pravidlo, na jehož základě zamítáme nebo nezamítáme H_0

- **testová statistika** $T_n = T_n(X_1, \dots, X_n)$ = náhodná veličina, která je funkcí pozorování X_1, \dots, X_n
- **kritický obor** C = možné výsledky pokusu, kdy H_0 **zamítáme**

Rozhodovací pravidlo:

- pokud $T_n \in C \rightarrow$ **zamítáme** hypotézu H_0 ve prospěch alternativy H_1
(naše data svědčí proti H_0 a prokazujeme tak platnost H_1)
- pokud $T_n \notin C \rightarrow$ hypotézu H_0 **nezamítáme**
(na základě našich dat nelze zamítnout H_0 , naše data nejsou v rozporu s H_0)

Pozor: **nesymetrie** mezi H_0 a H_1

Chyba I. a II. druhu

- rozhodujeme na základě náhodného výběru \rightarrow nemůžeme testovanou otázku zodpovědět s absolutní jistotou
- můžeme se **dopustit chyby** \rightarrow tyto chyby se budeme snažit omezit (resp. kontrolovat jejich pravděpodobnosti)

	H_0 zamítáme	H_0 nezamítáme
H_0 platí	chyba 1. druhu	OK
H_0 neplatí	OK	chyba 2. druhu

Označíme:

$$\alpha = P(\text{chyba 1. druhu}) = P(\text{zamítáme } H_0 | H_0 \text{ platí})$$

$$\beta = P(\text{chyba 2. druhu}) = P(\text{nezamítáme } H_0 | H_0 \text{ neplatí})$$

Přirozený požadavek: $\alpha, \beta \rightarrow \min \iff$ bohužel nelze současně

Chyba I. a II. druhu

- zvolíme **hladinu testu** α (zpravidla $\alpha = 0.05$)
 - maximální dovolená pst chyby 1. druhu
 - maximální pst **falešného prokázání** vědecké hypotézy
 - chyba 1.druhu je závažnější (falešně něco prokazujeme)
 - volíme **před** pokusem, nezávisle na jeho výsledku
- pro dané α chceme minimální $\beta \iff$ maximální $1 - \beta$
- síla testu** $1 - \beta$
 - pst zamítnutí neplatné H_0
 - pst, s jakou prokážeme platnou vědeckou hypotézu H_1
 - nemáme pod kontrolou (závisí na tom, co opravdu platí)
 - můžeme ovlivnit volbou statistického testu, počtem pozorování, ...

$\rightarrow \alpha$ máme plně pod kontrolou, o β toho moc nevíme

Dosažená hladina testu

Dosažená hladina testu p -hodnota (angl. p -value)

- pravděpodobnost, že dostaneme výsledek, který stejně nebo ještě méně podporuje H_0 , jestliže H_0 platí
- nejmenší hladina α , na které lze ještě H_0 zamítnout
- „stupeň důvěry“ v platnost H_0
- výsledek provedení statistického testu pomocí softwaru

Pravidlo:

- je-li $p \leq \alpha \rightsquigarrow$ zamítáme H_0
- je-li $p > \alpha \rightsquigarrow$ nezamítáme H_0

(Zapamatovat!)

Testování hypotéz – shrnutí

Při testování můžeme

- dojít ke správnému rozhodnutí
- udělat chybu 1. druhu (zamítnout platnou H_0) anebo 2. druhu (nezamítnout neplatnou H_0)

Postup:

- stanovíme dostatečně nízkou pravděpodobnost chyby 1. druhu α (hladinu testu)
(chyba 1. druhu je **závažnější** \rightsquigarrow její pst máme pod kontrolou)
- pravděpodobnost chyby 2. druhu β závisí na okolnostech (volba testu, počet pozorování, variabilita, ...) a její hodnotu v praxi neznáme

Proto: H_0 a H_1 nejsou posuzovány symetricky

Nesymetrie H_0 a H_1

H_0 a H_1 nejsou posuzovány symetricky:

- H_0 považujeme a priori za platnou a zamítáme ji jen tehdy, pokud k tomu máme dostatečně silné důvody
 - pokud jsme zamítli $H_0 \rightsquigarrow$ můžeme tvrdit, že data svědčí o tom, že H_0 neplatí (a prokazujeme platnost H_1)
 - pokud jsme H_0 nezamítli \rightsquigarrow pak
 - buď H_0 opravdu platí
 - anebo H_0 neplatí, ale data **neposkytují dostatečně „důkazy“** k jejímu zamítnutí (malá síla testu)
- nutné volit opatrné formulace závěrů (*hypotézu H_0 nelze na základě našich dat zamítnout apod.*)

Závěr

Hypotézu H_0 **nemůžeme prokázat, ale pouze vyvrátit**

Filozofie testování hypotéz

soudní proces ctící princip presumpce nevinny.

H_0 : „Obžalovaný je nevinen“.

H_1 : „Obžalovaný je vinen“.

- zamítneme-li $H_0 \rightsquigarrow$ odsoudíme obžalovaného k trestu
- nezamítneme-li $H_0 \rightsquigarrow$ obžalovaný je propuštěn
- data \leftrightarrow důkazy svědčící pro nebo proti vině
- testová statistika \leftrightarrow soudce
- kritický obor \leftrightarrow důkazní břemeno = množství důkazů nutné k odsouzení
- hladina testu $\alpha \leftrightarrow$ pst odsouzení nevinného
- síla testu $1 - \beta \leftrightarrow$ pst odsouzení skutečného pachatele

Filozofie testování hypotéz

Hladinu α zvolíme malou (např. 5 %)

- chráníme nevinné před odsouzením
- čím menší $\alpha \rightsquigarrow$ vyšší důkazní břemeno \rightsquigarrow řada viníků propuštěna pro nedostatek důkazů

Výsledek procesu:

- odsouzení obžalovaného \rightsquigarrow lze tvrdit, že je vinen
- propuštění obžalovaného \rightsquigarrow buď opravdu nevinen, anebo vinen, ale soud neměl dostatečné důkazy k jeho odsouzení

K odsouzení viníka může dopomoci (bez porušení presumpce nevinny):

- schopný soudce (vhodná testová statistika),
- dodatečné množství důkazů (více dat)
- málo chyb a omylů v důkazním materiálu (malý rozptyl)

Statistické testy

- statistických testů je obrovské množství
- uvedeme si jen několik vybraných základních
- podrobné odvození testové statistiky a kritického oboru jen u některých
- v praxi důležité:
 - výběr vhodného testu pro daný problém
 - provedení testu
 - ověření předpokladů testu (např. normalita dat, ...)
 - správná interpretace výsledku

Test o střední hodnotě v normálním rozdělení

Situace: X_1, \dots, X_n náhodný výběr z normálního rozdělení $N(\mu, \sigma^2)$, kde $\sigma > 0$ **známe**; chceme testovat

$$H_0 : \mu = \mu_0,$$

kde μ_0 je nějaká známá (předepsaná) hodnota, proti alternativě

$$H_1 : \mu > \mu_0.$$

Chceme: statistický test \leftrightarrow testová statistika a kritický obor

Jiné možné alternativy:

- $H_1 : \mu \neq \mu_0$ tzv. oboustranná alternativa
- $H_1 : \mu < \mu_0$ tzv. jednostranná alternativa

(volba alternativy dle zadání úlohy – vyplývá z její formulace)

Odvození testu – pokrač.

Postupně upravíme:

$$\begin{aligned} \alpha &= P(\bar{X}_n > K | H_0 \text{ platí}) = P(\bar{X}_n > K | \mu = \mu_0) \\ &= P\left(\underbrace{\sqrt{n} \frac{\bar{X} - \mu_0}{\sigma}}_{T_n \sim N(0,1)} > \underbrace{\sqrt{n} \frac{K - \mu_0}{\sigma}}_{=C} \mid \mu = \mu_0\right) = 1 - \Phi(C) \end{aligned}$$

Odtud

$$C = u_{1-\alpha}, \quad K = \frac{\sigma}{\sqrt{n}} u_{1-\alpha} + \mu_0$$

(Připomenutí: $u_{1-\alpha}$ je $1 - \alpha$ kvantil normálního rozdělení, $u_{1-\alpha} = z_\alpha$, kde z_α je kritická hodnota)

Odvození testu

Víme:

- střední hodnotu μ odhadujeme pomocí \bar{X}_n
- rozdělení \bar{X}_n je $N(\mu, \frac{\sigma^2}{n})$, a proto

$$\sqrt{n} \frac{\bar{X}_n - \mu}{\sigma} \sim N(0, 1)$$

Proti H_0 a ve prospěch H_1 svědčí hodnoty $\bar{X}_n \gg \mu_0$

- zvolíme hladinu testu α
- budeme hledat „mezni hodnotu“ K tak, že pro $\bar{X}_n > K$ už zamítneme H_0
- musí platit

$$P(\text{chyba 1.druhu}) = P(\bar{X}_n > K | H_0 \text{ platí}) = \alpha$$

Test o střední hodnotě normálního rozdělení při známém σ^2

Odvodili jsme test:

- testová statistika

$$T_n = \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma}$$

- kritický obor $C = (u_{1-\alpha}, \infty)$
- je-li $T_n > u_{1-\alpha} \rightsquigarrow$ zamítneme H_0
- je-li $T_n \leq u_{1-\alpha} \rightsquigarrow$ nezamítneme H_0

Podobným postupem bychom odvodili test H_0 proti

- $H_1 : \mu < \mu_0 \rightsquigarrow$ kritický obor $T_n < -u_{1-\alpha}$
- $H_1 : \mu \neq \mu_0 \rightsquigarrow$ kritický obor $|T_n| > u_{1-\frac{\alpha}{2}}$

Zvolíme-li hladinu $\alpha = 0.05$ dostaneme $u_{1-\alpha} = u_{0.95} = 1.64$ a $u_{1-\alpha/2} = u_{0.975} = 1.96$.

Příklad – pivo

Máme zakoupeno 10 piv, chceme otestovat, zda hostinský netočí pod míru. Předpokládejme, že z předchozí zkušenosti víme, že směrodatná odchylka naměřených objemů piva je 0.02 l.

Model: Předpokládáme, že data jsou realizací náhodného výběru z $N(\mu, \sigma^2)$, kde $\sigma = 0.02$ (známe)

Hypotézy: $H_0 : \mu = 0.5$ proti $H_1 : \mu < 0.5$

Hladina testu: zvolíme test na hladině 5 %, tj. $\alpha = 0.05$

Test: musíme zjistit, zda platí $T_n = \sqrt{n} \frac{\bar{X} - 0.05}{\sigma} < -u_{0.95} = -1.645$

Příklad – pokrač.

Dosažená hladina testu (p -hodnota)

- pravděpodobnost za platnosti H_0 , že dostaneme výsledek ještě „extrémněji“ svědčící proti H_0 a ve prospěch H_1
- $P(\sqrt{n} \frac{\bar{X}_n - 0.5}{\sigma} < -1.691) = \Phi(1.691) = 0.045$
- p -hodnota je rovna 0.045 (je tedy nižší než $\alpha = 0.05$)
- podařilo se nám tedy prokázat, že hostinský točí pod míru
- ale p -hodnota je jen těsně menší než $\alpha = 0.05 \rightsquigarrow$ ne úplně přesvědčivý výsledek

Provedení testu

- máme $\bar{X} = 0.4893$, odtud testová statistika

$$T_n = \sqrt{10} \frac{0.4893 - 0.5}{0.02} = -1.691$$

- test: platí $T_n < -u_{0.95} = -1.645 \rightsquigarrow$ zamítáme nulovou hypotézu a prokazujeme alternativu
- podařilo se nám tedy prokázat, že hostinský točí pod míru
- riskovali jsme 5%, že budeme nesprávně tvrdit, že hostinský točí pod míru, pokud to tak není

Jiné alternativy

- kdybychom se zajímali o test $H_0 : \mu = 0.5$ proti $H_1 : \mu > 0.5$, pak bychom se zkoumali, zda platí

$$T_n > 1.64$$

(neplatí)

- kdybychom se zajímali o test $H_0 : \mu = 0.5$ proti $H_1 : \mu \neq 0.5$, pak bychom se zkoumali, zda platí

$$|T_n| > u_{0.975} = 1.96$$

(neplatí)

Jednovýběrový t-test – úvod

- dosud jsme předpokládali, že σ^2 je známé
- v praxi většinou σ^2 neznáme \rightsquigarrow odhadujeme pomocí S_n^2
- v testové statistice místo σ použijeme S_n :

$$T_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n}$$

- rozdělení T_n za H_0 není normální $N(0, 1)$, ale nazývá se t-rozdělení s $n - 1$ stupni volnosti, značíme jej t_{n-1} rozdělení

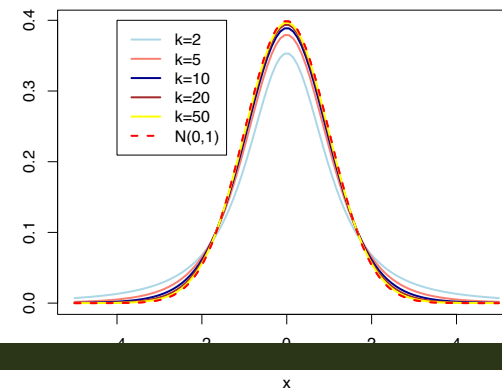
Kvantily t-rozdělení

- α -kvantil budeme značit $t_k(\alpha)$

k	α				
	0.9	0.95	0.975	0.99	0.995
5	1.476	2.015	2.571	3.365	4.032
10	1.372	1.812	2.228	2.764	3.169
20	1.325	1.725	2.086	2.528	2.845
50	1.299	1.676	2.009	2.403	2.678
100	1.290	1.660	1.984	2.364	2.626
$N(0, 1)$	1.282	1.645	1.960	2.326	2.576

t-rozdělení

- hustota rozdělení t_k má pro velké k tvar velmi podobný normovanému normálnímu rozdělení
- pro malé k má rozptyl větší než 1 a kritické hodnoty jsou vzdálenější od 0 (cena, kterou platíme za neznalost σ)



Jednovýběrový t-test

Situace: X_1, \dots, X_n náhodný výběr z rozdělení $N(\mu, \sigma^2)$, chceme otestovat hypotézu $H_0 : \mu = \mu_0$ proti (oboustranné) alternativě $H_1 : \mu \neq \mu_0$.

Testová statistika:

$$T_n = \sqrt{n} \frac{\bar{X}_n - \mu_0}{S_n}$$

Kritický obor

$$|T_n| > t_{n-1}(1 - \frac{\alpha}{2}) \implies \text{zamítáme } H_0,$$

kde $t_{n-1}(1 - \frac{\alpha}{2})$ je $(1 - \frac{\alpha}{2})$ -kvantil rozdělení t_{n-1}

Tento test nazýváme **jednovýběrový t-test** na hladině α .

Další možné alternativy

Lze uvažovat také jednostranné alternativy:

- $H_1 : \mu > \mu_0 \rightsquigarrow$ kritický obor $T_n > t_{n-1}(1 - \alpha)$
- $H_1 : \mu < \mu_0 \rightsquigarrow$ kritický obor $T_n < -t_{n-1}(1 - \alpha)$

Poznámky

- t -rozdělení se někdy také nazývá *Studentovo* t -rozdělení
- William Sealy Gosset (1876–1937) \longleftrightarrow chemik pracující v pivovaru Guinness
- 1908 odvození jednovýběrového t -testu (pseudonym Student)

Provedení testu

- spočteme

$$\bar{X} = 0.4893, \quad S = 0.0197,$$

- odtud

$$T_n = \sqrt{n} \frac{\bar{X} - 0.5}{S} = \sqrt{10} \frac{0.4893 - 0.5}{0.0197} = -1.7148$$

- máme $T_n > -t_9(0.95) = -1.833 \rightsquigarrow H_0$ **nelze** na hladině významnosti 5 % zamítnout
- **nelze prokázat**, že by hostinský točil pivo pod míru (buď skutečně pod míru netočí nebo tak málo, že tuto odchylku nemůžeme na základě našich dat prokázat)

Příklad — pivo

Máme zakoupeno 10 piv, chceme otestovat, zda hostinský netočí pod míru:

Model: Předpokládejme, že datům odpovídají nezávislé náhodné veličiny s normálním rozdělením $N(\mu, \sigma^2)$, σ^2 neznáme

Hypotézy:

$$H_0 : \mu = 0.5 \text{ proti } H_1 : \mu < 0.5$$

Hladina testu: opět budeme uvažovat test na hladině 5%

Test: zajímá nás, zda platí

$$T_n = \sqrt{n} \frac{\bar{X} - 0.5}{S} < -t_9(0.95) = -1.833$$

(pak budeme zamítnat H_0)

Příklad – výpočet v programu R

```
>t.test(pivo,mu=0.5,alternative="less")
One Sample t-test
```

```
data: pivo
```

```
t = -1.7148, df = 9, p-value = 0.06026
alternative hypothesis: true mean is less than 0.5
95 percent confidence interval:
 -Inf 0.5007382
sample estimates:
mean of x
0.4893
```

p-hodnota $> 0.05 \rightsquigarrow$ nezamítáme H_0 na hladině 5 %

Ověření předpokladu o normálním rozdělení

Jak ověříme, že data pocházejí skutečně z normálního rozdělení

- graficky
 - porovnáme histogram s hustotou normálního rozdělení
 - Q-Q graf (diagram normality) \rightsquigarrow porovnává výběrové kvantily s teoretickými kvantily normálního rozdělení
- statistickým testem
 - např. Shapirův-Wilkův test
 - H_0 : výběr pochází z normálního rozdělení
 - H_1 : výběr nepochází z normálního rozdělení
 - shapiro.test: p -hodnota \rightsquigarrow zamítáme nebo nezamítáme normalitu \rightsquigarrow lze nebo nelze použít jednovýběrový t-test

Porušení normality

Co dělat v případě, že normální rozdělení nelze pro naše data uvažovat?

- použijeme t-test
 - výsledek interpretujeme „asymptoticky“ (ve smyslu, že test je proveden na hladině, která je asymptoticky rovna α)
 - nutné mít **dostatečný počet pozorování**
- použijeme jiný (např. neparametrický) test

Porušení normality

Situace: X_1, \dots, X_n výběr z (jiného než normálního) rozdělení se střední hodnotou μ a konečným rozptylem, chceme testovat $H_0 : \mu = \mu_0$ proti alternativě $H_1 : \mu \neq \mu_0$

Jednovýběrový t-test

- předpoklad normality není splněn \rightsquigarrow skutečná hladina testu není rovna předepsanému α (a můžeme se tedy dopouštět daleko větší chyby)
- použijeme-li \rightsquigarrow hladinu testu se blíží k α pro $n \rightarrow \infty$ (zdůvodnění: centrální limitní věta)
- při velkém počtu pozorování n je hladina testu $\approx \alpha$

Závěr: Jednovýběrový t-test je možné použít k testování střední hodnoty **nenormálních** dat, pokud je pozorování dostatečně mnoho (řekněme alespoň 50).