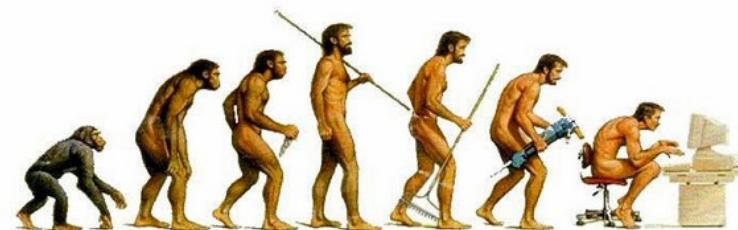


Masarykova univerzita v Brně
Přírodovědecká fakulta

APLIKOVANÁ STATISTIKA PRO ANTROPOLOGY

Zadání domácího úkolu – Skupina A



Brno, 2017

Pokyny k řešení domácího úkolu

Domácí úkol sestává z šesti příkladů. Za vyřešení příkladů lze získat $10+20+25+75+40+10=180$ bodů + 20 bodů za celkovou úpravu úkolu, kódu, komentáře k postupům, apod. Celkem lze tedy získat 200 bodů.

Aby byl úkol uznán za splněný, je potřeba získat alespoň **150 bodů** (75 %). Pokud nebude dodatečně stanoveny jinak, má student na vyřešení domácího úkolu 14 dní počínaje dnem zadání domácího úkolu. Pokud student potřebných 120 bodů nezíská, bude mu úkol navrácen a student dostane jeden týden na dořešení příkladů. Pokud ani potom student kýženého počtu nedosáhne, bude psát na konci semestru prověřovací písemku na látku obsaženou v celém semestru.

Řešení domácího úkolu vložte, prosím, do odevzdávárny k předmětu **MAS10c** (cvičení z AS). (Pozor! nesplést s odevzdávárnou předmětu **MAS01** - přednášky!).

Kompletním řešením je míněno:

- dodání **zcela funkčního** **R-Skriptu** s názvem **AS-2017-skupina-X-příjmeni-jmeno.R**. Namísto X vložte verzi vypracovaného domácího úkolu (A nebo B). Před odesláním skriptu vyučující si vyčistěte workspace (V RStudiou: Session → Clear Workspace) a všechny příkazy finálně projděte ještě jednou, abyste měli jistotu, že vše funguje, jak má. **Příklady, jejichž RSkript bude vyhazovat chybové hlášky, nebudou kontrolovány a automaticky budou vráceny k přepracování.**
- dodání textového souboru (Word) s názvem **AS-2017-skupina-X-příjmeni-jmeno.docx**, obsahujícího všechny potřebné komentáře, **interpretace výsledků**, popisy postupů, apod. Jako alternativu je možné odeslat také pouze funkční **R-Skript** obsahující popisy postupů formou **R-kových komentářů** (za symbolem #). V tom případě není nutné odevzdávat Wordovský dokument.

Na co si dát závěrem ještě pozor.

- Při programování domácího úkolu nepoužívejte diakritiku. Použití diakritiky vede v důsledku nekonzistentního kódování různých systémů (Windows, Mac, Linux) ke špatnému načítání R Skriptu. Domácí **úkoly s diakritikou budou vráceny k přepracování**.
- Při programování dodržujte jistou přehlednost kódu. Před a za symbolem <- uveďte vždy mezeru, takéž jednotlivé argumenty funkcí odděljte mezerami. Příklad správně a přehledně naprogramovaného kódu je k náhledu níže. Správné naprogramování kódu vede ke zvýšení jeho přehlednosti a větší radosti programátora z výsledné práce. :)
- interpretace výsledků jsou nedílnou součástí příkladu a jsou hodnoceny celkem vysokým počtem bodů. **Absence interpretací výsledků tedy může výrazně snížit celkový počet bodů** z jinak správně vypracovaného příkladu.

```
x <- 1:15
px <- dbinom(x, size = 15, p = 0.5)

plot(x, px, type = 'h', lty = 2, lwd = 1,
      main = 'Pravdepodobnostní funkce binomickeho rozdělení',
      cex.main = 0.9)
points(x, px, pch = 21, col = 'red', bg = 'salmon')

legend('topright', fill = c('salmon'), legend = c('binom'), bty = 'n')
```

Domácí úkoly budou opravovány hromadně po obdržení všech (nebo alespoň významné většiny) řešení úkolů, přičemž na opravení úkolů si vyučující vyhrazuje 14 denní lhůtu :).

Přeji vám hodně zdaru při řešení příkladů :).

Příklad 1 (10 b). U sedmnácti mladých dospělých žen byla změřena délka dolní končetiny (znak X - v mm) a délka trupu (znak Y - v mm). Naměřené hodnoty jsou uvedeny v následující tabulce.

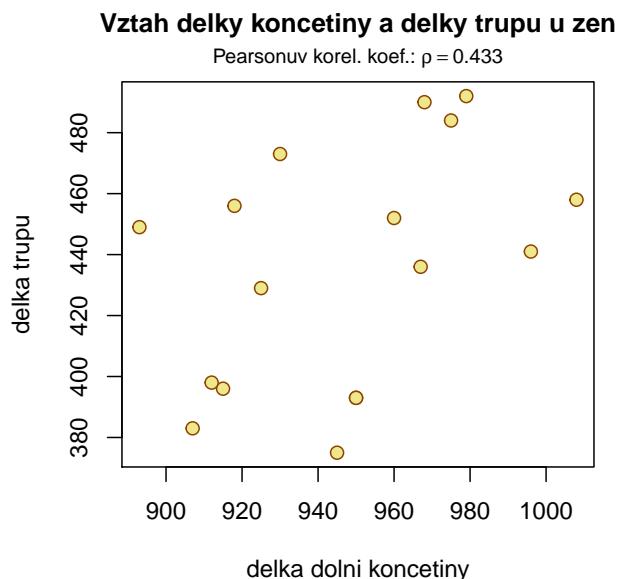
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
d.končetiny	960	967	925	918	968	915	996	950	975	930	945	912	1008	907	979	893	950
d.trupu	452	436	429	456	490	396	441	393	484	473	375	398	458	383	492	449	393

Ze zadaných údajů byly dopočítány následující charakteristiky: $m_1 = 946.94$, $m_2 = 435.18$, $s_1 = 32.921$, $s_2 = 39.026$, $s_{12} = 556.324$.

- Stanovte hodnotu odhadu korelačního koeficientu ρ a řádně ji interpretujte. (5 b)

```
## [1] 0.433
```

- Nakreslete dvourozměrný tečkový diagram vizualizující vztah mezi délkou dolní končetiny a délkou trupu. (5 b)



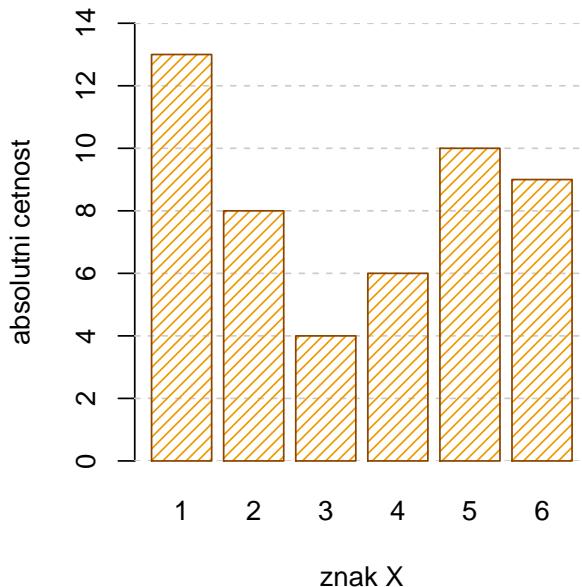
Tip: Podnadpis do tečkového grafu můžete vložit pomocí příkazu `mtext(bquote(paste('Pear.koef.: ', rho==.(cor.f))), line=0.3, cex=0.8)`, kde `cor.f` je hodnota korelačního koeficientu zaokrouhlená na čtyři desetinná místa.

Příklad 2 (20 b). Znak Y nabývá variant 1, 2, 3, 4, 5, 6 s četnostmi 13, 8, 4, 6, 10, 9.

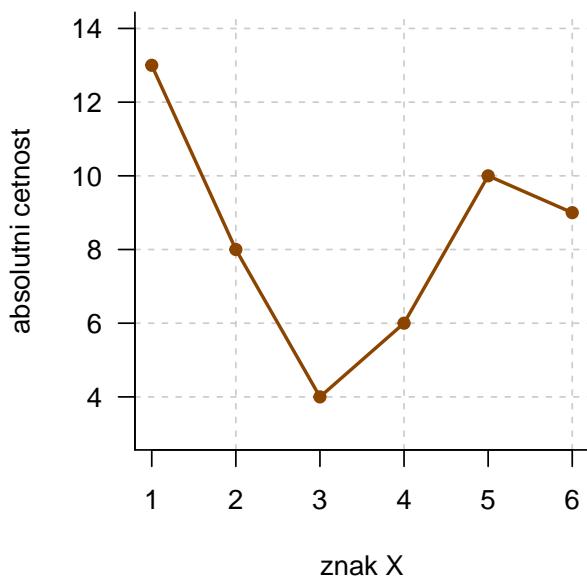
- Vypočítejte první decil $y_{0.1}$, dolní kvartil $y_{0.25}$, medián $y_{0.5}$, horní kvartil $y_{0.75}$ a nonil $y_{0.9}$ znaku Y . Hodnoty vložte do přehledné tabulky. (5 b)
- Hodnoty $y_{0.1}$, $y_{0.25}$, $y_{0.5}$, $y_{0.75}$ a $y_{0.9}$ řádně interpretujte. (5 b)
- Vykreslete sloupcový graf a polygon četností znaku Y . (10 b)

```
## 1. decil dolni kvartil median horni kvartil nonil
## 1           1           1       3.5           5       6
```

Sloupkovy diagram



Polygon ctnosti



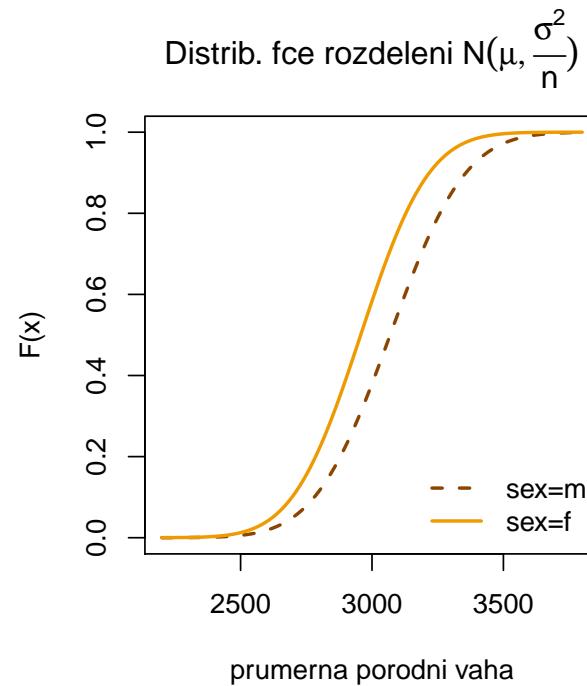
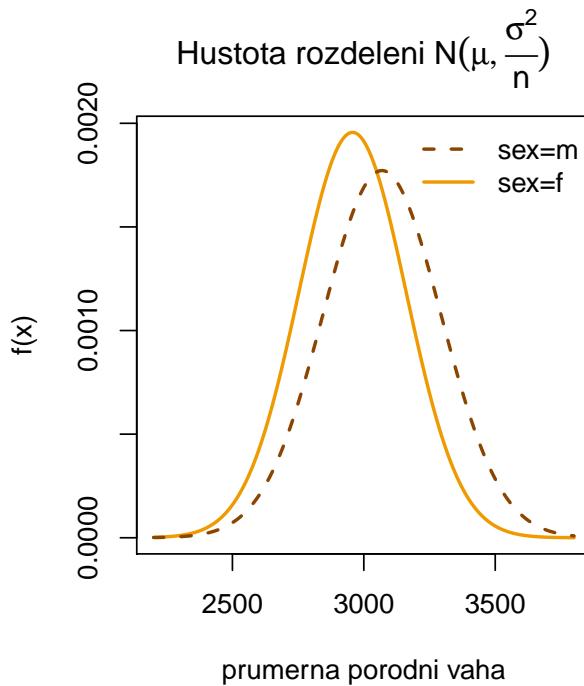
Příklad 3 (25 b). Předpokládejme, že porodní hmotnost prvorozenců – holčiček je normálně rozdělená okolo střední hodnoty 2957 g se směrodatnou odchylkou 645 g.

1. Vypočítejte pravděpodobnost, že **průměrná hmotnost** deseti náhodně vybraných narozených holčiček bude alespoň 3000 g. (7 b)

Tip: S řešením příkladu vám pomůže znění následující věty: Pokud náhodná veličina X pochází z normálního rozdělení se střední hodnotou μ a rozptylem σ^2 , tj. $X \sim N(\mu, \sigma^2)$, potom průměr $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ pochází z normálního rozdělení se střední hodnotou μ a rozptylem $\frac{\sigma^2}{n}$, tj. $\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$.

2. Vykreslete graf hustoty normálního rozdělení pro průměrnou hmotnost novorozených holčiček. Na osu x naneste posloupnost 1000 hodnot od 2200 g do 3800 g a na osu y hodnoty hustoty normálního rozdělení průměrné hmotnosti deseti novorozených holčiček ($\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$). Do grafu dokresele také křivku hustoty normálního rozdělení pro průměrnou hmotnost deseti novorozených chlapečků, víte-li, že porodní hmotnost prvorozenců – chlapečků je též normálně rozdělená okolo střední hodnoty 3069 g se směrodatnou odchylkou 712 g. (9 b)
3. Vykreslete graf distribuční funkce normálního rozdělení pro průměrnou hmotnost novorozených holčiček. Na osu x naneste posloupnost 1000 hodnot od 2200 g do 3800 g a na osu y hodnoty distribuční funkce normálního rozdělení průměrné hmotnosti deseti novorozených holčiček. Do grafu dokresele také křivku hustoty normálního rozdělení pro průměrnou hmotnost deseti novorozených chlapečků, víte-li, že porodní hmotnost prvorozenců – chlapečků je též normálně rozdělená okolo střední hodnoty 3069 g se směrodatnou odchylkou 712 g. (9 b)

```
## [1] 0.4165144
```



Příklad 4 (příklad z praxe; 75 b). Máme k dispozici soubor hodnot délky pravé dolní končetiny a délky trupu u 175 mladých dospělých jedinců (75 mužů (*m*) a 100 žen (*f*)). Údaje jsou vloženy v souboru AS-2017-DU-koncetiny-trup.txt. Ve sloupci *sex* jsou uvedeny údaje o pohlaví, ve sloupci *lowex* jsou vloženy hodnoty délky pravé dolní končetiny a ve sloupci *tru.L* jsou vloženy hodnoty délky trupu. Na hladině významnosti $\alpha = 0.05$ testujte nulovou hypotézu, že délka trupu u mužů je větší než délka trupu u žen.

Tip: Datový soubor obsahuje neznámé (tzv. NA) hodnoty. Před řešením příkladu je vhodné tyto hodnoty odstranit příkazem `na.omit()`.

V rámci tohoto příkladu provedte následující úkoly:

1. Pro každé pohlaví sestrojte tabulkou základních charakteristik pro délku trupu. Výsledky v tabulce základních charakteristik zaokrouhlete na čtyři desetinná místa. (10 b)

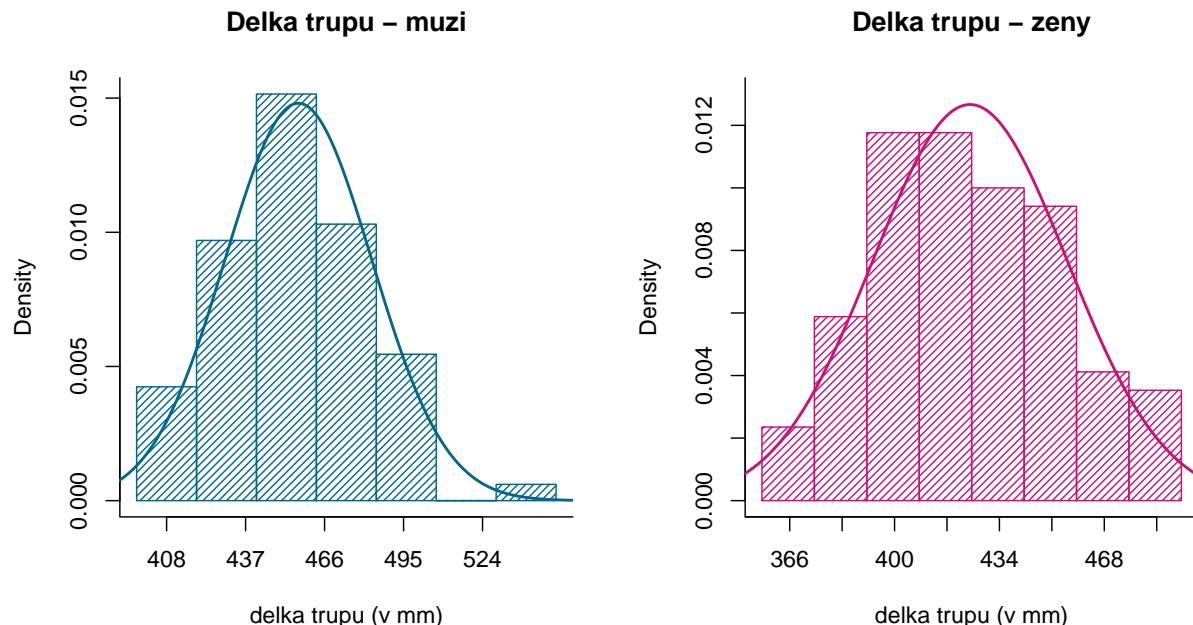
```
##      n      m      s min dolni.kv. median horni.kv. max sikmost spicatost
## muzi 75 456.3867 26.9393 400     435.0    457     475 548 0.3140  0.7067
## zeny 100 424.4700 31.5019 358     401.5    419     450 492 0.2414 -0.6654
```

2. Vykreslete histogram pro délku trupu u mužů. Ohlídejte správný počet třídicích intervalů (viz Sturgesovo pravidlo). Histogram superponujte křivkou normálního rozdělení $N(\mu_m, \sigma_m^2)$, kde odhad parametrů μ_m a σ_m^2 získáte z dat. (5 b)

Tip: Aby se vám křivka vykreslila správně, musíte v histogramu zadat argument `prob=T`. Tento argument převede měřítko *y*-ové osy z absolutní škály (na ose *y* jsou defaultně nastaveny absolutní četnosti) na relativní škálu (na ose *y* budou relativní četnosti).

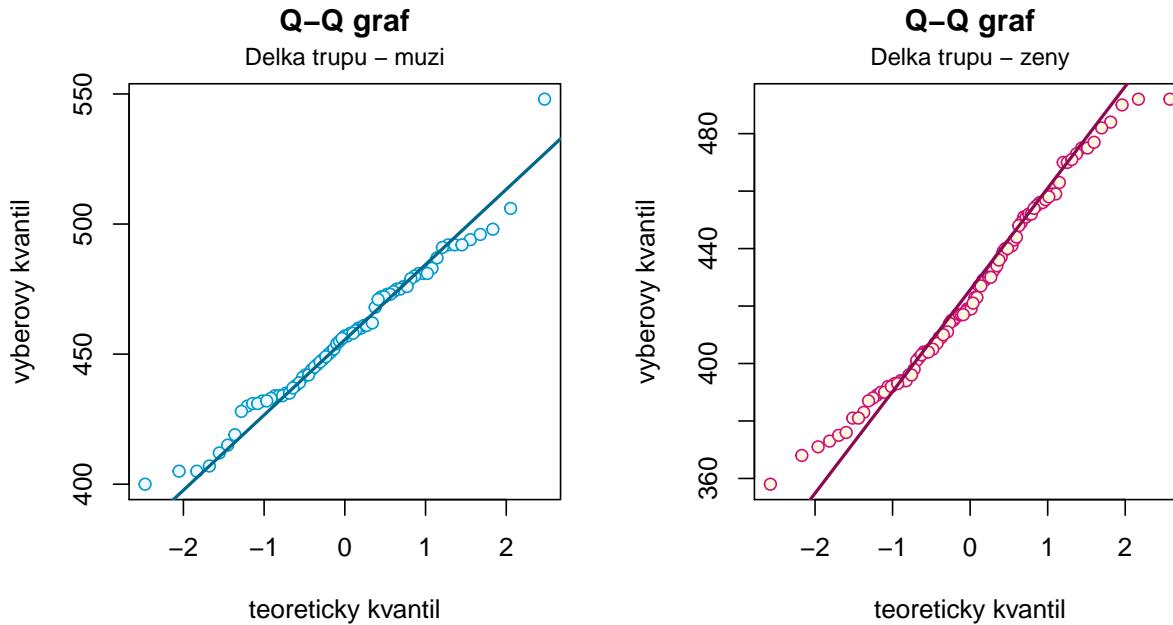
3. Vykreslete histogram pro délku trupu u žen. Ohlídejte správný počet třídicích intervalů (viz Sturgesovo pravidlo). Histogram superponujte křivkou normálního rozdělení $N(\mu_f, \sigma_f^2)$, kde odhad parametrů μ_f a σ_f^2 získáte z dat. (5 b)

Tip: Aby se vám křivka vykreslila správně, musíte v histogramu zadat argument `prob=T`. Tento argument převede měřítko *y*-ové osy z absolutní škály (na ose *y* jsou defaultně nastaveny absolutní četnosti) na relativní škálu (na ose *y* budou relativní četnosti).



4. Otestujte normalitu dat (k otestování zvolte vhodný test a jeho volbu zdůvodněte). K testování patří stanovení hypotéz H_0 , H_1 , zdůvodněné rozhodnutí o zamítnutí/nezamítnutí H_0 a interpretace výsledku testování. V rámci testu normality vykreslete také pro obě pohlaví Q-Q graf. (10 b)

```
## [1] 0.7821788
## [1] 0.1307722
```



5. Proveďte test o shodě rozptylů σ_1^2 a σ_2^2 . Testování proveďte kritickým oborem, intervalem spolehlivosti i p -hodnotou. K testování patří stanovení hypotéz H_0 , H_1 , zdůvodněné rozhodnutí o zamítnutí/nezamítnutí H_0 (u všech tří typů testování) a interpretace výsledku testování. (20 b)

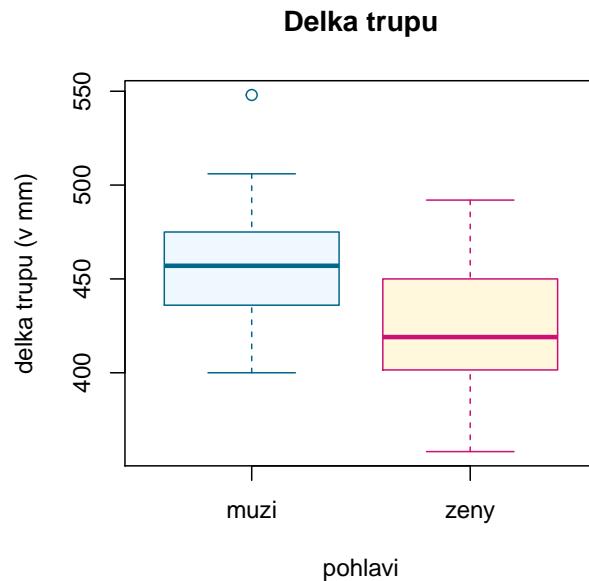
```
## [1] "Testovaci statistika:"
## [1] 0.7313046
## [1] "Kriticky obor:"
## [1] 0.6468828
## [1] 1.525232
## [1] "Interval spolehlivosti:"
## [1] 0.479471
## [1] 1.130506
## [1] "p-hodnota:"
## [1] 0.1580265
```

6. Otestujte nulovou hypotézu uvedenou v zadání. Testování proveďte kritickým oborem, intervalem spolehlivosti i p -hodnotou. K testování patří stanovení hypotéz H_0 , H_1 , zdůvodněné rozhodnutí o zamítnutí/nezamítnutí H_0 (u všech tří typů testování) a interpretace výsledku testování. (20 b)

```
## [1] "Testovaci statistika:"
## [1] 7.050237
## [1] "Kriticky obor:"
## [1] -1.653709
## [1] "Interval spolehlivosti:"
```

```
## [1] 39.40307
## [1] "p-hodnota:"
## [1] 1
```

7. Závěr testování podložte vykreslením boxplotů pro muže a ženy do jednoho grafu. (5 b)



Příklad 5 (40 b). Máme datový soubor obsahující údaje o délce pravé a levé klíční kosti u 33 mužů a 25 žen. Údaje jsou uloženy v souboru AS-2017-DU-klicni-kosti.csv, kde sloupec sex obsahuje údaje o pohlaví, sloupec length.R obsahuje údaje o délce pravé klíční kosti a sloupec length.L obsahuje údaje o délce levé klíční kosti. Na hladině významnosti $\alpha = 0.05$ testujte nulovou hypotézu, že délka pravé a levé klíční kosti u mužů jsou stejné.

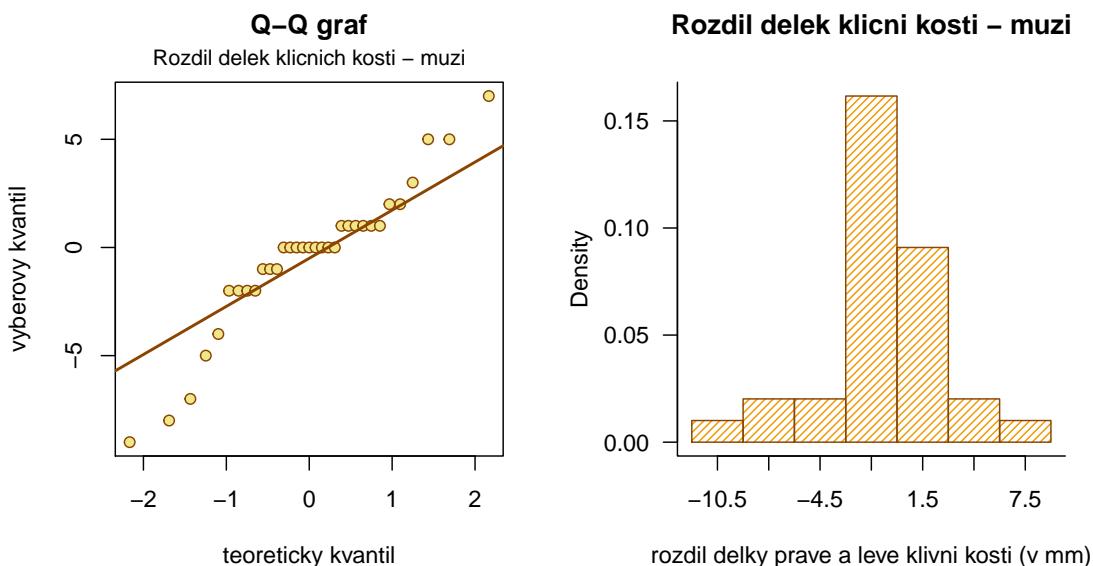
V rámci tohoto příkladu proveděte následující úkoly:

- Zamysle se nejprve nad tím, jaký typ dat máte před sebou a jakým typem testu (jednovýběrový, párový, dvouvýběrový) bude nejspíše potřeba nulovou hypotézu otestovat. Typ testu uveděte. **(2.5 b)**
- Proveďte test normality. **Návod:** Nebudete testovat normalitu ani délky pravých klíčních kostí u mužů, ani délky levých klíčních kostí u mužů, ani normalitu všech údajů dohromady. Čeho tedy máte normalitu testovat? Odpověď souvisí s bodem 1.

K otestování normality zvolte vhodný test a jeho volbu zdůvodněte. K testování patří stanovení hypotéz H_0 , H_1 , zdůvodněné rozhodnutí o zamítnutí/nezamítnutí H_0 a interpretace výsledku testování. **(5 b)**

```
## [1] 0.005251629
```

- Testování normality proveďte také graficky, pomocí Q-Q grafu a histogramu. Při vytváření histogramu ohlédněte správný počet třídicích intervalů (viz Sturgesovo pravidlo). **Návod:** Správným řešením je vykreslení pouze jednoho Q-Q grafu a jednoho histogramu. Oba grafy sestrojte pro tutéž 'veličinu', u které jste testovali normalitu dat. **(10 b)**



- Na základě výsledku testování normality vyberte vhodný test k otestování zadané hypotézy. Uveďte jeho celý název. (Začíná na W :)). Testování proveďte kritickým oborem, intervalem spolehlivosti i p -hodnotou. K testování patří stanovení hypotéz H_0 , H_1 , zdůvodněné rozhodnutí o zamítnutí/nezamítnutí H_0 (u všech tří typů testování) a interpretace výsledku testování. **(22.5 b)**

```
## [1] "Testovaci statistika:"
##      V
## 130.5
## [1] "Kriticky obor:"
## [1] 81.3
```

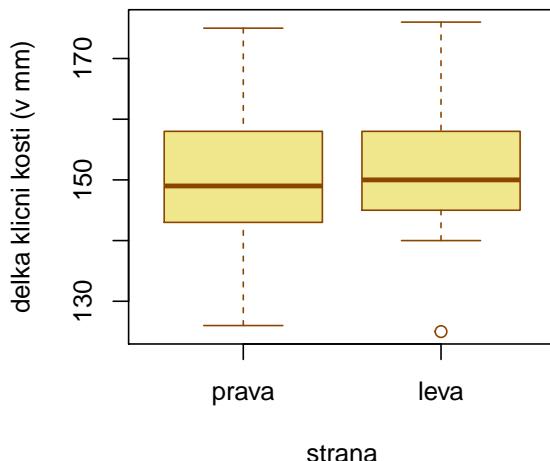
```

## [1] "Interval spolehlivosti:"
## [1] -2.000033
## [1] 1.000015
## [1] "p-hodnota:"
## [1] 0.5742881

```

5. Výsledek testování podpořte vykreslením krabicového grafu pro délku pravé klíční kosti a pro délku levé klíční kosti u mužů. (5 b)

Delka klicni kosti – muzi



Příklad 6 (10 b). Bonifác má na stole stojánek s černě a modře písícími propiskami v poměru 1:2 (33 % propisek má černou náplň, 67 % propisek má modrou náplň). Bohužel je trochu nepořádný a každou vypsanou propisku vrátí zpět do stojánku. Pravděpodobnost, že se ve stojánci vyskytuje modrá vypsaná propiska je 45 %, pravděpodobnost, že se ve stojánci vyskytuje černá vypsaná propiska je 10 %. Jaká je pravděpodobnost, že sáhne-li Bonifác náhodně do stojánci, vytáhne propisku, která píše?

```

## [1] 0.6655

```

