

# Základy biostatistiky

(MS710P09)  
ak. rok 2013/2014

Karel Zvára

karel.zvara@mff.cuni.cz

karel.zvara@natur.cuni.cz

<http://www.karlin.mff.cuni.cz/~zvara>

Katedra pravděpodobnosti a matematické statistiky MFF UK  
Ústav aplikací matematiky a výpočetní techniky PřF UK

(naposledy upraveno 27. dubna 2014)



## tři části přednášky

snad neodpadne žádná přednáška

- ▶ popisná statistika
  - ▶ několika čísla vystihnout důležitou vlastnost
  - ▶ jednoduchým grafem vyjádřit důležitou vlastnost
  - ▶ porovnat soubory dat
- ▶ abstraktní pohled (teorie)
  - ▶ pravděpodobnost, Bayesův vzorec, náhodná veličina, distribuční funkce, střední hodnota, nezávislost
  - ▶ populace a výběr
  - ▶ popisné statistiky jako odhady populačních parametrů
  - ▶ interval spolehlivosti pro populační parametr
  - ▶ test statistické hypotézy
- ▶ některé metody (modely)
  - ▶ testy o jednom, dvou či několika výběrech
  - ▶ rozhodování o závislosti kvantitativních či kvalitativních znaků
- ▶ cílem jsou principy, pojmy, základní metody, nikoliv vzorečky

## ► cvičení na počítačích v B5

- ▶ od úterý 18. února ve Viničné 7, 1. patro B5
- ▶ nutno **zapsat se do paralelky** prostřednictvím SIS
- ▶ zápočet za aktivní účast + odevzdávání souborů + písemky (upřesnění cvičící)
- ▶ nutno mít **aktivní účet v učebnách**, znát svoje heslo
- ▶ volně šířitelný program R (<http://cran.r-project.org/>)

## ► zkouška v B5

- ▶ jen se zápočtem, přihlašování prostřednictvím SIS
- ▶ kombinace písemného a ústního zkoušení
- ▶ řešení úloh na počítači, **interpretace výsledků**
- ▶ základy teorie (pojmy, metody a jejich volba, interpretace)

## ► literatura

- ▶ K. Zvára: Základy statistiky v prostředí R (Biomedicínská statistika IV), Karolinum 2013
- ▶ K. Zvára: Biostatistika. Karolinum 1998, ..., 2008

## ► konzultace

- út 14:00– prac. 209, Albertov 6 (ÚAMVT PřF UK)

## cvičení

- ▶ příležitost **procvičit** pojmy a postupy
- ▶ k tomu je třeba **sledovat přednášku** aspoň orientačně
- ▶ doporučuji aktivně využít cvičení, spolupracovat s cvičícím, ověřit si tak pochopení principů a pojmu
- ▶ u zkoušky mechanická aplikace nestačí, je třeba vysvětlit **proč** byl zvolen nějaký postup, **co vyšlo**, **interpretovat výsledky**; také znát **pojmy**, jejich podstatné vlastnosti a interpretaci
- ▶ cvičící mají svoje stránky s podrobnějšími informacemi:
- ▶ **cvičení není náhradou přednášky!**
- ▶ pracuje se v prostředí R, zejména v nadstavbě Rcmdr, která
  - ▶ nabízí řešení většiny reálných úloh
  - ▶ umožňuje modifikaci dosavadního postupu
  - ▶ poskytuje demonstrační pomůcky
  - ▶ R je volně šířitelný SW
  - ▶ v R pracují mnozí další učitelé

## statistika

nejzákladnější dělení, dvojí pohled

### ► statistika

- ▶ **popisná** (deskriptivní):  
data stručně popsat, něco z dat „vydolovat“  
tvrdit něco o daných datech, nezobecňovat
- ▶ **induktivní** (konfirmatorní):  
tvrdit něco nového, zobecnit na větší soubor (populaci),  
důležitá je interpretace

### ► příklady dat:

- ▶ **výšky**: výška desetiletých chlapců/dívek
- ▶ **děti**: pohlaví, porodní hmotnost a délka, hmotnost a délka  
v jednom roce, věk otce a matky, počet onemocnění otitidou  
v prvním roce věku
- ▶ **kolení**: hmotnost a porodní délka a ve 24. týdnu, věk a výška  
obou rodičů, zda těhotenství plánováno, zda dudlík, porodnice

## co měříme (zjišťujeme) a kde

- ▶ měříme na **statistických jednotkách** (osoba, obec, stát, pokusné pole, rostlinka pšenice, třetí list rostlinky pšenice, ...)
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ **znak** - vlastnost měřená na objektu (statistické jednotce)
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku**  
(stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků  
(umožní to vyšetřování závislostí)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti, které charakterizují celou velkou skupinu (**populaci**), ne jen právě změřené objekty
- ▶ hodnoty znaků zjišťujeme u jedinců,  
chceme vypovídat celých souborech jedinců
- ▶ kolik procent mužů ve věku 20–25 let kouří?

## měřítka

- ▶ **nula-jedničkové**  
pouze dvě možné hodnoty (muž/žena, kouří/nekouří)
- ▶ **nominální**  
seznam všech jednoznačně rozlišitelných hodnot,  
**faktor** (porodnice, pohlaví, odrůda)
- ▶ **ordinální**  
hodnoty nominálního měřítka jsou uspořádány,  
**uspořádaný faktor** (vzdělání matky, stupeň bolesti)
- ▶ **intervalové**  
stejné vzdálenosti sousedních hodnot (rok narození)  
„**o kolik** je  $x$  menší než  $y$ “ (nikoliv „kolikrát“)
- ▶ **poměrové**  
srovnání se zvolenou jednotkou (hmotnost, výška, věk)  
„**kolikrát** je  $x$  větší, než  $y$ “

## hrubší dělení měřítek

(bezprostředně ovlivně volbu metod)

- ▶ **kvalitativní**  
nula-jedničkové, nominální, zpravidla i ordinální
- ▶ u kvalitativních se zpravidla udávají **četnosti** jednotlivých hodnot (kolikrát která hodnota nastala)
- ▶ **kvantitativní** (spojité)  
intervalové, poměrové, někdy ordinální (ale není spojité)
- ▶ hodnoty kvantitativních – čísla
- ▶ pro četnosti hodnot v kvalitativním měřítku se používají zpravidla jiné charakteristiky a metody, než pro hodnoty v kvantitativním měřítku

## veličina, statistika

- ▶ číselně vyjádřený výsledek měření, pokusu
- ▶ **spojitá veličina**: možné hodnoty znaků v intervalovém nebo poměrovém měřítku jsou hustě rozmištěné, mezi dvěma hodnotami existuje nekonečně mnoho dalších hodnot, v praxi je zapisujeme s omezenou přesností
- ▶ **diskrétní veličina**: četnosti hodnot znaků v nula-jedničkovém, nominálním (či ordinálním) měřítku
- ▶ u veličin používáme číselné charakteristiky některých hromadných vlastností, např. **míry polohy** (míry centrální tendenze), **míry variability**, míry tvaru)
- ▶ **statistika** (další význam slova) – funkce pozorovaných hodnot např. průměrná teplota v roce, nejvyšší teplota v roce; číselně charakterizuje důležitou vlastnost veličiny (veličin), je to společná vlastnost skupiny statistických jednotek

## histogram (barplot u kvalitativní veličiny)

- ▶ **histogram**  
grafické znázornění intervalových četností spojité veličiny
- ▶ **barplot (sloupcový diagram)**  
grafické znázorněné četnosti (počtu hodnot) kvalitativního znaku
- ▶ plocha (výška) obdélníku úměrná četnosti
- ▶ relativní četnosti mají jen jiné měřítko svislé osy
- ▶ **výšečový diagram** pro relativní četnosti kvalitativního znaku (podíly nějakého celku)

## označení

rozlišujte  $n$ ,  $n_i$ ,  $m$ ,  $x_i$ ,  $x_i^*$  (nemusí být čísla)

$x_1$ ,	$x_2$ ,	...	$x_n$	zjištěné hodnoty
$x_1^*$ ,	$x_2^*$ ,	...	$x_m^*$	možné hodnoty (různé)
$n_1$ ,	$n_2$ ,	...	$n_m$	četnosti hodnot

$$n_1 + n_2 + \dots + n_m = \sum_{j=1}^m n_j = n$$

$$\frac{n_1}{n}, \frac{n_2}{n}, \dots, \frac{n_m}{n} - \text{relativní četnosti}$$

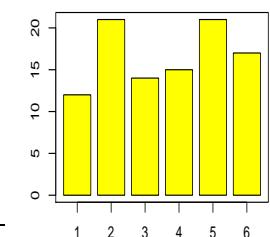
$$N_j = \sum_{i=1}^j n_i \quad \text{kumulativní četnosti}$$

pro kumulativní četnosti je nutné aspoň ordinální měřítko

## příklad hod kostkou A – barplot

zpracování četností (kostka A), nominální měřítko s šesti hodnotami

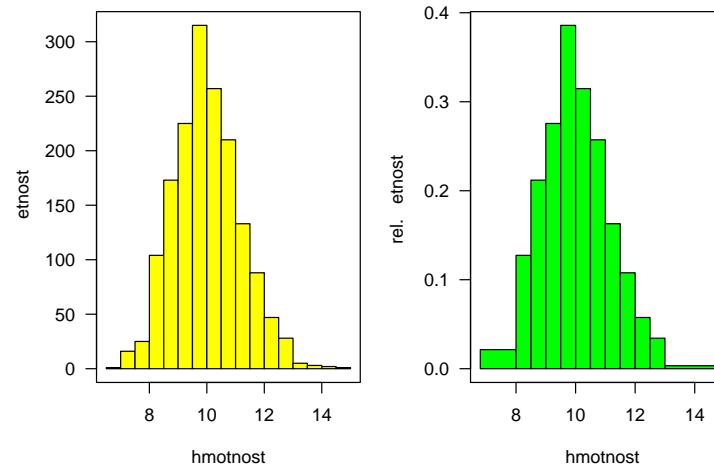
$j$		$n_j$	$f_j = n_j/n$
1		12	0,12
2		21	0,21
3		14	0,14
4		15	0,15
5		21	0,21
6		17	0,17
		$n = 100$	$1,00$





## histogram pro hmotnost v jednom roce

Svislá osa histogramu napravo popsána tak, aby vybarvená plocha byla rovna jedné.  
Nepřehlédněte, že většina sloupků má šířku rovnou jedné polovině.



## variační řada, pořadí

nutno rozlišovat  $x_i$  a  $x_{(i)}$

- ▶ původní hodnoty spojité veličiny (kvantitativní znak)

$x_1, x_2, \dots, x_n$  např. 7, 4, 5, 4, 2

- ▶ variační řada [sort(x)]

$x_{(1)} \leq x_{(2)} \dots \leq x_{(n)}$  např. 2, 4, 4, 5, 7

- ▶ pořadí: [rank(x)]

na které místo ve variační řadě se dostane daná hodnota  
nejmenší dostane pořadí 1, druhá nejmenší dostane 2, ...

- ▶ je-li několik hodnot stejných, dostanou průměr  
z odpovídajících pořadí

- ▶ pořadí hodnot 7, 4, 5, 4, 2 jsou po řadě 5, 2,5, 4, 2,5, 1

## empirická distribuční funkce

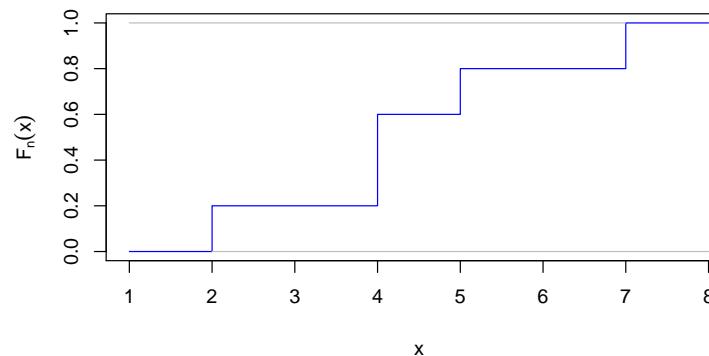
[empirical distribution function]

relativní četnost hodnot, které jsou menší nebo rovny  $x$

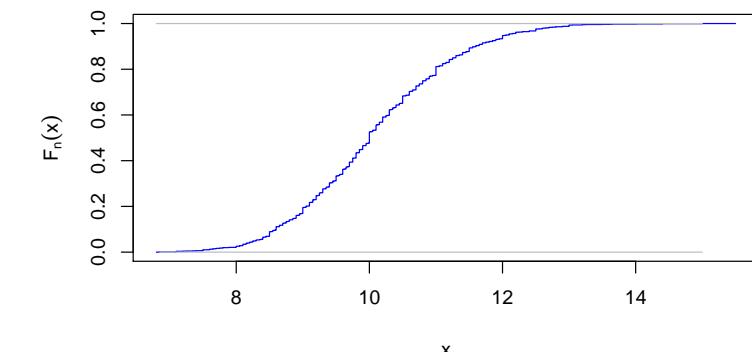
jaká část dat je **nejvýše**  $x$

$$F_n(x) = \frac{\#\{x_i \leq x\}}{n}$$

naše variační řada: 2, 4, 4, 5, 7



## empirická distribuční funkce



- ▶ příklad: váha dětí v jednom roce ( $n = 1633$ )
- ▶ připomíná hladkou neklesající funkci
- ▶ matematický model předpokládá pro celou populaci opravdu hladkou neklesající funkci

## průměry

- ▶ **průměr** `[mean(x)]`

$$\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

- ▶ **vážený průměr** s využitím četnosti ( $n = \sum_j n_j$ )

$$\bar{x} = \frac{1}{n} (n_1 x_1^* + n_2 x_2^* + \dots + n_m x_m^*) = \frac{1}{n} \sum_{j=1}^m n_j x_j^*$$

- ▶ obecněji s nezápornými vahami  $w_j$  hodnot  $x_j^*$

$$\bar{x} = \frac{\sum_j w_j x_j^*}{\sum_j w_j}$$

`[weighted.mean(x, w)]`

## příklad: vážený průměr známek vážený kredity

jaký je nevážený průměr?

známka	kreditů	součin
$x_j^*$	$w_j$	$x_j^* \cdot w_j$
1	6	6
2	4	8
2	2	4
3	4	12
celkem	16	30

$$\bar{x} = \frac{6 \cdot 1 + 4 \cdot 2 + 2 \cdot 2 + 4 \cdot 3}{6 + 4 + 2 + 4} = \frac{30}{16} = 1,875$$

`[weighted.mean(x=c(1,2,2,3),w=c(6,4,2,4))]`

## další míry polohy

opět jsou důležité závorky kolem indexů

- ▶ **medián** (prostřední hodnota, NIKOLIV střední hodnota)

$$\tilde{x} = \begin{cases} x_{(\frac{n+1}{2})} & n \text{ liché} \\ \frac{1}{2} (x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}) & n \text{ sudé} \end{cases}$$

`[median(x)]`

- ▶ **minimum, maximum**

$$x_{\min} = x_{(1)}$$

`[min(x)]`

$$x_{\max} = x_{(n)}$$

`[max(x)]`

`[range(x)]` spočítá dvojici ( $x_{\min}, x_{\max}$ )

- ▶ **variační průměr** `[mean(range(x))]`

$$\frac{1}{2} (x_{(1)} + x_{(n)}) = \frac{1}{2} (x_{\min} + x_{\max})$$

## kvartily, decily

- ▶ **medián**  $\tilde{x}$  je číslo, které dělí data na dvě poloviny: hodnot menších nebo stejných jako medián – hodnot větších nebo stejných jako medián `[median(x)] [quantile(x,probs=1/2)]`
- ▶ **dolní kvartil**  $Q_1$  je číslo, které oddělí čtvrtinu hodnot (menších či stejných jako  $Q_1$ ) od tří čtvrtin hodnot (větších či stejných jako  $Q_1$ ) `[quantile(x,probs=1/4)]`
- ▶ **horní kvartil**  $Q_3$  je číslo, které oddělí tři čtvrtiny hodnot (menších či stejných jako  $Q_3$ ) od čtvrtiny hodnot (větších či stejných jako  $Q_3$ ) `[quantile(x,probs=3/4)]`
- ▶ **první decil** je číslo, které oddělí desetinu nejmenších hodnot od ostatních hodnot `[quantile(x,probs=1/10)]`
- ▶ **percentil**  $x_p$  je číslo, které oddělí  $100p$  % nejmenších hodnot od ostatních hodnot `[quantile(x,probs=p)]`
- ▶ několik percentilů současně `[quantile(x,probs=(0:4)/4)]`

## výpočet percentilu $x_p$ (fakultativně)

jedna z nejčastěji užívaných metod výpočtu percentilu, standardní v R

- k daným  $n, p$  se najde celé číslo  $k$  splňující

$$\frac{k-1}{n-1} \leq p < \frac{k}{n-1}$$

- tedy  $k = \lfloor 1 + (n-1) \cdot p \rfloor$

( $\lfloor x \rfloor$  znamená celou část z  $x$ , zaokrouhlí dolů)

- provede se lineární interpolace mezi  $x_{(k)}$  a  $x_{(k+1)}$   
( $\{x\}$  znamená zlomkovou část  $x$ , o kolik přesahuje celé číslo)

$$q = \{1 + (n-1) \cdot p\} = (1 + (n-1) \cdot p) - k$$

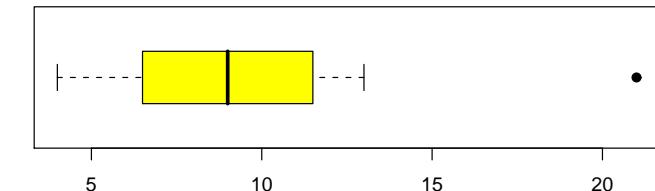
$$x_p = (1-q) \cdot x_{(k)} + q \cdot x_{(k+1)}$$

- např. pro  $n = 99, p = 0,25$  bude

$$k = \lfloor 1 + (99-1) \cdot 0,25 \rfloor = \lfloor 25,5 \rfloor = 25, \quad q = 25,5 - 25 = 0,5$$

$$Q_1 = x_{0,25} = (1 - 0,5) \cdot x_{(25)} + 0,5 \cdot x_{(26)}$$

## krabicový diagram



[boxplot(c(4,5,8,9,10,13,21),horizontal=TRUE,col=7,pch=16)]

znázorěna řada statistik pro data: 4, 5, 8, 9, 10, 13, 21

- medián ( $\tilde{x} = 9$ ) – příčka obdélníka
- kvartily ( $Q_1 = 6,5, Q_3 = 11,5$ ) – kratší strany obdélníka
- tykadla od kvartilu k minimu (maximu), pokud není odlehlé
- odlehlé pozorování – je dál, než  $3/2 \cdot (Q_3 - Q_1)$  (= 7,5) od blížšího kvartilu

## vlastnosti míry polohy

- přičteme-li ke každé hodnotě  $x$  stejnou konstantu  $a$ , musíme tutož konstantu  $a$  přičíst k průměru (mediánu, kvartilu, ...)
- vynásobíme-li každou hodnotu  $x$  stejnou kladnou konstantou  $b$ , musíme průměr (medián, kvartil, ...) vynásobit toutéž konstantou  $b$
- pro dobrou míru polohy  $\mu(X)$  platí:

$$\mu(a + X) = a + \mu(X)$$

$$\mu(b \cdot X) = b \cdot \mu(X) \quad (b > 0)$$

- dobrá míra polohy je citlivá vůči posunutí (pozná změnu úrovně) i vůči změně měřítka (např. přechod od g ke kg)

## míry variability

- míra variability  $\sigma(x)$  číselně charakterizuje jinou vlastnost, než míry polohy, proto na poloze **nesmí záviset**
- ukazuje nakolik jsou zjištěné hodnoty nestejně, velikost jejich kolísání, jejich **variabilitu**
- pro dobrou míru variability  $\sigma(X)$  platí:

$$\sigma(a + X) = \sigma(X) \quad \text{rozdíl proti míře polohy!!!}$$

$$\sigma(b \cdot X) = b \cdot \sigma(X) \quad b > 0$$

- přičtení konstanty  $a$  míru variability nezmění, na vynásobení kladnou konstantou  $b$  reaguje

## směrodatná odchylka, rozptyl

[standard deviation, variance]

► **rozptyl** (variance)  $s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

$$s_{b,x}^2 = b^2 s_x^2$$

[var(x)]

- např. pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme  $\bar{x} = 10$ , tedy

$$s_x^2 = \frac{1}{7-1} ((4-10)^2 + (5-10)^2 + \dots + (21-10)^2) = \frac{196}{6}$$

► **směrodatná odchylka**

$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

[sd(x)]

## další míry variability

- **rozpětí**  $R = x_{\max} - x_{\min}$  [range]
- **(mezi)kvartilové rozpětí**  $R_Q = Q_3 - Q_1$  [interquartile range]
- **variační koeficient** (nesplňuje ani jeden požadavek) slouží k porovnání variability při různých úrovních [coefficient of variation]

$$V_x = \frac{s_x}{\bar{x}}$$

- **entropie** (pro nominální, požadavky nemají smysl, nezávisí na označení hodnot, jen na jejich relativních četnostech) [entropy]

$$H = - \sum_{j=1}^m \frac{n_j}{n} \ln \frac{n_j}{n}$$

## příklad ICHS: vztah mužů ke kouření

vzděl.	vztah ke kouření				celk.	$H$
	nekuřák/bývalý	střední	silný			
zákl.	25	21,4 %	14	12,0 %	78	66,7 %
zákl.	117	0,854				
odb.	83	28,0 %	24	8,1 %	189	63,9 %
odb.	296	0,847				
stř.	99	33,2 %	24	8,1 %	175	58,7 %
stř.	298	0,882				
VŠ	115	48,3 %	17	7,1 %	106	44,5 %
VŠ	238	0,900				

muži se základním vzděláním:

$$H = - \left( \frac{25}{117} \ln \frac{25}{117} + \frac{14}{117} \ln \frac{14}{117} + \frac{78}{117} \ln \frac{78}{117} \right) = 0,854123$$

větší vyrovnanost  $\Rightarrow$  větší entropiemaximum pro  $n_1 = n_2 = n_3 = n_4$  vyjde  $H = \ln(4) = 1,386294$ 

## z-skóry

- **z-skóry** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}, \quad i = 1, 2, \dots, n$$

- $[(x-\text{mean}(x))/\text{sd}(x)]$  nebo [scale(x)]
- hodnoty  $z_1, z_2, \dots, z_n$  „ztratily“ informaci o poloze a variabilitě, vždy platí  $\bar{z} = 0$ ,  $s_z = 1$
- přičtení konstanty ani násobení konstantou z-skóry nezmění
- hodnocení vlastností nezávislých na poloze a variabilitě
- pro data: 4, 5, 8, 9, 10, 13, 21 platí  $\bar{x} = 10$ ,  $s_x = 5,715$
- proto dostaneme

$$z_1 = \frac{4 - 10}{5,715} = -1,050, \dots, z_7 = \frac{21 - 10}{5,715} = 1,925$$

## šikmost, špičatost

### ► šikmost (průměr 3. mocnin z-skórů)

$$g_1 = \frac{1}{n} \sum_{i=1}^n z_i^3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^3 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{s_x^3}$$

[mean(((x-mean(x))/sd(x))^3)]

### ► špičatost (průměr 4. mocnin z-skórů zmenšený o 3)

$$g_2 = \frac{1}{n} \sum_{i=1}^n z_i^4 - 3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^4 - 3$$

[mean(((x-mean(x))/sd(x))^4)-3]

- $g_1, g_2$  se používají k posouzení normality
- pro data: 4, 5, 8, 9, 10, 13, 21 dostaneme

$$g_1 = 0,771 \quad g_2 = -0,770$$

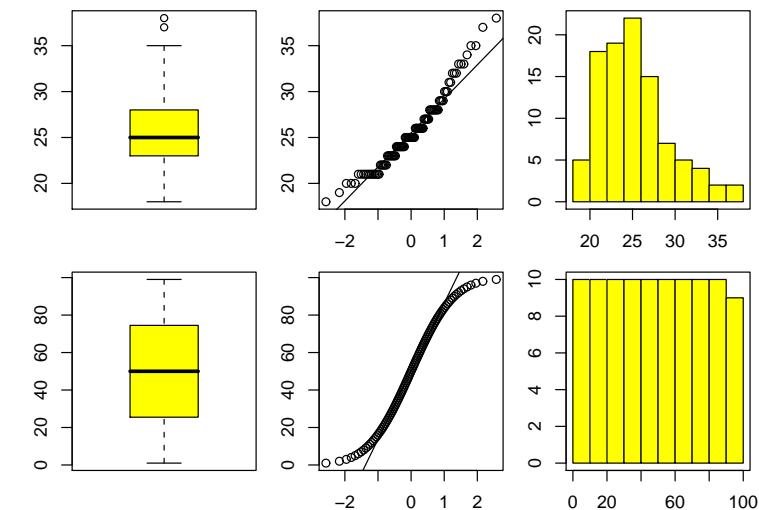
## normální diagram

[(normal) probability plot], [quantile-comparison plot]

- k ověřování předpokladu **normálního** rozdělení
- porovnává skutečnou variační řadu s ideální variační řadou normálního (Gaussova) rozdělení  $N(0, 1)$
- v ideálním případě body téměř na přímce
- systematická odchylka ukazuje na rozdělení, které není normální
- konvexní či konkávní průběh – nesymetrie (nenulová šikmost)
- esovitý průběh – nenulová špičatost
- [qqnorm(x)]
- přímku vloží [qqline(x)]
- některé programy mají zaměněny osy (Statistica)

## příklad: věk matky, čísla 1 až 99

věk matek:  $g_1 = 0,741, \quad g_2 = 0,220$  čísla 1 až 99:  $g_1 = 0, \quad g_2 = -1,236$



## závislost dvojice znaků

- možnost zkoumání závislosti dvou znaků
- způsob znázornění (prokazování) závisí na měřítcích znaků
- **kvantitativní – kvantitativní**  
rozptylový (bodový) diagram  
korelace, regrese
- **kvantitativní - kvalitativní**  
krabicevý diagram  
 $t$ -test, ANOVA
- **kvalitativní - kvalitativní**  
kontingenční tabulka  
chi-kvadrát test, Fisherův exaktní test

[scatter plot]

[correlation, regression]

[box-plot]

[contingency table]

## kvantitativní – kvantitativní

- pokud záleží na směru závislosti, pak vysvětlovanou (**závisle proměnnou**) veličinu umístíme na svislou osu  $y$
- korelační koeficient** vyjadřuje sílu a směr **vzájemné** závislosti

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}, \quad \text{kde } s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- [ $\text{cor}(x,y)$ ] [correlation coefficient]
- $s_{xy}$  – výběrová **kovariance** [covariance]
- pomocí z-skóru ( $\Rightarrow$  nezávislost na poloze a měřítku)

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right) \left( \frac{y_i - \bar{y}}{s_y} \right)$$

- pro  $r_{xy} > 0$  s rostoucím  $x$  v průměru roste  $y$
- pro  $r_{xy} < 0$  s rostoucím  $x$  v průměru klesá  $y$
- nezávislosti odpovídají hodnoty  $r_{xy}$  blízké nule

$$-1 \leq r_{xy} \leq 1$$

## příklad: kouření u mužů

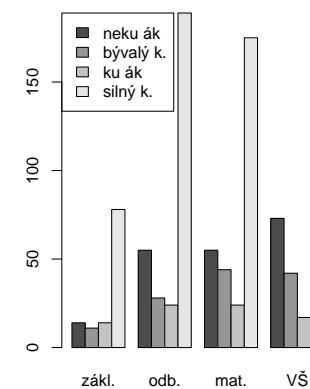
data: lchs

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	14	55	55	73	197
bývalý k.	11	28	44	42	125
kuřák	14	24	24	17	79
silný k.	78	189	175	106	548
celkem	117	296	298	238	949

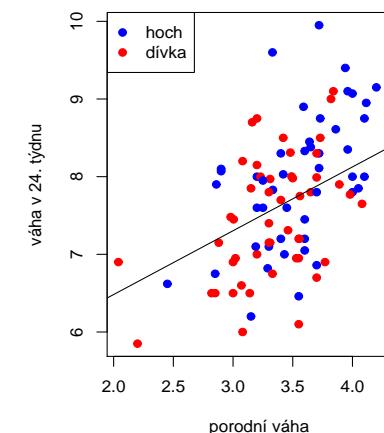
v grafu znázorneny **absolutní** četnosti

(sdružené, marginální četnosti)

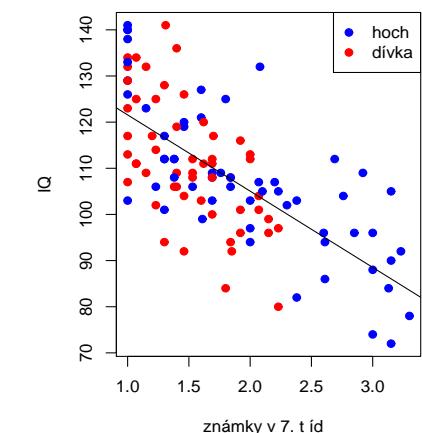
[barplot(t,beside=TRUE)]



## kvantitativní – kvantitativní, příklady

vlevo – závislost váhy v 24. týdnu na porodní váze s rozlišením pohlaví (data: Kojení)  
vpravo – závislost IQ na průměrné známce v 7. třídě (data: lq3)

$$r = 0,429$$



$$r = -0,689$$

## kvalitativní – kvalitativní

### kontingenční tabulka

obsahuje přehledně zapsané úplné údaje

► **sdružené** četnosti jednotlivých kombinací hodnot dvou znaků

### marginální četnosti:

- **řádkové** marginální četnosti: součty sdružených četností v jednotlivých řádcích (pro jednotlivé hodnoty řádkového znaku)

- **sloupcové** marginální četnosti: součty sdružených četností v jednotlivých sloupcích (pro jednotlivé hodnoty sloupcového znaku)

### [table(F,G)] nebo [xtabs(~ F + G)]

resp. [xtabs(~ F + G, data=DataFrame)]

kde F a G jsou v R faktory, DataFrame je databáze

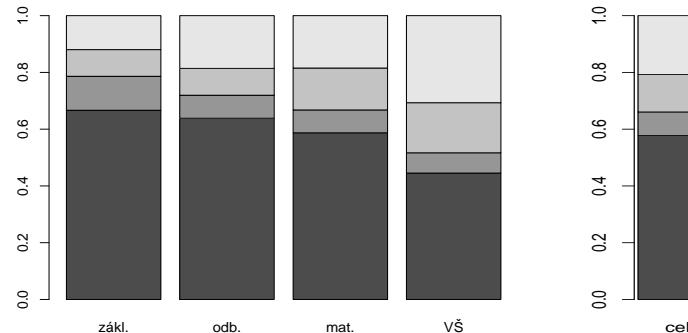
[contingency table]

## příklad: kouření u mužů

podmíněné relativní četnosti

marginální relativní četnosti

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	12,0 %	18,6 %	18,5 %	30,7 %	20,8 %
bývalý k.	9,4 %	9,5 %	14,8 %	17,6 %	13,2 %
kuřák	12,0 %	8,1 %	8,1 %	7,1 %	8,3 %
silný k.	66,7 %	63,9 %	58,7 %	44,5 %	57,7 %
celkem	100 %	100 %	100 %	100 %	100 %



## relativní četnosti v kontingenční tabulce

▶ **řádková procenta** (relativní četnosti v daném řádku)

- ▶ podíl jednotlivých hodnot sloupcového znaku pro danou hodnotu řádkového znaku

- ▶ **podmíněné rozdelení** hodnot sloupcového znaku pro danou hodnotu řádkového znaku

▶ **sloupcová procenta** (relativní četnosti v daném sloupci)

- ▶ podíl jednotlivých hodnot řádkového znaku pro danou hodnotu sloupcového znaku

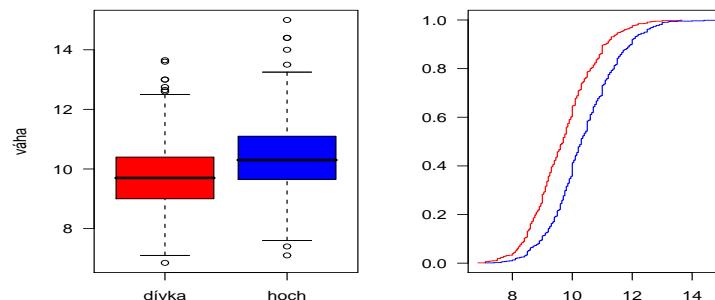
- ▶ **podmíněné rozdelení** hodnot řádkového znaku pro danou hodnotu sloupcového znaku

▶ **nezávislosti** obou znaků odpovídá situace, kdy jsou např. sloupcová procenta pro všechny hodnoty sloupcového znaku podobné; podobně pro řádková procenta

## kvantitativní – kvalitatívni

váha v jednom roce podle pohlaví, data: Deti1633

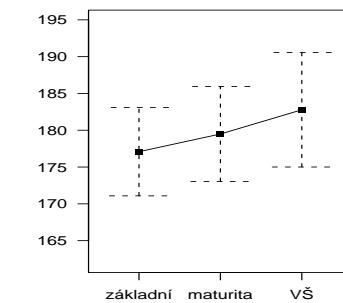
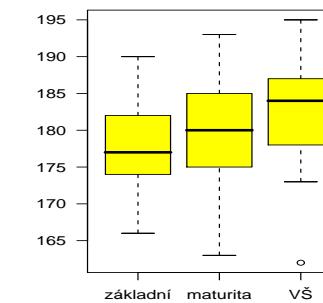
- ▶ lze chápat jako závislost spojité veličiny na kvalitativní
- ▶ srovnání souborů dat (spojitá veličina)
- ▶ krabicové diagramy resp. empirické distribuční funkce
- ▶ příklad: hmotnost chlapců a dívek v jednom roce
- ▶ **nezávislosti** odpovídá podobné umístění krabic resp. empirických distribučních funkcí



## příklad: závislost výšky otce na vzdělání matky

data: Kojení

- ▶ porovnáme výšky otců ve skupinách podle vzdělání matky
- ▶ napravo znázorníme průměry a směrodatné odchylky
- ▶ intervaly kolem průměru mívají i jinou interpretaci (jsou jiné)

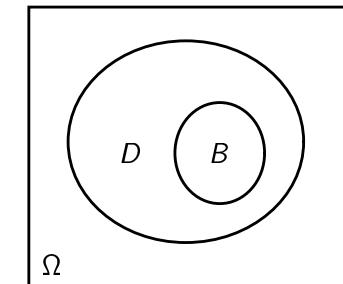


## Náhodné jevy

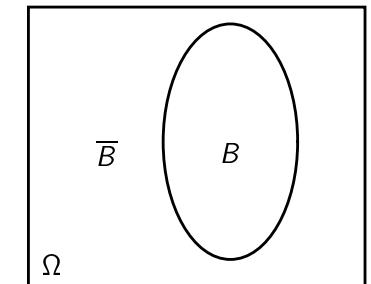
- ▶ **náhodný pokus** výsledek předem neurčitý
- ▶ předpokládá se **stabilita relativních četností** možných výsledků, která s nezávislými opakováními pokusu roste
- ▶ **náhodný jev** tvrzení o výsledku náhodného pokusu (podmnožina množiny  $\Omega$ )
- ▶ **jistý jev**  $\Omega$  nastává vždy
- ▶ **nemožný jev**  $\emptyset$  nenastává nikdy
- ▶ **podjev**:  $B \subset D$  znamená  $B \Rightarrow D$
- ▶ **jev opačný**:  $\bar{D} \Leftrightarrow$  neplatí  $D$
- ▶ **průnik jevů**  $B \cap D$  nastaly oba jevy
- ▶ **sjednocení jevů**  $D \cup B$  nastal **aspoň** jeden
- ▶ **neslučitelné jevy**  $B \cap D = \emptyset$

## znázornění pomocí Vennova diagramu celý obdélník – jev jistý

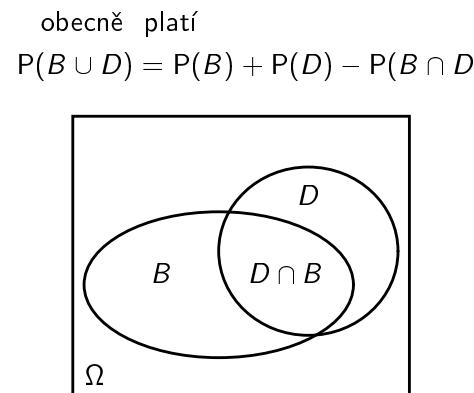
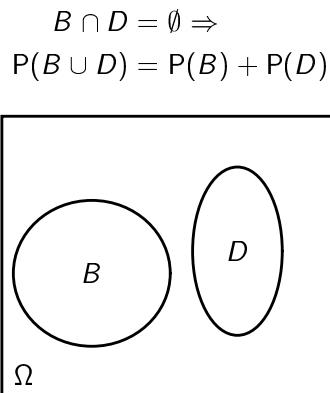
$$B \subset D \Rightarrow P(B) \leq P(D)$$



$$P(\bar{B}) = 1 - P(B)$$



velikost plochy odpovídá pravděpodobnosti



velikost plochy odpovídá pravděpodobnosti

## pravděpodobnost

- ▶ objektivní číselné vyjádření „naděje“, že nastane jev  $B$
- ▶ modelový protějšek relativní četnosti
- ▶ pravděpodobnost (pst) by měla mít stejné vlastnosti jako relativní četnost:
  - ▶  $0 \leq P(B) \leq 1$
  - ▶  $P(\Omega) = 1, P(\emptyset) = 0$
  - ▶  $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$   
**(sčítání pravděpodobností)**
  - ▶  $P(B \cup D) = P(B) + P(D) - P(B \cap D)$
  - ▶  $B \subset D \Rightarrow P(B) \leq P(D)$
  - ▶  $P(\bar{B}) = 1 - P(B)$

## klasická definice pravděpodobnosti

### ► klasická definice pravděpodobnosti

- $m$  stejně pravděpodobných elementárních jevů  $\omega_1, \dots, \omega_m$
- jsou neslučitelné, sjednocení všech je jistý jev
- $m_B$  elementárních jevů **příznivých jevu  $B$**   
(tj. takových  $\omega_i$ , že  $\omega_i \in B$ , je právě  $m_B$ )

$$P(B) = \frac{m_B}{m}$$

### ► příklad

- hází se dvěma kostkami (modrá, zelená)
- $B$  – součet aspoň 10

$$m = 6 \cdot 6 = 36; \quad m_B = 6 \quad \Rightarrow \quad P(B) = \frac{6}{36}$$

příznivé možnosti: (6,4), (6,5), (6,6), (5,5), (5,6), (4,6)

## kombinační číslo

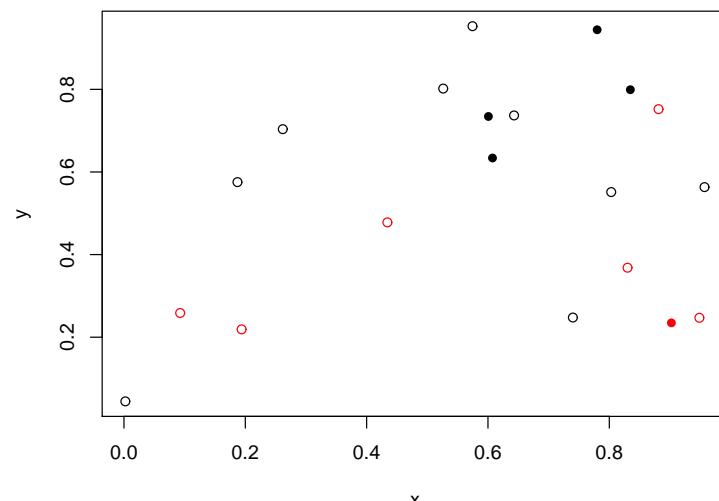
- $\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1)\cdots(n-k+1)}{k(k-1)\cdots 1}$
- kolika způsoby lze z  $n$  rozlišitelných objektů vybrat nějakých  $k$  objektů *bez ohledu na pořadí*
- kolika způsoby lze z 5 studentů vybrat trojici na přezkoušení?

$$\binom{5}{3} = \frac{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}{(3 \cdot 2 \cdot 1) \cdot (2 \cdot 1)} = \frac{5 \cdot 4 \cdot 3}{3 \cdot 2 \cdot 1} = \frac{5 \cdot 4}{2 \cdot 1} = 10$$

- v čitateli je počet možností, kolika způsoby lze postupně (s ohledem na pořadí!) uspořádat všech 5 studentů
- ve jmenovateli je součin dvou činitelů
- první udává kolikrát lze uspořádat tři vybrané studenty
- druhý udává kolikrát lze uspořádat dva nevybrané studenty
- každá trojice vybraných studentů se kombinuje s každou dvojkou studentů nevybraných

## Počítání ryb v rybníku

$$(m = 20), a = 7, n = 5, Y = 1 \Rightarrow \hat{m} = n \cdot a / Y = 35$$



## hypergeometrické rozdělení

### příklad na klasickou pravděpodobnost

- v rybníku je  $m$  ryb (zpravidla neznámý počet) a ryb vylovíme, označíme a vypustíme zpět
- po nějaké době vylovíme  $n$  ryb, z nich  $Y$  je označených
- číslo  $Y$  předem neznáme, je to **náhodná veličina**
- s jakou pravděpodobností je  $Y = k$ ?
  - celkem  $\binom{m}{n}$  možných  $n$ -tic vylovených ryb
  - $k$  označených lze vybrat  $\binom{a}{k}$  způsoby
  - $n - k$  neoznačených lze vybrat  $\binom{m-a}{n-k}$  způsoby

$$P(Y = k) = \frac{\binom{a}{k} \binom{m-a}{n-k}}{\binom{m}{n}}, \quad \max(0, n+a-m) \leq k \leq \min(a, n)$$

- např. odhad neznámého  $m$ :  $\hat{m} = \frac{n \cdot a}{Y}$  (neboť  $Y/n \doteq a/m$ )

## příklad ponožky

V noci vzbudili Kubu, že má jít hlídat tábor. Po tmě z pytlíku vytáhl dvě ponožky, aniž ověřil jejich barvu. Původně tam byly tři páry ponožek ze stejného materiálu: zelené, modré, šedivé.

Náhodné jevy a veličiny:

- ▶ A obě ponožky jsou stejné barvy
- ▶ B aspoň jedna obutá ponožka je zelená
- ▶ C aspoň jedna obutá ponožka je modrá
- ▶ D na pravé noze je zelená ponožka
- ▶ X počet obutých šedivých ponožek
- ▶ Y počet obutých modrých ponožek

## příklad ponožky – výpočet pravděpodobností jevů

označení (z,m) znamená barvu postupně na levé a na pravé noze

možnosti vytáhnou dvojici ponožek:  $m = 6 \cdot 5 = 30$

možnosti vytáhnout dvě zelené:  $m_{z,z} = 2 \cdot 1 = 2$

možnosti vytáhnout zelenou a modrou:  $m_{z,m} = 2 \cdot 2 = 4$

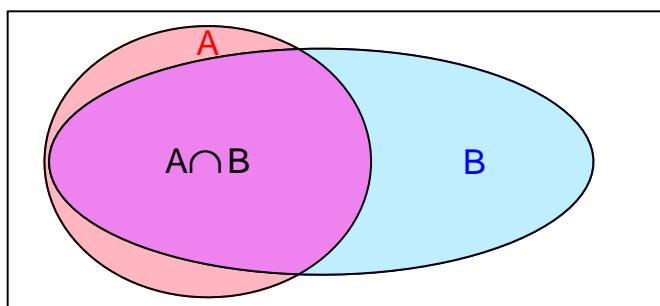
$\omega_i$	$P(\omega_i)$	A	B	C	D	$B \cap C$	$B \cup C$	Y	X
(z,z)	1/15	•	•		•		•	0	0
(z,m)	2/15		•	•		•	•	1	0
(z,š)	2/15		•				•	0	1
(m,z)	2/15		•	•	•	•	•	1	0
(m,m)	1/15	•		•			•	2	0
(m,š)	2/15			•			•	1	1
(š,z)	2/15		•		•		•	0	1
(š,m)	2/15			•			•	1	1
(š,š)	1/15	•					0	2	
pravděpodobnost		3/15	9/15	9/15	5/15	4/15	14/15		

$$P(B) + P(C) - P(B \cap C) = \frac{9}{15} + \frac{9}{15} - \frac{4}{15} = \frac{14}{15} = P(B \cup C)$$

## podmíněná pravděpodobnost

Vennův diagram: když víme, že nastalo A (je to jisté,  $P(A)$  za podmínky A je rovna 1), pak podmíněná pst jevu B za podmínky A bude rovna relativní velikosti  $B \cap A$  vzhledem k velikosti A

$$P(B|A) = \frac{P(A \cap B)}{P(A)}$$



## příklad ponožky: s jakou pstí se Kuba obul rozumně?

- ▶ bez další informace:  $P(A) = \frac{3}{15} = \frac{1}{5}$

▶ spolu bydlící ve stanu Aleš se v noci vzbudil a v pytlíku viděl páru zelených ponožek

$$P(A|\bar{B}) = \frac{P(A \cap \bar{B})}{P(\bar{B})} = \frac{2/15}{6/15} = \frac{1}{3} > \frac{1}{5} = P(A)$$

- ▶ v pytlíku chyběla aspoň jedna modrá nebo aspoň jedna zelená

$$P(A|(B \cup C)) = \frac{P(A \cap (B \cup C))}{P(B \cup C)} = \frac{2/15}{14/15} = \frac{1}{7} < \frac{1}{5} = P(A)$$

- ▶ na pravé noze má Kuba zelenou

$$P(A|D) = \frac{P(A \cap D)}{P(D)} = \frac{1/15}{5/15} = \frac{1}{5} = \frac{1}{5} = P(A)$$

## nezávislost náhodných jevů

informace, že na pravé noze je zelená ponožka (jev  $D$ ) neovlivnila pravděpodobnost jevu  $A$  (stejná barva ponožek)  
jevy  $A$  a  $D$  jsou **nezávislé**

$$P(A|D) = \frac{P(A \cap D)}{P(D)} = P(A)$$

a tedy po odstranění zlomku v druhé rovnosti

$$P(A \cap D) = P(A) \cdot P(D)$$

definuje **nezávislost** náhodných jevů  $A$  a  $D$   
(informace o výskytu  $D$  neovlivnila pravděpodobnost jevu  $A$ )  
vlastnost symetrická, nezávisí na pořadí

## vlastnosti podmíněné pravděpodobnosti

- ▶ pravděpodobnost jevu  $D$  za podmínky jevu  $C$

$$P(D|C) = \frac{m_{D \cap C}}{m_C} = \frac{m_{D \cap C}/m}{m_C/m} = \frac{P(D \cap C)}{P(C)}$$

- ▶ pravděpodobnost průniku jevů  $D, C$  obecně

$$P(D \cap C) = P(D|C)P(C)$$

$$P(C \cap D) = P(C|D)P(D)$$

- ▶ ale  $D \cap C = D \cap C$ , proto  $P(C \cap D) = P(D \cap C)$

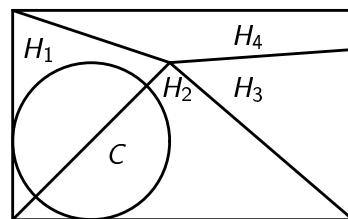
- ▶ odtud shoda pravých stran  $P(D|C)P(C) = P(C|D)P(D)$

- ▶ vyděl  $P(C) \Rightarrow$  **Bayesův vzorec:**

$$P(D|C) = \frac{P(C|D)P(D)}{P(C)}$$

## vzorec pro úplnou pst, Bayesův vzorec

počítáme  $P(H_i|C)$ , např.  $C$  – správná odpověď,  $H_j$  – správná známka  $j$



$$\begin{aligned} P(H_1) &= 0,231 \\ P(H_2) &= 0,375 \\ P(H_3) &= 0,219 \\ P(H_4) &= 0,175 \\ P(C|H_1) &= 0,589 \\ P(C|H_2) &= 0,362 \quad (\text{proč je } P(C|H_2) < P(C|H_1)?) \end{aligned}$$

$$P(C \cap H_1) = P(C|H_1)P(H_1), \quad P(C \cap H_2) = P(C|H_2)P(H_2)$$

$$P(C) = P(C \cap H_1) + P(C \cap H_2) = 0,136 + 0,136 = 0,272$$

$$P(H_1 \cap C) = P(H_1|C)P(C)$$

$$P(H_1|C) = \frac{P(H_1 \cap C)}{P(C)} = \frac{P(C|H_1)P(H_1)}{P(C|H_1)P(H_1) + P(C|H_2)P(H_2)} = \frac{1}{2}$$

## obecný vzorec pro úplnou pravděpodobnost

(totéž, ale obecně)

- ▶  $H_1, \dots, H_k$  neslučitelné (tj.  $H_i \cap H_j = \emptyset$  pro  $i \neq j$ )
- ▶ sjednocení  $H_1, \dots, H_k$  dá jev jistý (tj.  $H_1 \cup \dots \cup H_k = \Omega$ )

z definice podmíněné pstí plyne  $P(C \cap H_j) = P(C|H_j) \cdot P(H_j)$

$$\begin{aligned} P(C) &= P(C \cap \Omega) = P(C \cap (H_1 \cup H_2 \cup \dots \cup H_k)) \\ &= P((C \cap H_1) \cup (C \cap H_2) \cup \dots \cup (C \cap H_k)) \quad (\text{neslučitelné jevy}) \\ &= P(C \cap H_1) + P(C \cap H_2) + \dots + P(C \cap H_k) \\ &= P(C|H_1)P(H_1) + P(C|H_2)P(H_2) + \dots + P(C|H_k)P(H_k) \end{aligned}$$

tedy obecně 
$$P(C) = \sum_{j=1}^k P(C|H_j)P(H_j)$$

$P(C)$  je **váženým průměrem** podmíněných pstí  $P(C|H_j)$

## Bayesův vzorec [Bayes formula]

stejné předpoklady:  $H_i$  neslučitelné, sjednocení všech jistý jev

$$P(H_i|C) = \frac{P(H_i \cap C)}{P(C)}, \quad P(C|H_i) = \frac{P(C \cap H_i)}{P(H_i)}$$

odtud je pro libovolně zvolené  $i$

$$P(H_i \cap C) = P(C \cap H_i) = P(C|H_i) P(H_i)$$

proto pro každé  $i$ ,  $i = 1, \dots, k$  platí

$$P(H_i|C) = \frac{P(H_i \cap C)}{P(C)} = \frac{P(C|H_i) P(H_i)}{P(C)} = \frac{P(C|H_i) P(H_i)}{\sum_{j=1}^k P(C|H_j) P(H_j)}$$

$H_1, \dots, H_k$  – **hypotézy**,  $P(H_1|C), \dots, P(H_k|C)$  – **aposteriorní** psti  
 $P(H_1), \dots, P(H_k)$  – **apriorní** psti (nutně  $P(H_1) + \dots + P(H_k) = 1$ )

## příklad: zkoušení

$H_j$  – student si zaslouží známku  $j$ , učitel studenta (tedy  $j$ ) nezná

$C$  – student správně odpoví na položenou otázku

$P(H_j)$  – apriorní představa učitele o neznámém studentovi

$P(C|H_j)$  – obtížnost otázky, volí učitel

$H_j$	$P(H_j)$	$P(C H_j)$	$P(C H_j) P(H_j)$	$P(H_j C)$	$P(H_j C_2)$	$P(H_j C_3)$
1	0,20	1,00	0,2000	0,2694	0,3451	0,4230
2	0,35	0,80	0,2800	0,3771	0,3865	0,3790
3	0,25	0,65	0,1625	0,2189	0,1822	0,1452
4	0,20	0,50	0,1000	0,1347	0,0863	0,0529
$\Sigma$	1,00		0,7425	1,0000	1,0000	1,0000

$$P(C) = 0,7425$$

podobně  $C_2, C_3$  správné odpovědi na další stejně obtížné otázky,  
když použijeme předchozí aposteriorní psti jako apriorní

## senzitivita, specificita, prevalence

- ▶  $D$  – subjekt je nemocen, **prevalence** – podíl nemocných v populaci  $P(D)$ , zvolme  $P(D) = 0,001$
- ▶ nemoc je skrytá, vyhledáváme ji pomocí testu s vlastnostmi:
  - ▶  $P(T|D)$  – pravděpodobnost pozitivního výsledku u nemocného (**senzitivita**, pokud možno velká, zvolme  $P(T|D) = 0,98$ , na test pozitivně reaguje 98 % nemocných)
  - ▶  $P(\bar{T}|\bar{D})$  – pravděpodobnost negativního výsledku u zdravého (**specificita**, pokud možno velká, zvolme  $P(\bar{T}|\bar{D}) = 0,99$ , na test pozitivně reaguje jen  $P(T|\bar{D}) = 1 - P(\bar{T}|\bar{D}) = 1\%$  zdravých)

## senzitivita, specificita, prevalence

- ▶ jaká je pst, že pozitivně reagující je opravdu nemocný?

$$\begin{aligned} P(D|T) &= \frac{P(T|D) P(D)}{P(T|D) P(D) + P(\bar{T}|\bar{D}) P(\bar{D})} \\ &= \frac{0,98 \cdot 0,001}{0,98 \cdot 0,001 + 0,01 \cdot 0,999} \doteq 0,089 \end{aligned}$$

- ▶ jaká je pst, že jde o zdravého člověka v případě, že test byl negativní?

$$\begin{aligned} P(\bar{D}|\bar{T}) &= \frac{P(\bar{T}|\bar{D}) P(\bar{D})}{P(\bar{T}|\bar{D}) P(\bar{D}) + P(\bar{T}|D) P(D)} \\ &= \frac{0,99 \cdot 0,999}{0,99 \cdot 0,999 + 0,02 \cdot 0,001} = 0,99998 \end{aligned}$$

- ▶ porovnej s apriorními pstmi: 0,001 resp. 0,999

## náhodná veličina

[random variable]

- ▶ číselně vyjádřený výsledek náhodného pokusu
- ▶ předem nevíme, který výsledek vyjde, známe jen
  - ▶ možné hodnoty
  - ▶ jejich pravděpodobnosti
- ▶ každému elementárnímu jevu přiřadíme reálné číslo
- ▶ **diskrétní rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro počty případů (četnosti)
  - ▶ možné hodnoty  $x_1^*, x_2^*, \dots$
  - ▶ pstí hodnot  $P(X = x_1^*), P(X = x_2^*), \dots$  (pstní funkce)
- ▶ **spojité rozdělení** náhodné veličiny  $X$ 
  - ▶ model pro spojitou veličinu (délka, váha, koncentrace ...)
  - ▶ obor (množina) možných hodnot  $X$
  - ▶ hustota  $f(x)$

## příklad: ponožky

 **$X$  a  $Y$  mají stejné rozdělení**

- náhodná veličina  $Y$  – počet modrých ponožek  
 rozdělení  $Y$  dáno hodnotami  $y_j^*$  a pstmi těchto hodnot  $P(Y = y_j^*)$   
 náhodná veličina  $X$  – počet šedivých ponožek  
 rozdělení  $X$  dáno hodnotami  $x_j^*$  a pstmi těchto hodnot  $P(X = x_j^*)$

$\omega_i$	$P(\omega_i)$	$Y$	$X$
(z,z)	1/15	0	0
(z,m)	2/15	1	0
(z,š)	2/15	0	1
(m,z)	2/15	1	0
(m,m)	1/15	2	0
(m,š)	2/15	1	1
(š,z)	2/15	0	1
(š,m)	2/15	1	1
(š,š)	1/15	0	2

$j$	$x_j^*$	$P(X = x_j^*)$
1	0	2/15+4/15=6/15
2	1	0/15+8/15=8/15
3	2	1/15+0/15=1/15

$j$	$y_j^*$	$P(Y = y_j^*)$
1	0	2/15+4/15=6/15
2	1	0/15+8/15=8/15
3	2	1/15+0/15=1/15

▶ Střední hodnota

## distribuční funkce

protějšek empirické distribuční funkce (str. 19), [(cumulative) distribution function]

- ▶ pst, že  $X$  nepřekročí  $x$  
$$F_X(x) = P(X \leq x)$$
- ▶ diskrétní rozdělení: 
$$F(x) = \sum_{k \leq x} P(X = k)$$
- ▶ spojité rozdělení:  $F(x) = \int_{-\infty}^x f(t)dt$ , kde  $f(x) = \frac{dF(x)}{dx}$
- ▶ vlastnosti distribuční funkce

$$0 \leq F(x) \leq 1$$

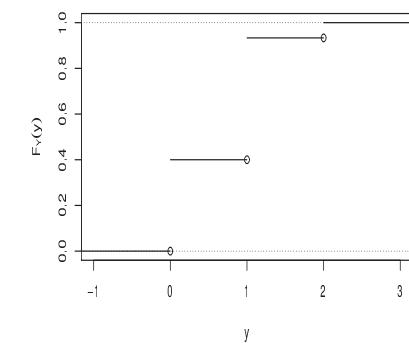
neklesající:  $x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$ 

$$P(x_1 < X \leq x_2) = F(x_2) - F(x_1)$$

## příklad diskrétního rozdělení

rozdělení počtu modrých ponožek  $Y$ 

$j$	$y_j^*$	$P(Y = y_j^*)$	$F_Y(y_j^*)$
1	0	6/15	6/15=0,400
2	1	8/15	14/15=0,933
3	2	1/15	15/15=1,000



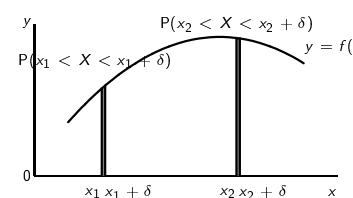
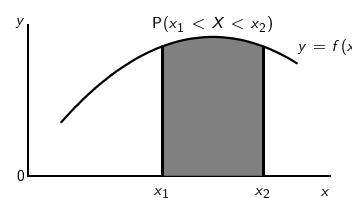
## hustota spojitého rozdělení

[density function]

- nechť  $f(x)$  je hustota náhodné veličiny  $X$
- hustota je nezáporná, plocha pod celou hustotou je rovna jedné

$$f(x) \geq 0, \quad \int_{-\infty}^{\infty} f(x)dx = 1$$

- plocha pod hustotou nad intervalom  $x_1, x_2$  je rovna pravděpodobnosti, že  $X$  je mezi  $x_1, x_2$



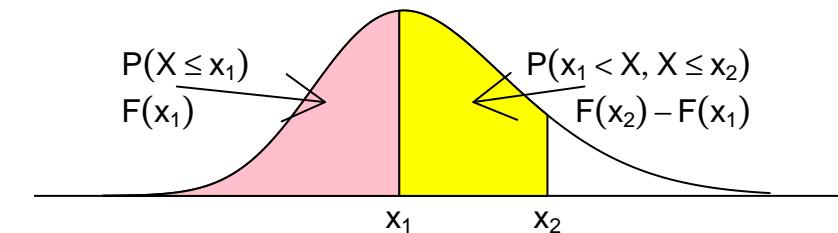
## geometrický význam hustoty

$P(x_1 < X, X \leq x_2) = P(x_1 < X \leq x_2)$ , vpravo stručnější, používaný zápis

$$\begin{aligned} F(x_2) &= P(X \leq x_2) = P(X \leq x_1) + P(x_1 < X \leq x_2) \\ &= F(x_1) + P(x_1 < X \leq x_2) \end{aligned}$$

odtud

$$P(x_1 < X \leq x_2) = F(x_2) - F(x_1) = \int_{x_1}^{x_2} f_X(x) dx$$

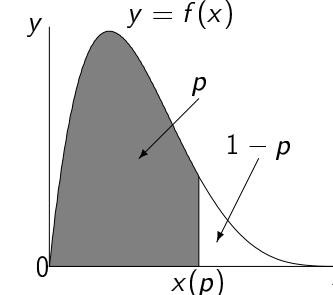
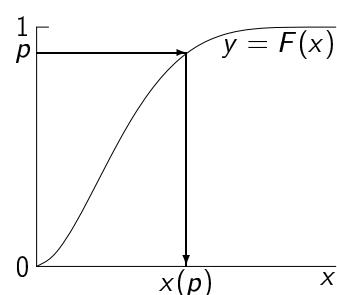


## p-kvantil $x(p)$

- $x(p)$  je hodnota, pod kterou je  $100p$  procent pravděpodobnosti

$$P(X \leq x(p)) = p$$

- populační protějšek percentilu
- např. [qnorm(0.975)] dá 1,959964  $\doteq 1,96$



## střední hodnota

pokračujeme v idealizovaných představách

- míra polohy, očekávaná hodnota [expected value, mean value]
- metoda výpočtu se značí  $E X$
- vypočtená hodnota se značí  $\mu$  nebo úplněji  $\mu_X$
- **vážený průměr možných hodnot**
- ideální protějšek výběrového průměru
- diskrétní rozdělení: vahami jsou pravděpodobnosti

$$\mu_X = E X = \sum_j x_j^* P(X = x_j^*)$$

- spojité rozdělení: místo vah je hustota  $f_X(x)$

$$\mu_X = E X = \int_{-\infty}^{\infty} x f_X(x) dx$$

- praktická představa: průměr celé populace – **populační průměr**

## příklad ponožky

 $X$  – počet modrých ponožek

$j$	$x_j^*$	$P(X = x_j^*)$	$x_j^* \cdot P(X = x_j^*)$
1	0	6/15	0
2	1	8/15	8/15
3	2	1/15	2/15
součet		15/15	10/15

$$\mu_X = 0 \cdot \frac{6}{15} + 1 \cdot \frac{8}{15} + 2 \cdot \frac{1}{15} = \frac{10}{15} = \frac{2}{3}$$

▶ Náhodná veličina

(populační) rozptyl  $\sigma^2$ , (populační) směrodatná odchylka  $\sigma$   
[variance, standard deviation]

- ▶ míra variability, **populační rozptyl, popul. směr. odchylka**
- ▶ udává velikost kolísání (variabilitu) kolem střední hodnoty
- ▶ metoda výpočtu se značí  $\text{var } X$
- ▶ vypočtená hodnota  $\sigma^2$ , úplněji  $\sigma_X^2$
- ▶ lze vyjádřit pomocí střední hodnoty

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = E(X^2) - (\mu_X)^2$$

- ▶  $\sigma_X^2$  – ideální protějšek výběrového rozptylu
- ▶  $\sigma_X$  – ideální protějšek výběrové směrodatné odchylky
- ▶ diskrétní rozdělení

$$\sigma_X^2 = \text{var } X = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$$

- ▶ spojité rozdělení  $\sigma_X^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$

## příklad ponožky

 $X$  – počet šedivých ponožek,  $\mu_X = 2/3$ 

$j$	$x_j^*$	$P(X = x_j^*)$	$x_j^* - \mu_X$	$(x_j^* - \mu_X)^2$	$(x_j^* - \mu_X)^2 P(X = x_j^*)$
1	0	6/15	-2/3	4/9	24/135
2	1	8/15	1/3	1/9	8/135
3	2	1/15	4/3	16/9	16/135
$\sum$		15/15	???		48/135=16/45

$$\begin{aligned}\sigma_X^2 &= \sum_j (x_j^* - \mu_X)^2 p_j \\ &= (0 - 2/3)^2 \cdot 6/15 + (1 - 2/3)^2 \cdot 8/15 \\ &\quad + (2 - 2/3)^2 \cdot 1/15 = 16/45 \doteq 0,356 \\ \sigma_X &= \sqrt{16/45} \doteq 0,596\end{aligned}$$

## sdružené rozdělení

- ▶ abychom mohli popsat **závislost** náhodných veličin, zajímáme se o **společné** chování dvojice (trojice, ...) náhodných veličin, tedy chování **náhodného vektoru**
- ▶ příklad **ponožky**
  - ▶  $X$  – počet šedivých ponožek
  - ▶  $Y$  – počet modrých
  - ▶  $Z$  – počet jiných než šedivých ponožek
- ▶ zajímá nás rozdělení náhodného vektoru  $(X, Y)$
- ▶ proč nemá smysl vyšetřovat **vektor**  $(X, Z)$ ?
- ▶ (protože  $Z$  je určeno  $X$  jednoznačně:  $Z = 2 - X$ )

## příklad ponožky

$X$  šedivých ponožek,  $Y$  počet modrých ponožek

sdružené pravděpodobnosti, marginální pravděpodobnosti, podmíněné pravděpodobnosti  $Y$  při daném  $X = x$

$\omega_i$	$P(\omega_i)$	$Y$	$X$
(z,z)	1/15	0	0
(z,m)	2/15	1	0
(z,š)	2/15	0	1
(m,z)	2/15	1	0
(m,m)	1/15	2	0
(m,š)	2/15	1	1
(š,z)	2/15	0	1
(š,m)	2/15	1	1
(š,š)	1/15	0	2

$x_i^*$	$y_j^*$			celkem
	0	1	2	
0	1/15	4/15	1/15	6/15
1	4/15	4/15	0/15	8/15
2	1/15	0/15	0/15	1/15
	6/15	8/15	1/15	15/15

$x_i^*$	$y_j^*$			celkem
	0	1	2	
0	1/6	4/6	1/6	1
1	3/6	3/6	0/6	1
2	6/6	0	0	1

## kovariance

protějšek  $s_{xy}$  (str. 37), [covariance]

kovariance vyjadřuje vzájemnou závislost náhodných veličin:

$$\sigma_{X,Y} = E(X - \mu_X)(Y - \mu_Y)$$

$$\sigma_{X,Y} = \sum_i \sum_j (x_i^* - \mu_X)(y_j^* - \mu_Y) P(X = x_i^*, Y = y_j^*)$$

označení metody výpočtu:  $\text{cov}(X, Y)$

zřejmě platí  $\text{cov}(X, X) = \text{var } X$  tj.  $\sigma_{X,X} = \sigma_X^2$

náhodné veličiny jsou nezávislé právě tehdy, když jsou nezávislé všechny jevy  $A$  (tvrzení o  $X$ ) a  $B$  (tvrzení o  $Y$ ), tj. když platí

$$P(X = x_i^*, Y = y_j^*) = P(X = x_i^*) \cdot P(Y = y_j^*), \quad \forall (x_i^*, y_j^*)$$

(ze znalosti hodnoty jedné veličiny nic nevíme o druhé)

jou-li  $X, Y$  – nezávislé  $\Rightarrow \sigma_{X,Y} = 0$  (nikoliv obrácená implikace)

## sdružené, marginální a podmíněné rozdělení

sdružené rozdělení – popisuje společné chování  $X, Y$

$$P(X = x_i^*, Y = y_j^*) \text{ resp. } f_{X,Y}(x, y)$$

marginální rozdělení: chování jedné bez ohledu na hodnotu druhé

$$P(X = x_i^*) = \sum_j P(X = x_i^*, Y = y_j^*) \quad \forall x_i^*$$

$$P(Y = y_j^*) = \sum_i P(X = x_i^*, Y = y_j^*) \quad \forall y_j^*$$

podmíněné rozdělení: chování  $Y$  při dané hodnotě  $X$

$$P(Y = y_j^* | X = x_i^*) = \frac{P(X = x_i^*, Y = y_j^*)}{P(X = x_i^*)}$$

## shrnutí vlastností populačního průměru a rozptylu

srovnej s požadavky na míry polohy a míry variability

$$\mu_{\alpha+X} = \alpha + \mu_X,$$

$$\sigma_{\alpha+X}^2 = \sigma_X^2,$$

$$\sigma_{\alpha+X} = \sigma_X,$$

$$\mu_{\beta X} = \beta \cdot \mu_X,$$

$$\sigma_{\beta X}^2 = \beta^2 \cdot \sigma_X^2,$$

$$\sigma_{\beta X} = |\beta| \cdot \sigma_X,$$

pro součet náhodných veličin  $X + Y$  dále platí

$$\mu_{X+Y} = \mu_X + \mu_Y$$

$$\sigma_{X+Y}^2 = \sigma_X^2 + \sigma_Y^2 + 2\sigma_{XY}$$

obecně

$$\sigma_{X,Y} = 0$$

pro nezávislé  $X, Y$

$$\sigma_{X+Y}^2 = \sigma_X^2 + \sigma_Y^2$$

pro nezávislé  $X, Y$

$\mu_X, \sigma_X, \dots$  jsou konstanty, vyjadřují (charakterizují) polohu, variabilitu ... náhodné veličiny  $X$

## ukázka důkazu

$$\begin{aligned}
 \mu_{\alpha+\beta X} &= E(\alpha + \beta X) \\
 &= \sum_i (\alpha + \beta x_i^*) P(X = x_i^*) \\
 &= \sum_i \alpha P(X = x_i^*) + \sum_i \beta x_i^* P(X = x_i^*) \\
 &= \alpha \sum_i P(X = x_i^*) + \beta \sum_i x_i^* P(X = x_i^*) \\
 &= \alpha + \beta \cdot E X = \alpha + \beta \cdot \mu_X
 \end{aligned}$$

**normovaní** náhodné veličiny  $X$  (populační obdoba z-skóru)

$$\begin{aligned}
 Z &= \frac{X - \mu_X}{\sigma_X} \quad (\text{bezrozměrné!}) \\
 \Rightarrow \mu_Z &= 0, \quad \sigma_Z = 1
 \end{aligned}$$

## charakteristiky založené na normované verzi I

charakteristiky  $X$  nezávislé na  $\mu_X$  a  $\sigma_X$ , protějšky popisných statistik

- (populační) **korelační koeficient** [correlation coefficient]

$$\rho_{XY} = \text{cov}\left(\frac{X - \mu_X}{\sigma_X}, \frac{Y - \mu_Y}{\sigma_Y}\right) = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

- připomeďme: jsou-li náhodné veličiny  $X$  a  $Y$  **nezávislé**, platí  $\text{cov}(X, Y) = \sigma_{XY} = 0$
- jsou-li náhodné veličiny  $X$  a  $Y$  **nezávislé**, je nutně  $\rho_{XY} = 0$
- předchozí tvrzení nic neříká o závislých náhodných veličinách
- pro **závislé** náhodné veličiny **může** vyjít  $\rho_{XY} = 0$
- je-li  $\rho_{XY} \neq 0$ , pak  $X, Y$  nemohou být nezávislé, jsou nutně závislé
- vždy platí  $-1 \leq \rho_{XY} \leq 1$

## příklad ponožky

$x_i^*$	$y_j^*$			celkem
	0	1	2	
0	1/15	4/15	1/15	6/15
1	4/15	4/15	0/15	8/15
2	1/15	0/15	0/15	1/15
	6/15	8/15	1/15	15/15

$$\mu_X = \mu_Y = 2/3 \quad \sigma_X^2 = \sigma_Y^2 = 48/135 = 16/45$$

$$\begin{aligned}
 \sigma_{XY} &= (0 - 2/3) \cdot (0 - 2/3) \cdot 1/15 + (0 - 2/3) \cdot (1 - 2/3) \cdot 4/15 \\
 &\quad + (0 - 2/3) \cdot (2 - 2/3) \cdot 1/15 + (1 - 2/3) \cdot (0 - 2/3) \cdot 4/15 \\
 &\quad + (1 - 2/3) \cdot (1 - 2/3) \cdot 4/15 + (1 - 2/3) \cdot (2 - 2/3) \cdot 0/15 \\
 &\quad + (2 - 2/3) \cdot (0 - 2/3) \cdot 1/15 + (2 - 2/3) \cdot (1 - 2/3) \cdot 0/15 \\
 &\quad + (2 - 2/3) \cdot (2 - 2/3) \cdot 0/15 = -24/135 \doteq -0,177
 \end{aligned}$$

$X, Y$  jsou závislé, neboť např.

$$6/15 \cdot 8/15 \doteq 0,213 < 4/15 \doteq 0,267, \quad \rho_{X,Y} = -1/2$$

## charakteristiky založené na normované verzi II

charakteristiky  $X$  nezávislé na  $\mu_X$  a  $\sigma_X$ , protějšky popisných statistik

- (populační) **šíkmost** náhodné veličiny  $X$  [skewness]

$$\gamma_1 = E\left(\frac{X - \mu_X}{\sigma_X}\right)^3 = \frac{E(X - \mu_X)^3}{\sigma_X^3}$$

- (populační) **špičatost** náhodné veličiny  $X$  (někdy bez  $-3$ ) [kurtosis]

$$\gamma_2 = E\left(\frac{X - \mu_X}{\sigma_X}\right)^4 - 3 = \frac{E(X - \mu_X)^4}{\sigma_X^4} - 3$$

## příklad ponožky

$x^*$	0	1	2
$P(X = x^*)$	$6/15$	$8/15$	$1/15$

stř. hodnota, rozptyl:  $\mu = 2/3$ ,  $\sigma^2 = 16/45$ ,  $\sigma = 4/(3\sqrt{5})$

### šikmost

$$E(X - \mu)^3 = \frac{6}{15} \left(0 - \frac{2}{3}\right)^3 + \frac{8}{15} \left(1 - \frac{2}{3}\right)^3 + \frac{1}{15} \left(2 - \frac{2}{3}\right)^3 = \frac{8}{135}$$

$$\gamma_1 = \frac{8}{135} \left(\frac{3\sqrt{5}}{4}\right)^3 = \frac{\sqrt{5}}{8}$$

špičatost podobně

$$\gamma_2 = \dots = \frac{8}{27} \left(\frac{3\sqrt{5}}{4}\right)^4 - 3 = \frac{75}{32} - 3 = -\frac{21}{32}$$

## alternativní rozdělení

nula-jedničkové, Bernoulliovo

- ▶ **X – počet zdarů** v jednom pokusu
- ▶ pravděpodobnost zdaru  $\pi$ ,  $0 < \pi < 1$
- ▶  $\pi$  je jediný parametr
- ▶ pouze dvě možné hodnoty: 1 (nastal zdar), 0 (nezdar)
- ▶  $P(X = 1) = \pi$ ,  $P(X = 0) = 1 - \pi$
- ▶ X je vlastně počet zdarů v onom pokusu
- ▶  $X \sim \text{alt}(\pi)$
- ▶  $\mu_X = E X = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- ▶

$$\sigma_X^2 = \text{var } X = E(X - \mu_X)^2 = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$$

## binomické rozdělení

[binomial distribution]

- ▶ **n nezávislých** pokusů, v nichž rozlišujeme pouze zdar a nezdar
- ▶  $P(\text{zdar}) = \pi$ ,  $(0 < \pi < 1)$
- ▶ Y je **počet zdarů** v těchto pokusech
- ▶ možné hodnoty: 0, 1, ..., n
- ▶  $P(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}$ ,  $k = 0, 1, \dots, n$
- ▶ [dbinom(k,n,prob)]
- ▶  $Y \sim \text{bi}(n, \pi)$
- ▶ např. ze 7 vajíček se vylíhne Y slepiček,  $Y \sim \text{bi}(7, 1/2)$
- ▶ např. při 60 hodech kostkou padlo Y šestek,  $Y \sim \text{bi}(60, 1/6)$
- ▶ předem nevíme, kolik bude slepiček (šestek), ale  
v dlouhodobém průměru je relativní četnost blízká 1/2 (1/6)

## příklad: kuřáci

- mezi dvacetiletými muži je (řekněme) 35 % kuřáků ( $\pi = 0,35$ )
- je-li dvacetiletých 70 tisíc ( $m = 70\ 000$ ), pak je kuřáků asi  $m\pi = 70\ 000 \cdot 0,35 = 24\ 500$ , ale nevíme, kteří to jsou
- vyberme náhodně  $n = 60$  dvacetiletých mužů, označme jako  $Y$  počet kuřáků mezi nimi, je tedy  $Y \sim bi(60, 0,35)$
- střední hodnota (očekávaný počet), rozptyl

$$\mu_Y = 60 \cdot 0,35 = 21 \quad \sigma_Y^2 = 60 \cdot 0,35 \cdot 0,65 = 13,65 \doteq (3,7)^2$$

- ukázky pravděpodobností možných hodnot

$k$	15	17	19	21	23	25
$P(Y = k)$	0,029	0,062	0,095	0,107	0,091	0,059

- pravděpodobnosti počítány pomocí  
[dbinom(c(15,17,19,21,23,25),60,0.35)]

## příklad

souvislost binomického a Poissonova rozdělení

s jakou pravděpodobností se může vyskytnout, že v 55 studentech je 5 kuřáků, je-li populace studentů charakterizována tím, že 8% je kuřáků?

- binomické rozdělení  $Y \sim bi(55, 0,08)$  [dbinom(5,55,0.08)]

$$P(Y = 5) = \binom{55}{5} \cdot 0,08^5 \cdot 0,92^{50} = 0,176$$

- aproximace Poissonovým rozdělením (použij  $\lambda = n\pi = 4,4$ )  
 $Y \sim Po(55 \cdot 0,08) = Po(4,4)$  [dpois(5, 4.4)]

$$P(Y = 5) = \frac{4,4^5}{5!} e^{-4,4} = 0,169$$

## Poissonovo rozdělení

[Poisson distribution]

- $X \sim Po(\lambda) \quad (\lambda > 0)$
- zákon vzácných (řídkých) jevů
- kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- předpokládá se, že počet výskytů jevu v jednom intervalu **nezávisí** na počtu výskytu jevu v jiném intervalu

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$$

- $\mu_X = \lambda, \sigma_X^2 = \lambda$
- při nestejných intervalech, objemech ... je parametr úměrný velikosti intervalu ... (např.  $\lambda t$  u časového intervalu délky  $t$ )
- pro velké  $n$  a malé  $\pi$  lze rozdělení  $bi(n, \pi)$  approximovat pomocí rozdělení  $Po(n\pi)$
- např. počet kolonií na Petriho misce

## normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$

[normal (Gaussian) distribution]

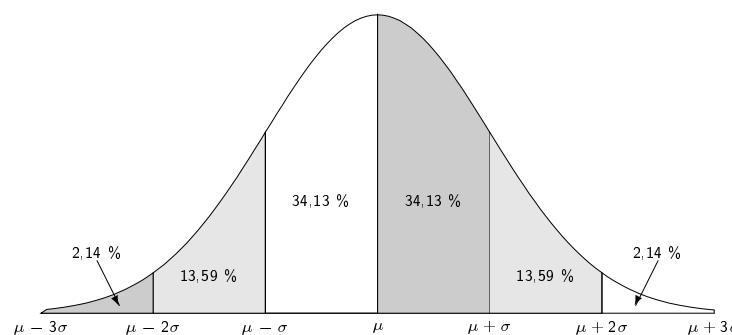
- $\mu_X = \mu, \sigma_X^2 = \sigma^2$
- spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- maximální hodnota hustoty přibližně  $0,4/\sigma$
- $N(0, 1)$  (normované normální rozdělení):  
 $\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  (hustota),  
 $\Phi(x) = \int_{-\infty}^x \varphi(t) dt$  (distr. fce)
- $X \sim N(\mu, \sigma^2)$ , pak  $Z = \frac{X-\mu}{\sigma} \sim N(0, 1)$

$$P(a < X < b) = \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right)$$

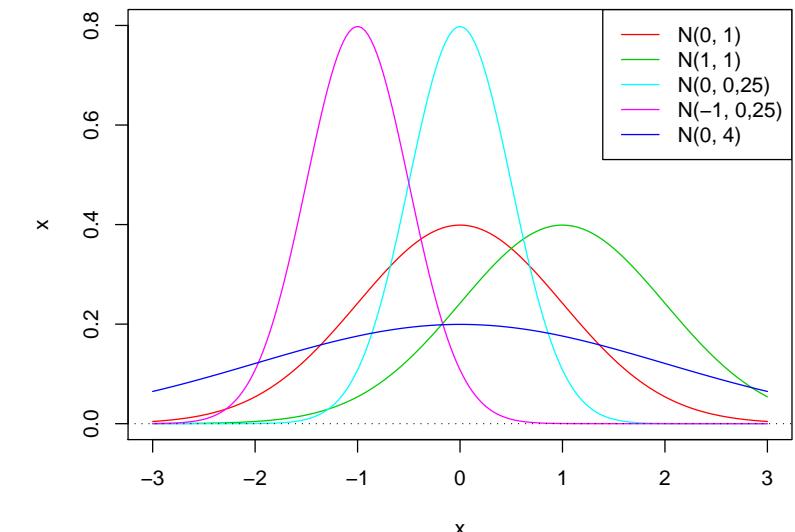
- model vzniku: součet velkého počtu nepatrných příspěvků
- velmi často modeluje znaky v poměrovém měřítku

graf hustoty  $N(\mu, \sigma^2)$ 

výpočet hustoty: [dnorm(x,mu,sigma)]

normální (Gaussovo) rozdělení  $N(\mu, \sigma^2)$ 

význam parametrů

výpočet pravděpodobnosti, že  $a < X < b$ pomocí distribuční funkce  $N(0, 1)$ 

$$P(a < X < b) = F_X(b) - F_X(a) \quad \text{platí obecně pro spoj. rozděl.}$$

$$X \sim N(\mu, \sigma^2) \Rightarrow Z = \frac{X - \mu}{\sigma} \sim N(0, 1)$$

$$P(X \leq x) = P\left(\frac{X - \mu}{\sigma} \leq \frac{x - \mu}{\sigma}\right) = P\left(Z \leq \frac{x - \mu}{\sigma}\right) = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

$$\boxed{P(a < X < b) = \Phi\left(\frac{b - \mu}{\sigma}\right) - \Phi\left(\frac{a - \mu}{\sigma}\right)}$$

[pnorm((b-mu)/sigma)-pnorm((a-mu)/sigma)]

v programu R je distribuční funkce  $N(\mu, \sigma^2)$  s obecnými parametry:

[pnorm(b,mu,sigma)-pnorm(a,mu,sigma)]

## příklad

- u jakého dílu populace desetiletých hochů naměříme výšku od 135 do 140 cm, když pro výšku desetiletých platí  $X \sim N(136,1, 6,4^2)$
- předpokládáme zaokrouhllování na celá čísla při měření, takže hodnoty od 135 cm do 140 cm naměříme, když měřené výšky budou od 134,5 cm do 140,5 cm:

$$P(134,5 < X < 140,5) = \Phi\left(\frac{140,5 - 136,1}{6,4}\right) - \Phi\left(\frac{134,5 - 136,1}{6,4}\right) \\ = 0,754 - 0,401 = 0,353$$

[pnorm((140.5-136.1)/6.4)-pnorm((134.5-136.1)/6.4)]

- pomocí distribuční fce s obecnými parametry  
[pnorm(140.5,136.1,6.4)-pnorm(134.5,136.1,6.4)]

## kvantily normálního a Studentova $t$ -rozdělení

[Student distribution]

### ► normální rozdělení $N(0, 1)$

[qnorm(1-alpha)]

$$Z \sim N(0, 1) : P(Z < z(1-\alpha)) = 1-\alpha \quad P(Z > z(1-\alpha)) = \alpha$$

ze symetrie platí  $P(|Z| > z(1 - \alpha/2)) = \alpha$

### ► Studentovo $t$ -rozdělení s $k$ stupni volnosti $t_k$

(podobné normálnímu, protože místo  $\sigma$  používá jeho odhad, má větší rozptyl)

$$T \sim t_k : P(|T| > t_k(1 - \alpha/2)) = \alpha$$

[qt(1-alpha/2,k)]

## některé kritické hodnoty

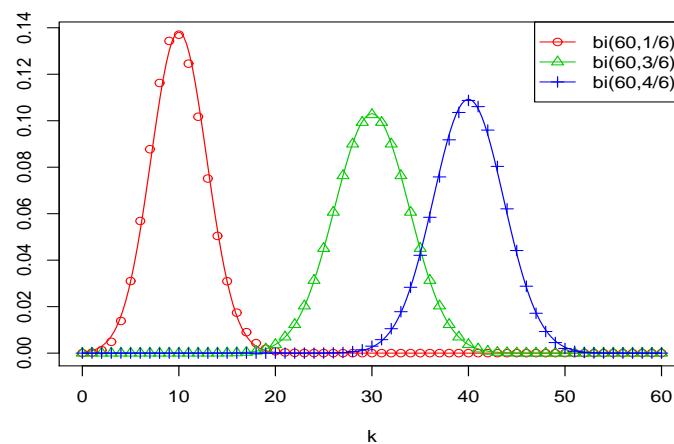
$\alpha$	0,50	0,25	0,10	<b>0,05</b>	0,01
$z(1 - \alpha/2)$	0,674	1,150	1,645	<b>1,960</b>	2,576
$t_{100}(1 - \alpha/2)$	0,677	1,157	1,660	<b>1,984</b>	2,626
$t_{20}(1 - \alpha/2)$	0,687	1,185	1,725	<b>2,086</b>	2,845
$t_5(1 - \alpha/2)$	0,727	1,301	2,015	<b>2,571</b>	4,032

- $T \sim t_k$  má jediný parametr  $k$  (počet stupňů volnosti)
- s rostoucím  $k$  se chování blíží normálnímu rozdělení  $N(0, 1)$
- pro  $Z \sim N(0, 1)$  je 95 % hodnot v intervalu  $(-1,960; 1,960)$
- pro  $T \sim t_5$  je 95 % hodnot v intervalu  $(-2,571; 2,571)$
- pro  $T \sim t_{20}$  je 95 % hodnot v intervalu  $(-2,086; 2,086)$
- pro  $T \sim t_{100}$  je 95 % hodnot v intervalu  $(-1,984; 1,984)$

## aproximace binomického rozdělení normálním

se stejnou střední hodnotou a stejným rozptylem

rozdělení  $bi(n, \pi)$  lze approximovat pomocí  $N(n\pi, n\pi(1 - \pi))$



## další rozdělení související s normálním

[F-distribution, chi-square distribution]

- $V$  má rozdělení (musí být  $P(V > 0) = 1 !!$ )  
**logaritmicko-normální**, platí-li  $\ln V \sim N(\mu, \sigma^2)$
- **Fisherovo  $F$ -rozdělení  $F_{k,m}$**  [qf(1-alpha,k,m)]
- $F \sim F_{k,m} : P(F > F_{k,m}(1 - \alpha)) = \alpha$
- **rozdělení chí-kvadrát  $\chi_k^2$**  [qchisq(1-alpha,k)]
- $X^2 \sim \chi_k^2 : P(X^2 > \chi_k^2(1 - \alpha)) = \alpha$
- speciálně platí:
  - $\chi_1^2(0,95) = 3,841 = 1,960^2$
  - $\chi_1^2(1 - \alpha) = (z(1 - \alpha/2))^2$
  - $F_{1,m}(1 - \alpha) = (t_m(1 - \alpha))^2$

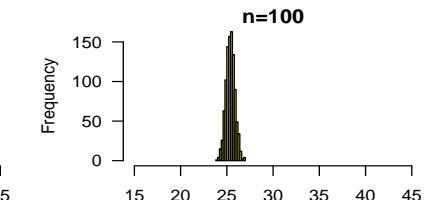
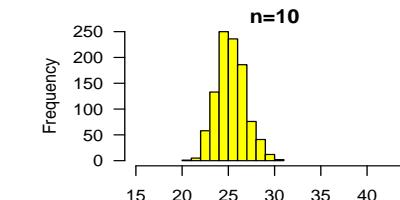
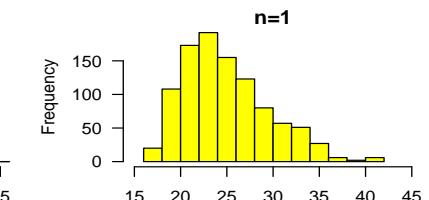
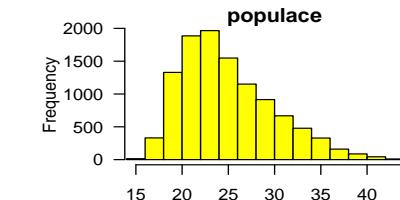
## příklad: věk matek (motivační příklad)

nepřehlédněte slova **populace**, **populační**

- ▶ velká **populace** dětí (a tedy jejich matek, téměř 11 tisíc)
- ▶ **známe populační průměr**  $\mu$  věku matek
- ▶ když náhodně vybereme matku (dítě), její věk je náhodná veličina se střední hodnotou  $\mu$
- ▶ náhodně vybráno 1000 matek (vlastně průměry výběrů rozsahu  $n = 1$ ), nakreslen histogram
- ▶ 1000 krát náhodně vybráno vždy  $n = 10$  matek, vždy spočítán **výběrový průměr**, nakreslen histogram **výběrových** průměrů
- ▶ 1000 krát náhodně vybráno vždy  $n = 100$  matek, spočítán **výběrový průměr**, nakreslen histogram **výběrových** průměrů
- ▶ podle teorie by každý další rozptyl ze 1000 **výběrových** průměrů měl být desetkrát menší než ten založený na desetkrát menším  $n$
- ▶ skutečné rozptyly (odhadu z 1000 realizací): 23,5; 2,20; 0,21

## příklad: věk matek (umělá situace)

populace - 10 916 matek, opakování výběry rozsahu  $n = 1, 10, 100$   
je patrná variabilita klesající s rostoucím  $n$



## příklad: věk matek

průměrný věk matek v opakových výběrech, počet opakování  $B = 1000$   
(20. března 2012 některé hodnoty opraveny)

rozsah výběru $n$	průměr průměrů	směr. odch. průměrů	rozptyl průměrů	rozptyl průměrů teoreticky
1	25,42	4,625	21,388	24,428
10	25,35	1,544	2,385	2,443
100	25,39	0,480	0,231	0,244
1000	25,40	0,150	0,022	0,024
populace	$\mu = 25,40$	$\sigma = 4,932$	$\sigma^2 = 24,428$	

## průměr z náhodného výběru

nemusí jít o normální rozdělení!

- ▶  $X_1, \dots, X_n$  **nezávislé**, mají stejné rozdělení  
 $\mu_{X_i} = E X_i = \mu$  (stejná střední hodnota)  
 $\sigma_{X_i}^2 = \text{var } X_i = \sigma^2$  (stejný rozptyl)
- ▶  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n}(X_1 + X_2 + \dots + X_n)$
- ▶  $\mu_{\bar{X}} = E \bar{X} = \mu$ 
  - ▶ výběrový průměr  $\bar{X}$  je opět náhodná veličina
  - ▶ je **nestranným** odhadem [**unbiased estimator**] parametru  $\mu$
  - ▶ nestranným odhadem populačního průměru (střední hodnoty)
  - ▶ když pořizujeme výběry opakováně, průměry kolísají kolem skutečné hodnoty populačního průměru
- ▶ z příkladu víme, že rozptyl  $\bar{X}$  závisí na  $n$

## rozptyl průměru z náhodného výběru

$$\sigma_{\bar{X}}^2 = \text{var} \left( \frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \sum_{i=1}^n \text{var} X_i = \frac{\sigma^2}{n} = \left( \frac{\sigma}{\sqrt{n}} \right)^2 = (\text{S.E.}(\bar{X}))^2$$

►  $\text{S.E.}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$  – střední chyba průměru

[standard error of mean]

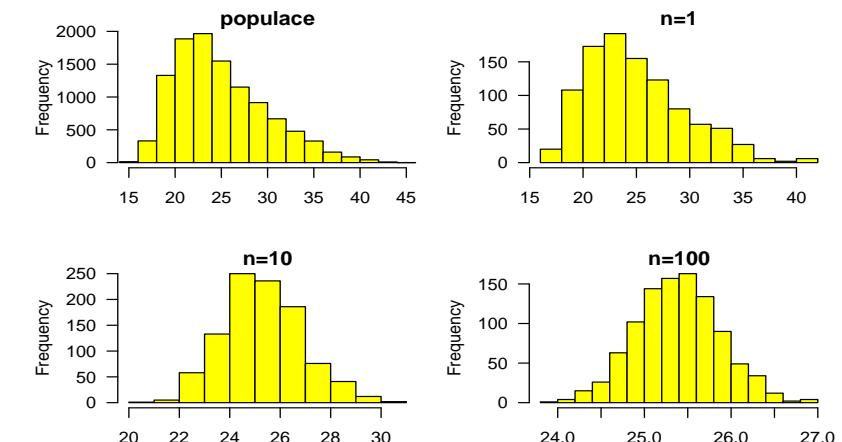
- variabilita průměrů (měřená rozptylem) z výběru rozsahu  $n$  je  $n$ -krát menší, než variabilita jednotlivých pozorování  $\sigma^2$
- střední chyba průměru je  $\sqrt{n}$ -krát menší než  $\sigma$
- čím jsou rozsahy výběru větší, tím méně výběrové průměry kolísají (kolem populačního průměru)
- speciálně pro normální rozdělení  $X_i \sim N(\mu, \sigma^2)$  nezávislé:

$$\bar{X} \sim N(\mu, \sigma^2/n) \Rightarrow Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

(všimněte si závislosti na  $n$ )

## příklad: věk matek (nestejná měřítka!)

populace - 10 916 matek, opakování výběry rozsahu  $n = 1, 10, 100$   
je patrné, že s rostoucím  $n$  se histogram blíží histogramu norm. rozdělení



## příklad: věk matek

průměrný věk matek v opakování výběrech,  
počet opakování  $B = 1000$

rozsah výběru $n$	průměr průměrů	směr. odch. průměrů	šíkmost průměrů	špičatost průměrů
1	25,42	4,625	0,740	0,287
10	25,35	1,544	0,275	-0,038
100	25,39	0,480	0,081	-0,053
1000	25,40	0,150	0,003	0,037
populace	$\mu = 25,40$	$\sigma = 4,942$	$\gamma_1 = 0,773$	$\gamma_2 = 0,192$

## centrální limitní věta (CLV, CLT)

[Central Limit Theorem]

- Nechť  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdělením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$  (nemusí pocházet z normálního rozdělení). Potom pro velké  $n$  má průměr  $\bar{X}$  přibližně rozdělení  $N(\mu, \sigma^2/n)$ , součet  $X_1 + \dots + X_n$  pak rozdělení  $N(n\mu, n\sigma^2)$ .
- prakticky: průměr má pro dost velká  $n$  normální rozdělení s rozptylem  $n$ -krát menším než jednotlivá pozorování, a to bez ohledu na výchozí rozdělení jednotlivých pozorování
- CLT je často důvodem předpokladu o normálním rozdělení, výsledná hodnota je ovlivněna součtem velikého počtu nahodilých malých vlivů
- příklad: průměrný věk matek z velkých výběrů má už (témař) normální rozdělení

## interval spolehlivosti pro $\mu$ (pro populační průměr)

výběr z  $N(\mu, \sigma^2)$  nebo velké  $n$ 

[confidence interval]

- víme, že  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy  $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$

$$P(|Z| < 1,96) = P\left(\frac{|\bar{X} - \mu|}{\sigma/\sqrt{n}} < 1,96\right) = 0,95$$

- což je totéž, jako ( $\mu$  se od  $\bar{X}$  liší nejvýše ...)

$$P\left(|\bar{X} - \mu| < 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- tedy (všimněte si zkracování intervalu s rostoucím  $n$ )

$$P\left(\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}}\right) = 0,95$$

- dostali jsme 95% interval spolehlivosti pro parametr  $\mu$

## interpretace intervalu spolehlivosti

- je to **intervalový odhad** populačního průměru (stř. hodnoty)  $\mu$
- $\bar{X}$  je **bodový odhad**  $\mu$
- **základní vlastnost:** 95% interval spolehlivosti **překryje** s pravděpodobností 95 % **neznámé  $\mu$  (odhadovaný parametr)**
- kdybychom postup prováděli opakovaně, pak asi v 95 % případů interval překryje skutečnou hodnotu  $\mu$ , ve zbylých asi 5 % zůstane skutečné  $\mu$  mimo interval spolehlivosti
- pro obecné  $\alpha$  (spolehlivost  $1 - \alpha$ ):

$$P\left(\bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(1 - \alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(1 - \alpha/2)\right) = 1 - \alpha$$

- POZOR na nesprávné interpretace, vypovídá o neznámé konstantě  $\mu$ , nikoliv o **náhodných veličinách  $X$**  nebo  $\bar{X}$

## příklad: výšky desetiletých chlapců

- $$\left(\bar{X} - \frac{\sigma}{\sqrt{n}} \cdot z(1 - \alpha/2) < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} \cdot z(1 - \alpha/2)\right)$$

- náhodně vybráno  $n = 15$  desetiletých chlapců,
- je známo (předpokládá se), že je  $\sigma = 6,4$  cm
- průměrná výška ve výběru 139,1 cm
- $\alpha = 5\%$ , tedy  $z(1 - \alpha/2) = z(0,975) = 1,96$
- 95% interval spolehlivosti pro **průměrnou výšku všech desetiletých chlapců (populační průměr)**:

$$\left(139,13 - \frac{6,4}{\sqrt{15}} \cdot 1,96; 139,13 + \frac{6,4}{\sqrt{15}} \cdot 1,96\right) \\ (135,9; 142,3)$$

- **(populační) průměr výšek všech** desetiletých chlapců leží s pravděpodobností 95 % v rozmezí od 135,9 cm do 142,3 cm

## interval spolehlivosti při neznámém $\sigma$

- když neznáme směr. odchylku  $\sigma$ , je třeba použít kritické hodnoty Studentova  $t$ -rozdělení (pozor na jiné označení u Studentova  $t$ -rozdělení v Biostatistice)

$$P\left(\bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(1 - \alpha/2) < \mu < \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(1 - \alpha/2)\right) = 1 - \alpha$$

- jako odhad  $\sigma$  se použije **výběrová směrodatná odchylka**

$$S_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$$

- při velkých  $n$  ( $n \geq 50$ ) stačí použít  $z(1 - \alpha/2)$  místo  $t_{n-1}(1 - \alpha/2)$
- interval spolehlivosti se počítá i při odhadu jiných parametrů
- je to interval, který s požadovanou pravděpodobností překryje odhadovaný parametr – **intervalový odhad**

## příklad: věk matek

normální rozdelení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,95) = 1,98$

- ▶ 95% interval spolehlivosti pro populační průměr věku všech matek na základě výběru 99 matek

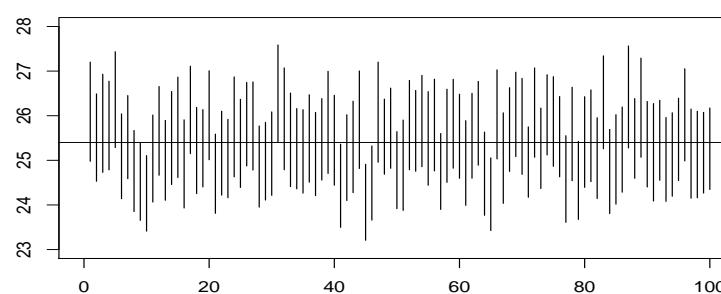
$$\left( 25,7 - \frac{4,1}{\sqrt{99}} \cdot 1,98; 25,7 + \frac{4,1}{\sqrt{99}} \cdot 1,98 \right) = (24,9; 26,5)$$

[confint(lm(vek.m~1,data=Kojeni))], [t.test(Kojeni\$vek.m)]

- ▶ 99% interval spolehlivosti pro populační průměr věku všech matek na základě výběru 99 matek (bude užší nebo širší?)
- ▶ větší jistotu zajistí delší interval spolehlivosti (delší – méně vypovídající)

$$\left( 25,7 - \frac{4,1}{\sqrt{99}} \cdot 2,63; 25,7 + \frac{4,1}{\sqrt{99}} \cdot 2,63 \right) = (24,6; 26,8)$$

[confint(lm(vek.m~1,data=Kojeni),level=0.99)]



znázorněno celkem 100 95% intervalů spolehlivosti pro  $\mu$   
ve skutečnosti mimořádně víme, že  $\mu = 25,4$   
v 7 případech je  $\mu$  nepřekryto  
(7 je realizace náhodné veličiny s rozdelením  $bi(100, 0,05)$ )

## příklad: věk matek

normální rozdelení průměrů dáno CLT a velkým  $n$ ,  $t_{98}(0,90) = 1,66$

- ▶ 90% interval spolehlivosti pro populační průměr věku všech matek na základě výběru 99 matek

$$\left( 25,7 - \frac{4,1}{\sqrt{99}} \cdot 1,66; 25,7 + \frac{4,1}{\sqrt{99}} \cdot 1,66 \right) = (25,0; 26,4)$$

[confint(lm(vek.m~1,data=Kojeni),level=0.9)] všech matek na základě výběru 99 matek je pochopitelně užší, než interval 95%

- ▶ příklady nesprávné interpretace 90% intervalu spolehlivosti:
  - ▶ 90 % žen má věk v intervalu (25,0; 26,4)  
např. mezi našimi 99 matkami je jen 12 žen ve věku 25 a 10 ve věku 26 roků, navíc, s rostoucím  $n$  se interval zužuje
  - ▶ výběrový průměr věku matek je s pravděpodobností 90 % v intervalu (25,0; 26,4)  
výběrový průměr je uprostřed (tedy uvnitř) intervalu **vždy**

## simulované výběry pro $n = 100$ (věk matek)

## centrální limitní věta pro četnosti

- ▶ (CLT obecně:) Nechť  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny se stejným rozdelením, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2 > 0$ . Potom pro velké  $n$  má průměr z nich přibližně rozdelení  $N(\mu, \frac{\sigma^2}{n})$ , jejich součet přibližně rozdelení  $N(n\mu, n\sigma^2)$ .
- ▶  $Y \sim bi(n, \pi)$ :  $Y$  je absolutní četnost výskytu jevu s pravděpodobností výskytu  $\pi$  v  $n$  nezávislých pokusech
- ▶  $Y = \sum_{i=1}^n X_i$  je součet nezávislých náhodných veličin  $X_i$  s alternativním rozdelením,  $X_i \sim alt(\pi)$ ,  $\text{var } X_i = \pi(1 - \pi)$
- ▶ podle CLT proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
- ▶ relativní četnost  $Y/n = \bar{X}$  je průměr veličin s alternativním rozdelením, označme  $\hat{\pi} = Y/n$
- ▶ podle CLT je přibližně  $\hat{\pi} \sim N(\pi, \pi(1 - \pi)/n)$
- ▶  $\hat{\pi}$  je **nestranný** odhad  $\pi$

## interval spolehlivosti pro pravděpodobnost $\pi$

- ▶ odmocnina z rozptylu odhadu  $\hat{\pi}$  je  $\sqrt{\frac{\pi(1-\pi)}{n}}$
- ▶ střední chyba relativní četnosti = směrodatná odchylka relativní četnosti
- ▶ pravděpodobnost  $\pi$  neznáme, odhadneme ji pomocí relativní četnosti  $\hat{\pi} = Y/n$
- ▶ odtud je  $100(1 - \alpha)\%$  přibližný interval spolehlivosti pro  $\pi$

$$\left( \hat{\pi} - \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}} \cdot z(1 - \alpha/2); \hat{\pi} + \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}} \cdot z(1 - \alpha/2) \right)$$

`[prop.test(y,n,correct=FALSE)]`

- ▶ existují přesnější (pracnější) postupy
- `[binom.test(y,n)]`

## populace a výběr

`[population, (random) sample, representative, parameter, statistics, estimator]`

- ▶ **populace (základní soubor)**: soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  $\Rightarrow$  rozdelení náhodné veličiny
- ▶ **výběr**: náhodně vybraná vyšetřovaná část populace (vzorek)
- ▶ **reprezentativní výběr** obráží poměry v populaci (nutná vlastnost výběru, aby mohl vypovídat o populaci)
- ▶ **náhodný výběr**: nezávislé náhodné veličiny se stejným rozdelením (model pro měření na výběru)
- ▶ **parametr**: (neznámé) číslo popisující nějakou **vlastnost populace**, charakteristika rozdelení náhodné veličiny
- ▶ **statistika**: funkce náhodného výběru (pozorování)
- ▶ **odhad**: statistika použitá k odhadu parametru

## příklad: hody s hrací kostkou

- ▶ odhadujeme pravděpodobnost šestky,  $\alpha = 0,05$
- ▶ kostka A:  $n = 100, y = 17, \hat{\pi}_A = 0,17$

$$\left( 0,17 - t \sqrt{\frac{0,17 \cdot 0,83}{100}} \cdot 1,96; 0,17 + \sqrt{\frac{0,17 \cdot 0,83}{100}} \cdot 1,96 \right) = (0,10; 0,24)$$

- ▶ kostka B:  $n = 100, y = 41, \hat{\pi}_B = 0,41$

$$\left( 0,41 - \sqrt{\frac{0,41 \cdot 0,59}{100}} \cdot 1,96; 0,41 + \sqrt{\frac{0,41 \cdot 0,59}{100}} \cdot 1,96 \right) = (0,31; 0,51)$$

- ▶ důležitý rozdíl: u kostky A patří  $1/6 = 0,167$  do 95% intervalu spolehlivosti; u kostky B nikoliv

## Jsou desetiletí hoši stejně vysoci jako desetileté dívky?

- ▶ Jak porovnat různě vysoké chlapce s různě vysokými dívkami?
- ▶ potřebujeme nějaké číslo charakterizující výšky **všech** chlapců a podobné číslo pro dívky: **populační průměry**
- ▶ budeme rozhodovat o porovnání **populačního** průměru výšek chlapců s **populačním** průměrem výšek dívek
- ▶  $X_1, \dots, X_n$  jsou výšky **náhodně vybraných** chlapců; předem je neznáme  $\Rightarrow$  v úvahách jsou to **náhodné veličiny**
- ▶ hodnoty  $X_1, \dots, X_n$  kolísají kolem střední hodnoty  $E X_i = \mu_X$  (populační průměr)
- ▶ velikost kolísání popisuje rozptyl  $\sigma^2$
- ▶ (bodovým) odhadem populačního průměru bude výběrový průměr  $\bar{X}$  spočítaný z  $n$  skutečně zjištěných výšek
- ▶ Jaké vlastnosti má průměr  $\bar{X}$ ?

příklad: výška desetiletých chlapců

- ▶ v roce 1951 bylo provedeno rozsáhlé měření výšky desetiletých hochů, výška byla vyšetřena v populaci desetiletých chlapců:  
 $\mu = 136,1$  cm,  $\sigma = 6,4$  cm
  - ▶ na základě výběru pořízeného v roce 1961 máme rozhodnout, zda se po deseti letech výška populace desetiletých **zvýšila**
  - ▶ hodnoty zjištěné v roce 1961 [cm]: 130, 140, 136, 141, 139, 133, 149, 151, 139, 136, 138, 142, 127, 139, 147
  - ▶  $\bar{x} = 139,13$  cm,  $s^2 = 6,56^2$  cm<sup>2</sup>
  - ▶ jiný (další) výběr z roku 1961 by obsahoval jiných 15 hochů, tedy by vedl k jinému výběrovému průměru (náhodná veličina)
  - ▶ stačí rozdíl  $139,13 - 136,1 = 3,03$  (náhodná veličina, proč?), abychom prokázali, že se **populační průměr** výšek desetiletých chlapců po deseti letech změnil?

## statistické rozhodování

[significance level, power, p-value]

- ▶ **hladina testu**  $\alpha$  (zpravidla  $\alpha = 5\%$ )
    - ▶ maximální dovolená pravděpodobnost chyby prvního druhu
    - ▶ volí se před pokusem, nezávisle na jeho výsledku
    - ▶ **pevná** (nenáhodná) hodnota
  - ▶ **síla testu**  $1 - \beta$ 
    - ▶ pravděpodobnost zamítnutí neplatné  $H_0$
    - ▶ pst, s jakou prokážeme platnou „vědeckou hypotézu“
    - ▶ závisí na skutečné hodnotě parametru
  - ▶ **p-hodnota**
    - ▶ za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$
    - ▶ nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout
    - ▶ „stupeň důvěry“ v platnost nulové hypotézy
    - ▶ je to **náhodná veličina**, nikoliv pravděpodobnost  $H_0$
  - ▶  $H_0$  se **zamítá**, právě když  $p \leq \alpha$  (zapamatujte si)

## testování statistických hypotéz

[hypothesis testing, null hypothesis, alternative hypothesis, critical (rejection) region, Type I (II) error, significance level]

- ▶ **nulová hypotéza**  $H_0$ : tvrzení o populaci (parametru), o jehož platnosti rozhodujeme (**není rozdíl**, **nezávisí**, **neliší se od ...**)
  - ▶ **alternativní hypotéza**  $H_1$ : (alternativa) zbývající možnost (k  $H_0$ ), často „vědecká hypotéza“, kterou chceme dokázat
  - ▶ hypotézy  $H_0, H_1$  jsou dány úlohou, nikoliv naší volbou
  - ▶ **kritický obor**: možné výsledky pokusu, kdy  $H_0$  zamítáme; zpravidla popsán pomocí statistiky (např.  $|Z| \geq z(1 - \alpha/2)$ )
  - ▶ **obor přijetí**: možné výsledky pokusu, kdy  $H_0$  nezamítáme
  - ▶ **chyba prvního druhu**: (náhodný jev) rozhodnutí zamítnout  $H_0$ , když platí  $H_0$ , tj. falešně prokázat „vědeckou hypotézu“
  - ▶ **chyba druhého druhu**: (náhodný jev) rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$ , tj. nepoznat neplatnost  $H_0$

Základy biostatistiky (MS710P09) ak. rok 2013/2014

## testování statistických hypotéz

rozhodnutí	skutečnost	
	$H_0$ platí	$H_0$ neplatí
$H_0$ zamítнут (reject)	<b>chyba</b> <b>1. druhu</b> (pst $\leq \alpha$ )	správné rozhodnutí (pst = $1 - \beta$ )
$H_0$ nezamítnout (accept, přijmout)	správné rozhodnutí (pst $\geq 1 - \alpha$ )	chyba 2. druhu (pst = $\beta$ )

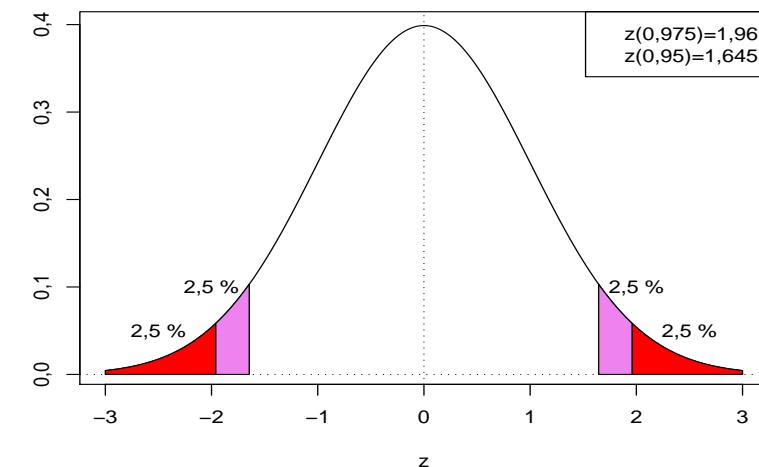
- ▶ zamítnutí  $\Leftrightarrow$  výsledek pokusu v kritickém oboru
  - ▶ přijetí  $\Leftrightarrow$  výsledek pokusu v oboru přijetí
  - ▶ nikdy spolehlivě nevíme, zda  $H_0$  platí
  - ▶ chybu 1. druhu nechceme dělat často  $\Rightarrow \alpha$  volíme malé

## rozhodování o populačním průměru normálního rozdělení ( $\sigma$ známé)

- ▶  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  nezávislé;  $\sigma > 0$  známe
- ▶  $\bar{X} \sim N(\mu, \sigma^2/n)$ , tedy S.E.( $\bar{X}$ ) =  $\sigma/\sqrt{n}$
- ▶  $H_0 : \mu = \mu_0$  (dané číslo, jiný zápis  $H_0 : \mu - \mu_0 = 0$ )
- ▶ platí-li  $H_0$ , pak  $Z = \frac{\bar{X} - \mu_0}{S.E.(\bar{X})} = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim N(0, 1)$
- ▶  $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  $|Z|$  velké, tj.  $|Z| \geq z(1 - \alpha/2)$
- ▶  $H_1 : \mu > \mu_0$ : zamítout pro  $Z \geq z(1 - \alpha)$
- ▶  $H_1 : \mu < \mu_0$ : zamítout pro  $Z \leq z(\alpha) = -z(1 - \alpha)$
- ▶ volba jednostranné alternativy jen podle zadání úlohy, nikoliv podle výsledku pokusu (nezávisle na datech)

$$\text{kritický obor pro } Z = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}$$

červeně na 5% hladině, červeně a fialově na 10% hladině, hustota  $Z$  za  $H_0$



## příklad: výška desetiletých chlapců

pozor, jednostranná alternativa!

- ▶ zvolíme klasickou hladinu  $\alpha = 5\%$
- ▶ v roce 1951 velký výběr:  $\mu_0 = 136,1$  cm,  $\sigma = 6,4$  cm
- ▶ v roce 1961 změreno  $n = 15$  náhodně vybraných desetiletých hochů,  $\bar{x} = 139,13$  cm
- ▶ stačí tento vzrůst k důkazu, že nová generace je vyšší?
- ▶ vzrostla výška desetiletých?  $H_0 : \mu = \mu_0$  proti  $H_1 : \mu > \mu_0$

$$z = \frac{139,13 - 136,1}{6,4} \sqrt{15} = 1,836$$

- ▶  $z(0,05) = 1,645 < 1,836$ , tedy  $H_0$  na 5% hladině **zamítáme**
- ▶ na 5% hladině jsme prokázali, že nová generace je vyšší
- ▶ v případě, že nová generace není vyšší, riskovali jsme jen 5% pravděpodobnost, že budeme nesprávně tvrdit, že vyšší je

## příklad: výška desetiletých chlapců

kritický obor (nezapomeň na jednostrannou alternativu!)

- ▶ kritický obor pomocí  $Z$ :

$$Z = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \geq z(1 - \alpha)$$

- ▶ totéž pro  $\bar{X}$ :

$$\bar{X} \geq \mu_0 + \frac{\sigma}{\sqrt{n}} z(1 - \alpha)$$

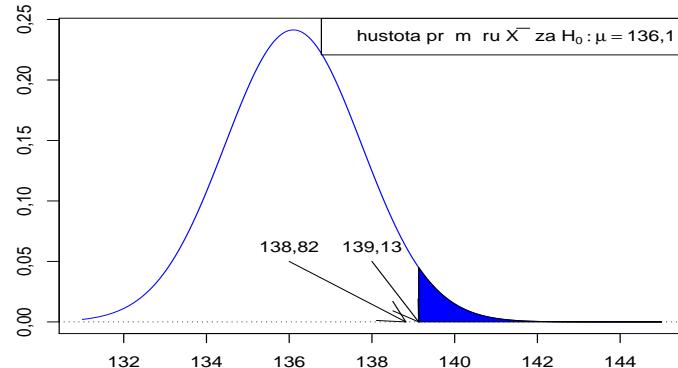
- ▶ konkrétně pro výšku hochů:

$$\bar{X} \geq 136,1 + \frac{6,4}{\sqrt{15}} \cdot 1,645 = 138,82$$

## výška desetiletých hochů

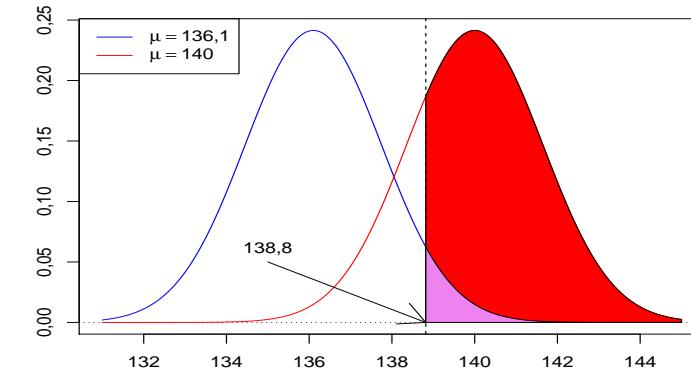
hustota  $\bar{X}$  za platnosti hypotézy  $H_0 : \mu = 136,1$ ,  $H_1 : \mu > \mu_0$  při  $\sigma = 6,4$

- ▶ p-hodnota – pst, že za  $H_0$ :  $Z = (\bar{X} - \mu_0) / \sigma \sqrt{n} > 1,836$  tj.  
 $\bar{X} > 136,1 + 1,836 \cdot 6,4 / \sqrt{15} = 139,13$  [1-pnorm(1.836)]
- ▶ p-hodnota – modrá plocha napravo od 139,13,  $p = 3,3\%$



## výška desetiletých chlapců – síla testu

hustota  $\bar{X}$  za hypotézy (modře) a při  $\mu = 140$  (červeně)  
 hladina testu = fialová plocha, síla testu = fialová + červená plocha



hraniční hodnota  $\bar{X}$ , při které se „láme“ rozhodování (hranice kritického oboru a oboru přijetí):  $136,1 + 6,4 / \sqrt{15} \cdot 1,645 = 138,8$

## volba rozsahu výběru

$H_0 : \mu = \mu_0$  proti  $H_1 : \mu \neq \mu_0$

- ▶ pro zvolenou hodnotu  $\mu_1 \neq \mu_0$  požadujeme sílu  $1 - \beta$
- ▶  $1 - \beta$  je pravděpodobnost, s jakou odhalíme neplatnost  $H_0$ , je-li ve skutečnosti  $\mu = \mu_1$

$$n \geq \left( \frac{z(1 - \alpha/2) + z(1 - \beta)}{\mu_1 - \mu_0} \right)^2 \sigma^2$$

- ▶ při jednostranné alternativě by bylo  $z(1 - \alpha)$  místo  $z(1 - \alpha/2)$
- ▶ aby při jednostranné alternativě pro  $\mu_1 = 140$  byla síla 90 % (tj.  $1 - \beta = 0,9$ ,  $\beta = 0,1$ ,  $z(0,9) = 1,282$ ), bude třeba aspoň

$$n \geq \left( \frac{1,645 + 1,282}{140 - 136,1} \right)^2 6,4^2 = 23,1$$

(místo 15 pozorování jich potřebujeme aspoň 24, při oboustranné alternativě aspoň 29)

## jednovýběrový t-test

výběr z  $N(\mu, \sigma^2)$ ,  $\sigma$  neznámé

- ▶  $n$  nezávislých pozorování  $X_1, \dots, X_n$  z rozdělení  $N(\mu, \sigma^2)$
- ▶  $H_0 : \mu = \mu_0$  (populační průměr roven dané konstantě)
- ▶ nutno odhadnout neznámý rozptyl  $\sigma^2$

$$S_x^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

- ▶ statistika (místo  $\sigma$  použijeme  $S_x$ )

$$T = \frac{\bar{X} - \mu_0}{S.E.(\bar{X})} = \frac{\bar{X} - \mu_0}{S_x} \sqrt{n}$$

- ▶  $H_1 : \mu \neq \mu_0$  zamítat při  $|T| \geq t_{n-1}(1 - \alpha/2)$
- ▶  $H_1 : \mu > \mu_0$  zamítat při  $T \geq t_{n-1}(1 - \alpha)$
- ▶  $H_1 : \mu < \mu_0$  zamítat při  $T \leq t_{n-1}(\alpha) = -t_{n-1}(1 - \alpha)$

## výšky hochů pro případ neznámého $\sigma$

- ▶  $H_0 : \mu = 136,1$  proti  $H_1 : \mu > 136,1$  ( $\alpha = 5\%$ )

$$\bar{x} = 139,133 \quad s_x^2 = 6,556^2$$

$$t = \frac{139,133 - 136,1}{6,556} \sqrt{15} = 1,792 > 1,761 = t_{14}(0,95)$$

$$p = P(T \geq 1,792) = 0,047 \quad (\text{tj. } 4,7\%)$$

- ▶ na 5% hladině jsme prokázali zvýšení populačního průměru ( $H_0$  se na 5% hladině **zamítá**)
- ▶ `[t.test(hosi,mu=136.1,alternative="greater")]`

## výšky hochů pro případ neznámého $\sigma$ (jiné zadání úlohy)

- ▶ **kdybychom** předem neměli určenu jednostrannou alternativu, museli bychom zvolit  $H_1 : \mu \neq 136,1$ , pak

$$|t| = |1,792| < 2,145 = t_{14}(0,975)$$

$$p = P(|T| \geq 1,792) = 0,0948 \quad (\text{tj. } 9,48\%)$$

- ▶ hypotézu na 5% hladině nezamítáme
- ▶ `[t.test(hosi,mu=136.1,alternative="two.sided")]`, stačí ale `[t.test(hosi,mu=136.1)]`

## výšky hochů pro případ neznámého $\sigma$

- ▶ 95% interval spolehlivosti:  $(135,5; 142,8)$   
s 95% pravděpodobností je skutečný populační průměr (střední hodnota  $\mu$ ) v uvedeném intervalu
- ▶ je jen 5% riziko, že leží mimo uvedený interval
- ▶ 99% interval spolehlivosti  $(134,1; 144,2)$   
`[t.test(hosi,mu=136.1,conf.level=0.99)]` (vedlejší výsledek)  
`[confint(lm(hosi~1),level=0.99)]`
- ▶ aby byla zajištěna větší spolehlivost intervalu (větší pravděpodobnost, že zachytí skutečnou hodnotu), je nutně 99% interval spolehlivosti delší, než 95% interval spolehlivosti

## souvislost s intervalem spolehlivosti pro $\mu$

při oboustranné alternativě

- ▶ oboustranný interval spolehlivosti pro  $\mu$  (viz str. 112)

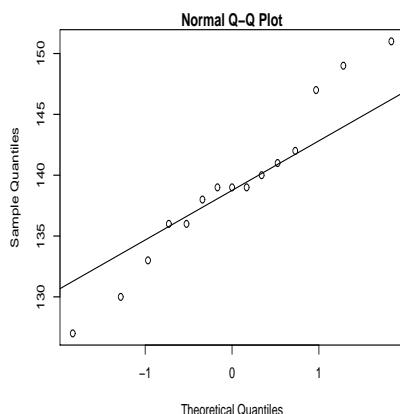
$$\left( \bar{X} - \frac{S_x}{\sqrt{n}} t_{n-1}(1 - \alpha/2), \bar{X} + \frac{S_x}{\sqrt{n}} t_{n-1}(1 - \alpha/2) \right)$$

- ▶  $\mu_0$  patří do intervalu spolehlivosti, právě když platí

$$|\bar{X} - \mu_0| < \frac{S_x}{\sqrt{n}} t_{n-1}(1 - \alpha/2)$$

- ▶ tedy, právě když se nezamítne hypotéza  $H_0 : \mu = \mu_0$  při oboustranné alternativě  $H_1 : \mu \neq \mu_0$
- ▶ interval spolehlivosti obsahuje takové hodnoty  $\mu_0$ , pro které bychom **nezamítli** hypotézu  $H_0 : \mu = \mu_0$
- ▶ podobně u jednostranných intervalů spolehlivosti a jednostranných alternativ

## ověření předpokladu o normálním rozdělení



### ► Shapirův-Wilkův test

- $H_0$  : normální rozdělení s nějakými (neznámými) parametry
- `[shapiro.test(hosi)]`
- $W = 0,966, p = 80\%$
- test hodnotí kvalitu přiblížení bodů k přímce na diagramu normality
- `[qqnorm(hosi); qqline(hosi)]`

## pravděpodobnost výskytu jevu

test hypotézy o parametru  $\pi$  binomického rozdělení

- $Y \sim bi(n, \pi)$   $H_0 : \pi = \pi_0$ :

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{\hat{\pi} - \pi_0}{S.E.(\hat{\pi})} = \frac{\hat{\pi} - \pi_0}{\sqrt{\pi_0(1 - \pi_0)/n}} \sim N(0, 1)$$

- podobnost s intervalem spolehlivosti pro  $\pi$  na str. 116
- někdy s opravou na spojitost (Yates)

$$Z = \frac{|Y - n\pi_0| - 0,5}{\sqrt{n\pi_0(1 - \pi_0)}} \text{sign}(Y - n\pi_0) \sim N(0, 1)$$

- $H_1 : \pi \neq \pi_0$ : zamítout pokud  $|Z| \geq z(1 - \alpha/2)$
- $H_1 : \pi > \pi_0$ : zamítout pokud  $Z \geq z(1 - \alpha)$
- $H_1 : \pi < \pi_0$ : zamítout pokud  $Z \leq z(\alpha) = -z(1 - \alpha)$
- existuje přesný postup, bez použití approximace

## příklad kalous

- pokusit se prokázat, že kalous dá přednost infikované myši před myší neinfikovanou
- $Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pest, že zvolí infikovanou
- $Y$  má **binomické rozdělení** za  $H_0 : \pi = 1/2$  ( $= \pi_0$ , myši se neliší) je  $Y \sim bi(50, 1/2)$
- **alternativní hypotéza:**  $H_1 : \pi > 1/2$
- v pokusu z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou
- **kritický obor:** velká hodnota  $Y$  (tj. velké  $\hat{\pi}$  resp. velké  $Z$ )

$$z = \frac{33 - 50 \cdot 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,263 \quad p = P(Z \geq 2,263) = 0,0118$$

- s opravou na spojitost jsme opatrnejší:

$$z = \frac{33 - 50 \cdot 0,5 - 0,5}{\sqrt{50 \cdot 0,5 \cdot 0,5}} = 2,121 \quad p = P(Z \geq 2,121) = 0,0169$$

## příklad kalous

- `prop.test()` počítá  $Z^2$ , která má za  $H_0$  rozdělení  $\chi_1^2$   
`[prop.test(33,n=50,p=0.5,alternative="greater",correct=FALSE)]`  
`[prop.test(33,50,alternative="greater")]`  
`[binom.test(33,50,alternative="greater")]`
- **p-hodnota (dosažená hladina):** za  $H_0$  počítaná pest, že dostaneme výsledek aspoň tolik odpovídající nulové hypotéze, jako ve skutečném pokusu:

$$\begin{aligned} p &= P(Y \geq 33) = 1 - P(Y \leq 32) \\ &= \sum_{k=33}^{50} \binom{50}{k} 0,5^k (1 - 0,5)^{50-k} \\ &= 0,0164 \end{aligned}$$

$$[1-pbinom(32,50,1/2)]$$

$$[sum(dbinom(33:50,50,0.5))]$$

## párové testy

(převedou úlohu na jednovýběrové testy)

- ▶  $(U_1, V_1), \dots, (U_n, V_n)$  – párová pozorování  
**nezávislé** dvojice (možná) závislých náhodných veličin
- ▶  $U_i, V_i$  – dvojice měření na stejných jedincích, např. hodnota zjištěná před ošetřením a po něm
- ▶ např. výška otce a jeho syna nebo věk otce a věk matky
- ▶ **nezajímá nás** zda je mezi nimi **závislost**, tu připouštíme, těsná závislost uvnitř dvojic je dokonce výhodná
- ▶ **zajímá nás zda jsou co do polohy stejné**, nebo např. synové v (populačním) průměru vyšší, než otcové
- ▶  $X_i = U_i - V_i$  (označení rozdílů)
- ▶ předp. **stejný druh rozdělení**  $X_1, \dots, X_n$  (např. normální)
- ▶  $H_0$  tvrdí, že např. mezi výškami otců a synů **není rozdíl**, tedy že rozdíly  $X_i$  **kolísají kolem nuly**: populační míra polohy rozdílů je nulová (např. populační průměr – střední hodnota)

## párový t-test

předpoklad: normální rozdělení rozdílů

- ▶ předpoklad:  $X_i = U_i - V_i$  mají **normální** rozdělení, **nezávislé**
- ▶  $X_i = U_i - V_i \sim N(\mu_U - \mu_V, \sigma^2) = N(\mu, \sigma^2)$
- ▶ vlastně **jednovýběrový t-test** pro  $X_i = U_i - V_i$ :
- ▶  $H_0 : \mu = \mu_0$  (zpravidla  $\mu_0 = 0$ , pak je  $\mu_U = \mu_V$ )
- ▶ odhad  $\sigma^2$ :  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
- ▶  $T = \frac{\bar{X} - \mu_0}{S.E.(\bar{X})} = \frac{\bar{X} - \mu_0}{S} \sqrt{n} = \frac{\bar{U} - \bar{V} - \mu_0}{S} \sqrt{n}$
- ▶ ve prospěch  $H_1 : \mu \neq 0$ , když  $|T| \geq t_{n-1}(1 - \alpha/2)$
- ▶ ve prospěch  $H_1 : \mu < 0$ , když  $T \leq t_{n-1}(\alpha) = -t_{n-1}(1 - \alpha)$
- ▶ ve prospěch  $H_1 : \mu > 0$ , když  $T \geq t_{n-1}(1 - \alpha)$

## příklad: výšky rodičů (párová pozorování!)

$H_0$ : otcové jsou o 10 cm vyšší než matky,  $H_1$  oboustranná

- ▶  $U$  – výška otce,  $V$  – výška matky,  $X = U - V$
- ▶  $\alpha = 0,05$ ,  $H_0 : \mu_U = \mu_V + 10$  resp.  $\mu_U - \mu_V = 10$
- ▶  $n = 99$ ,  $\bar{u} = 179,267$ ,  $\bar{v} = 166,970$
- ▶  $\bar{x} = \bar{u} - \bar{v} = 12,293$ ,  $s_x = s_{U-V} = 8,144$
- ▶  $t = \frac{12,293-10}{8,144} \sqrt{99} = 2,801$ , tedy  $|t| > t_{98}(0,975) = 1,9845 \Rightarrow$  zamítout  $H_0$
- ▶  $p = P(|T| \geq |t|) = 0,0061$  (0,61 %)
- ▶ 95% interval spolehlivosti pro  $\mu_U - \mu_V$ :  

$$\left( 12,293 - \frac{8,144}{\sqrt{99}} 1,9845 ; 12,293 + \frac{8,144}{\sqrt{99}} 1,9845 \right) = (10,67; 13,92)$$

```
[shapiro.test(vyska.o-vyska.m)]          ověření normality
[t.test(vyska.o,vyska.m, mu=10, paired=TRUE)]
[t.test(vyska.o-vyska.m, mu=10)]
```

## znaménkový test

bez předpokladu normálního rozdělení, stačí libovolné **spojité** rozdělení

- ▶ stačí znát znaménka rozdílů  $X_i = U_i - V_i$
- ▶ pozorování s  $U_i = V_i$  (tj.  $X_i = 0$ ) se vynechají, upraví se  $n$
- ▶  $Y$  – počet **kladných** znamének  $X_i = U_i - V_i$
- ▶  $H_0$ : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $P(U_i > V_i) = P(X_i > 0) = 1/2$ , tedy  $Y \sim bi(n, 1/2)$
- ▶  $H_0$  zamítáme pro velká nebo malá  $Y$ :

$$Z = \frac{Y - n/2}{\sqrt{n/4}}, \quad |Z| \geq z(1 - \alpha/2)$$

- ▶ pro malá  $n$  je bezpečnější použít Yatesovu korekci

$$Z = \frac{|Y - n/2| - 0,5}{\sqrt{n/4}}, \quad |Z| \geq z(1 - \alpha/2)$$

## příklad: věk rodičů (párová pozorování!)

normalitu rozdílu věku rodičů sotva lze předpokládat

- celkem 99 dvojic (otec, matka), sledujeme jejich věk ( $U, V$ )
- $H_0 : \mu_U = \mu_V + 2$  (populační míra polohy věku otců je o 2 roky větší, než matek),  $H_1$  oboustranná
- v jedenácti případech je  $\text{vek.o} - \text{vek.m} = 2$ , tyto dvojice nepoužijeme, proto  $n = 99 - 11 = 88$
- u 50 dvojic je  $\text{vek.o} - \text{vek.m} > 2$ , proto

$$z = \frac{50 - 88/2}{\sqrt{88/4}} = 1,279, \quad p = 0,201 \text{ (20,1 %)}$$

- s Yatesovou korekcí:  $z = 1,172$ ,  $p = 0,241$  (24,1 %)

```
[n = sum(vek.o-vek.m != 2)]
[y = sum(vek.o-vek.m > 2)]
[prop.test(y,n,correct=FALSE)]
[prop.test(y,n,correct=TRUE)]
```

počet nenulových  $X_i$   
počet kladných  $X_i$   
bez Yatesovy korekce  
s Yatesovou korekcí

## párový Wilcoxonův test [Wilcoxon signed rank test]

(silnější předpoklad, než u znaménkového testu)

- nutné **spojité** a **symetrické** rozdělení  $X_i = U_i - V_i$
- $H_0$ : populační medián  $X_i$  je roven 0 (tj.  $P(X_i > 0) = 0,5$ )
- opět vyloučíme případy  $U_i = V_i$  (tj.  $X_i = 0$ )
- určíme pořadí  $R_i^+$  absolutních hodnot  $|X_i| = |U_i - V_i|$
- $W$  součet těch pořadí, kde bylo  $U_i > V_i$  (tj.  $X_i > 0$ )

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

- pod odmocninou bývá ještě oprava na výskyt shodných hodnot, která jmenovatele poněkud zmenší  
`wilcox.test(vyska.o,vyska.m,mu=10,paired=TRUE)`
- pro malá  $n$  se čitatel zpravidla přibližuje o 1/2 k nule:  
(všimněte si zkrácených názvů parametrů – jednoznačnost!)  
`wilcox.test(vyska.o,vyska.m,m=10,p=TRUE,cor=FALSE)`

## příklad: porovnání dvou metod učení nazepaměť

- u **devíti** osob provedeno porovnávání dvou způsobů předávání informace (např. poslouchání vers. čtení)
- rozhodnout, zda je mezi oběma způsoby rozdíl
- $H_0$ : rozdělení  $U$  a  $V$  stejná, tedy populační medián rozdílů  $X = U - V$  je roven 0
- znaménkový test s Yatesovou korekcí (málo pozorování):

$$y = 5 \quad n = 8$$

$$z = \frac{|5 - 8/2| - 0,5}{\sqrt{8/4}} = 0,3536 \quad p = 72,4 \%$$

$u_i$	90	86	72	65	44	52	46	38	43
$v_i$	85	87	70	62	44	53	42	35	46
$x_i$	5	-1	2	3	0	-1	4	3	-3
$r_i^+$	8	1,5	3	5	–	1,5	7	5	5

## příklad: porovnání dvou metod učení nazepaměť

párový Wilcoxonův test [Wilcoxon signed-rank test]

- $H_0$ : populační medián rozdílů = 0
- nově předpokládáme symetrii
- Wilcoxonův test: 
$$\frac{\sum_{i=1}^n r_i^+}{n} \quad \begin{array}{ccccccccc} 5 & -1 & 2 & 3 & -1 & 4 & 3 & -3 \\ 8 & 1,5 & 3 & 5 & 1,5 & 7 & 5 & 5 \end{array}$$

$$n = 8$$

$$w = 8 + 3 + 5 + 7 + 5 = 28$$

$$z = \frac{28 - 8 \cdot 9/4 - 1/2}{\sqrt{8 \cdot 9 \cdot 17/24}} = \frac{9,5}{\sqrt{51}} = 1,33$$

$$p = 18,3 \%$$

- program R dá  $p = 18,1 \%$ , protože kromě opravy na spojitost bere ohled na shody (přesný výpočet by dal  $p = 19,5 \%$ )

## porovnání populačních měr polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový t-test	jednovýběrový Wilcoxonův, znaménkový
výběr dvojic	párový t-test	párový Wilcoxonův, znaménkový
dva nezávislé výběry	dvouvýběrový t-test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr r-tic	analýza rozptylu náhodné bloky	Friedman

## dvouvýběrový t-test

(předpoklad **normálního rozdělení**, testuje se **shoda středních hodnot**  $\mu_X = \mu_Y$ )

- ▶  $n_X$  nezávislých pozorování  $X$ ,  $n_Y$  nezávislých pozorování  $Y$
- ▶ tyto výběry musí být **nezávislé** (musí to zajistit způsob pořízení dat)
- ▶ rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné (lze ověřit, odhadu  $S_X^2, S_Y^2$  podobné)
- ▶ normální rozdělení v obou výběrech (lze ověřit, pro velká  $n_X, n_Y$  nenormalita tolik nevadí)
- ▶ společný odhad rozptylu (vážený průměr odhadů z jednotlivých výběrů)

$$S^2 = \frac{n_X - 1}{n_X + n_Y - 2} S_X^2 + \frac{n_Y - 1}{n_X + n_Y - 2} S_Y^2$$

- ▶ statistika (pro test hypotézy, že rozdělení  $X$  a  $Y$  jsou stejná)

$$T = \frac{\bar{X} - \bar{Y}}{\text{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_X n_Y}{n_X + n_Y}}$$

## dvouvýběrový t-test

- ▶  $H_0 : \mu_X = \mu_Y$   
zamítout ve prospěch alternativy
  - ▶  $H_1 : \mu_X \neq \mu_Y$  když  $|T| \geq t_{n_X+n_Y-2}(1 - \alpha/2)$
  - ▶  $H_1 : \mu_X > \mu_Y$  když  $T \geq t_{n_X+n_Y-2}(1 - \alpha)$
  - ▶  $H_1 : \mu_X < \mu_Y$  když  $T \leq t_{n_X+n_Y-2}(\alpha) = -t_{n_X+n_Y-2}(1 - \alpha)$
- [`t.test(hosi,divky,var.equal=TRUE)`] nebo  
[`t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)`]
- ▶ zamítáme-li  $H_0$ , říkáme, že rozdíl výběrových průměrů **je (statisticky) významný**
- ▶ pochyby o shodě rozptylů: Welchův test (modifikace t-testu)  
[`t.test(hosi,divky,var.equal=FALSE)`] (pro  $\sigma_X \neq \sigma_Y$ )  
[`t.test(hosi,divky)`] resp. [`t.test(vyska~Hoch)`] (pro  $\sigma_X \neq \sigma_Y$ )
- ▶ shodu rozptylů lze ověřit např. F-testem  $(H_0 : \sigma_X = \sigma_Y)$   
[`var.test(hosi,divky)`]
- ▶ ověření normality nutně pro každý výběr zvlášt!

## příklad: výšky desetiletých dětí

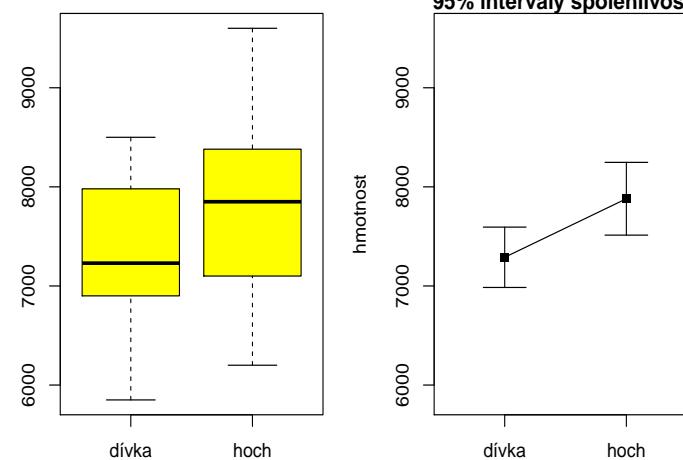
	rozsah	průměr	výb. rozptyl
hoši	15	139,13	42,98
dívky	12	140,83	33,79

$$s^2 = \frac{15 - 1}{15 + 12 - 2} 42,98 + \frac{12 - 1}{15 + 12 - 2} 33,79 = 38,936$$

$$|t| = \frac{|139,13 - 140,83|}{\sqrt{38,936}} \sqrt{\frac{15 \cdot 12}{15 + 12}} = |-0,703| < 2,06 = t_{25}(0,975)$$

- [`shapiro.test(hosi)`]  $p = 80\%$
- [`shapiro.test(divky)`]  $p = 38\%$
- [`tapply(vyska,Hoch,shapiro.test)`] (spočítá test pro oba výběry)
- [`var.test(hosi,divky)`]  $p = 70\%$
- [`t.test(hosi,divky,var.equal=TRUE)`]  $p = 49\%$
- [`t.test(vyska~Hoch,data=Vysky,var.equal=TRUE)`]

## příklad: váha dětí maturantek v 24. týdnu věku dítěte

 $t = 2,52, p = 1,5 \%,$  rozdíl je významný

## dvouvýběrový t-test a intervaly spolehlivosti

(poznámka na okraj, platí pro  $\alpha = 5 \%$ )

**D:** disjunktní int. spol. versus **V:** významný rozdíl  
**(PP:** průměry jsou v CI druhého výběru)

**D  $\Rightarrow$  V** disjunktní intervaly spolehlivosti  $\Rightarrow$  významný rozdíl  
**non V  $\Rightarrow$  non D** nevýznamný rozdíl průměrů  $\Rightarrow$  překryv intervalů  
**V  $\neq$  D** rozdíl průměrů může být významný a současně se intervaly mohou překrývat

**PP  $\Rightarrow$  non V** pokud každý z intervalů spolehlivosti obsahuje výběrový průměr druhého výběru, rozdíl průměrů není významný (nemusí platit v případě, kdy oba rozsahy výběru jsou do čtyř)

## příklad: váha dětí matek maturantek v 24. týdnu

- ▶ 95% interval spolehlivosti pro hochy [kg]: (7,51; 8,25)
- ▶ 95% interval spolehlivosti pro dívky [kg]: (6,98; 7,59)
- ▶ intervaly se poněkud překrývají, přestože t-test dal:  
 $t = 2,52, p = 1,5 \%,$  tedy významný rozdíl

## dvouvýběrový Wilcoxonův test (Mannův-Whitneyův)

(stačí spojité rozdělení)

- ▶ dva nezávislé výběry rozsahu  $n_X, n_Y$
- ▶ spojitá rozdělení
- ▶  $H_0:$  rozdělení jsou stejná, tedy i **populační mediány** stejné
- ▶ za  $H_0$  jsou výběry „dobře promíchané“
- ▶ určíme pořadí v rámci spojených výběrů
- ▶ kritický obor: průměrná pořadí se příliš liší
- ▶  $W_X$  součet pořadí hodnot  $X$

$$Z = \frac{W_X - n_X(n_X + n_Y + 1)/2}{\sqrt{n_X n_Y (n_X + n_Y + 1)/12}}$$

- ▶ shodu zamítni, pokud  $|Z| \geq z(1 - \alpha/2)$  (přibližný test)
- ▶ citlivý vůči posunutí, méně vůči nestejné variabilitě

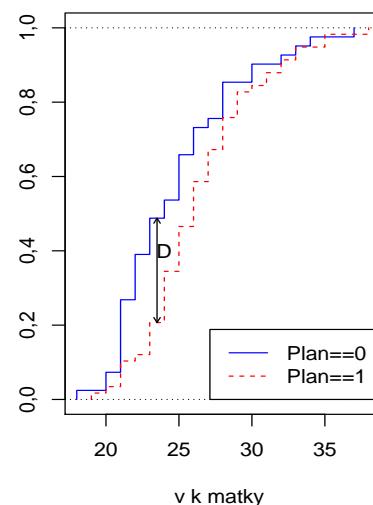
## příklad: věk matek vers. plánované těhotenství

- ▶ věk matky nemá normální rozdělení: Shapirův-Wilkův test dal  $p$ -hodnoty  $p = 0,0045$  a  $p = 0,0470$   
`[tapply(vek.m, Plan, shapiro.test)]`
- ▶ rozdělení věku matek je nepochybně spojité
- ▶ výběry (0 – neplánované, 1 – plánované těhotenství) jsou nezávislé
- ▶ dvouvýběrový Wilcoxonův test  $H_0:$  shodná rozdělení (shodné mediány) dal  $p = 0,02067,$  rozdíl je na 5 % hladině **průkazný**  
`[wilcox.test(vek.m ~ Plan)]`
- ▶  $W = 864$  je  $\#(vek0 > vek1) + \#(vek0 == vek1)/2,$  kde  $vek0$  je věk matky s  $Plan == 0,$  podobně  $vek1$

## Kolmogorovův-Smirnovův test

(stačí spojité rozdělení)

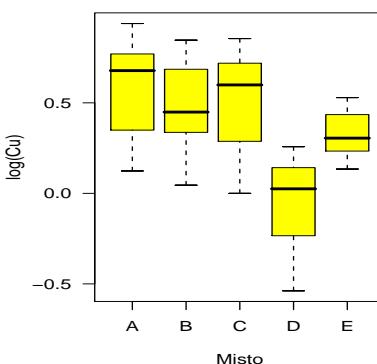
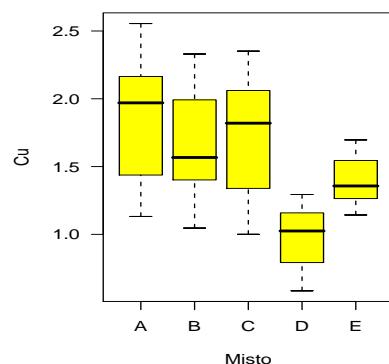
- porovná empirické distribuční funkce dvou **nezávislých** výběrů
- určí jejich největší „svislou“ vzdálenost
- citlivý vůči všem neshodám (nejen co do populačního průměru či populačního mediánu)
- porovnání věku matek podle plánovaného těhotenství
- $D = \frac{20}{41} - \frac{12}{58} = 0,2808$   
 $p = 4,5\%$



[ks.test(vek.m[Plan==0],vek.m[Plan==1])]

## motivační příklad pro analýzu rozptylu (játra):

- pět míst na řece, vždy vyloveno po 7 rybách
- zjištována koncentrace mědi v játrech
- liší se tato místa svým znečištěním?
- logaritmování na pravé straně stabilizuje rozptyl

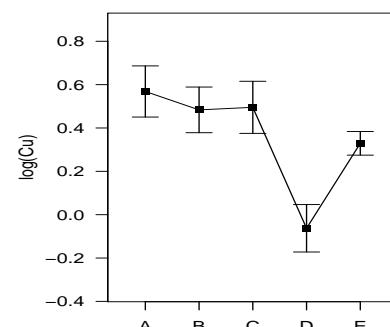
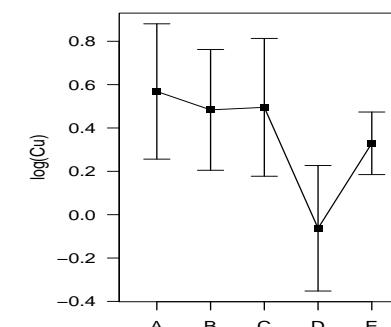


## porovnání populačních měr polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový <i>t</i> -test	jednovýběrový Wilcoxon
výběr dvojic	párový <i>t</i> -test	znaménkový, Wilcoxon
dva nezávislé výběry	douvýběrový <i>t</i> -test	Mann-Whitney (Kolmogorov-Smirnov)
<i>k</i> nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr <i>r</i> -tic	analýza rozptylu náhodné bloky	Friedman

## jiné zobrazení dat (error bars)

- v obou grafech jsou znázorněny průměry na jednotlivých místech
- vlevo: úsečky = směrodatné odchylky, vyjadřují **variabilitu dat**
- vpravo úsečky = střední chyba průměru, vyjadřují **přesnost odhadů středních hodnot**



## analýza rozptylu jednoduchého třídění (ANOVA)

- ▶  $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$  (první výběr, průměr  $\bar{Y}_{1\bullet}$ )  
 $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$  (druhý výběr, průměr  $\bar{Y}_{2\bullet}$ )
- ...  
 $Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$  ( $k$ -tý výběr, průměr  $\bar{Y}_{k\bullet}$ )
- ▶ **nezávislé** výběry (shodné rozptyly, normální rozdělení)
- ▶  $H_0 : \mu_1 = \mu_2 = \dots = \mu_k (= \mu)$     $H_1 : \text{neplatí } H_0$
- ▶ celkový průměr  $\bar{Y}_{\bullet\bullet}$ , celkový rozsah  $n = \sum_{i=1}^k n_i$
- ▶ rozklad součtu čtverců

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$S_T = S_A + S_e$$

$$f_T = f_A + f_e$$

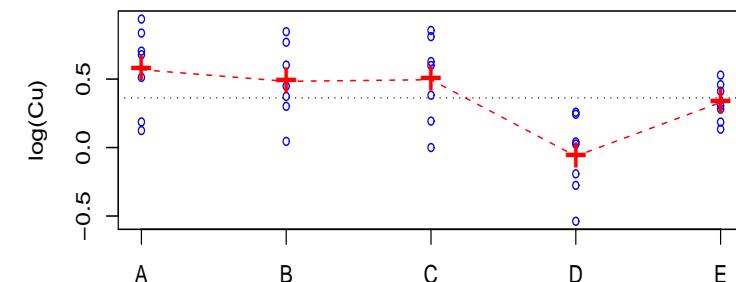
$$(n - 1) = (k - 1) + (n - k)$$

## rozklad součtu čtverců

příklad játra (celkový průměr  $\bar{y}_{\bullet\bullet} = 0,36$ )

(celková variabilita) = (variabilita mezi) + (variabilita uvnitř)

$$\sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum_{i=1}^k n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{t=1}^{n_i} (Y_{it} - \bar{Y}_{i\bullet})^2$$



## tabulka analýzy rozptylu

$$H_0 \text{ zamítout, je-li } F_A = \frac{S_A/f_A}{S_e/f_e} \geq F_{f_A, f_e}(1 - \alpha)$$

variabilita	$S$	$f$	$S/f$	$F$	$p$
výběry	$S_A$	$f_A = k - 1$	$S_A/f_A$	$F_A$	$p_A$
reziduální	$S_e$	$f_e = n - k$	$S_e/f_e$		
celková	$S_T$	$f_T = n - 1$			

- ▶  $S$  – součty čtverců, jejich rozklad
- ▶  $f$  – počty stupňů volnosti
- ▶  $S/f$  – průměrné čtverce
- ▶  $F$  –  $F$ -statistika
- ▶  $p$  –  $p$ -hodnota

variab.	$S$	$f$	$S/f$	$F$	$p$
místa	1,796	4	0,4490	5,862	0,0013
rezid.	2,285	30	0,0762		
celk.	4,081	34			

$$F = 5,862 > F_{4,30}(0,95) = 2,690$$

na 5% hladině jsme **prokázali rozdíl**

[summary(aov(lnCu~Misto,data=Med))]

nebo také

[anova(lm(lnCu~Misto,data=Med))]

## ověření předpokladů

- **nezávislost:** dánou organizací (plánem) pokusu předpoklad nelze vynechat či nahradit
- **shoda rozptylu:** (vyvážený model je málo citlivý na neshodu)

- Leveneův test  
(vlastně jednoduché třídění s  $|Y_{it} - \text{med}_t Y_{it}|$ )  
 $p = 64,8\%$  [levene.test(lnCu,Misto)]
- Bartlettův test  
(citlivý na splnění předpokladu o normálním rozdělení)  
 $p = 45,3\%$  [bartlett.test(lnCu,Misto)]

- **normální rozdělení:** (vyvážený model je málo citlivý na nenormalitu), test normality nutno uplatnit na rezidua  
 $Y_{it} - \bar{Y}_{i\bullet}$  (na všech  $n$  reziduí najednou)  $p = 6,8\%$   
[shapiro.test(resid(aov(lnCu~Misto)))]
- nebo [shapiro.test(resid(lm(lnCu~Misto)))]

## varianty zápisu modelu AR jednoduchého třídění

- **model** – idealizovaná představa o vzniku pozorované hodnoty
- měření = úroveň + náhodná „chyba“  
měření = systematická složka + náhodná složka

$$\begin{aligned} Y_{it} &= \mu_i + E_{it} \quad 1 \leq t \leq n_i, \quad 1 \leq i \leq k \\ &= \mu + (\mu_i - \mu) + E_{it} \quad E_{it} \text{ nezávislé} \\ &= \mu + \alpha_i + E_{it} \quad E_{it} \sim N(0, \sigma^2) \end{aligned}$$

- **reparametrisace** ( $\alpha_i$  – efekty faktoru  $A$ ):

$$\sum_{i=1}^k \alpha_i = 0$$

- $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_k$  (totéž jako  $\mu_1 = \mu_2 = \dots = \mu_k$ )
- pro  $k = 2$  je  $F_A = T^2$  (vztah s dvouvýběrovým  $t$ -testem)

## mnohonásobná srovnání

(Tukeyův test, Kramerova verze)

- nutnost zachovat zvolenou hladinu testu i při současném rozhodování o řadě hypotéz  
(např. že  $\mu_1 = \mu_2$ ,  $\mu_1 = \mu_3$ ,  $\mu_2 = \mu_3$ , ...)
- které dvojice úrovní faktoru (stř. hodnoty  $\mu$ ; resp. efekty  $\alpha_i$ ) se liší?

$$|\bar{Y}_{i\bullet} - \bar{Y}_{j\bullet}| \geq q_{k,n-k}(1-\alpha) \sqrt{\frac{S^2}{2} \left( \frac{1}{n_i} + \frac{1}{n_j} \right)}$$

kde  $q_{k,n-k}(1-\alpha)$  je tabelovaná kritická hodnota

$$S^2 = \frac{S_e}{f_e} = \frac{\sum \sum (Y_{it} - \bar{Y}_{i\bullet})^2}{n - k}$$

## příklad játra

místo	počet	průměr	efekt	směr. odchylka
A	7	0,568	0,206	0,312
B	7	0,484	0,121	0,279
C	7	0,495	0,133	0,318
D	7	-0,063	-0,426	0,290
E	7	0,329	-0,034	0,144
celkem	35	0,363	0,000	0,104

$$q_{5,30}(0,95) \sqrt{\frac{0,0762}{2} \left( \frac{1}{7} + \frac{1}{7} \right)} = 4,10 \cdot 0,104 = 0,428$$

$-0,063 + 0,428 = 0,365 \Rightarrow$  na 5% hladině se místa D s nejmenším průměrem liší všechna místa s průměry aspoň 0,365, tedy místa A, B, C, nikoliv E

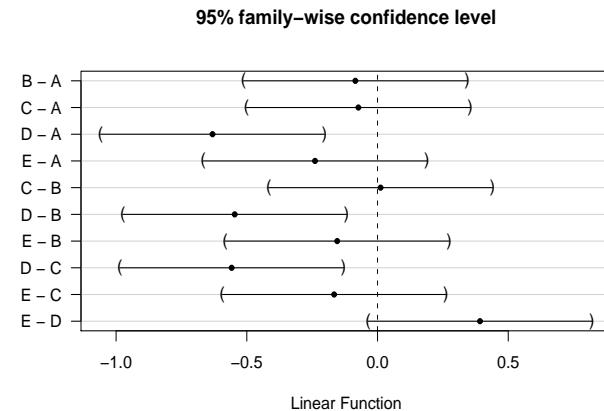
[TukeyHSD(aov(lnCu~Misto,data=Med))]

## příklad játra

funkce [TukeyHSD(aov(lnCu~Misto,data=Med))]

dá tabulku porovnání všech dvojic

pomocí knihovny Rcmdr dostaneme také graf



## Kruskal-Wallisův test

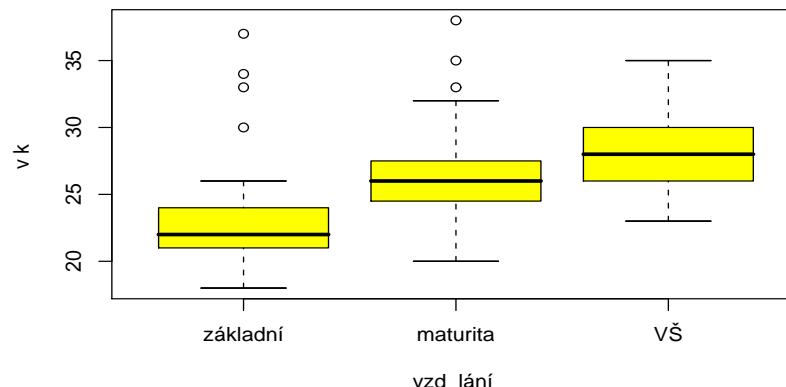
(neparametrický test)

- ▶ zobecnění dvouvýběrového Wilcoxonova testu (použije opět pořadí místo původních hodnot)
- ▶ předpoklady:
  - ▶  $k$  nezávislých výběrů
  - ▶ spojitá rozdělení
- ▶  $H_0$ : rozdělení jsou stejná (tedy i mediány jsou stejné)
- ▶  $T_i$  - součet pořadí v  $i$ -té výběru

$$Q = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{T_i^2}{n_i} - 3(n+1)$$

$H_0$  se zamítá při  $Q \geq \chi_{k-1}^2(1-\alpha)$   
(velká variabilita průměrných pořadí)

## příklad kojení – věk matek podle vzdělání



je patrná nesymetrie, zejména u základního vzdělání

## příklad kojení – věk matek podle vzdělání

vzdělání	$n_i$	průměrný věk	střední chyba	součet pořadí	průměrné pořadí
základní	34	23,412	0,638	1025	30,15
maturita	47	26,278	0,543	2618	55,70
VŠ	18	28,500	0,877	1307	72,61
celk.	99	25,697		4950	50,00

$$Q = \frac{12}{99 \cdot 100} \left( \frac{1025^2}{34} + \frac{2618^2}{47} + \frac{1307^2}{18} \right) - 3 \cdot 100 = 29,25$$

$$\chi_2^2(0,05) = 5,99 \quad p < 0,0001$$

[kruskal.test(vek.m~Vzdelani,data=Kojeni)]

(přesnější hodnocení přihlíží ke shodám při určování pořadí)

## porovnání populačních měr polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový <i>t</i> -test	jednovýběrový Wilcoxon
výběr dvojic	párový <i>t</i> -test	znaménkový, Wilcoxon
dva nezávislé výběry	dvouvýběrový <i>t</i> -test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr <i>r</i> -tic	analýza rozptylu náhodné bloky	Friedman

## motivační příklad diety: váhové přírůstky za danou dobu rozšíření úlohy párového testu

vrh	dieta				průměr
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
průměr	8,56	8,06	10,28	10,58	9,370

- ▶  $r = 4$  ošetření (pevné efekty, zvolili jsme je sami)
- ▶  $k = 5$  vrhů (náhodné efekty, zvolila je náhodně příroda)
- ▶ jsou patrné rozdíly mezi průměry pro jednotlivá ošetření i pro jednotlivé vrhy
- ▶ kdyby byly jen dvě diety ( $r = 2$ ), použili bychom párový test (sourozenci možná reagují na dietu podobně)

## náhodné bloky

### normální rozdělení náhodné složky modelu

- ▶ účel: porovnat dvě nebo více **ošetření** na stejných objektech
- ▶ zobecnění **párových testů** na *r*-tice
- ▶ **náhodný blok**
  - ▶ homogenní skupina *r* objektů
  - ▶ počet objektů ve skupině = počet ošetření (nebo jeho násobek)
  - ▶ ošetření se přiřadí uvnitř bloku **náhodně** (každému ošetření stejný počet objektů)
- ▶ bloky – náhodné efekty  $A_i \sim N(0, \sigma_A^2)$  (vliv bloku)  
ošetření – pevné efekty  $\beta_j$  ( $\sum_{j=1}^r \beta_j = 0$ ) (vliv ošetření)

$$Y_{ij} = \mu + A_i + \beta_j + E_{ij}, \quad E_{ij} \sim N(0, \sigma^2) \quad j = 1, \dots, r; i = 1, \dots, k$$

předpokládá se **aditivní** vliv, symbolicky zapisovaný  $A + B$   
(vliv ošetření je stejný při různých hodnotách  $A_i$ )

## náhodné bloky

- ▶ testované hypotézy
  - ▶  $H_B : \beta_1 = \dots = \beta_r = 0$  (ošetření *B* nemá vliv)
  - ▶ případně  $H_A : \sigma_A^2 = 0$  (nulová variabilita mezi bloky)
- ▶ rozklad variability
- ▶  $S_T = S_A + S_B + S_e$
- ▶ vliv dvou faktorů
  - ▶ A – náhodný: nastavuje příroda, při opakování pokusu budou úrovně jiné
  - ▶ B – pevný: nastavuje experimentátor, při opakování pokusu budou úrovně stejné
  - ▶ rozhodování zda A je pevný nebo náhodný efekt závisí na cíli výzkumu, na interpretaci

## příklad diety

- tabulka ANOVA (správná)

variabilita	<i>S</i>	<i>f</i>	<i>S/f</i>	<i>F</i>	<i>p</i>
vrhy	91,932	4	22,983	(22,26)	(<0,0001)
dieta	23,322	3	7,774	7,53	0,0043
reziduální	12,388	12	1,032	-	-
celk.	127,642	19	-	-	-

- na 5% hladině jsme prokázali rozdíl mezi dietami ( $p = 0,4\%$ )
- variabilita mezi vrhy je také průkazná ( $p < 0,1\%$ )
- `[summary(aov(prirustek~Error(Vrh)+Dieta,data=Mysi))]`
- pro takto jednoduchý model vyjde tabulka stejně i když považujeme faktor A za pevný (nenáhodný); porovnáváme pak konkrétních pět vrhů, vrhy nechápeme jako vzorek všech možných vrhů

## příklad diety

- kdybychom **nesprávně** nevzali v úvahu závislost některých pozorování způsobenou náhodnými bloky (vrhy), dostali bychom model ANOVA jednoduchého třídění

variabilita	<i>S</i>	<i>f</i>	<i>S/f</i>	<i>F</i>	<i>p</i>
dieta	23,332	3	7,774	1,193	0,344
reziduální	104,320	16	6,520	-	-
celk.	127,642	19	-	-	-

- `[summary(aov(prirustek~Dieta,data=Mysi))]`
- porovnání se správnou tabulkou analýzy rozptylu

$$S_e = 91,932 + 12,388 = 104,320, \quad f_e = 4 + 12 = 16$$

## Friedmanův test, zobecnění znaménkového testu

(neparametrický test, bez předpokladu normality)

- model  $Y_{ij} = \mu + A_i + \beta_j + E_{ij}$  (náhodný řádkový efekt)  
nebo  $Y_{ij} = \mu + \alpha_i + \beta_j + E_{ij}$  (pevný řádkový efekt,  
jde vlastně o **dvojně třídění bez interakcí**)
  - $E_{ij}$  nezávislé, spojité rozdělení (nemusí být normální)
  - $H_0 : \beta_1 = \dots = \beta_r$  (nezávisí na ošetření)
  - určí pořadí v rámci každého bloku (řádku)  $R_{ij}$
  - za hypotézy je v každém řádku náhodná permutace čísel  $1, \dots, r$ , součty ve sloupcích (pro ošetření) jsou podobné
  -
- $$Q = \frac{12}{kr(r+1)} \sum_{j=1}^r \left( \sum_{i=1}^k R_{ij} \right)^2 - 3k(r+1)$$
- zamítat  $H_0$ : pro  $Q \geq \chi^2_{r-1}(1-\alpha)$

## příklad diety

`[friedman.test(prirustek~Dieta|Vrh,data=Mysi)]`

vrh	dieta				prům.
	A	B	C	D	
1	6,6	5,2	7,4	9,1	7,075
2	10,1	11,4	13,0	12,6	11,775
3	5,8	4,2	9,5	8,8	7,075
4	12,1	10,7	11,9	13,0	11,925
5	8,2	8,8	9,6	9,4	9,000
prům.	8,56	8,06	10,28	10,58	9,370

vrh	dieta				součet
	A	B	C	D	
1	2	1	3	4	
2	1	2	4	3	
3	2	1	4	3	
4	3	1	2	4	
5	1	2	4	3	
součet	9	7	17	17	

$$k = 5$$

$$r = 4$$

$$Q = \frac{12}{5 \cdot 4 \cdot 5} (9^2 + 7^2 + 17^2 + 17^2) - 3 \cdot 5 \cdot 5 = 9,96$$

$$Q > \chi^2_3(0,95) = 7,8147$$

$$p = 0,0189$$

## dvojné třídění s interakcemi

motivační příklad Howells

údaje zjištěné na exhumovaných lebkách

- ▶ místo: Austrále (AUSTR), Rakousko (BERG), Sibiř (BURIAT)
- ▶ pohlaví: M, F
- ▶ vysvětlované znaky:
  - ▶ největší délka mozkovny GOL
  - ▶ týlní úhel OCA
- ▶ bude rozdíl mezi pohlavími na všech místech stejný?
  - ▶ pokud ano (vliv je aditivní, **dvojné tř. bez interakcí**)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + E_{ijt}$$

- ▶ pokud ne (vliv není aditivní, rozdíl závisí na místě)

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt}$$

## testy ve dvojném třídění

- ▶  $H_{AB} : \gamma_{ij} = 0$  (**aditivita** obou faktorů, interakcí netřeba)
  - vliv úrovně faktoru A je stejný při všech úrovních faktoru B
  - vliv úrovně faktoru B je stejný při všech úrovních faktoru A
  - (vliv pohlaví je stejný na všech místech)
- ▶  $H_A : \alpha_i = 0$ : faktor A nemá vliv (nezáleží na místu)
- ▶  $H_B : \beta_j = 0$ : faktor B nemá vliv (nezáleží na pohlaví)
- ▶ pokud zamítneme  $H_{AB}$ , nemá smysl testovat  $H_A, H_B$ , neboť prostřednictvím interakcí oba faktory vliv mají
- ▶ v takovém případě je lépe přejít k modelu jednoduchého třídění s kombinovanými úrovněmi

## dvojné třídění s interakcemi

opět **normální rozdělení**, oba faktory **pevné**

- ▶ vliv dvou faktorů nemusí být aditivní ( $1 \leq t \leq T$ )

$$Y_{ijt} = \mu + \alpha_i + \beta_j + \gamma_{ij} + E_{ijt} \quad E_{ijt} \sim N(0, \sigma^2)$$

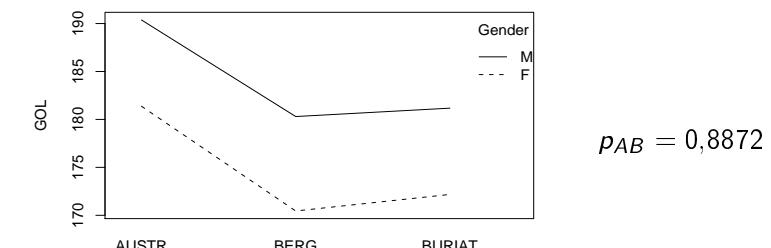
- ▶ symbolicky  $A + B + AB$
- ▶  $\sum_i \alpha_i = 0$  (reparametizační podmínka)  
**efekty** faktoru A odpovídající jeho  $k$  úrovním
- ▶  $\sum_j \beta_j = 0$  (reparametizační podmínka)  
**efekty** faktoru B odpovídající jeho  $r$  úrovním
- ▶  $\sum_i \gamma_{ij} = 0, \sum_j \gamma_{ij} = 0$  (reparametizační podmínka)  
**interakce** vyjadřují neaditivitu obou faktorů  
(vliv A závisí na úrovni B, vliv B závisí na úrovni A), pak dvojné třídění bez interakcí (s opakováním pro  $T > 1$ )

## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme největší délku mozkovny GOL

`[anova(lm(gol~Gender*Popul))]`  
`[anova(lm(gol~Gender+Popul+Gender:Popul))]`

nebo



## příklad Howells (GOL)

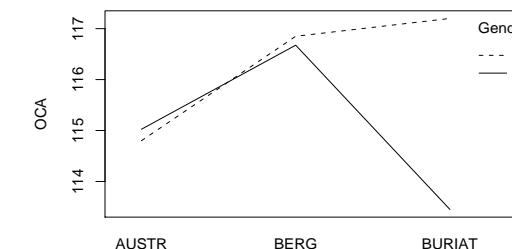
pohlaví	místo	$n_{ij}$	$\bar{y}_{ij}$	$s_{ij}$
M	Berg	40	180,300	7,293
F	Berg	40	170,450	6,641
M	Austrálie	40	190,375	5,555
F	Austrálie	40	181,375	6,632
M	Sibiř	40	181,175	6,468
F	Sibiř	40	172,175	5,228

variabilita	$S$	$f$	$S/f$	$F$	$p$
místa	5242,1	2	2621,1	65,2	<0,0001
pohlaví	5170,8	1	5170,8	128,6	<0,0001
interakce	9,6	2	4,8	0,1	0,8872
reziduální	9410,6	234	40,2		
celková	19833,2	239			

## příklad Howells

- ▶ lebky exhumované na třech místech (A)
- ▶ lebky jsou rozlišovány podle pohlaví (B)
- ▶ měříme týlní úhel OCA

[anova(lm(oca~Gender\*Popul))]  
[anova(lm(oca~Gender+Popul+Gender:Popul))]



$$p_{AB} = 0,0222$$

nebo

## příklad Howells (OCA)

pohlaví	místo	$n_{ij}$	$\bar{y}_{ij}$	$s_{ij}$
M	Berg	40	116,675	5,567
F	Berg	40	116,850	5,682
M	Austrálie	40	115,025	4,382
F	Austrálie	40	114,800	4,286
M	Sibiř	40	113,450	4,782
F	Sibiř	40	117,200	4,973

variabilita	$S$	$f$	$S/f$	$F$	$p$
místa	150,908	2	75,454	3,05	0,0493
pohlaví	91,267	1	91,267	3,69	0,0560
interakce	191,608	2	95,804	3,87	0,0222
reziduální	5789,550	234	24,742		
celková	6223,333	239			

## porovnání populačních měr polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový $t$ -test	jednovýběrový Wilcoxon
výběr dvojic	párový $t$ -test	znaménkový, Wilcoxon
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney (Kolmogorov-Smirnov)
$k$ nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr $r$ -tic	analýza rozptylu náhodné bloky	Friedman

## vyšetřování závislosti

nezávisle proměnná (é)	závisle proměnná	
	spojitá	nominální
spojitá	regrese korelace	logistická regrese
nominální	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů

## korelace a regrese

[correlation, regression]

### ▶ korelace (dvojice náhodných veličin)

- ▶ měří sílu (těsnost) vzájemné závislosti spojitych veličin
- ▶ lze použít k prokazování existence vzájemné závislosti  $X, Y$
- ▶ k porovnávání síly (těsnosti) závislosti v několika populacích
- ▶ symetrická vlastnost veličin  $X$  a  $Y$

### ▶ regrese (náhodná veličina na nenáhodné veličině)

- ▶ udává jak závisí střední hodnota spojité veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
- ▶ nesymetrická vlastnost:  $(záv. Y na x) \neq (záv. X na y)$
- ▶ lze použít k prokazování existence závislosti závisle proměnné  $Y$  na nezávisle proměnné  $x$
- ▶ umožňuje předpovídat stř. hodnotu  $Y$  pro zvolenou hodnotu  $x$

## korelační koeficient

(rozlišuj výběrový a populační korelační koeficient)

- ▶ (populační) korelační koeficient  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$  (str. 82)
  - ▶  $|\rho_{XY}| \leq 1$
  - ▶ pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - ▶ konstanta, která měří sílu lineární závislosti
- ▶ (výběrový) korelační koeficient  $r_{xy}$  (zaveden na obr. 37)

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2} \sqrt{\sum (Y_i - \bar{Y})^2}}$$

- ▶ náhodná veličina (závisí na datech)
- ▶ odhaduje populační korelační koeficient  $\rho_{XY}$
- ▶ přesnost odhadu závisí na  $n$
- ▶ alternativní označení: Pearsonův korelační koeficient, momentový korelační koeficient, [correlation coefficient]

## dokazování závislosti $X, Y$

- ▶ k prokázání závislosti je nutné normální rozdelení ( $X, Y$ )
- ▶  $H_0 : X, Y$  nezávislé (tedy  $\rho_{XY} = 0$ ) se na hladině  $\alpha$  zamítá:

$$T = \frac{r}{\sqrt{1 - r^2}} \sqrt{n - 2}, \quad |T| \geq t_{n-2}(1 - \alpha/2)$$

( $r$  je dost daleko od nuly)

### ▶ Spearmanův korelační koeficient

- ▶ měří sílu monotonní závislosti (nejen lineární závislosti)
- ▶ místo hodnot  $X_i, Y_i$  použije jejich pořadí  $R_i, Q_i$
- ▶ lze upravit na tvar

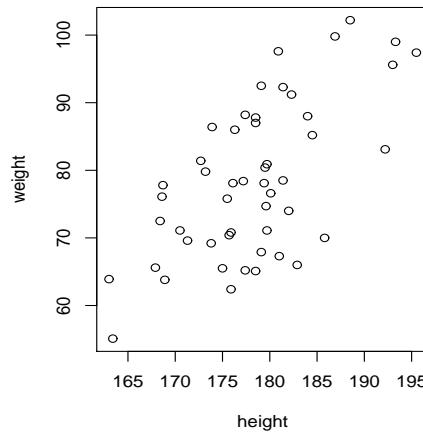
$$r_{XY}^{(S)} = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n (R_i - Q_i)^2$$

- ▶ k testu nezávislosti nepotřebuje normální rozdelení
- ▶  $H_0$ : (nezávislost) se zamítá, je-li  $|r_{XY}^{(S)} \sqrt{n - 1}| \geq z(1 - \alpha/2)$

## závislost váhy a výšky u mužů

data: Policie

[plot(weight~height)]



[cor.test(weight,height)]

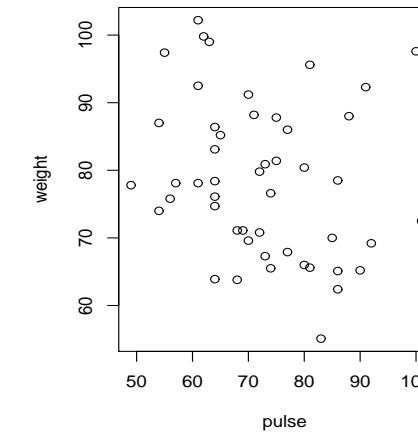
$$\begin{aligned} r &= 0,648 \\ t &= 5,814 \\ p &< 0,001 \end{aligned}$$

## závislost váhy a pulsu u mužů

data: Policie

[cor.test(pulse,weight)]

[plot(weight~pulse)]



## Fisherova z-transformace

(přiblíží rozdělení výběrového korelačního koeficientu  $r$  normálnímu rozdělení)

$$Z = \frac{1}{2} \ln \frac{1+r}{1-r} \sim N\left(\frac{1}{2} \ln \frac{1+\rho}{1-\rho}, \frac{1}{n-3}\right)$$

## test shody dvou nezávisle odhadovaných korel. koeficientů

příklad **Kojeni**: výška rodičů chlapců a dívek

$$\text{dívky: } r_1 = 0,279, n_1 = 50, z_1 = \frac{1}{2} \ln \frac{1+0,279}{1-0,279} = 0,286$$

$$\text{hoši: } r_2 = 0,150, n_2 = 49, z_2 = \frac{1}{2} \ln \frac{1+0,150}{1-0,150} = 0,151$$

► test  $H_0 : \rho_1 = \rho_2$  proti  $H_1 : \rho_1 \neq \rho_2$ 

$$z = \frac{0,286 - 0,151}{\sqrt{\frac{1}{50-3} + \frac{1}{49-3}}} = 0,650.$$

srovnej s kritickou hodnotou  $z(1 - 0,05/2) = 1,960$ ,  
 $p = 51,6\%$

interval spolehlivosti pro  $\rho$ opět potřebujeme normální rozdělení  $(X, Y)$ 

► ve dvou krocích:

- interval spolehlivosti pro  $\zeta = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$
- pomocí inverzní transformace pak int. spol. pro  $\rho$
- takto postupuje funkce cor.test(), např.  
`[cor.test(~vyska.o+vyska.m,subset=HochL,data=Kojeni)]`

► interval spolehlivosti

► náš příklad:

skupina	$r$ (bodový odhad)	95% int. spol. pro $\rho$	$p$
dívky	0,279	(0,000; 0,517)	5,01 %
hoši	0,150	(-0,137; 0,414)	30,3 %

► u chlapců nelze prokázat na 5% hladině závislost

► u děvečat je závislost na 10% hladině průkazná, na 5% hladině těsně nikoliv (interval spolehlivosti je jen přibližný!)

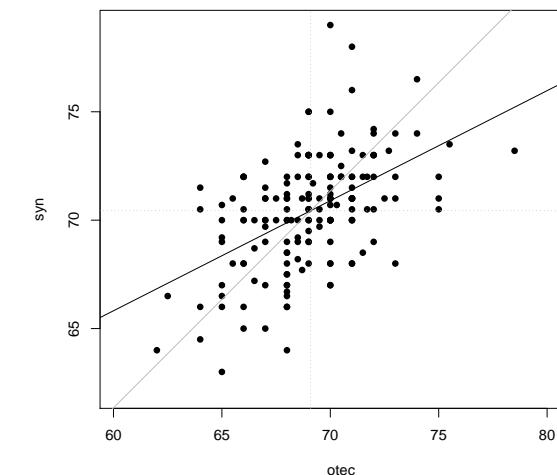
## regrese

(původ pojmu)

- ▶ tendence (návrat) k průměrnosti  
F. Galton (1886) vyšetřoval dědičnost výšky postavy
- ▶ uvažujme otce, jejichž výška je rovna průměrné výšce generace **všech** otců; průměrná výška synů otců této výšky bude rovna průměrné výšce **všech** synů
- ▶ uvažujme otce o 10 cm **vyšší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen asi o 5 cm **vyšší**, než průměrná výška generace synů
- ▶ uvažujme otce o 10 cm **nížší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen o asi 5 cm **nížší**, než průměrná výška generace synů
- ▶ průměrné výšky synů nereprodukují celou odchylku výšky otce od průměru, je tu návrat k průměru (regrese)

## Závislost výšky syna na výšce otce

výšky v ang. palcích, Galtonova data, ke každému otci náhodně vybrán jeden z jeho synů proložena přímka:  $y = 35,4 + 0,5x$ , pro porovnání šedivé přímka s jednotkovou směrnicí



## regresní přímka

- ▶ **předpokládaná** závislost střední hodnoty  $Y$  na nenáhodné  $x$ :

$$Y_i = \beta_0 + \beta_1 x_i + E_i, \quad E_i \sim N(0, \sigma^2)$$

- ▶  $Y_i$  = systematická složka  $(\beta_0 + \beta_1 x_i)$  + náhodná složka  $(E_i)$

- ▶ k daným  $x_1, \dots, x_n$  zjistíme  $Y_1, \dots, Y_n$

- ▶ předpoklady:

- ▶ **nezávislá** pozorování  $Y_1, \dots, Y_n$  (tedy také  $E_1, \dots, E_n$ )
- ▶ **stejný** rozptyl  $\sigma^2$
- ▶ **normální** rozdělení  $E_1, \dots, E_n$  (potřebné až pro testy, normalitu nelze ověřovat testováním přímo  $Y_1, \dots, Y_n$ !)

- ▶ neznámé populační parametry  $\beta_0, \beta_1$  odhadujeme metodou **nejmenších čtverců**:

minimalizovat přes  $\beta_0, \beta_1$  výraz  $\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$

- ▶ odhady označíme  $b_0, b_1$

## Metoda nejmenších čtverců



## metoda nejmenších čtverců

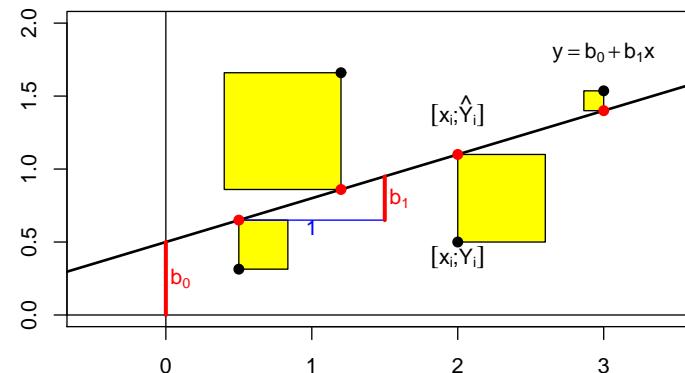
odhadovaná závislost:  $y = \beta_0 + \beta_1 \cdot x$  (populace)

odhad závislosti:  $y = b_0 + b_1 \cdot x$  (výběr)

$i$ -tá vyrovnaná hodnota:  $\hat{Y}_i = b_0 + b_1 \cdot x_i$  (výběr)

$i$ -té reziduum:  $U_i = Y_i - \hat{Y}_i$  (výběr)

celková plocha čtverců:  $S_e = \sum_{i=1}^n U_i^2$  (výběr)



►  $b_1$  – odhad směrnice  $\beta_1$

►  $b_1 = (b_0 + b_1(x+1)) - (b_0 + b_1x)$   
– odhad změny střední hodnoty závisle proměnné  $Y$   
při jednotkové změně nezávisle proměnné  $x$

►  $i$ -té reziduum  $U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1x_i)$

►  $Y_i = \hat{Y}_i + U_i$

► (vysvětlováno)=(vysvětleno závislost)+(nevysvětleno)

► **reziduální součet čtverců** (nevysvětlená variabilita):

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1x_i)^2 = \sum_{i=1}^n U_i^2$$

► **reziduální rozptyl** (odhad rozptylu  $\sigma^2$ )

$$S^2 = \frac{S_e}{n-2}$$

## alternativní formulace

► uvažovanou závislost lze psát ve tvaru

$$\begin{aligned} Y_i &= (\beta_0 + \beta_1 \bar{x}) + \beta_1(x_i - \bar{x}) + E_i \\ &= \beta_0^* + \beta_1(x_i - \bar{x}) + E_i \end{aligned}$$

- $\beta_0^*$  vyjadřuje střední úroveň vysvětlované proměnné  $Y$  při průměrné hodnotě nezávisle proměnné  $x$
- $\beta_1$  vyjadřuje citlivost, s jakou reaguje střední hodnota vysvětlované proměnné  $Y$  na jednotkovou odchylku nezávisle proměnné  $x$  od jejího průměru  $\bar{x}$
- $E_i$  vyjadřuje náhodnou složku  $i$ -tého pozorování,  
 $E_i \sim N(0, \sigma^2)$
- odhadem závislosti je ( $b_1$  je stejně jako při klasickém vyjádření)  
 $\hat{Y}_i = \bar{Y} + b_1(x_i - \bar{x})$

## prokazování závislosti

- modelujeme závislost  $E Y$  na  $x$  pomocí  $E Y = \beta_0 + \beta_1 x$
- nezávislost  $y = \beta_0 + \beta_1 x$  na  $x$  znamená  $\beta_1 = 0$
- hypotézu  $H_0 : \beta_1 = 0$  testujeme pomocí statistiky

$$T = \frac{b_1}{S.E.(b_1)}$$

- hypotézu zamítáme, je-li  $|T| \geq t_{n-2}(1 - \alpha/2)$   
tj. je-li příslušná  $p$ -hodnota  $\leq \alpha$
- pokud  $H_0$  zamítнемe, říkáme, na hladině  $\alpha$  je **závislost průkazná**

## příklad závislost procenta tuku na výšce

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	-53,870	24,657	-2,185	0,0338
height	0,379	0,138	2,742	0,0086

- ▶ předpověď:  $\hat{Y}_i = -53,870 + 0,379 \cdot x_i$ ;
- ▶  $\hat{fat} = -53,870 + 0,379 \cdot height$
- ▶ závislost procenta tuku na výšce je na 5% hladině průkazná, neboť  $p = 0,0086$  %
- ▶ na každý centimetr výšky v průměru přibude 0,379 procentního bodu tuku
- ▶ [summary(lm(fat~height))]

## koeficient determinace

[coefficient of determination]

- ▶ podíl variability  $Y$  vysvětlené uvažovanou závislostí (jakou část variability  $Y$  se podařilo závislosti na  $x$  vysvětlit)

▶

$$\begin{aligned} R^2 &= \frac{\text{variabilita vysvětlená}}{\text{variabilita vysvětlovaná}} = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \\ &= 1 - \frac{\text{variabilita nevysvětlená}}{\text{variabilita vysvětlovaná}} = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y})^2} \\ &= 1 - \frac{S_e}{\sum(Y_i - \bar{Y})^2} \end{aligned}$$

- ▶  $R^2$  je bezrozměrné číslo, často vyjádřeno v procentech
- ▶  $R^2$  ukazuje, zda má smysl předpovídat pomocí regrese
- ▶ v případě regresní přímky je  $R^2 = r_{XY}^2$

## tabulka analýzy rozptylu

varia-	součet	st.	prům.	$F$	$p$
bilita	čtverců	vol.	čtverec		
regrese	362,54	1	362,54	7,519	0,0086
rezid.	2314,41	48	48,22		
celk.	2676,95	49	(54,63)		

- ▶  $s^2 = 48,22$
- ▶  $R^2 = \frac{362,54}{2676,95} = 1 - \frac{2314,41}{2676,95} = 0,135$
- ▶ závislost na výšce jsme vysvětlili jen 13,5 % variability procenta tuku
- ▶ [anova(lm(fat~height))]

## mnohonásobná lineární regrese

- ▶ závislost na dvou (nebo více) nezávisle proměnných
- ▶ pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- ▶ představa (model)

$$Y_i = \underbrace{\beta_0 + \beta_1 x_i + \beta_2 v_i}_{E Y_i} + E_i$$

- ▶ střední hodnota  $Y_i$  (tj. systematická, nenáhodná složka  $Y_i$ ) vysvětlena pomocí  $x_i, v_i$  jako  $\beta_0 + \beta_1 x_i + \beta_2 v_i$
- ▶  $E_1, \dots, E_n$  (také  $Y_1, \dots, Y_n$ ) jsou **nezávislé** náhodné veličiny
- ▶  $E_i \sim N(0, \sigma^2)$  (normální rozdělení se stejným rozptylem)
- ▶  $\beta_0, \beta_1, \beta_2$  – odhadování parametrů  $\beta_0, \beta_1, \beta_2$

## interpretace

- ▶  $b_1$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $x$  a **nezměněné** hodnotě  $v$
- ▶  $b_2$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $v$  a **nezměněné** hodnotě  $x$
- ▶  $U_i$  – **reziduum**

$$U_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1 x_i + b_2 v_i)$$

- ▶ **rozklad variability**  $S_T = S_R + S_e$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

## koeficient determinace

- ▶ **koeficient determinace**  $R^2$   
podíl celkové variability, který se podařilo vysvětlit závislostí  $Y$  na  $x$  a  $v$  (jakou část variability  $Y$  se podařilo vysvětlit)

$$R^2 = \frac{S_R}{S_T} = 1 - \frac{S_e}{S_T}$$

- ▶  $H_0 : \beta_1 = \beta_2 = 0$  (chování  $Y$  nezávisí ani na  $x$  ani na  $v$ )

$$F = \frac{S_R/2}{S_e/(n-3)} \geq F_{2,n-3}(1-\alpha)$$

- ▶  $p$ -hodnota tohoto testu bývá uváděna spolu s  $R^2$

## testy o přínosu jednotlivých regresorů

- ▶ model  $y = \beta_0 + \beta_1 x + \beta_2 v$
- ▶  $H_0 : \beta_2 = 0$   
k vysvětlení chování  $Y$  stačí  $x$ , tj.  $y = \beta_0 + \beta_1 x$

$$T_2 = \frac{b_2}{S.E.(b_2)}, \quad \text{zamítat pro } |T_2| \geq t_{n-3}(1-\alpha/2)$$

- ▶  $H_0 : \beta_1 = 0$   
k vysvětlení chování  $Y$  stačí  $v$ , tj.  $y = \beta_0 + \beta_2 v$

$$T_1 = \frac{b_1}{S.E.(b_1)}, \quad \text{zamítat pro } |T_1| \geq t_{n-3}(1-\alpha/2)$$

- ▶  $H_0 : \beta_0 = 0$  zpravidla nemá reálný smysl

## příklad: závislost procenta tuku na výšce a váze

data: Policie

regresor	$b_j$	S.E.( $b_j$ )	$t$	$p$
abs. člen	11,327	16,682	0,679	0,5005
height	-0,262	0,110	-2,376	0,0216
weight	0,624	0,0690	9,050	<0,0001

- ▶ `[summary(lm(fat~height+weight))]`
- ▶ při **stejně výšce** očekáváme na každý kg hmotnosti o 0,6 proc. bodu více tuku
- ▶ u mužů, kteří se liší výškou o 10 cm a **mají stejnou hmotnost** očekáváme, že ti vyšší mají v průměru o 2,6 proc. bodu **méně** tuku
- ▶ na 5% hladině nelze vyloučit výšku, průkazně přispívá k vysvětlení pomocí váhy
- ▶ na 1% hladině nelze vyloučit váhu, průkazně přispívá k vysvětlení pomocí výšky

## tabulka analýzy rozptylu

(*F*-statistika je v `summary()`, v commanderu nutno zvolit typ I a přínosy regresorů sečítat)

variabilita	souč. čtv.	st. vol.	prům. čtv.	<i>F</i>	<i>p</i>
regrese	1833,11	2	916,55	51,050	<0,001
rezid.	843,85	47	17,95		
celk.	2676,95	49	(54,63)		

- ▶  $R^2 = 1833,11/2676,95 = 1 - 843,85/2676,95 = 0,685$
- ▶ závislostí na výšce a váze jsme vysvětlili 68,5 % variability procenta tuku
- ▶  $s^2 = 17,95$
- ▶ na každé rozumné hladině zamítáme hypotézu, podle které procento tuku nezávisí ani na výšce ani na váze

## regresní diagnostika

zda byly splněny předpoklady

- a) zvolili jsme správně **tvar závislosti**?
- b) je **rozptyl** všude **stejný**?
- c) je přiměřeně splněn předpoklad o **normálním rozdělení**?
- d) jsou opravdu pozorování **nezávislá**?  
problém často tam, kde působí čas
- ▶ k odstranění problémů s body a), b), c) často pomůže transformace, např. logaritmování závisle proměnné
- ▶ `[plot(lm(fat~height+weight))]`

## vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	(logistická regrese)
<b>nominální</b>	analýza rozptylu	<b>kontingenční tabulky</b>

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztočku
- ▶ barva očí a barva vlasů

## hodnocení kvalitativních znaků

- ▶ znaky v **nominálním** měřítku
- ▶ někdy i v ordinálním měřítku, ale uspořádání zde přehlížíme
- ▶ postupy pro ordinální znaky existují, ale zde není pro ně čas
- ▶ **příklady**
  - ▶ počty osob s krevními skupinami A, B, AB, 0
  - ▶ počty dětí narozených v jednotlivých měsících v Praze
  - ▶ počty matek se základním, středním, vysokoškolským vzděláním
- ▶ statistické jednotky třídíme podle hodnoty nominálního znaku do *k* neslučitelných kategorií
- ▶ výsledkem je *k*-tice (náhodný vektor) četností
- ▶ modelem pro tento vektor je multinomické rozdělení

## multinomické rozdělení

příklad: hod hrací kostkou,  $k = 6$

- ▶ v dílčím pokusu  $k$  možných výsledků (jevů)  $A_1, \dots, A_k$
- ▶  $A_1, \dots, A_k$  jsou neslučitelné jevy, sjednocení všech je jev jistý
- ▶  $\pi_j$  je pravděpodobnost, že vyjde  $A_j$  ( $\pi_1 + \pi_2 + \dots + \pi_k = 1$ )
- ▶  $n$  nezávislých dílčích pokusů ( $n$  opakování)
- ▶  $N_j$  – počet dílčích pokusů, kdy nastalo  $A_j$
- ▶  $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
- ▶ **pravděpodobnost** toho, že  $N_1 = n_1, \dots, N_k = n_k$   
 $(n_1 + n_2 + \dots + n_k = n, \quad n_1 \geq 0, \dots, n_k \geq 0)$

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

## souvislost s binomickým rozdělením

příklad: zajímáme se jen šestku na hrací kostce

- ▶ pro  $k = 2$  jsou v dílčím pokusu jen dva možné výsledky, binomické rozdělení je speciálním případem multinomického

$$P(N_1 = n_1, N_2 = n_2) = \frac{n!}{n_1! n_2!} \pi_1^{n_1} \pi_2^{n_2}$$

je totéž jako (platí přece  $n_1 + n_2 = n$ )

$$P(N_1 = n_1) = \binom{n}{n_1} \pi_1^{n_1} (1 - \pi_1)^{n-n_1}$$

- ▶ každé  $N_j$  (samotné, proti ostatním četnostem) má binomické rozdělení, tedy

$$N_j \sim bi(n, \pi_j), \quad E N_j = n\pi_j$$

## vlastnost $\chi^2$ (chí-kvadrát), chí-kvadrát test dobré shody

( $X^2$  – velké  $\chi^2$ )

- ▶ platí pro velká  $n$ , např. pokud  $n\pi_j \geq 5$  pro všechna  $j$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j)^2}{n\pi_j} \text{ má přibližně rozdělení } \chi^2_{k-1}$$

- ▶ **chí-kvadrát test dobré shody**  $H_0: \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
 (pravděpodobnosti jsou hypotézou dány jednoznačně)
- ▶ platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $E N_j = n\pi_j^0$ :
- ▶  $H_0$  zamítáme, je-li  $X^2 \geq \chi^2_{k-1}(1 - \alpha)$ ,

$$X^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j^0)^2}{n\pi_j^0}$$

- ▶  $N_j$  – **empirické** (experimentální) četnosti,  
 $n\pi_j^0$  – **očekávané** (teoretické) četnosti
- ▶ statistika  $X^2$  (velké chí-kvadrát) porovnává empirická a očekávané četnosti (měří jejich neshodu, „vzdálenost“)

## počty studentů biologie narozených v jednotlivých měsících

**nulová hypotéza:** děti se rodí během roku rovnoměrně

[chisq.test(nj,p=c(31,28,31,30,31,30,31,31,30,31,30,31)/365)]

měsíc	$n_j$	$n\pi_j^0$	přínos k chí-kvadrát
1	11	9,43	0,2623
2	9	8,52	0,0276
3	13	9,43	1,3539
4	11	9,12	0,3861
5	8	9,43	0,2161
6	5	9,12	1,8635
7	10	9,43	0,0348
8	6	9,43	1,2461
9	13	9,12	1,6473
10	8	9,43	0,2161
11	8	9,12	0,1383
12	9	9,43	0,0194
celkem	111	111,00	7,4115

$$X^2 = 7,4115 < \chi^2_{12-1}(0,95) = 19,675 \quad p = 76,5 \%$$

## příklad: reprezentativnost výběru

(porovnat procenta v populaci a v výběru nastačí)

- ve vzorku pacientů byly počty osob s krevními skupinami 0, A, B a AB po řadě 56, 72, 54, 18 (tedy  $n = 200$ )
- ve vyšetřované populaci jsou krevní skupiny 0, A, B a AB v poměru 35 %, 35 %, 20 % a 10 % (to určuje  $H_0$ )
- v průměru** očekáváme četnosti  $200 \cdot 0,35 = 70$  (70, 40, 20)
- lze považovat tento výběr za **reprezentativní vzhledem k výskytu krevních skupin?**

$$\chi^2 = \frac{(56 - 70)^2}{70} + \frac{(72 - 70)^2}{70} + \frac{(54 - 40)^2}{40} + \frac{(18 - 20)^2}{20} = 7,96 > 7,81 = \chi^2_3(0,95) \quad p = 4,7 \%$$

- výběr **nelze** považovat za reprezentativní
- při polovičních četnostech ve výběru (28, 36, 27, 9) by vyšlo  $\chi^2 = 3,98$ ,  $p = 26,4 \%$  (lze považovat za reprezentativní)

## příklad hrách: barva květů a tvar pylových zrnek

segregace dvou typů genů (C. R. Rao: Lineární metody statistické indukce ..., str. 439)

- barva květů – purpurová : červená v poměru 3 : 1 (dáno)

- tvar pylu – oválný : kulatý v poměru 3 : 1 (dáno)

platí-li nulová hypotéza ( $H_0$  : jde o **nezávislostu** segregaci), pak čtyři možné kombinace musí být v poměru 9 : 3 : 3 : 1

barva tvar	pupuropová oválný	červená oválný	purpurová kulatý	červená kulatý	celkem
$n_j$	296	27	19	85	427
$o_j$	3843/16	1281/16	1281/16	427/16	427
$\frac{(n_j - o_j)^2}{o_j}$	12,97	35,17	46,57	127,41	222,12

$$\chi^2 = 222,12 > \chi^2_3(0,95) = 7,81$$

- nezávislost jsme **zamítli**

## příklad hrách: barva květů a tvar pylových zrnek

dodatečné ověření předpokladu známého poměru

- co způsobilo zamítnutí hypotézy?

barva	purpurová	červená	celkem
oválný tvar	296	27	323
kulatý tvar	19	85	104
celkem	315	112	427

- jsou barvy v očekávaném poměru 3 : 1?  
[chisq.test(c(315,112),p=c(3/4,1/4))]

$$\chi^2 = 0,3443 \quad p = 55,7 \%$$

- jsou tvary v očekávaném poměru 3 : 1?

$$\chi^2 = 0,0945 \quad p = 75,9 \%$$

- důvodem zamítnutí je nutně závislost

## stejný příklad, štěpný poměr neznáme

proč takto počítáme, bude časem

tvar	barva		celkem
	purpurová	červená	
oválný	296	27	323
kulatý	19	85	104
celkem	315	112	427

očekávané četnosti:

$$323 \cdot 315/427 = 238,28$$

$$104 \cdot 315/427 = 76,72$$

$$323 \cdot 112/427 = 84,72$$

$$104 \cdot 112/427 = 27,28$$

$$\chi^2 = \frac{(296 - 238,28)^2}{238,28} + \frac{(27 - 84,72)^2}{84,72} + \frac{(19 - 76,72)^2}{76,72} + \frac{(85 - 27,28)^2}{27,28} = 215,10$$

$p < 0,001$ , očekávané četnosti jsou větší, než 5

## složená nulová hypotéza (hypotéza o struktuře)

- ▶ hypotéza určuje vztahy mezi pravděpodobnostmi  $\pi_1, \dots, \pi_k$   
některé parametry zůstávají volné, je třeba je odhadnout
- ▶ příklad antigen: (Hardy-Weinberg equilibrium, nezávislost)  
model pro fenotypy AA, Aa, aa

$$P(AA) \equiv \pi_1(\theta) = \theta^2$$

$$P(Aa) \equiv \pi_2(\theta) = 2\theta(1 - \theta)$$

$$P(aa) \equiv \pi_3(\theta) = (1 - \theta)^2$$

- ▶ neurčený parametr  $\theta$  – pravděpodobnost alely A
- ▶ jsou zjištěny četnosti fenotypů  $n_1 = 18$ ,  $n_2 = 17$ ,  $n_3 = 6$   
v souladu s modelem, tj. s H-W rovnováhou?

## odhad metodou maximální věrohodnosti za $H_0$

[maximum likelihood estimate]

$$P(N_1 = n_1, N_2 = n_2, N_3 = n_3) = \frac{n!}{n_1! n_2! n_3!} (\theta^2)^{n_1} (2\theta(1-\theta))^{n_2} ((1-\theta)^2)^{n_3}$$

- ▶ najít  $\theta$  takové, aby pravděpodobnost konkrétního výsledku byla maximální možná (maximálně věrohodná)
- ▶ odhad  $\theta$  maximalizací *logaritmické věrohodnostní funkce*

$$\begin{aligned}\ell(\theta) &= \ln(P(N_1 = n_1, N_2 = n_2, N_3 = n_3)) \\ &= \ln \left( c_1 (\theta^2)^{n_1} (2\theta(1-\theta))^{n_2} ((1-\theta)^2)^{n_3} \right) \\ &= c_2 + (2n_1 + n_2) \ln \theta + (n_2 + 2n_3) \ln(1 - \theta)\end{aligned}$$

- ▶ v našem příkladu vyjde

$$\hat{\theta} = \frac{2 \cdot N_1 + N_2}{2n} \quad \left( = \frac{2 \cdot 18 + 17}{82} = 0,646 \right)$$

(počet alel A na počet „míst“ pro alely)

- ▶  $\theta$  má obecně  $q$  nezávislých složek, zde  $q = 1$   
každý odhadovaný parametr ubere jeden stupeň volnosti
- ▶  $H_0$  zamítá pokud

$$\chi^2 = \sum_{j=1}^k \frac{(N_j - n\pi_j(\hat{\theta}))^2}{n\pi_j(\hat{\theta})} \geq \chi^2_{k-1-q}(1 - \alpha)$$

- ▶ příklad:  $\chi^2 = 0,355 < \chi^2_{3-1-1}(0,95) = 3,84$   
 $p = 55,1\%$       hypotézu na 5% hladině nemůžeme zamítnout

## nezávislost nominálních znaků

příklad hráč: barva květů a tvar pylových zrnek

- ▶ nominální znak s hodnotami  $A_1, \dots, A_r$  (tvar)
- ▶ nominální znak s hodnotami  $B_1, \dots, B_c$  (barva)
- ▶  $N_{ij}$  kolikrát současně  $A_i$  a  $B_j$  (**sdružené četnosti**)
- ▶ **marginální četnosti**

$$N_{i\bullet} = \sum_{j=1}^c N_{ij} \quad N_{\bullet j} = \sum_{i=1}^r N_{ij}$$

- ▶ **nezávislost** znaků: pro všechny dvojice  $i, j$  platí

$$P(A_i \cap B_j) = P(A_i) P(B_j)$$

- ▶ charakteristika nezávislosti: z **marginálních** pstí jevů  $A_i, B_j$   
dokážeme rekonstruovat **sdružené psti** jevů  $A_i \cap B_j$

## test nezávislosti dvou kvalitativních znaků

hodnocení kontingenční tabulky

- $H_0$  : znaky jsou **nezávislé**

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(N_{ij} - o_{ij})^2}{o_{ij}}$$

- teoretické četnosti (protějšek  $N_{ij}$ ) – četnosti, které v **průměru očekáváme, platí-li hypotéza**

$$o_{ij} = n \cdot P(\widehat{A_i \cap B_j}) = n \cdot \widehat{P(A_i)} \cdot \widehat{P(B_j)} = n \cdot \frac{N_{i\bullet}}{n} \cdot \frac{N_{\bullet j}}{n} = \frac{N_{i\bullet} N_{\bullet j}}{n}$$

- nezávislost se zamítá pokud  $\chi^2 \geq \chi^2_{(r-1)(c-1)}(1-\alpha)$
- stupně volnosti  $n - 1 - q = r \cdot c - 1 - (r-1) - (c-1) = r \cdot c - r - c + 1 = (r-1)(c-1)$
- mělo by být  $o_{ij} \geq 5 \forall (i,j)$  (tj. pro všechny dvojice)

## příklad: kouření u mužů

data: lchs

### empirické sdružené a marg. četnosti

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	14	55	55	73	197
bývalý k.	11	28	44	42	125
kuřák	14	24	24	17	79
silný k.	78	189	175	106	548
celkem	117	296	298	238	949

### očekávané sdružené a marg. četnosti

vzdělání	zákl.	odb.	mat.	VŠ	celk.
nekuřák	24,3	61,4	61,9	49,4	197
bývalý k.	15,4	39,0	39,3	31,3	125
kuřák	9,7	24,6	24,8	19,8	79
silný k.	67,6	170,9	172,1	137,4	548
celkem	117	296	298	238	949

```
[chisq.test(matrix(c(14,11,14,78, 55,28,24,189, 55,44,24,175, 73,42,17,106),nr=4,nc=4))]
```

závislost jsme na 5% hladině prokázali

## příklad barva květů a tvar pylových zrnek

štěpný poměr neznáme

tvar	barva		celkem
	purpurová	červená	
oválný	296	27	323
kulatý	19	85	104
celkem	315	112	427

očekávané četnosti:

$$323 \cdot 315 / 427 = 238,28$$

$$104 \cdot 315 / 427 = 76,72$$

$$323 \cdot 112 / 427 = 84,72$$

$$104 \cdot 112 / 427 = 27,28$$

$$\chi^2 = \frac{(296-238,28)^2}{238,28} + \frac{(27-84,72)^2}{84,72} + \frac{(19-76,72)^2}{76,72} + \frac{(85-27,28)^2}{27,28} = 222,12$$

$p < 0,001$ , očekávané četnosti jsou větší, než 5

## příklad Baden

barva očí	barva vlasů				celkem
	světlá	hnědá	černá	ryšavá	
modrá	1 768	807	189	47	2 811
šedá/zelená	946	1 387	746	53	3 132
hnědá	115	438	288	16	857
celkem	2 829	2 632	1 223	116	6 800

- barva očí  $r = 3$ , barva vlasů  $c = 4$ ,  $n = 6800$

$$\circ_{11} = 2811 \cdot 2829 / 6800 = 1169 \dots$$

$$\circ_{34} = 116 \cdot 857 / 6800 = 14,62 \geq 5$$

$$\chi^2 = \frac{(1768-1169)^2}{1169} + \frac{(807-1088)^2}{1088} + \dots = 1073,5$$

$$> \chi^2_{0,95} = 12,5916$$

$$p < 0,0001$$

závislost je na každé rozumné hladině prokázána

## test homogeneity

- hodnoty znaku  $B_1, \dots, B_c$
- $r$  **nezávislých** výběrů z různých populací
- $H_0$ : populace se **nelíší**
- dál stejně jako pro nezávislost
- příklad **krevní skupiny**

populace	skupina				celkem
	0	A	B	AB	
C	121	120	79	33	353
D	118	95	121	30	364
celkem	239	215	200	63	717

$$\chi^2 = \frac{(121 - 353 \cdot 239/717)^2}{353 \cdot 239/717} + \dots = 11,742 > \chi^2_3(0,95) = 7,815$$

nejm. teoretická četnost:  $353 \cdot 63/717 = 31,02 > 5$ ,  $p = 0,8\%$

## McNemarův test (test symetrie)

nezaměňovat s testem nezávislosti!

- **párový** test pro nominální veličinu s hodnotami  $B_1, \dots, B_k$
- zjišťujeme hodnoty nominálního znaku na **stejných** objektech za **dvojích** okolností (před ošetřením, po ošetření)
- $N_{ij}$  počet objektů, u nichž první měření  $B_i$  a druhé měření  $B_j$
- **nulová hypotéza**: pravděpodobnosti možných hodnot znaku jsou **stejné** za obojích okolností (před ošetřením i po něm)

$$\chi^2 = \sum_{i < j} \sum \frac{(N_{ij} - N_{ji})^2}{N_{ij} + N_{ji}}$$

- hypotézu zamítneme při  $\chi^2 \geq \chi^2_{k(k-1)/2}(1-\alpha)$
- výrazy ve jmenovateli musí být kladné!
- nezávisí na počtu objektů, kdy vyšly oba výsledky stejně ( $N_{ii}$ )

## příklad stromy

1994	1995			celkem
	1	2	3	
1	4	3	3	10
2	7	21	11	39
3	1	15	35	51
celkem	12	39	49	100

- stav týchž stromů ve dvou sezónách
- celkem 100 stromů

$$\chi^2 = \frac{(3-7)^2}{3+7} + \frac{(3-1)^2}{3+1} + \frac{(11-15)^2}{11+15} = 3,215$$

- $\chi^2_3(0,95) = 7,8147$ ,  $p = 36,0\%$
- rozdíl mezi sezónami jsme neprokázali
- `[mcnemar.test(matrix(c(4,7,1,3,21,15,3,11,35),3,3))]`

## případ malých četností

- je-li některá očekávaná četnost malá, pak lze u čtyřpolní tabulky použít upravený postup: **Yatesova korekce**

$$\chi^2_Y = \frac{n(|ad - bc| - n/2)^2}{(a+c)(b+d)(a+b)(c+d)}$$

- Fisherův exaktní test** počítá přímo dosaženou hladinu  $p$
- pro tabulku s velkými četnostmi je výpočet Fisherova testu výpočetně náročný (paměťové nároky, trvání výpočtu)
- existuje zobecnění Fisherova testu i pro větší tabulky, než je čtyřpolní

## komplexní příklad hraboš

<i>Frenkelia spp.</i>	<i>Sarcocystis spp.</i>		celkem
	+	-	
+	4	27	31
-	11	473	484
celkem	15	500	515

- souvisí spolu nákazy dvěma cizopasníky?

- nulová hypotéza: **nezávislost**

$$\chi^2 = \frac{515(4 \cdot 473 - 11 \cdot 27)^2}{15 \cdot 500 \cdot 31 \cdot 484} = 11,643, \quad p = 0,06 \%$$

- nejmenší očekávaná četnost:  $15 \cdot 31 / 515 = 0,9 < 5$
- [`chisq.test(matrix(c(4,11,27,473),2,2),correct=FALSE)`]

## příklad hraboš

- Yates:**  $\chi^2 = 8,187 \quad p = 0,42 \%$   
[`chisq.test(matrix(c(4,11,27,473),2,2))`]
- Fisherův test:**  $p = 0,92 \%$   
[`fisher.test(matrix(c(4,11,27,473),2,2))`]
- na 5% hladině závislost **prokázána**
- vyskytuje se dvojí cizopasníci se stejnou pestí?**  
(zcela jiná otázka, než na nezávislost)
- odpověď dá McNemarův test:

$$\chi^2 = \frac{(11 - 27)^2}{11 + 27} = 6,7368, \quad p = 0,94 \%$$

[`mcnemar.test(matrix(c(4,11,27,473),2,2),correct=FALSE)`]

## jak statistiku použijeme

- co o problému zjistili jiní? (přečti, sepiš)
- co chceš zjistit?
  - zformuluj otázku (to určí možné statistické metody)
  - zformuluj nulovou a alternativní hypotézu
- zvol hladinu testu  $\alpha$
- zvol rozsah výběru (přesnost, délka int. spolehlivosti, síla testu)
- poříd data
  - proved' měření (podrobné záznamy!)
  - převed' do elektronické formy (kódování)
  - vyčisti data (grafy, popisné statistiky, ...)
- proved' výpočty, kresli grafy
- použij výsledky a grafy, interpretuj

## dvojí původ dat

### ► plánovaný (organizovaný) pokus

- ▶ aktivně zasahujeme
- ▶ fixujeme okolnosti (stálá teplota, světelný režim)
- ▶ nastavujeme úrovně zvoleného faktoru (např. živné roztoky)
- ▶ jedincům náhodně přiřazujeme ošetření
- ▶ zjistíme-li rozdíl, známe jeho příčinu

### ► šetření (sledování dění)

- ▶ pouze sledujeme, nezasahujeme
- ▶ rozdíl mezi porovnávanými skupinami může být způsoben matoucí (**confounding**) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem (příklad: plánované těhotenství na vzdělání matky, matoucí veličinou je věk matky)
- ▶ rozdělení do skupin nemůžeme ovlivnit, je dáno
- ▶ může záležet na tom, zda dělíme podle možných příčin (kohortové studie, poměr rizik RR vypovídá) nebo následků (case-control, RR nevypovídá, poměr šancí OR ano)

## jaké úlohy řešíme

dělení podle skupin statistických metod

### ► popsat stav (popisná statistika, Exploratory Data Analysis ⇒ formulace vědeckých hypotéz)

- ▶ poloha (průměr, medián, kvartily, ...)
- ▶ variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
- ▶ závislost (korelační koeficient, Spearmanův korel. koeficient)
- ▶ tvar rozdělení (šíkmost, špičatost)

### ► prokázat vliv ošetření (induktivní, konfirmační statistika)

- ▶ změna polohy (*t*-testy, analýza rozptylu)
- ▶ změna variability (Levene, *F*-test, Bartlettův test)
- ▶ jiná změna rozdělení (Kolmogorov-Smirnov)

### ► prokázat závislost (induktivní, konfirmační statistika)

- ▶ obě spojité (korelační koeficient, regrese)
- ▶ spojité na kvalitativními (ANOVA)
- ▶ obě kvalitativní (chi-kvadrát v kontingenční tabulce)
- ▶ predikce spojité veličiny na spojitéch či kvalitativních (regrese)

## výběr metody

### ► jakou úlohu řešíme?

### ► jsou výběry nezávislé?

- ▶ zajistit organizací pokusu

### ► lze předpokládat normální rozdělení?

- ▶ lze soudit z grafu (normální diagram)
- ▶ lze ověřovat pomocí testů
- ▶ v jednotlivých výběrech nebo z reziduí (v regresi)

### ► je rozptyl stálý?

- ▶ lze soudit z grafu (rozptylový diagram)
- ▶ lze ověřovat pomocí testů
- ▶ porovnat výběry nebo z reziduí
- ▶ u regrese lze ověřit pomocí Breuschova-Paganova testu

## volba nulové a alternativní hypotézy

### ► $H_0$ zjednodušuje model

- ▶ hypotéza přesněji určuje model (např. test dobré shody)
- ▶ populace se nelíší (výběry se liší jen náhodně)
- ▶ veličiny jsou nezávislé
- ▶  $H_0$  zpravidla chceme vyvrátit abychom prokázali svoji vědeckou hypotézu

### ► $H_1$ je opak nulové hypotézy

- ▶ pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit před pokusem na základě úvah, které **nejsou** založeny na použitých datech
- ▶ zpravidla obsahuje více možností než nulová hypotéza
- ▶ zpravidla obsahuje tvrzení, které chceme dokázat
- ▶ pouze zamítnutím  $H_0$  něco dokazujeme
- ▶ u každého testu jsou nulová i alternativní hypotézy dány, nemůžeme je přehodit

## porovnání populačních měr polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián (distribuční funkce)
jeden výběr	jednovýběrový <i>t</i> -test	jednovýběrový Wilcoxon
výběr dvojic	párový <i>t</i> -test	znaménkový, Wilcoxon
dva nezávislé výběry	dvouvýběrový <i>t</i> -test	Mann-Whitney (Kolmogorov-Smirnov)
<i>k</i> nezávislých výběrů	analýza rozptylu jedn. třídění	Kruskal-Wallis
výběr <i>r</i> -tic	analýza rozptylu náhodné bloky	Friedman

## vyšetřování závislosti

nezávisle proměnná(é)	závisle proměnná	
	<b>spojitá</b>	<b>nominální</b>
<b>spojitá</b>	regrese korelace	(logistická regrese)
<b>nominální</b>	analýza rozptylu	kontingenční tabulky

příklady:

- ▶ hmotnost na výšce
- ▶ rakovina plic na počtu vykouřených cigaret
- ▶ hmotnost obilky na živném roztoku
- ▶ barva očí a barva vlasů