

NEPARAMETRICKÉ JEDNOVÝBĚROVÉ TESTY A PÁROVÉ TESTY

7.12.2017

ÚVODNÍ NASTAVENÍ.

- Z internetové stránky `www.karlin.mff.cuni.cz/~hudecova/education/` si můžete si stáhnout zdrojový kód k dnešnímu cvičení `cviceni10.R`.
- Otevřete si program R Studio, změňte si pracovní adresář a vyčistěte pracoviště


```
setwd("H:/nmsa331")
rm(list=ls())
```
- Načtěte si data `Hosi.txt` a ujistěte se, že se Vám data dobře načetla.
- Do proměnné `alpha` is uložte testovací hladinu 0.05.
- Opět se budeme zabývat porodní hmotností a opět budeme nejprve pracovat pouze s (náhodným) podvýběrem o rozsahu $n = 100$ pozorování.


```
set.seed(07122017)
hmot100 = sample(Hosi$por.hmot, 100)
n=length(hmot100)

hmot=Hosi$por.hmot
```

JEDNOVÝBĚROVÝ ZNAMÉNKOVÝ TEST

1. Minule jsme se zabývali otázkou, zda je průměrná porodní hmotnost chlapců rovna 3,3 kg. Zopakujte tuto analýzu (pomocí t-testu) na „dnešní“ data.
 - Připomeňte si pravděpodobnostní model, který jsme uvažovali a nulovou i alternativní hypotézu.
 - Zformulujte závěr.
2. Nyní se budeme snažit zodpovědět tutéž otázku pomocí znaménkového testu.
 - Připomeňte si předpoklady tohoto testu (tj. uvažovaný model pro naše data).
 - Formulujte nulovou a alternativní hypotézu.
 - Testová statistika má tvar

$$Y_n = \sum_{i=1}^n I[X_i > m_0],$$

kde m_0 je námi testovaná hodnota 3300 g. Jaké má přesné a jaké asymptotické rozdělení?

Provedeme asymptotickou variantu znaménkového testu nejprve „manuálně“. Nejprve musíme vyřadit pozorování, která jsou přesně rovna 3300, a budeme pracovat jen se zbylými daty.

```
sum(hmot100 == 3300)
```

```
(nLess <- sum(hmot100 < 3300))
```

```
(nMore <- sum(hmot100 > 3300))
```

```
(N <- nLess + nMore)
```

Naše analýza tedy bude založena na N počtu pozorování, v proměnné `nMore` je hodnota testové statistiky Y_n . Pro provedení asymptotického testu si ji příslušně znormujeme. Následně ji porovnáme s kvantilem normálního rozdělení, nebo spočítáme přímo p -hodnotu:

```
(Z = (nMore - N/2) / sqrt(N*1/4))
qnorm(1-alpha/2)
```

```
# p- hodnota (dve moznosti, jak spocitat):
2*(1-pnorm(abs(Z)))
2*pnorm(-abs(Z))
```

K jakému závěru jsme došli?

3. Celý výpočet můžeme provést rychleji pomocí funkce `prop.test`, která slouží k testování pravděpodobnosti (proporce) v alternativním rozdělení.

```
prop.test(x=nMore, n=N, p=1/2, correct=FALSE)
```

Všimněte si, že jsme dostali opravdu stejnou p -hodnotu. Testová statistika je ale jiná. Najdete souvislost s naším výsledkem uloženým v `Z`? Jaké asymptotické rozdělení má tedy testová statistika funkce `prop.test`?

Nastavení `correct=FALSE` zakazuje tzv. korekci pro spojitost, která je jinak defaultně zapnutá. Více v samostatném cvičení č. 3.

4. Vyzkoušejte, co by se stalo, kdybychom celý výpočet prováděli s `nLess` namísto `nMore`.
5. Jelikož znaménkový test převádí naše naměřená data na binární, podíváme se na to, jak vizualizovat kategoriální veličinu:

```
Y <- hmot100[hmot100 != 3300]; # vybereme hmotnosti ruzne od 3300
Y <- factor(Y > 3300) # udelame z nich 0-1 veliciny a chapeme je jako "faktor"
levels(Y) <- c("< 3300", "> 3300") # pojmenujeme kategorie
summary(Y) # kontrola s nLess a nMore

plot(Y, col=2:3);
# totez jako:
barplot(table(Y), col=2:3)
# nebo
barplot(c(nLess, nMore), col=2:3, legend=c("< 3300", "> 3300"))

#proporcionalne:
pie(table(Y), col=2:3)
# nebo
barplot(prop.table(as.matrix(c(nLess, nMore))), col=2:3, legend=c("< 3300", "> 3300"))
```

JEDNOVÝBĚROVÝ WILCOXONŮV TEST

6. Stále se budeme zabývat otázkou, zda je průměrná porodní hmotnost chlapců rovna 3,3 kg. Nyní k testu použijeme Wilcoxonův test

- (a) Jaký model předpokládáme pro naše data nyní?
- (b) Jak budeme teď formulovat testované hypotézy?
- Porovnejte předpoklady Wilcoxonova testu s předpoklady přesného t-testu a s předpoklady asymptotického t-testu.
 - Porovnejte, kdy jsou testované hypotézy ekvivalentní a kdy naopak nejsou.
 - Uveďte příklad situace, pro kterou můžeme použít Wilcoxonův test a t-test by nebyl vhodný, a situace opačné.
- (c) Připomeňte si testovou statistiku tohoto testu: Je-li $Z_i = X_i - \delta_0$, kde δ_0 je pro nás 3300, pak

$$W = \sum_{i \in I} R_i,$$

kde R_i jsou pořadí $|Z_i|$ a I je množina indexů i takových, že $Z_i > 0$. Test můžeme provést jak přesný (pro rozumně malé n ; viz samostatné cvičení č. 4.) nebo asymptotický založený na tom, že

$$\frac{W - \frac{n(n+1)}{4}}{\sqrt{\frac{n(n+1)(2n+1)}{24}}}$$

má asymptoticky $N(0, 1)$.

Pro provedení testu musíme opět nejprve odstranit pozorování rovné přímo δ_0 . V případě výskytu shod je potřeba jmenovatel zmenšit o tzv. korekci rozptylu (viz přednáška, str. 82). V R se toto děje defaultně. Navíc se uvažuje ještě korekce pro spojitost, kdy se jmenovatel snižuje o 1/2 podobně jako u znaménkového testu (viz samostatné cvičení č.3.). Toto lze vypnout pomocí `correct=FALSE`.

- (d) Provedeme test
- ```
wilcox.test(hmot100, mu = 3300, correct=FALSE)
```
- Jaký je náš závěr?

7. Ověříme, že uvedená testová statistika je skutečně  $W$  uvedené výše

```
x <- hmot100 - 3300
x <- x[x != 0] ### nebudeme pouzivat porodni hmotnosti 3300
(R <- rank(abs(x)))
(Sign <- -1*(x < 0) + 1*(x > 0))
(Splus <- sum(R[x > 0]))
```

8. Vypočítáme p-hodnotu pro test bez korekce i s korekcí pro spojitost. Vzorec pro korekci byl na přednášce, viz str. 82.

```
ESplus <- N*(N+1)/4
totez jako 1/2*sum(1:N)
varSplus_NoTies <- N * (N + 1) * (2 * N + 1) / 24

#vypocet korekce:
(tx <- table(R)) # Pocet jednotlivych hodnot
varCorrectWithTies <- sum(tx^3 - tx) / 48 # Korekce v pripade shod
varSplus <- varSplus_NoTies - varCorrectWithTies
```

```
(U <- (Splus - ESplus) / sqrt(varSplus))
(U.corr <- (Splus - ESplus - 0.5) / sqrt(varSplus))
```

```
P-hodnoty
(P <- 2*pnorm(-abs(U)))
(P.corr <- 2*pnorm(-abs(U.corr)))
```

Což můžeme srovnat s p-hodnotami:

```
wilcox.test(hmot100, mu = 3300, correct = FALSE)$p.val
wilcox.test(hmot100, mu = 3300)$p.val
```

Výsledné p-hodnoty zkuste sami porovnat s p-hodnotou, kterou bychom dostali bez korekce jmenovatele.

9. Porovnáme sílu t-testu, znaménkového testu a Wilxonova testu pro normální rozdělení.

```
opak=1000
n=100

p.t=numeric(opak)
p.z=numeric(opak)
p.w=numeric(opak)
for(i in 1:opak){
 x=rnorm(n,mean=0.2,sd=1)
 p.t[i]=t.test(x,mu=0)$p.val
 p.w[i]=wilcox.test(x,mu=0)$p.val
 p.z[i]=prop.test(sum(x>0),n,p=1/2)$p.val
}

mean(p.t<=0.05)
mean(p.w<=0.05)
mean(p.z<=0.05)
```

Zkuste změnit velikost rozsahu  $n$  nebo alternativu, za které simulujeme, a sledujte, jak se mění síla. Lze udělat nějaký obecný závěr?

## PÁROVÝ PROBLÉM

10. Některé zdroje uvádějí, že chlapci v průběhu prvního roku života přiberou v průměru více než 6,5 kg. Máme za úkol ověřit, zda jsou naše data v souladu s tímto tvrzením.
- Jsou porodní hmotnost a hmotnost v jednom roce nezávislé veličiny? Uveďte další možné příklady párového problému.
  - Spočítáme si váhový přírůstek během prvního roku:

```

hmot<- Hosi$por.hmot
hmot1 <- Hosi$hmotnost
rozdil=hmot1-hmot

```

- (c) Nejprve použijeme t-test.
- Jaký model předpokládáme (uvažte pomocí vhodných grafů) a jak zní nulová a alternativní hypotéza?
  - Proved'te test a interpretujte výsledek.
- (d) Nyní na stejný problém použijeme znaménkový test.
- Co nyní předpokládáme? A co testujeme? Je obecně nějaká souvislost mezi testovanou kvantitou a charakteristikami původních párových veličin (porodní hmotnosti a hmotnost v 1 roce)?
  - Provedeme test
 

```

n.more=sum(rozdil>6500)
n=sum(rozdil!=6500)
prop.test(n.more, n, alternative = "greater")

```

 Jaký je náš závěr?
- (e) Nakonec si na tomto problému vyzkoušíme ještě i Wilcoxonův test.
- Co nyní předpokládáme? Co předpokládáme navíc proti jednovýběrovému Wilcoxonovu testu? Jaké testujeme hypotézy?
  - Proved'te test.

11. Zajímá nás věkový rozdíl mezi rodiči chlapců. Konkrétně bychom rádi věděli, zda jsou otcové v průměru o více než 2 roky starší než matky.

- (a) Nejprve si prohlédněte vhodné popisné statistiky a grafy, které ilustrují rozdělení věkového rozdílu.
- (b) Zvolte test, který Vám přijde pro tato data nejvhodnější a proved'te jej. Uvědomte si, jaký uvažujete model, jaké testujete hypotézy a jak budeme interpretovat závěr.

### SAMOSTATNÁ PRÁCE

1. V rámci tohoto cvičení jsme pro test hypotézy, zda je porodní hmotnost chlapců rovna 3,3 kg, použili několik rozličných testů, které v praxi mohou vést k různým p-hodnotám a různým závěrům. Kterému výsledku tedy máme „věřit“?
2. Pomocí znaménkového testu proved'te test hypotézy, zda je porodní hmotnost nižší než 3,5 kg. Zformulujte řádně nulovou a alternativní hypotézu a proved'te test.
3. Vyzkoušejte si znaménkový test se zapnutou korekcí pro spojitost. Ověřte, že v tomto případě se počítá testová statistika

$$Z^C = \frac{Y_n - \frac{n}{2} - \frac{1}{2}\text{sgn}(Y_n - \frac{n}{2})}{\sqrt{\frac{n}{4}}}$$

(resp. její druhá mocnina). Použijte postup analogický tomu v bodě 2.

Korekce pro spojitost zde vychází z toho, že  $Y_n$  má diskrétní rozdělení a  $P(Y_n \leq y) = P(Y_n < y+1)$ . Tudíž při přechodu k asymptotické aproximaci spojitým normálním rozdělením s distribuční funkcí  $F$  lze  $P(Y_n \leq y)$  aproximovat jak  $F(y + \varepsilon)$  pro všechna  $\varepsilon \in [0, 1]$ . Jako určitý kompromis tedy vezmeme  $F(y + 1/2)$ .

4. Pro Wilcoxonův test můžeme použít i přesný test, založený na přesném rozdělení  $W$ . Je však nutné, aby v datech nebyly shody a žádné pozorování nebylo rovno přesně testované hodnotě. Pro vyšší  $n$  může být ale výpočet časově náročný. Vyzkoušejte si to na simulovaných datech z rovnoměrného rozdělení:

```
x=runif(5000,0,1)
wilcox.test(x[1:100],mu=1/2,exact=TRUE)
```

Postupně zvyšujte počet použitých dat ze 100 na 200,500, 1000, 2000.

5. Porovnejte sílu jednovýběrových testů pro rovnoměrné rozdělení (stejně jako v 9.). Například simulujte data z  $R[0, 1.2]$  a testujte, zda je střední hodnota (medián) rovna  $1/2$ .
6. Znaménkový test má kromě asymptotické verze (kterou jsme dělali výše) i přesnou variantu založenou na binomickém rozdělení. V R můžeme použít funkce `binom.test`, parametry této funkce jsou pak stejné jako u `prop.test`. Proveďte pro porovnání test hypotézy, zda je porodní hmotnost nižší než 3,5 kg, i pomocí přesného testu. Vyzkoušejte použití našich 100 vybraných hodnot i všech dostupných dat.