

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) \leftrightarrow 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 \leftrightarrow **odhady parametrů**
- rozhodování o platnosti nějakého výroku \leftrightarrow **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 nevadí).

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 $\text{var } X$
- 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 $\text{cov}(X, Y)$

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



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

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

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) nebo 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).