

## TESTY O PROPORCI

### 18.12.2018

JEDNOVÝBĚROVÝ PROBLÉM PRO BINÁRNÍ DATA. V roce 2008 se v České republice živě narodilo 119 570 dětí, z toho 58 244 dívek a 61 326 chlapců (zdroj [ČSÚ](#)). Zajímá nás, zda je pravděpodobnost narození chlapce  $1/2$ .

1. Jaký předpokládáme model a jaké budeme testovat hypotézy?
2. Nejprve budeme uvažovat Wilsonův test založený na testové statistice

$$W_n = \sqrt{n} \frac{\hat{p}_n - p_0}{\sqrt{p_0(1-p_0)}},$$

kteřá má asymptoticky normální rozdělení  $N(0, 1)$ .

```
alpha=0.05
n=119570
divky=58244
chlapci=61326

#rucne:
p0=1/2
W=sqrt(n)*(chlapci/n - p0)/sqrt(p0*(1-p0))
qnorm(1-alpha/2)
2*(1-pnorm(abs(W)))

# pomoci funkce v R
prop.test(chlapci,n,p=1/2,correct=FALSE)
```

Jaký je nyní náš závěr?

3. Připomeňte si vztah mezi  $W_n$  a testovou statistikou uváděnou funkcí `prop.test`. Vypočtěte p-hodnotu pomocí rozdělení této statistiky.
4. Mohli bychom uvažovat i jinou testovou statistiku  $Z_n$ , která by měla také asymptoticky  $N(0, 1)$  rozdělení? Proveďte ručně test pomocí této statistiky.
5. Jak je konstruován uvedený interval spolehlivosti ve funkci `prop.test`? A jaký jiný intervalový odhad se spolehlivostí 95 % byste uměli zkonstruovat?
6. Nyní provedeme test téže hypotézy pomocí přesného testu

```
binom.test(chlapci,n,p=1/2)
```

Na jakém rozdělení je založený tento test? Jaký je nyní náš závěr?

7. Jelikož alternativní rozdělení splňuje předpoklady centrální limitní věty, mohli bychom použít i asymptotický t-test. Odvoďte, jak vypadá v tomto případě testová statistika  $T_n$ . Jak se liší od testové statistiky  $Z_n$ ?

8. Nyní t-test provedeme (potřebujeme ale naše data ve formě vektoru 0 a 1). Ten vyrobíme následovně:

```
data=c(rep(1,chlapani),rep(0,divky))
t.test(data,mu=0.5)
```

9. Rozhodněte, zda lze tvrdit, že jsou pravděpodobnosti narození chlapce a dívky v ČR v poměru 21:20.

10. Na rozmyšlení na doma: Odhadněte intervalově, kolikrát je pravděpodobnost narození chlapce vyšší než pravděpodobnost narození dívky.

DVOUVÝBĚROVÝ PROBLÉM PRO BINÁRNÍ DATA. Na Slovensku se v roce 2010 narodilo 60 410 dětí, z nichž bylo 30 544 chlapců a 29 866 děvčat (zdroj [pluska.cz](http://pluska.cz)). Zajímá nás, zda je pravděpodobnost narození chlapce stejná v ČR a na Slovensku.

11. Porovnejte procentuální zastoupení chlapců mezi narozenými dětmi pro ČR a SR. Vykreslete i vhodné obrázky.

12. Provedeme dvouvýběrový test o proporci založený na rozdílu pravděpodobností.

- Jaký předpokládáme model? Jak zní testované hypotézy?
- Testová statistika, kterou počítá R ve funkci `prop.test` je založená na statistice

$$\tilde{T}_d = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\tilde{p}(1 - \tilde{p})(\frac{1}{n} + \frac{1}{m})}},$$

kde  $\tilde{p}$  je odhad společné pravděpodobnosti úspěchu za nulové hypotézy. Funkce nám ve výstupu dává  $\tilde{T}_d^2$ .

- `nSR=60410`  
`chlapaniSR=30544`  
`divkySR=29866`

```
prop.test(c(chlapani,chlapaniSR),c(n,nSR),correct=FALSE)
```

Jaký učiníme závěr na základě tohoto testu?

13. Ještě spočítáme testovou statistiku ručně

```
xCR=chlapani/n
xSR=chlapaniSR/nSR
xall=(chlapani+chlapaniSR)/(n+nSR)

(Td=(xCR-xSR)/sqrt(xall*(1-xall)*(1/n+1/nSR)))
2*(1-pnorm(abs(Td)))
```

14. Alternativně bychom mohli odhadnout rozptyl v každém výběru zvlášť a použít tak statistiku

$$T_d = \frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\hat{p}_1(1 - \hat{p}_1)/n + \hat{p}_2(1 - \hat{p}_2)/m}},$$

známou z přednášky:

```
(Td2=(xCR-xSR)/sqrt(xCR*(1-xCR)/n+xSR*(1-xSR)/nSR))
2*(1-pnorm(abs(Td2)))
```

15. Pro danou situaci bychom mohli použít i dvouvýběrový asymptotický t-test (Welchův test):

```
dataSR=c(rep(1,chlapaniSR),rep(0,divkySR))
```

```
t.test(data,dataSR)
```

Porovnejte výslednou p-hodnotu s výsledkem funkce `prop.test`. Jak se liší testové statistiky?

16. V roce 1970 se v ČSSR živě narodilo 117 137 chlapců a 111 394 děvčat. Zjistěte, zda se pravděpodobnost narození chlapce v ČR v roce 2008 liší oproti situaci v ČSSR v roce 1970.

#### TESTY PRO MULTINOMICKÉ ROZDĚLENÍ

17. V rámci přednášky pro studenty chemie PřF UK v letech 2006-2013 bylo zjišťováno mimo jiné, v jakém měsíci slaví narozeniny. Naměřena byla následující data:

Měsíc	1	2	3	4	5	6	7	8	9	10	11	12
Počet studentů	29	20	23	28	35	25	31	33	31	26	23	24

Data zapsaná v R formátu:

```
x=c(29, 20, 23, 28, 35, 25, 31, 33, 31, 26, 23, 24 )
```

Zajímá nás, zda je pravděpodobnost narození v lednu stejná jako pravděpodobnost narození v prosinci.

Budeme tedy předpokládat, že  $\mathbf{X}$  je náhodný vektor s multinomickým rozdělením  $\text{Mult}_{12}(n, \mathbf{p})$ , kde  $n = 328$  a  $\mathbf{p} = (p_1, \dots, p_{12})^\top$ .

- Odhadněte parametry tohoto multinomického rozdělení.
- Formulujte nulovou a alternativní hypotézu.
- Navrhněte vhodnou testovou statistiku. Využijte při tom, že z přednášky víte, že pro vektor  $\mathbf{c}$  platí

$$\sqrt{n}(\mathbf{c}^\top \hat{\mathbf{p}} - \mathbf{c}^\top \mathbf{p}) \xrightarrow{D} N(0, V_c), \quad V_c = \mathbf{c}^\top \mathbf{V} \mathbf{c},$$

kde  $\mathbf{V} = \text{diag}(\mathbf{p}) - \mathbf{p}\mathbf{p}^\top$ .

- Pomocí R test proveďte. Pro výpočet  $\hat{V}_c$  si buď příslušný výraz zjednodušte a vyjádřete pomocí  $\hat{p}_1$  a  $\hat{p}_{12}$  nebo můžeme použít násobení matic pomocí `%*%`. Matici  $\mathbf{V}$  vytvoříme následovně

```
V=diag(p)-p%*%t(p)
```

18. Otestujte podobně, zda jsou pravděpodobnosti narození dítěte v I. a III. čtvrtletí stejné. Formulujte opět nulovou a alternativní hypotézu a proveďte ručně vhodný test.
19. Studenti dále uváděli počet svých sourozenců. Z 326 studentů 50 uvedlo, že nemá žádného sourozence, 183 má jednoho a zbytek má dva a více sourozenců. Otestujte zda je pravděpodobnost jednoho sourozence 3 krát větší než pravděpodobnost žádného sourozence.

### SAMOSTATNÁ PRÁCE

- (i) V aplikacích (nebo např. v domácím úkolu) se nám může hodit umět převést vektor spojitých hodnot na kategoriální veličinu. Např. uvažujme vektor  $x$ , který si nagenujeme z normálního rozdělení  $N(0, 1)$ , pro který chceme vytvořit vektor  $s$ , který bude identifikátor toho, zda je  $x_i > 0$ . Ten pak můžeme ještě dále převést na tzv. typ `factor`:

```
(x=rnorm(20,0,1))
(s=ifelse(x>0,1,0)) # 1 priradime tam, kde x>0 a jinde bude 0
summary(s)

sf=factor(s)
summary(sf)
```

Všimněte si rozdílného výstupu funkce `summary`. Počet „úspěchů“ ve vektoru  $s$  pak spočteme jako `sum(s)` nebo `sum(sf=="1")`.

- (ii) Ve skriptech máte kromě Wilsonova intervalu spolehlivosti a přesného intervalu spolehlivosti pro proporci uvedený také interval spolehlivosti založený na logitu a klasické asymptotické metodě (dále Waldův interval). Stáhněte si z internetu a načtěte si soubor `pokryti.R`, který obsahuje předem připravenou funkci, která počítá pro všechny čtyři metody skutečné pokrytí pro různé hodnoty parametru  $p$  a pro zadaný rozsah výběru  $n$ . Výsledkem je tedy graf skutečného pokrytí v závislosti na  $p$  a tabulka délky jednotlivých intervalů pro několik různých  $p$ . Vyzkoušejte tuto funkci pro několik různých voleb  $n$ :

```
source("pokryti.R")

pokryti(n=20)
pokryti(n=50)
pokryti(n=200)
```

Jak je to se skutečným pokrytím přesného intervalu spolehlivosti? Který z intervalů spolehlivosti Vám připadá nejlepší?

- (iii) Funkce `binom.test` nepočítá  $p$ -hodnotu podle vzorce ze skript na str. 112. Uvažujme test hypotézy  $H_0 : p_X = 0.14$  proti oboustranné alternativě a data  $X_n = 6$  a  $n = 20$ . Podle definice ze skript bychom  $p$ -hodnotu spočetli následovně:

```
Xn=6;n=20;p0=0.14
2*min(pbinom(Xn, size = n, p = p0), 1-pbinom(Xn-1, size = n, p = p0))
```

```
binom.test(Xn,n,p=p0)
```

To ale neodpovídá p-hodnotě ve funkci `binom.test`. Tato funkce považuje za hodnoty, které stejně nebo ještě více svědčí proti  $H_0$ , ty hodnoty, jejichž pravděpodobnost napozorování za nulové hypotézy je stejná nebo menší, než co jsme napozorovali ve skutečnosti:

```
qq <- as.logical(dbinom(0:n, size = n, p = p0) <= dbinom(Xn, size=n, p=p0));
```

```
# p-hodnota
sum(dbinom(0:n, size = n, p = p0)[qq])
```

(iv) Sestrojte intervalový odhad podílu pravděpodobností narození chlapce v ČR a SR.

(v) Porovnání hladiny testu a síly statistik  $T_d$  a  $\tilde{T}_d$  pro dvouvýběrový problém:

```
opak=1000
n1=20
n2=40
p.T1=numeric(opak)
p.T2=numeric(opak)
for(i in 1:1000){
  x=rbinom(1,size=n1,prob=1/4)
  y=rbinom(1,size=n2,prob=1/4)
  p.T1[i]=prop.test(c(x,y),c(n1,n2),correct=F)$p.val

  var2=(x/n1)*(1-x/n1)/n1+(y/n2)*(1-y/n2)/n2
  T2=(y/n2- x/n1)/sqrt(var2)
  p.T2[i]=2*pnorm(-abs(T2))
}

mean(p.T1<=0.05)
mean(p.T2<=0.05)
```

Takto sledujeme hladiny testu. Když změníme  $1/4$  v předpisu pro generování jednoho z výběrů, tak dostaneme odhad síly testu.