Kritická práce s daty II

Přednáška 1-2

Mojmír Dočekal

2022-11-09

Experimentální lingvistika

2 revoluce

- ve formální lingvistice od druhé poloviny 20. století 2 revoluce:

the whole goal of science is to replace complex visibles by simple invisibles. That is science. If you are not doing that, then it is something else, it is data organization, flower collection. Sometimes the latter is useful, but it should not be confused with science. If it is science, since Galileo, it is an effort to satisfy Galileo's maxim: nature is simple. If we have not figured it out, it is our problem.

2 revoluce

- ve formální lingvistice od druhé poloviny 20. století 2 revoluce:

1. Chomsky (1957): kognitivní a formální přístup k syntaxi:

the whole goal of science is to replace complex visibles by simple invisibles. That is science. If you are not doing that, then it is something else, it is data organization, flower collection. Sometimes the latter is useful, but it should not be confused with science. If it is science, since Galileo, it is an effort to satisfy Galileo's maxim: nature is simple. If we have not figured it out, it is our problem.

2. 90.léta: experimentální obrat v lingvistice (klasické učebnice: Baayen (2008), Kruschke (2011))

(1) a. Já jsem nepřišel.
b. *Já nejsem přišel.

2. 90.léta: experimentální obrat v lingvistice (klasické učebnice: Baayen (2008), Kruschke (2011))

- možná ještě důležitější

(1) a. Já jsem nepřišel.
b. *Já nejsem přišel.

2. 90.léta: experimentální obrat v lingvistice (klasické učebnice: Baayen (2008), Kruschke (2011))

- možná ještě důležitější
- analýza velkého množství dat (ať už uložených: korpusy, nebo experimentálně získaných)

(1) a. Já jsem nepřišel.
b. *Já nejsem přišel.

2. 90.léta: experimentální obrat v lingvistice (klasické učebnice: Baayen (2008), Kruschke (2011))

- možná ještě důležitější
- analýza velkého množství dat (ať už uložených: korpusy, nebo experimentálně získaných)
- dost často jde o subtilnější a více variovaná data než v syntaxi dříve:

(1) a. Já jsem nepřišel.
b. *Já nejsem přišel.

2. 90.léta: experimentální obrat v lingvistice (klasické učebnice: Baayen (2008), Kruschke (2011))

- možná ještě důležitější
- analýza velkého množství dat (ať už uložených: korpusy, nebo experimentálně získaných)
- dost často jde o subtilnější a více variovaná data než v syntaxi dříve:
- syntaktický a jasný rozdíl:

(1) a. Já jsem nepřišel.
b. *Já nejsem přišel.

- názorný příklad (z NESČ):

- názorný příklad (z NESČ):
- neutralizace časových a aspektuálních rozdílů v negovaných větách

- názorný příklad (z NESČ):
- neutralizace časových a aspektuálních rozdílů v negovaných větách
- příklad z jazyka *bafut* (Kamerun)

- názorný příklad (z NESČ):
- neutralizace časových a aspektuálních rozdílů v negovaných větách
- příklad z jazyka *bafut* (Kamerun)
- mizí rozdíl mezi přítomným perfektem a nedávnou minulostí v negovaných větách

(2) a. mbìŋ lòó
déšť padal
‘Pršelo/Měli jsme deštivo.’

b. mbìŋ lòò me’
déšť padal IMPST
‘Pršelo/Právě pršelo.’

c. kāā mbìŋ sì lōò
NEG déšť NEG padal
‘Nepršelo.’

- neutralizace aspektového rozdílu: pod negací musíme použít default (časový nebo aspektový)

- podobně pro češtinu se tvrdí, že (Hajičová z NESČ):

O souhře č. slovesné n. a vidu se zpravidla říká, že dok. sloveso v imper. má ve své základní funkci (zákaz, záporná rada aj.) jako přímý záporný protějšek sloveso nedok.: *Sedni si dopředu! – Nesedej si dopředu!* Jde však o jev širší, protože obdobně se chová i sloveso durativní ve vztahu k iterativnímu: *Jeďte zítra do Pardubic! – Nejezděte zítra do Pardubic!* Kromě toho nejde jen o imper., ale i o různé významově příbuzné vazby: *Měli byste jet do Pardubic – Neměli byste jezdit do Pardubic;Rád by jel do Pardubic – Nerad by jezdil do Pardubic*. Hranice tohoto jevu dosud nebyly s plnou soustavností prostudovány (viz přehled popisů v Karlík and Nübler (1998)), podobně jako není jasné, do jaké míry platí o užití imper. ve smyslu varování (výstrahy), že takové variaci nepodléhá. Jistě to platí např. o *Nesedni si na klobouk!*, ale není to docela jasné u ostatních příkladů n. u vět jim podobných.

- pokud chceme popsat takové jevy, tak musíme pracovat nejen s intuicí

- pokud chceme popsat takové jevy, tak musíme pracovat nejen s intuicí
- a používat nástroje pro práci s nejednoznačnými daty (signál a šum: https://en.wikipedia.org/wiki/The_Signal_and_the_Noise)

- pokud chceme popsat takové jevy, tak musíme pracovat nejen s intuicí
- a používat nástroje pro práci s nejednoznačnými daty (signál a šum: https://en.wikipedia.org/wiki/The_Signal_and_the_Noise)
- příklad z historie: Galton a jeho studie o dědičnosti výšky

- pokud chceme popsat takové jevy, tak musíme pracovat nejen s intuicí
- a používat nástroje pro práci s nejednoznačnými daty (signál a šum: https://en.wikipedia.org/wiki/The_Signal_and_the_Noise)
- příklad z historie: Galton a jeho studie o dědičnosti výšky
- podobný vzor: intuitivně jasná korelace, ale spousta protipříkladů

Francis Galton

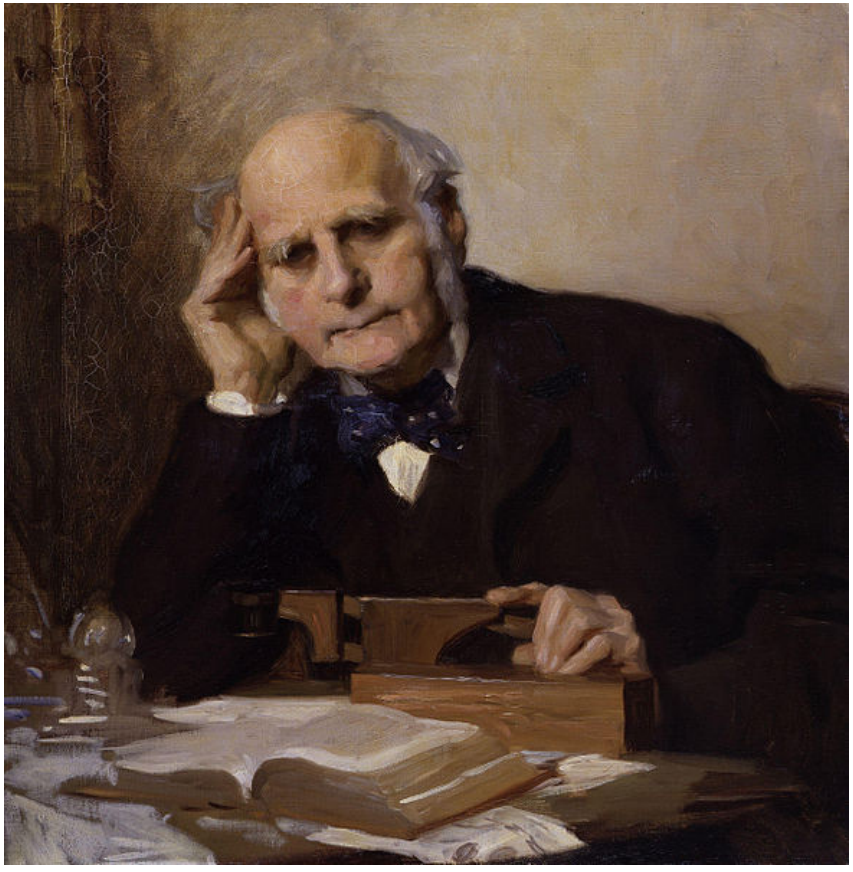

Figure 1: Galton

- cestovatel, antropolog, eugenik

(3) Známe-li výšku rodičů, lze předpovědět výšku jejich dětí?

- cestovatel, antropolog, eugenik
  - základy deskriptivní statistiky (median – vox populi) a inferenční statistiky (lineární regrese)

(3) Známe-li výšku rodičů, lze předpovědět výšku jejich dětí?

- cestovatel, antropolog, eugenik
  - základy deskriptivní statistiky (median – vox populi) a inferenční statistiky (lineární regrese)
  - také meteorolog, statistik (efektivita modliteb) a poměřovatel krásy žen v různých částech Anglie

(3) Známe-li výšku rodičů, lze předpovědět výšku jejich dětí?

- cestovatel, antropolog, eugenik
  - základy deskriptivní statistiky (median – vox populi) a inferenční statistiky (lineární regrese)
  - také meteorolog, statistik (efektivita modliteb) a poměřovatel krásy žen v různých částech Anglie
- viktoriánský učenec s vášní pro data

(3) Známe-li výšku rodičů, lze předpovědět výšku jejich dětí?

- cestovatel, antropolog, eugenik
  - základy deskriptivní statistiky (median – vox populi) a inferenční statistiky (lineární regrese)
  - také meteorolog, statistik (efektivita modliteb) a poměřovatel krásy žen v různých částech Anglie
- viktoriánský učenec s vášní pro data
- bratranec Charlese Darwina

(3) Známe-li výšku rodičů, lze předpovědět výšku jejich dětí?

- cestovatel, antropolog, eugenik
  - základy deskriptivní statistiky (median – vox populi) a inferenční statistiky (lineární regrese)
  - také meteorolog, statistik (efektivita modliteb) a poměřovatel krásy žen v různých částech Anglie
- viktoriánský učenec s vášní pro data
- bratranec Charlese Darwina
- výzkumná otázka:

(3) Známe-li výšku rodičů, lze předpovědět výšku jejich dětí?

- výzkumná otázka se ve statistice vždy staví proti nulové hypotéze:

(4) Mezi výškou rodičů a výškou dětí není žádný vztah.

- výzkumná otázka se ve statistice vždy staví proti nulové hypotéze:

(4) Mezi výškou rodičů a výškou dětí není žádný vztah.

- Galton: shromáždil data o cca 400 rodičích a jejich 400 dcerách a synech

- databáze

- databáze
- 1 palec = 2.54 cm

- databáze
- 1 palec = 2.54 cm
- dnešní průměrná výška mužů a žen v UK je 69 a 63 palců (vs. 69.5 a 64 medián v Galtonově vzorku)

- databáze
- 1 palec = 2.54 cm
- dnešní průměrná výška mužů a žen v UK je 69 a 63 palců (vs. 69.5 a 64 medián v Galtonově vzorku)
- dál statistické zpracování z R Core Team (2021)

- databáze
- 1 palec = 2.54 cm
- dnešní průměrná výška mužů a žen v UK je 69 a 63 palců (vs. 69.5 a 64 medián v Galtonově vzorku)
- dál statistické zpracování z R Core Team (2021)
- napřed deskriptivní statistika

- databáze
- 1 palec = 2.54 cm
- dnešní průměrná výška mužů a žen v UK je 69 a 63 palců (vs. 69.5 a 64 medián v Galtonově vzorku)
- dál statistické zpracování z R Core Team (2021)
- napřed deskriptivní statistika
- následuje výstup z jazyka R (v české mat. terminologie se používá desetinná čárka)

```
## [1] "Fathers: počet záznamů, deskriptivní stat."

## [1] "standard deviation (směrodatná odchylka)"

## [1] 197

##    Min. 1st Qu.  Median    Mean 3rd Qu.    Max. 
##   62.00   68.00   69.50   69.35   71.00   78.50 

## [1] 2.622034

## [1] "Mothers"

## [1] 197

##    Min. 1st Qu.  Median    Mean 3rd Qu.    Max. 
##   58.00   62.70   64.00   63.98   65.50   70.50 

## [1] 2.355607
```

```
## [1] "Sons"

## [1] 465

##    Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
##   60.00   67.50   69.20   69.23   71.00   79.00

## [1] 2.631594

## [1] "Daughters"

## [1] 433

##    Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
##   56.00   62.50   64.00   64.11   65.50   70.50

## [1] 2.37032
```

- quantile: česky dolní kvantil, medián, horní kvantil

- důležité termíny: **mean** (průměr) vs. **median** (medián)

```
x <- c(2,4,8,10,100)
mean(x)
```

```
## [1] 24.8
```

```
median(x)
```

```
## [1] 8
```

```
sd(x)
```

```
## [1] 42.15685
```

```
y <- c(2,4,8,10)
sd(y)
```

```
## [1] 3.651484
```

- důležité termíny: **mean** (průměr) vs. **median** (medián)
- směrodatná odchylka

```
x <- c(2,4,8,10,100)
mean(x)
```

```
## [1] 24.8
```

```
median(x)
```

```
## [1] 8
```

```
sd(x)
```

```
## [1] 42.15685
```

```
y <- c(2,4,8,10)
sd(y)
```

```
## [1] 3.651484
```

```
## [1] "Boxplot (krabicový graf)"
```

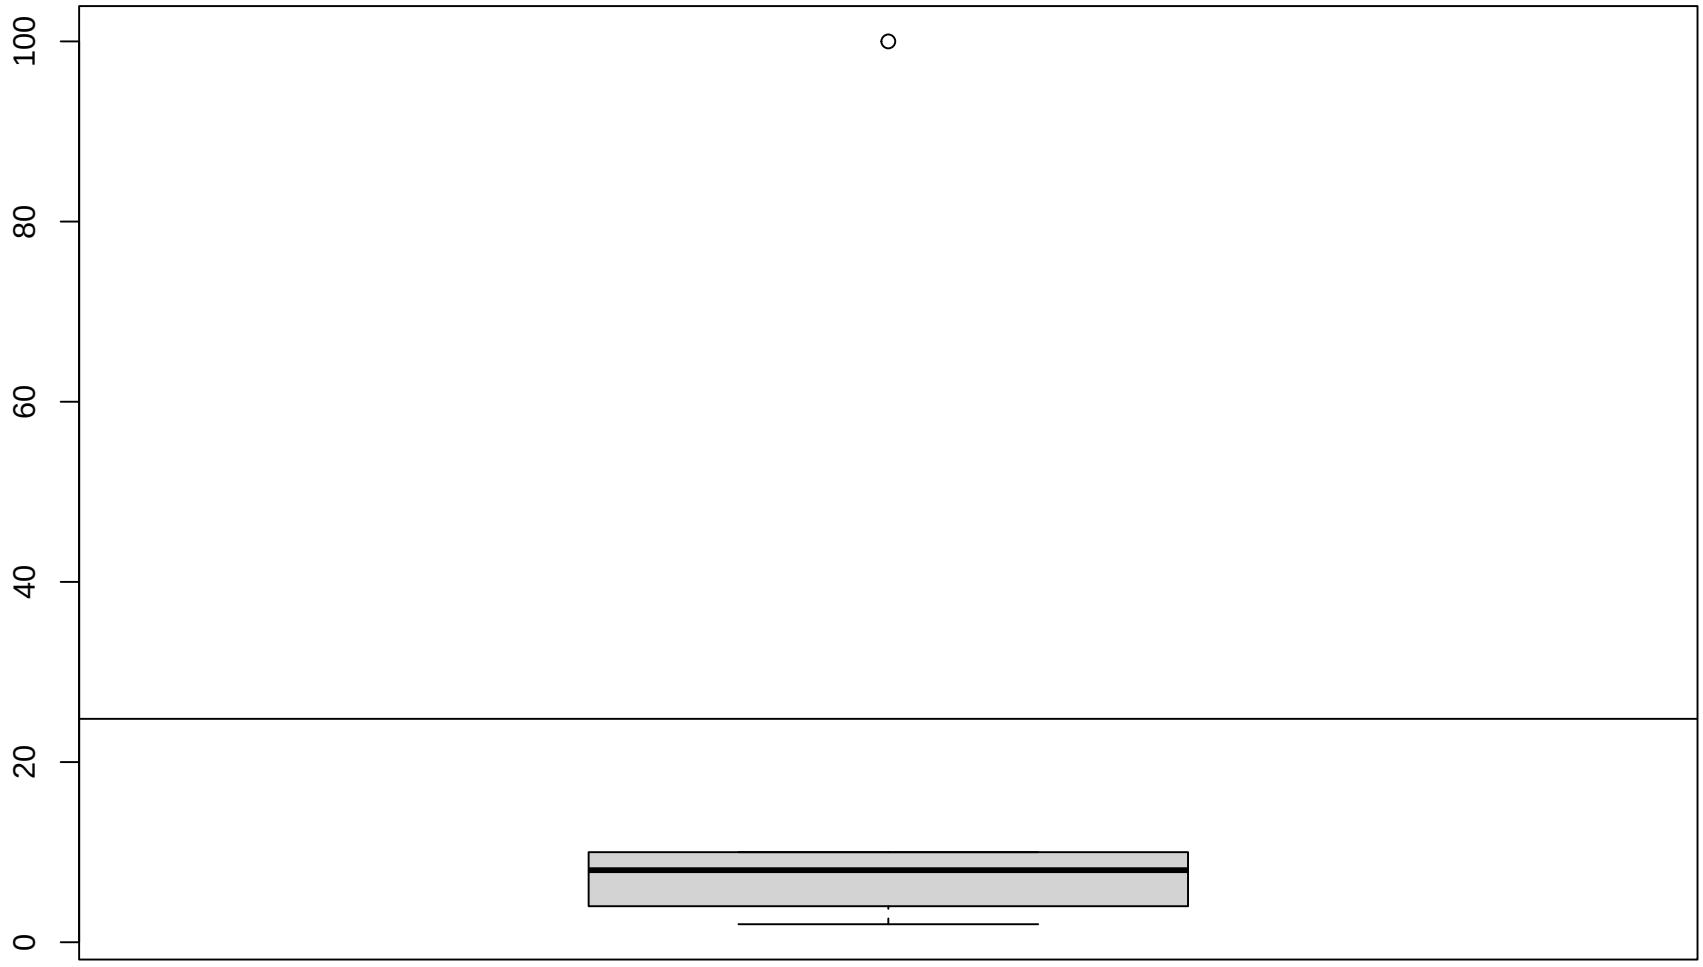

- obvyklé grafické znázornění: tzv. boxplot nebo scatter plot (korelační diagram)

- obvyklé grafické znázornění: tzv. boxplot nebo scatter plot (korelační diagram)
- deskriptivní statistika

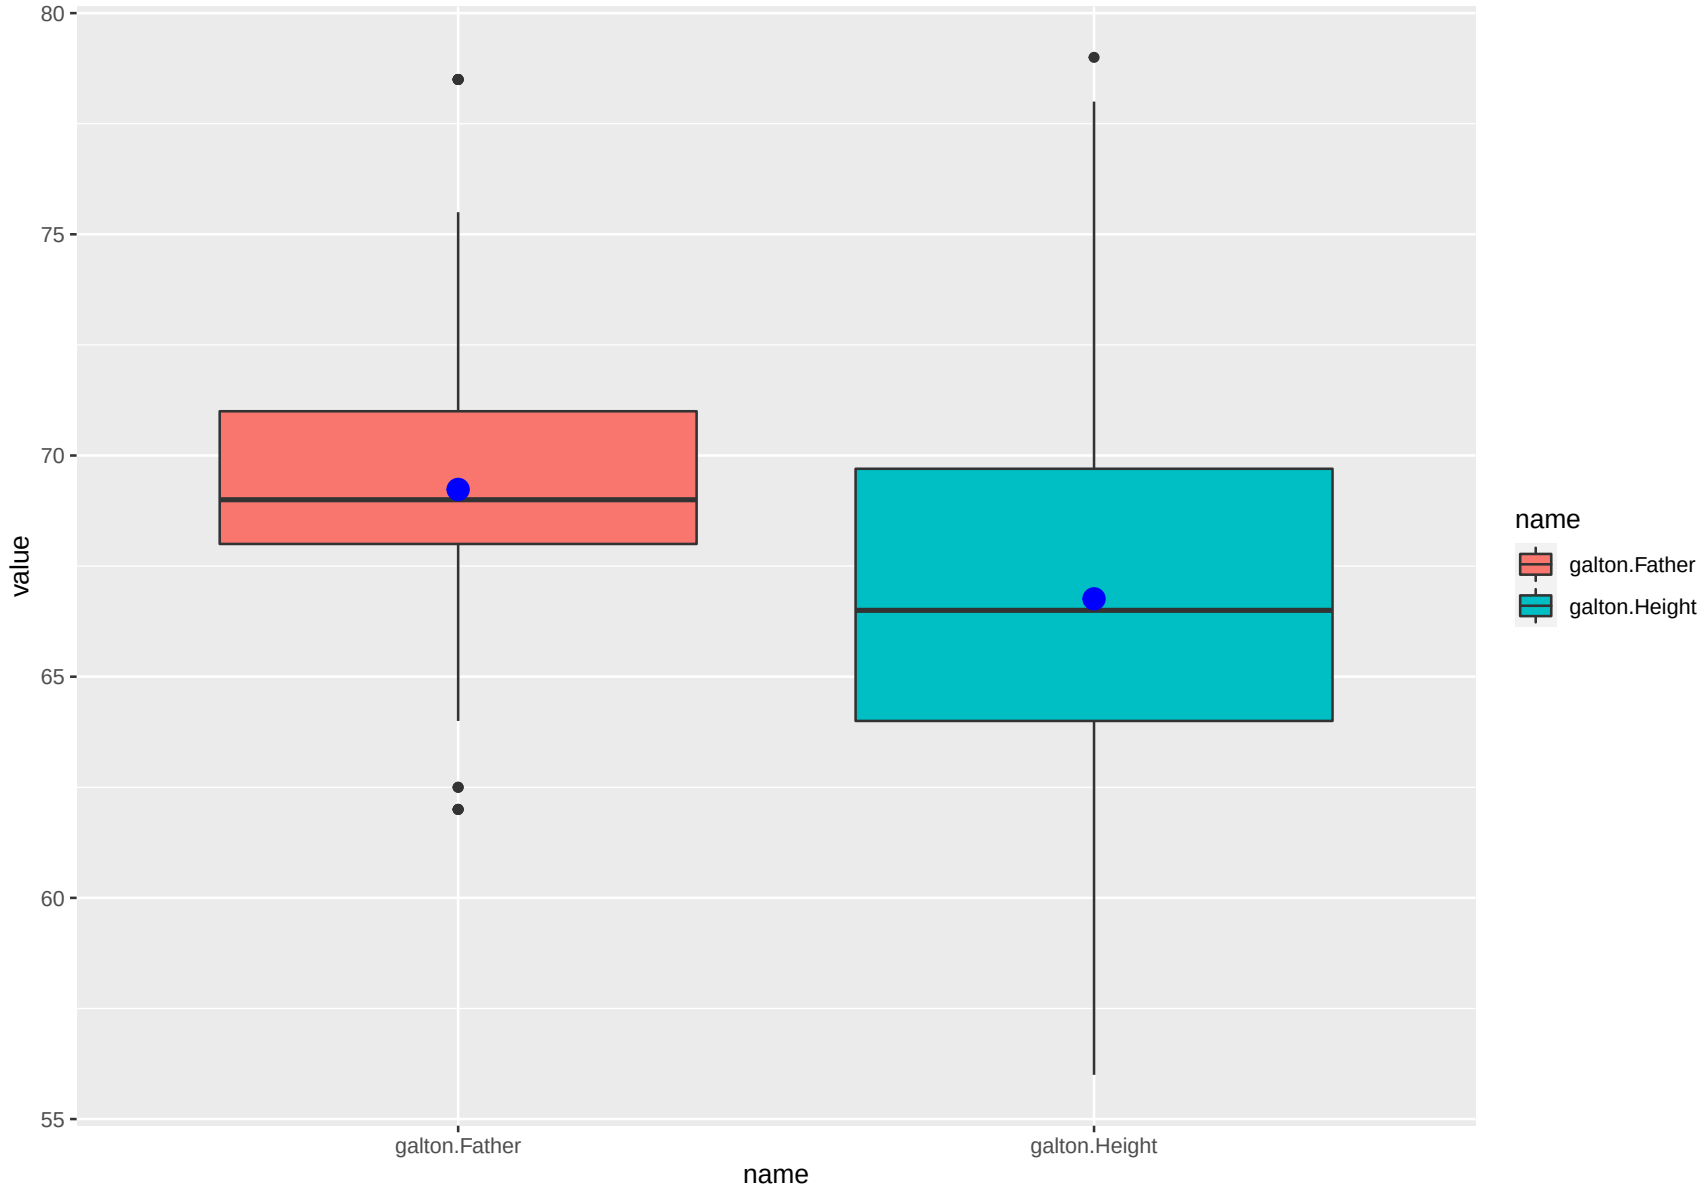
80
75
70
65
60
55
value
galton.Father
galton.Height
name
name
galton.Father
galton.Height

- následující slide: tzv. scatter-plot graf výšky otců (x) oproti výšce synů (y)

- následující slide: tzv. scatter-plot graf výšky otců (x) oproti výšce synů (y)
- přidaný jitter pro odlišení stejných hodnot

- následující slide: tzv. scatter-plot graf výšky otců (x) oproti výšce synů (y)
- přidaný jitter pro odlišení stejných hodnot
- přerušovaná čára: výška otce = výška syna

- následující slide: tzv. scatter-plot graf výšky otců (x) oproti výšce synů (y)
- přidaný jitter pro odlišení stejných hodnot
- přerušovaná čára: výška otce = výška syna
- tlustá čára (regresní přímka): lineární regrese, tzv. best fit (nejlepší aproximace?)

- následující slide: tzv. scatter-plot graf výšky otců (x) oproti výšce synů (y)
- přidaný jitter pro odlišení stejných hodnot
- přerušovaná čára: výška otce = výška syna
- tlustá čára (regresní přímka): lineární regrese, tzv. best fit (nejlepší aproximace?)
- reziduální chyba: vzdálenost bodu od lineárně regresní přímky

- následující slide: tzv. scatter-plot graf výšky otců (x) oproti výšce synů (y)
- přidaný jitter pro odlišení stejných hodnot
- přerušovaná čára: výška otce = výška syna
- tlustá čára (regresní přímka): lineární regrese, tzv. best fit (nejlepší aproximace?)
- reziduální chyba: vzdálenost bodu od lineárně regresní přímky
- podle Spiegelhalter (2019)

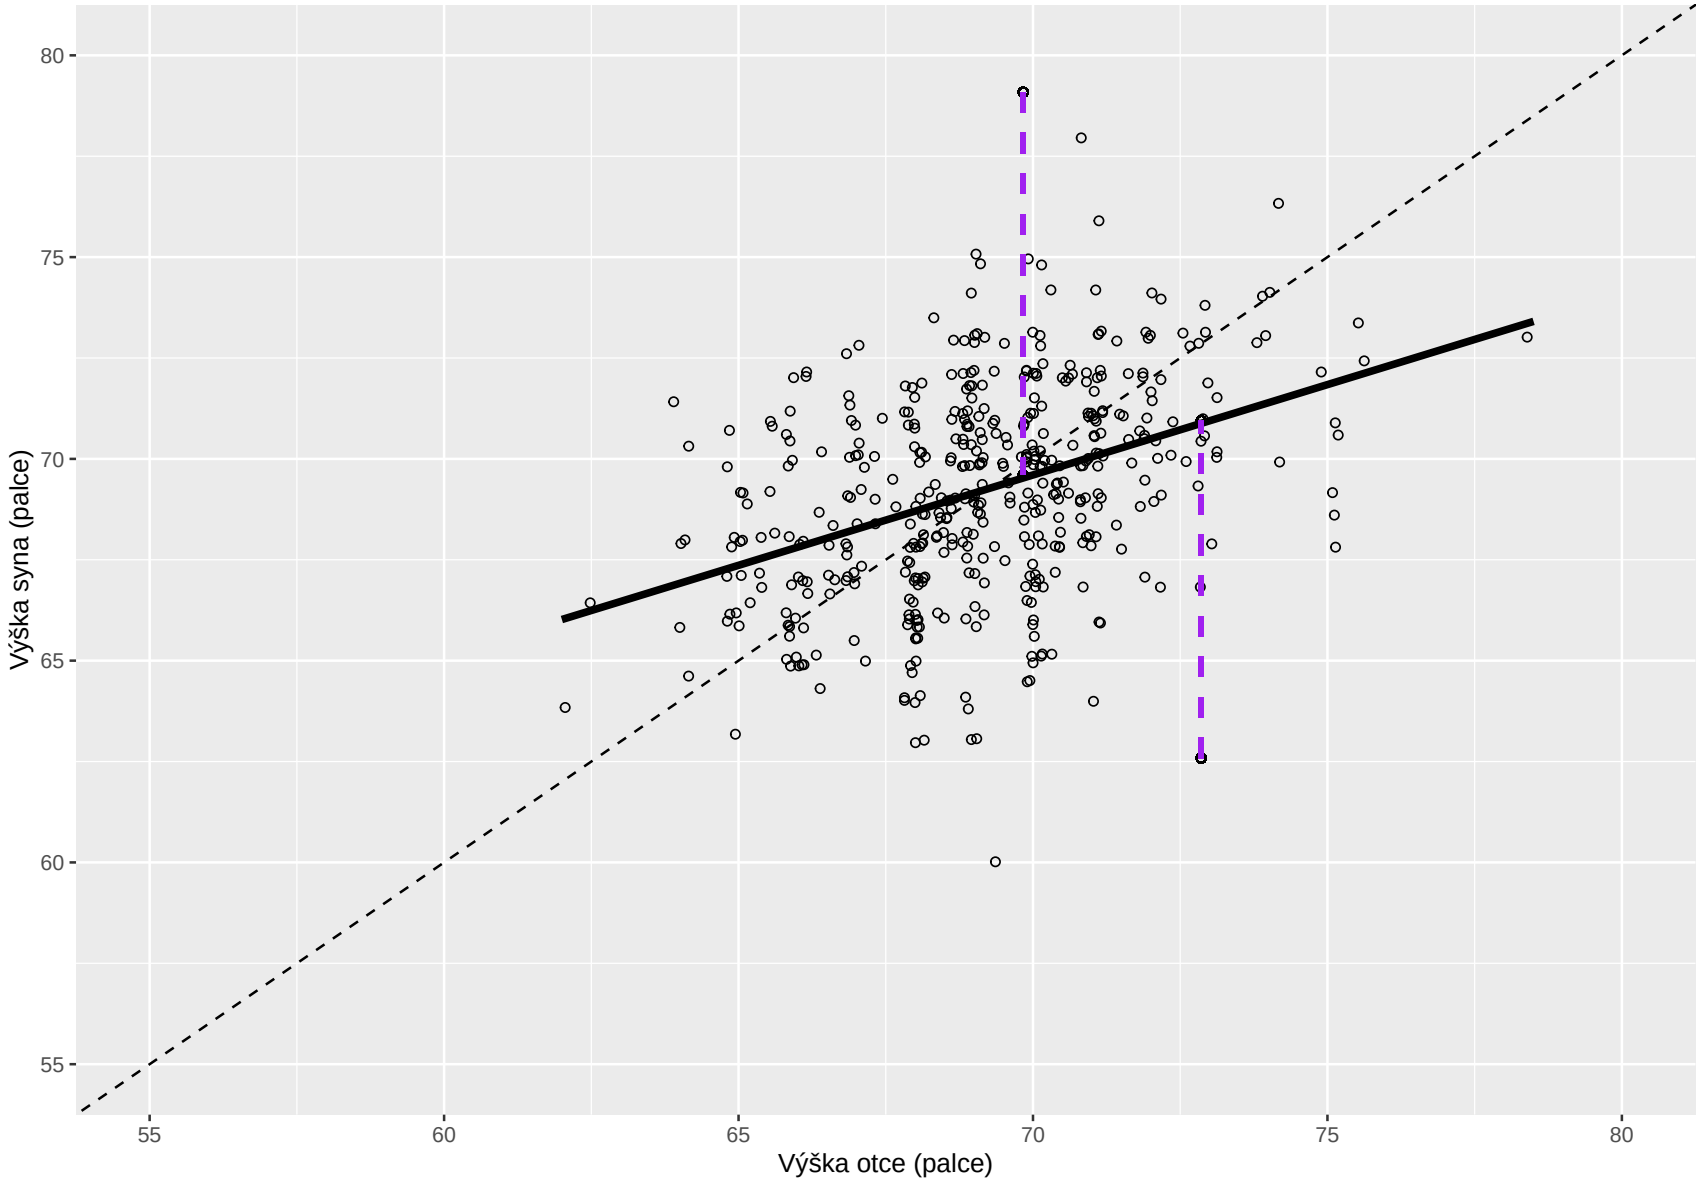
Výška syna (palce)
80
75
70
65
60
55
55
60
65
70
75
80
Výška otce (palce)

- moderní interpretace pomocí tzv. lineárního modelu:

- moderní interpretace pomocí tzv. lineárního modelu:
- Estimate (odhad): jak se změní výška syna, vzroste-li explanatory (vysvětlující?) proměnná (výška otce) o 1 (palec), plus intercept (průsečík)

- moderní interpretace pomocí tzv. lineárního modelu:
- Estimate (odhad): jak se změní výška syna, vzroste-li explanatory (vysvětlující?) proměnná (výška otce) o 1 (palec), plus intercept (průsečík)
- t-value: stejné jako Studentův t-test: jak daleko je estimate od 0 měřeno standardními chybami (více než abs. 2 – statisticky signifikantní (významný) efekt)

- moderní interpretace pomocí tzv. lineárního modelu:
- Estimate (odhad): jak se změní výška syna, vzroste-li explanatory (vysvětlující?) proměnná (výška otce) o 1 (palec), plus intercept (průsečík)
- t-value: stejné jako Studentův t-test: jak daleko je estimate od 0 měřeno standardními chybami (více než abs. 2 – statisticky signifikantní (významný) efekt)
- p-hodnota: pravděpodobnost nulové hypotézy

```
##
## Call:
## lm(formula = Son ~ FatherS)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -9.3774 -1.4968  0.0181  1.6375  9.3987
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept) 38.25891    3.38663   11.30   <2e-16 ***
## FatherS      0.44775    0.04894    9.15   <2e-16 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 2.424 on 463 degrees of freedom
## Multiple R-squared:  0.1531, Adjusted R-squared:  0.1513
## F-statistic: 83.72 on 1 and 463 DF,  p-value: < 2.2e-16
```

- to už je inferenční (úsudková) statistika (induktivní úsudek ze vzorku na populaci)

- to už je inferenční (úsudková) statistika (induktivní úsudek ze vzorku na populaci)
- přesně tento typ modelů (ale smíšených) pak využíváme v lingvistice: Michaela Hulmanová: Asymmetry of cumulative readings with distributive conjunctions: an experimental study

- ilustrace inferenční statistiky

```
MDI <- 194/2.54
over_median <- MDI - 69.5
over_median
```

```
## [1] 6.877953
```

```
MDII <- 69.2 + over_median*0.45
MDII
```

```
## [1] 72.29508
```

```
metric <- MDII*2.54
metric
```

```
## [1] 183.6295
```

- ilustrace inferenční statistiky
- https://www.britannica.com/topic/regression-to-the-mean

```
MDI <- 194/2.54
over_median <- MDI - 69.5
over_median
```

```
## [1] 6.877953
```

```
MDII <- 69.2 + over_median*0.45
MDII
```

```
## [1] 72.29508
```

```
metric <- MDII*2.54
metric
```

```
## [1] 183.6295
```

- ilustrace inferenční statistiky
- https://www.britannica.com/topic/regression-to-the-mean
- seriózní analýza by musela vzít v úvahu česká data: http://www.szu.cz/uploads/documents/obi/CAV/6.CAV_2_Dlouhodobe_zmeny_rustu.pdf

```
MDI <- 194/2.54
over_median <- MDI - 69.5
over_median
```

```
## [1] 6.877953
```

```
MDII <- 69.2 + over_median*0.45
MDII
```

```
## [1] 72.29508
```

```
metric <- MDII*2.54
metric
```

```
## [1] 183.6295
```

Zpět k lingvistice

- příklad s neutralizací aspektu v negovaných imperativních větách

(5) V českých imperativech dochází u negovaných sloves k neutralizaci vidového rozdílu (sloveso je použito v defaultním, tj. imperfektivním vidu).

(6) Negace nemá vliv na neutralizaci vidového rozdílu.

Zpět k lingvistice

- příklad s neutralizací aspektu v negovaných imperativních větách
- výzkumná hypotéza v (5)

(5) V českých imperativech dochází u negovaných sloves k neutralizaci vidového rozdílu (sloveso je použito v defaultním, tj. imperfektivním vidu).

(6) Negace nemá vliv na neutralizaci vidového rozdílu.

Zpět k lingvistice

- příklad s neutralizací aspektu v negovaných imperativních větách
- výzkumná hypotéza v (5)
- oproti tomu nulová hypotéza v (6):

(5) V českých imperativech dochází u negovaných sloves k neutralizaci vidového rozdílu (sloveso je použito v defaultním, tj. imperfektivním vidu).

(6) Negace nemá vliv na neutralizaci vidového rozdílu.

Zpět k lingvistice

- příklad s neutralizací aspektu v negovaných imperativních větách
- výzkumná hypotéza v (5)
- oproti tomu nulová hypotéza v (6):

(5) V českých imperativech dochází u negovaných sloves k neutralizaci vidového rozdílu (sloveso je použito v defaultním, tj. imperfektivním vidu).

(6) Negace nemá vliv na neutralizaci vidového rozdílu.

- první krok: data

- pro tento typ dat je vhodný Český národní korpus

- pro tento typ dat je vhodný Český národní korpus
- hledání slov, frází:

- pro tento typ dat je vhodný Český národní korpus
- hledání slov, frází:

1. kernel

- pro tento typ dat je vhodný Český národní korpus
- hledání slov, frází:

1. kernel

2. širší než delší

- hledání podle morfologických značek (tag):

(oproti zbytku převažují perfektiva: 11 514 033 (Imperf.) vs. 5 787 695 (Perf.))

- hledání podle morfologických značek (tag):

1. baseline (základní případ?):

(oproti zbytku převažují perfektiva: 11 514 033 (Imperf.) vs. 5 787 695 (Perf.))

- hledání podle morfologických značek (tag):

1. baseline (základní případ?):

a. počet imperativních imperfektiv:
`[tag="Vi.............I"]`: 104 385

(oproti zbytku převažují perfektiva: 11 514 033 (Imperf.) vs. 5 787 695 (Perf.))

- hledání podle morfologických značek (tag):

1. baseline (základní případ?):

a. počet imperativních imperfektiv:
   `[tag="Vi.............I"]`: 104 385

b. počet imperativních perfektiv: `[tag="Vi.............P"]`:
   165 924

(oproti zbytku převažují perfektiva: 11 514 033 (Imperf.) vs. 5 787 695 (Perf.))

2. počty negovaných perfektiv a imperfektiv:

2. počty negovaných perfektiv a imperfektiv:

a. negovaná imperfektiva: `[tag="Vi.....N....I"]`: 27 256

2. počty negovaných perfektiv a imperfektiv:

a. negovaná imperfektiva: `[tag="Vi.....N....I"]`: 27 256

b. negovaná perfektiva: `[tag="Vi.....N....P"]`: 4 567

- grafy: boxplot relativní frekvence (krabicový graf relativní četnosti)

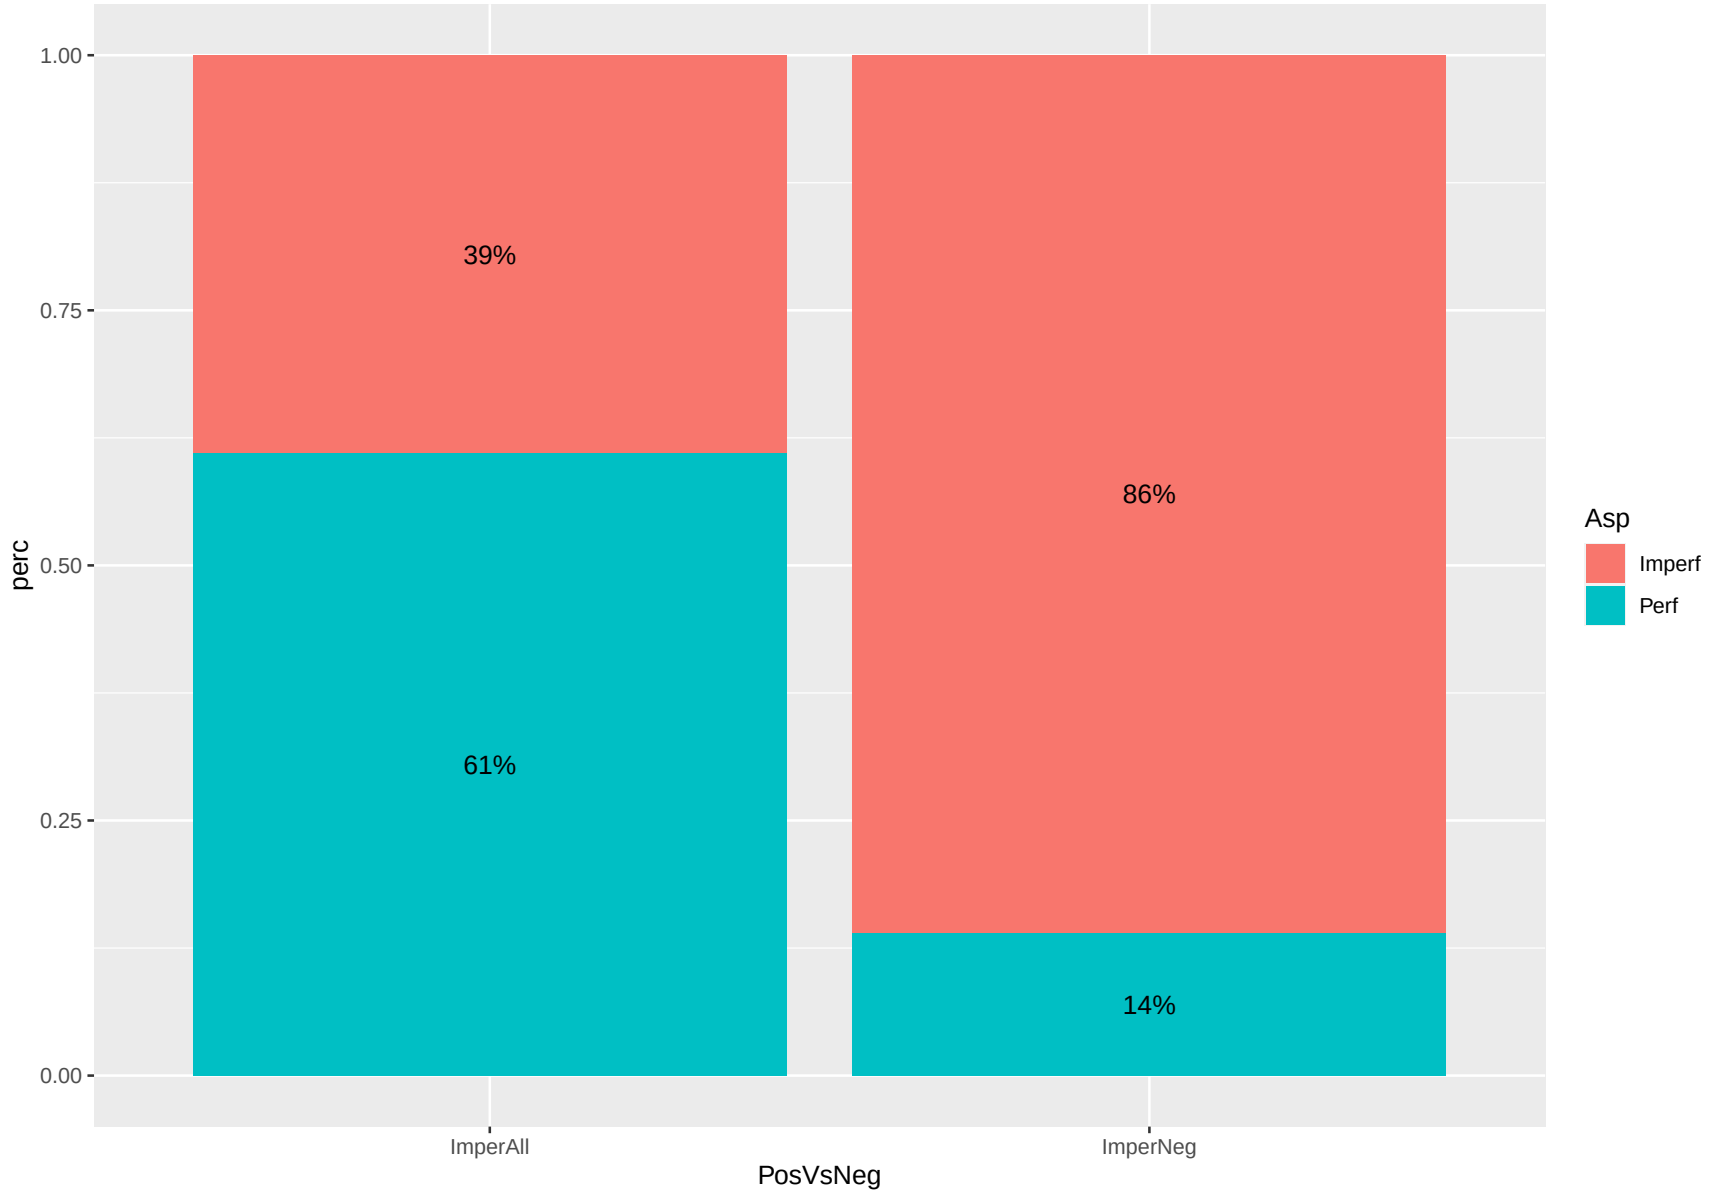
1.00
0.75
0.50
0.25
0.00
perc
39%
61%
86%
14%
ImperAll
ImperNeg
PosVsNeg
Asp
Imperf
Perf

- k inferenční statistice (od vzorku k populaci):

- k inferenční statistice (od vzorku k populaci):
- u těchto tzv. count (spočetných?) dat je nejobvyklejší způsob testování přes Fisherův nebo chi square test (rozdělění chí-kvadrát)

- k inferenční statistice (od vzorku k populaci):
- u těchto tzv. count (spočetných?) dat je nejobvyklejší způsob testování přes Fisherův nebo chi square test (rozdělění chí-kvadrát)
- Fisherův test:

```r
data <- matrix(c(27256, 104385, 4567, 165924), ncol = 2, dimnames = list(c("ImperAl
fisher.test(data)
```

```
##
##  Fisher's Exact Test for Count Data
##
## data:  data
## p-value < 2.2e-16
## alternative hypothesis: true odds ratio is not equal to 1
## 95 percent confidence interval:
##  9.182734 9.796871
## sample estimates:
## odds ratio
##   9.487635
```

- pravděpodobnost, že s takovými daty je kompatibilní nulová hypotéza: *p-value < 2.2e-16*

- pravděpodobnost, že s takovými daty je kompatibilní nulová hypotéza: *p-value < 2.2e-16*
- a pro negovaný imperativ je 9.49 krát pravděpodobnější, že sloveso bude v imperfektivu (oproti všem imperativům)

- pravděpodobnost, že s takovými daty je kompatibilní nulová hypotéza: *p-value < 2.2e-16*
- a pro negovaný imperativ je 9.49 krát pravděpodobnější, že sloveso bude v imperfektivu (oproti všem imperativům)
- confidence interval (interval spolehlivosti): 95% pravděpodobnost, že jakýkoliv jiný náhodný vzorek v populaci se bude chovat stejně: 9.182734 – 9.796871

- pravděpodobnost, že s takovými daty je kompatibilní nulová hypotéza: *p-value < 2.2e-16*
- a pro negovaný imperativ je 9.49 krát pravděpodobnější, že sloveso bude v imperfektivu (oproti všem imperativům)
- confidence interval (interval spolehlivosti): 95% pravděpodobnost, že jakýkoliv jiný náhodný vzorek v populaci se bude chovat stejně: 9.182734 – 9.796871
- tj. pravděpodobnost *nepřečti* v češtině oproti *nečti* leží někde v tomto 95% confidence intervalu

Alternativní analýza v Bayesiánské statistice i

```
library(BayesFactor)
```

```
## Loading required package: coda

## Loading required package: Matrix

##
## Attaching package: 'Matrix'

## The following objects are masked from 'package:tidyr':
##
##     expand, pack, unpack

## ************
## Welcome to BayesFactor 0.9.12-4.4. If you have questions, please contact Richard
##
## Type BFManual() to open the manual.
## ************
```

Alternativní analýza v Bayesiánské statistice ii

```
ctBFout <- contingencyTableBF(data, sampleType="poisson", posterior=FALSE)
ctBFout
```

```
## Bayes factor analysis
## --------------
## [1] Non-indep. (a=1) : 2.12788e+5874 ±0%
##
## Against denominator:
##   Null, independence, a = 1
## ---
## Bayes factor type: BFcontingencyTable, poisson
```

```
ctMCMCout <- contingencyTableBF(data, sampleType="poisson", posterior=TRUE, iterati
summary(ctMCMCout)
```

Alternativní analýza v Bayesiánské statistice iii

```
##
## Iterations = 1:10000
## Thinning interval = 1
## Number of chains = 1
## Sample size per chain = 10000
##
## 1. Empirical mean and standard deviation for each variable,
##    plus standard error of the mean:
##
##               Mean     SD Naive SE Time-series SE
## lambda[1,1]  27255 165.62   1.6562         1.6197
## lambda[2,1] 104387 320.50   3.2050         3.2050
## lambda[1,2]   4568  67.34   0.6734         0.6734
## lambda[2,2] 165928 410.69   4.1069         4.1069
##
## 2. Quantiles for each variable:
##
##               2.5%    25%    50%    75%  97.5%
```

Alternativní analýza v Bayesiánské statistice iv

```
## lambda[1,1]  26933  27144  27255  27366  27577
## lambda[2,1] 103764 104173 104385 104596 105024
## lambda[1,2]   4438   4523   4568   4613   4700
## lambda[2,2] 165126 165651 165928 166205 166733
```

Interpretace Bayesova faktoru

Bayes factor	Strength of evidence
1 to 3	not worth more than a bare mention
3 to 20	positive
20 to 150	strong
>150	very strong

Table 11.3

Kass and Raftery's scale for interpretation of Bayes factors in favour of a hypothesis.[8]

Figure 2: Bayes Factor … strength of evidence

T-test a domácí úkol

- testování individuálních sloves

T-test a domácí úkol

- testování individuálních sloves
- obecně je rozdíl mezi imperfektivy a perfektivy v imperativu očekávatelný

T-test a domácí úkol

- testování individuálních sloves
- obecně je rozdíl mezi imperfektivy a perfektivy v imperativu očekávatelný
- nicméně každé sloveso vnáší svoji nahodilost

- napřed list nejčastějších imperfektivních imperativů

- napřed list nejčastějších imperfektivních imperativů
- pak list perfektivních imperativů

- napřed list nejčastějších imperfektivních imperativů
- pak list perfektivních imperativů
- pak počítání frekvence negovaných lemmat imperativů

- napřed list nejčastějších imperfektivních imperativů
- pak list perfektivních imperativů
- pak počítání frekvence negovaných lemmat imperativů
- pak t.test

GitHub link

https://github.com/MojmirDocekal/ImperNegT-testGitHub

- synchronizace s Rstudio cloud

GitHub link

https://github.com/MojmirDocekal/ImperNegT-testGitHub

- synchronizace s Rstudio cloud
- rozdělení úkolů

GitHub link

https://github.com/MojmirDocekal/ImperNegT-testGitHub

- synchronizace s Rstudio cloud
- rozdělení úkolů
- úkol:

GitHub link

https://github.com/MojmirDocekal/ImperNegT-testGitHub

- synchronizace s Rstudio cloud
- rozdělení úkolů
- úkol:

1. zpracovat vlastních 8 sloves

GitHub link

https://github.com/MojmirDocekal/ImperNegT-testGitHub

- synchronizace s Rstudio cloud
- rozdělení úkolů
- úkol:

1. zpracovat vlastních 8 sloves
2. zaslat data i s výsledkem t.testu do mailu

GitHub link

https://github.com/MojmirDocekal/ImperNegT-testGitHub

- synchronizace s Rstudio cloud
- rozdělení úkolů
- úkol:

1. zpracovat vlastních 8 sloves
2. zaslat data i s výsledkem t.testu do mailu
3. načíst jednu kapitolu z Text mining with R

Čtení na příště

Relationships between words: n-grams and correlations

- zkusit si cvičně klonování do Rstudia cloud

Příklad minimálního experimentu

- při překřížení rukou někteří lidí: pravá nahoře, ...

(7) Nulová hypotéza: mezi oběma proměnnými není žádný vztah.

Příklad minimálního experimentu

- při překřížení rukou někteří lidí: pravá nahoře, ...
- výzkumná otázka: má biologický rod vliv na to která?

(7) Nulová hypotéza: mezi oběma proměnnými není žádný vztah.

Příklad minimálního experimentu

- při překřížení rukou někteří lidí: pravá nahoře, ...
- výzkumná otázka: má biologický rod vliv na to která?

(7) Nulová hypotéza: mezi oběma proměnnými není žádný vztah.

- kód: RstudioCloud

Příprava na příště

- založit si účet na RstudioCloud

Příprava na příště

- založit si účet na RstudioCloud
- zkopírovat z učebních materiálů Fisherův test

Příprava na příště

- založit si účet na RstudioCloud
- zkopírovat z učebních materiálů Fisherův test
- nahrát na RStudioCloud

Příprava na příště

- založit si účet na RstudioCloud
- zkopírovat z učebních materiálů Fisherův test
- nahrát na RStudioCloud
- vložit vlastní jméno

Příprava na příště

- založit si účet na RstudioCloud
- zkopírovat z učebních materiálů Fisherův test
- nahrát na RStudioCloud
- vložit vlastní jméno
- udělat report: File -> Knit document (HTML)

Příprava na příště

- založit si účet na RstudioCloud
- zkopírovat z učebních materiálů Fisherův test
- nahrát na RStudioCloud
- vložit vlastní jméno
- udělat report: File -> Knit document (HTML)
- poslat do mailu

Čtení do příště

- pěkný úvodní text:

R for Data Science

Text mining in R

Čtení do příště

- pěkný úvodní text:

R for Data Science

- navážeme pak:

Text mining in R

References i

Baayen, H. 2008. *Analyzing linguistic data: A practical introduction to statistics using R*. Cambridge University Press.

Chomsky, Noam. 1957. *Syntactic Structures*. the Hague: Mouton.

Kruschke, John K. 2011. *Doing Bayesian Data Analysis : A Tutorial with r and BUGS*. Burlington, MA: Academic Press. http://www.amazon.com/Doing-Bayesian-Data-Analysis-Tutorial/dp/0123814855.

R Core Team. 2021. *R: A Language and Environment for Statistical Computing*. Vienna, Austria: R Foundation for Statistical Computing. https://www.R-project.org/.

Spiegelhalter, David. 2019. *The Art of Statistics: Learning from Data*. London: Penguin books.