

# Statistika

(MD360P03Z, MD360P03U)

ak. rok 2007/2008

Karel Zvára

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

(naposledy upraveno 7. ledna 2008)



## cvičení, zápočet, zkouška

- ▶ cvičení v počítačových učebnách
  - ▶ PUA (suterén Albertov 6)
  - ▶ Z3 (Albertov 6, u schodů do suterénu)
  - ▶ B5 (Viničná 7, 1. patro)
- ▶ MS Excel
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>)
- ▶ (aktivní účast na cvičení, maximálně dvě absence) & (napsání zápočtového testu) ⇒ zápočet
- ▶ obsah cvičení více přizpůsoben studovanému oboru
- ▶ přednášky formulovány obecněji
- ▶ zkouška nejspíš písemná, kombinovaná s ústní, zápočet **musí** zkoušce **předcházet**; přihlašování ke zkoušce přes SIS

## literatura

- ▶ K. Zvára: Biostatistika, Karolinum Praha, 1998, 2000, 2001, 2003, 2006
- ▶ Z. Pavlík, K. Kühnl: Úvod do kvantitativních metod pro geografii, SPN Praha, 1981
- ▶ T. H. Wonnacot, R. J. Wonnacot: Statistika pro obchod a hospodářství, Victoria Publishing Praha, 1992
- ▶ slajdy přednášky na adrese <http://www.karlin.mff.cuni.cz/~zvara> (celý semestr, může dojít k úpravám)
- ▶ postupně doplňované slajdy uskutečněných přednášek

## přehled témat

- ▶ popisná statistika (měřítka, charakteristiky polohy, variability, souvislost znaků)
- ▶ statistika v geografických/demografických/sociálních vědách
- ▶ pravděpodobnost (základní kombinatorické pojmy, klasická definice, podmíněná pravděpodobnost, nezávislost)
- ▶ náhodná veličina (rozdělení, střední hodnota, rozptyl, hustota, distribuční funkce)
- ▶ důležitá rozdělení (normální, binomické, Poissonovo)
- ▶ statistické usuzování (populace a výběr, parametry a jejich odhady, interval spolehlivosti, volba rozsahu výběru)
- ▶ testování hypotéz (chyba 1. druhu, 2. druhu, hladina testu, síla testu,  $p$ -hodnota)
- ▶ testy (o populačním průměru, populačním podílu či podílech, nezávislosti, regresních koeficientech)
- ▶ regrese, kontingenční (čtyřpolní) tabulky

## příklad statistického zjišťování I

- ▶ zjišťování se týká 200 mužů středního věku
- ▶ v souboru je 80 kuřáků a 120 nekuřáků
- ▶ 85 mužů má oči modré, 25 hnědé, 90 jiné barvy
- ▶ 27 mužů má jen základní vzdělání, 44 neúplné střední, 65 maturitu, 64 vysokoškolské
- ▶ 22 se jich narodilo v roce 1942, 19 v roce 1943, 25 v roce 1944, . . . , 18 v roce 1951
- ▶ hmotnosti jednotlivých mužů jsou 83, 92, . . . , 63 kg
- ▶ výška jednotlivých mužů jsou 172, 176, . . . , 178 cm
- ▶ Co mají tyto údaje společného? Čím se údaje v jednotlivých podskupinách liší? Souvisí kouření a vzdělání? Souvisí příjem se vzděláním? Je tato souvislost stejná, jako v zemi XY?

## co a jak měříme (zjišťujeme)

- ▶ měříme na mnoha **statistických jednotkách** (osoba, domácnost, obec, okres, stát, pokusné pole . . . )
- ▶ měříme (zjišťujeme) hodnoty **znaků**
- ▶ zjištěnou hodnotu vyjadřujeme ve zvoleném **měřítku** (stupnici)
- ▶ na jedné jednotce můžeme měřit několik znaků (závislost)
- ▶ měříme na skupinách jednotek – **souborech**
- ▶ zajímají nás **hromadné** vlastnosti ve velkých souborech
- ▶ můžeme **porovnávat** vlastnosti znaku **mezi soubory**

## příklad statistického zjišťování II

- ▶ zjišťování se týká příjmů obyvatel
- ▶ hodnotíme hrubý příjem za rok
- ▶ přihlížíme k místu trvalého bydliště (velikost obce, který kraj)
- ▶ přihlížíme k vzdělání (druh, doba školní docházky)
- ▶ přihlížíme k věku a pohlaví
- ▶ Co mají tyto údaje společného? Čím se údaje liší?

## měřítko

- ▶ **nula-jedničkové** (muž/žena, kuřák/nekuřák)
- ▶ **nominální** (země původu, barva očí) jednoznačně dané hodnoty
- ▶ **ordinální** (dosažené vzdělání, stupeň bolesti) jednoznačně dané hodnoty, možné hodnoty jsou *uspořádané*
- ▶ **intervalové** (teplota v Celsiově stupnici, rok narození) konstantní vzdálenosti mezi sousedními hodnotami, nula jen konvence; o *kolik* stupňů je je dnes tepleji, než bylo vloni?
- ▶ **poměrové** (hmotnost, výška, HDP, počet obyvatel, věk) násobek zvolené jednotky, nula = neexistence měřené vlastnosti *kolikrát* je A starší (vyšší . . . ) než B

## měřítka (stručnější dělení)

- ▶ **kvalitativní**: nula-jedničkové, nominální, často i ordinální
- ▶ u kvalitativních se zpravidla udávají **četnosti** jednotlivých hodnot (kolikrát která hodnota nastala)
- ▶ **kvantitativní** (spojité): intervalové, poměrové, někdy ordinální (není spojité)
- ▶ hodnoty kvantitativních – čísla
- ▶ zařazení znaku k určitému měřítku může záviset na účelu šetření

## příklad: 100 hodů kostkou

počty puntíků coby různé obrázky – nominální znak

kostka A										kostka B									
4	2	5	6	3	1	1	2	2	2	1	4	6	2	3	2	6	1	5	2
2	4	5	3	1	1	3	5	5	5	5	6	5	5	6	4	2	4	5	6
4	3	2	5	5	5	2	2	5	2	3	6	3	6	5	6	1	3	5	1
2	6	5	5	2	3	6	6	4	6	6	6	2	1	1	2	6	3	2	3
5	4	1	4	2	2	4	5	2	5	4	4	1	6	6	2	6	3	2	6
5	5	3	3	5	3	6	6	6	5	2	6	1	2	6	1	5	5	6	5
3	5	4	5	1	1	4	3	2	4	6	6	5	1	6	6	6	1	2	6
1	2	4	6	6	3	4	6	1	2	6	2	5	6	2	6	6	5	6	4
6	6	1	2	6	2	4	3	2	3	6	1	2	6	2	1	6	6	6	6
1	1	6	5	2	6	4	4	6	3	6	5	1	5	6	6	1	6	6	6

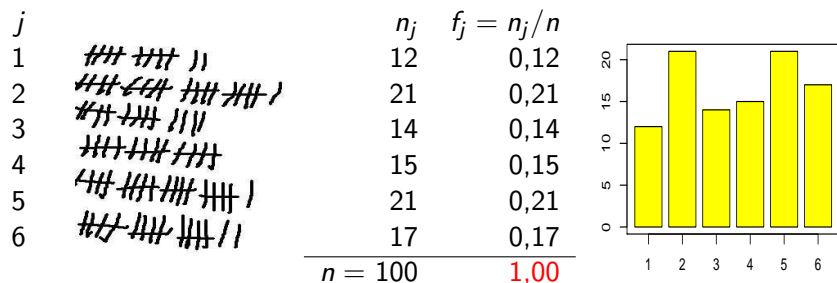
## veličina

- ▶ číselně vyjádřený výsledek měření
- ▶ *hodnoty* znaků v intervalovém, poměrovém měřítku jsou husté – **spojitá veličina**
- ▶ *četnosti hodnot* znaků v nula-jedničkovém, nominálním (či ordinálním) měřítku – **diskrétní veličina**
- ▶ pro veličiny máme charakteristiky některých jejich hromadných vlastností (**charakteristiky polohy, variability, tvaru rozdělení**)
- ▶ popisné charakteristiky (statistiky) mají jedním číslem vyjádřit danou vlastnost

## hody kostkou jako hromadný jev

- ▶ chceme 100 zjištěných hodnot (počtů puntíků) vyjádřit názorně, aby vypovídaly o vlastnostech kostky
- ▶  $n_j$  (absolutní) **četnost** [frequency] hodnoty – kolikrát nastala
- ▶  $f_j = \frac{n_j}{n}$  **relativní četnost** hodnoty (lze vyjádřit v %) – v jakém dílu měření nastala (nutně platí  $n = n_1 + n_2 + \dots + n_k = \sum_{j=1}^k n_j$ )
- ▶ tabulka četností (absolutních, relativních)
- ▶ grafické vyjádření četností – **histogram** [histogram] (velikost plochy je úměrná četnosti)
- ▶ rozhodování o kvalitě kostky (zda je symetrická) je úlohou **statistické indukce** [inference] – později

## zpracování četností (kostka A)



## příklad: věk 99 matek

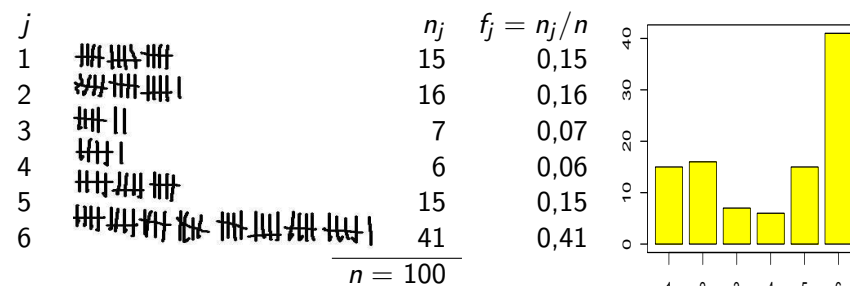
99 zjištěných hodnot – soubor naměřených hodnot

```

26 35 21 25 27 24 24 30 23 18
35 21 25 26 26 19 29 22 21 27
26 30 28 28 27 29 27 26 21 23
24 21 28 25 34 24 21 28 25 28
22 26 32 22 32 25 21 25 24 32
24 22 31 33 23 30 26 27 25 24
24 23 25 23 26 28 24 25 25 26
28 28 22 23 20 20 21 31 24 21
29 28 26 38 20 23 25 37 33 23
27 23 21 25 21 33 22 29 21
    
```

▶ Jdi k variační řadě

## zpracování četností (kostka B)



## variační řada, pořadí

- ▶  $x_1, x_2, \dots, x_n$  původní (neuspořádaná) data – hodnoty znaku v měřítku aspoň ordinálním uvedené v původním pořadí, bez ohledu na případná opakování
- ▶ **variační řada**  $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$  [sort(x)]  
data uspořádána tak, aby hodnoty neklesaly
- ▶ proto **závorky u indexů**
- ▶ **pořadí** [rank] – umístění pozorování ve variační řadě; shodným hodnotám dáváme průměrné pořadí [rank(x)]

$x_j$	22	15	17	15	21	13	18
pořadí $R_j$	7	2,5	4	2,5	6	1	5

**příklad: věk 99 matek – variační řada**

uspořádaný soubor hodnot – variační řada

```

18 19 20 20 20 21 21 21 21 21
21 21 21 21 21 21 21 22 22 22
22 22 22 23 23 23 23 23 23 23
23 23 24 24 24 24 24 24 24 24
24 24 25 25 25 25 25 25 25 25
25 25 25 25 26 26 26 26 26 26
26 26 26 26 27 27 27 27 27 27
28 28 28 28 28 28 28 28 28 29
29 29 29 30 30 30 31 31 32 32
32 33 33 33 34 35 35 37 38

```

▶ Jdi k původním pozorováním

**věk matek – třídní četnosti** $k = 7$ 

interval	$x_j^*$	$n_j$	$f_j = n_j/n$	$N_j$	$N_j/n$
do 20	19	5	0,051	5	0,051
21 až 23	22	27	0,273	32	0,324
24 až 26	25	32	0,322	64	0,646
27 až 29	28	19	0,192	83	0,838
30 až 32	31	8	0,081	91	0,919
33 až 35	34	6	0,061	97	0,980
36 a více	37	2	0,020	99	1,000

▶ Jdi k histogramu věku matek

▶ Jdi k míram polohy věku matek

**třídění, třídní četnosti**

- ▶ spojitá veličina s velkým počtem naměřených hodnot
- ▶ obor hodnot rozdělíme na nepřekrývající se třídy (intervaly), nejlépe stejné délky (ne vždy je to praktické či možné)
- ▶ všechna pozorování z daného intervalu nahradíme zástupnou hodnotou (zpravidla středem intervalu)  $x_j^*$
- ▶ zjistíme (**absolutní**) **četnosti**  $n_1, \dots, n_k$  jednotlivých tříd
- ▶ **kumulativní četnosti** udávají počet hodnot v dané třídě a třídách předcházejících ( $1 \leq j \leq k$ ) [cumsum( )]

$$N_j = n_1 + n_2 + \dots + n_j = \sum_{i=1}^j n_i$$

**grafické znázornění třídních četností**


- ▶ **histogram** je založen na třídění do intervalů, výjimečně zobrazuje přímo četnosti jednotlivých hodnot (barplot) [hist( )]
- ▶ každé třídě odpovídá obdélník o **ploše úměrné četnosti** (absolutní nebo relativní)
- ▶ při stejných šířkách intervalů  $h$  odpovídají četnostem výšky obdélníků (protože základny jsou stejně dlouhé)
- ▶ počet intervalů  $k$ : volí se 5–15 tak, aby středy byly okrouhlé
- ▶ pomůckou Sturgesovo pravidlo

$$k \approx 1 + 3,3 \cdot \log_{10} n = 1 + \log_2 n$$

- ▶ příklad věk matek:  $k \approx 1 + 3,3 \cdot \log_{10} 99 \approx 7,6$


příklad (věk matek): histogram,  $h=3$  ( $k=7$ )

[hist(vek.m,seq(17,38,by=3),col="yellow")]



[Jdi k četnostem věku matek](#)

## příklad (věk matek): kumulativní relativní četnosti



## třídění při nestejně dlouhých intervalech

- ▶ někdy jsou data nepravidelně rozmístěna
- ▶ zpravidla jsou soustředěna u levého okraje intervalu hodnot (věkové či příjmové složení obyvatelstva)
- ▶ pak vhodné zvolit nestejně dlouhé intervaly
- ▶ je vhodné zvolit délky intervalů tak, aby delší byly násobkem kratších
- ▶ při nestejně dlouhých intervalech musí zjištěné četnosti odpovídat **plocha**, nikoliv výška; pak se na svislou osu nanášejí **relativní** četnosti

## příklad: tolary

měsíční příjmy 99 osob v tolarech

## četnosti


$x_j^*$	10	11	12	13	14	15	16	17	18	19	20		
$n_j$	7	14	16	10	6	3	9	3	1	5	3		
$x_j^*$	21	22	24	26	27	28	32	35	36	40	43	45	47
$n_j$	4	3	3	1	2	1	1	1	2	1	1	1	1

## třídní četnosti

třída	10	11	12	13-16	17-20	21-30	31-50	celkem
$x_j^*$	10	11	12	14,5	18,5	25,5	40,5	
$n_j^*$	7	14	16	28	12	14	8	99
hustota	7	14	16	7	3	1,4	0,4	

[Jdi k hodnocení tolarů](#)

## příklad (tolary): histogram



## kvartily, percentily

- ▶ **dolní (horní) kvartil**  $Q_1$  ( $Q_3$ ) [lower (upper) quartile] vyděljuje čtvrtinu nejmenších (největších) hodnot
- ▶ kvartil – speciální případ percentilu
- ▶ **percentil** [percentile]  $x_p$  vyděljuje  $100p$  % nejmenších hodnot od ostatních
- ▶ výpočet percentilů – mnoho vzorečků
- ▶ medián je také percentilem, totiž  $x_{0,5}$
- ▶ podobně  $Q_1 = x_{1/4} = x_{0,25}$ ,  $Q_3 = x_{3/4} = x_{0,75}$   
[quantile(x, probs=c(1/4,3/4))]

## výběrové charakteristiky polohy: medián

snaha charakterizovat úroveň jediným číslem

- ▶ medián je číslo, které dělí data na dvě stejně velké části (větších hodnot a menších hodnot)
- ▶ **medián** [median] (prostřední hodnota)  $\tilde{x}$  [median(x)]

$$\tilde{x} = x_{(\frac{n+1}{2})} \quad \text{pro } n \text{ liché}$$

$$\tilde{x} = \frac{1}{2} \left( x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)} \right) \quad \text{pro } n \text{ sudé}$$

- ▶ **závorky u indexů jsou nutné: znamenají, že hodnoty byly předem uspořádány do variační řady**
- ▶ 5, 3, 4, 7, 6  $\tilde{x} = 5$  (3 < 4 < 5 < 6 < 7)

## výpočet percentilů (jako v R), jen pro ilustraci

jedna z možných definic – Gumbel(1939)

- ▶ najde se 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  $x$ )
- ▶ 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

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

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

### příklad: věk 99 matek – variační řada

variační řada, medián  $\tilde{x} = 25$


kvartily  $Q_1 = (23+23)/2 = 23$ ,  $Q_3 = (28+28)/2 = 28$

18	19	20	20	20	21	21	21	21	21
21	21	21	21	21	21	21	22	22	22
22	22	22	23	23	23	23	23	23	23
23	23	24	24	24	24	24	24	24	24
24	24	25	25	25	25	25	25	25	25
25	25	25	25	26	26	26	26	26	26
26	26	26	26	27	27	27	27	27	27
28	28	28	28	28	28	28	28	28	29
29	29	29	30	30	30	31	31	32	32
32	33	33	33	34	35	35	37	38	

► Návrat míry var. věku matek


### krabicový diagram

- **krabicový diagram** [box-plot] zobrazuje kvartily, medián, minimum, maximum, případně odlehlá pozorování: od bližšího kvartilu dále než  $3/2 \cdot (Q_3 - Q_1)$  [boxplot(x)]
- příklad: věk matek ( $Q_1 = 23$ ,  $\tilde{x} = 25$ ,  $Q_3 = 28$ , dvě odlehlá pozorování)



### příklad: tolary ( $\tilde{x} = 14$ , $Q_1 = 12$ , $Q_3 = 19,5$ )

10	10	10	10	10	10	10	11	11	11
11	11	11	11	11	11	11	11	11	11
11	12	12	12	12	12	12	12	12	12
12	12	12	12	12	12	12	13	13	13
13	13	13	13	13	13	13	14	14	14
14	14	14	15	15	15	16	16	16	16
16	16	16	16	16	17	17	17	18	19
19	19	19	19	20	20	20	21	21	21
21	22	22	22	24	24	24	26	27	27
28	32	35	36	36	40	43	45	47	



### průměr

- **průměr** [mean] (kdyby bylo všech  $n$  hodnot stejných) [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**: [weighted mean] založen na četnostech

$$\bar{x} = \frac{1}{n} (n_1 x_1^* + \dots + n_k x_k^*) = \frac{1}{n} \sum_{j=1}^k n_j x_j^* = \sum_{j=1}^k \frac{n_j}{n} x_j^* = \frac{\sum_{j=1}^k n_j x_j^*}{\sum_{j=1}^k n_j}$$

- obecněji s vahami  $w_1, \dots, w_k$  hodnot  $x_1^*, \dots, x_k^*$

$$\frac{\sum_{j=1}^k w_j x_j^*}{\sum_{j=1}^k w_j}$$

váhy musí být nezáporné ( $w_j \geq 0$ )



## příklad: vážený průměr známek

předmět	známka	kredity	součin
A	1	6	6
B	1	6	6
C	2	4	8
D	3	4	12
celkem	7	20	32

- ▶ průměr (nevážený):  $\bar{x} = 7/4 = 1,75$
- ▶ vážený průměr (vahami kredity):  $\bar{x} = 32/20 = 1,6$

## modus

- ▶ **modus**  $\hat{x}$  [mode] nejčastější hodnota (lze počítat také pro nominální či ordinální měřítko)
- ▶ modus nemusí být určen jednoznačně, např. věk matek:

$x_j^*$	18	19	20	21	22	23	24	25	26	27
$n_j$	1	1	3	12	6	9	10	12	10	6
$x_j^*$	28	29	30	31	32	33	34	35	37	38
$n_j$	9	4	3	2	3	3	1	2	1	1

## průměr pro nula-jedničkovou veličinu

- ▶ u nula-jedničkového měřítka: průměr = relativní četnost jedniček
- ▶ počet jedniček/počet všech hodnot (nul i jedniček)
- ▶ procento jedniček mezi všemi hodnotami (nulami a jedničkami)
- ▶ procento jedinců s danou vlastností
- ▶ pozor, nejde o pravděpodobnost, nanejvýš jde o její odhad!

## příklad – věk matek

- ▶ již známe  $\bar{x} = 25$ ,  $Q_1 = 23$ ,  $Q_3 = 28$
- ▶ modus není určen jednoznačně:  $\hat{x} = 21$ ,  $\hat{x} = 25$
- ▶ průměr

$$\bar{x} = \frac{1}{99} (26 + 35 + \dots + 21 + 23) = \frac{2544}{99} \doteq 25,7$$

- ▶ vážený průměr založený na třídění

$$\begin{aligned} \bar{x} &= \frac{5 \cdot 19 + 27 \cdot 22 + 32 \cdot 25 + 19 \cdot 28 + 8 \cdot 31 + 6 \cdot 34 + 2 \cdot 37}{5 + 27 + 32 + 19 + 8 + 6 + 2} \\ &= \frac{2547}{99} \doteq 25,7 \end{aligned}$$

## příklad – tolary

- ▶ průměr

$$\bar{x} = \frac{1}{99} (26 + 20 + \dots + 12 + 10) = \frac{1687}{99} \doteq 17,04$$

- ▶ vážený průměr založený na četnostech jednotlivých hodnot

$$\bar{x} = \frac{7 \cdot 10 + 14 \cdot 11 + 16 \cdot 12 + \dots + 1 \cdot 47}{7 + 14 + 16 + \dots + 1} = \frac{1687}{99} \doteq 17,04$$

- ▶ vážený průměr založený na třídnicích četnostech (obr. 24)

$$\begin{aligned} \bar{x} &= \frac{7 \cdot 10 + 14 \cdot 11 + 16 \cdot 12 + 28 \cdot 14,5 + \dots + 8 \cdot 40,5}{7 + 14 + 16 + 28 + 12 + 14 + 8} \\ &= \frac{1725}{99} \doteq 17,42 \end{aligned}$$

- ▶ modus:  $\hat{x} = 12$

▶ Jdi k četnostem tolary

příklad (věk matek): useknutý průměr  
(průměr počítán pouze z černých čísel)

vyloučí se  $[0,1 \cdot 99] = [9,9] = 9$  ( $\lfloor x \rfloor$  znamená celou část z  $x$ )  
nejmenších a 9 největších hodnot

18	19	20	20	20	21	21	21	21	21
21	21	21	21	21	21	21	22	22	22
22	22	22	23	23	23	23	23	23	23
23	23	24	24	24	24	24	24	24	24
24	24	25	25	25	25	25	25	25	25
25	25	25	25	26	26	26	26	26	26
26	26	26	26	27	27	27	27	27	27
28	28	28	28	28	28	28	28	28	29
29	29	29	30	30	30	31	31	32	32
32	33	33	33	34	35	35	37	38	

## useknutý průměr

také míra polohy

- ▶ **alfa-useknutý průměr** [trimmed mean]: nejprve se oddělí (usekne)  $100\alpha$  % nejmenších a  $100\alpha$  % největších hodnot, ze zbytku se spočítá průměr

- ▶ je robustní (necitlivý) vůči odlehlým hodnotám

- ▶ volí se zpravidla  $\alpha = 0,1$  (0,15)

- ▶ příklad: věk matek [mean(vek.m,trim=0.1)]

$$\frac{1}{99 - 18} (x_{(10)} + x_{(11)} + \dots + x_{(89)} + x_{(90)}) = 25,3$$

## vlastnosti charakteristik polohy

- ▶ změníme-li všechny hodnoty  $x_i$  tak, že přidáme ke každé stejnou konstantu  $a$ , změní se o tutéž konstantu také charakteristika polohy (posunutí)
- ▶ změníme-li všechny hodnoty  $x_i$  tak, že je vynásobíme kladnou konstantou  $b$ , toutéž konstantou musíme vynásobit původní charakteristiku polohy, abychom dostali charakteristiku polohy pro upravená data (změna měřítka)
- ▶ obecně pro míru polohy  $m(x)$

$$\begin{aligned} m(a + x) &= a + m(x), \\ m(b \cdot x) &= b \cdot m(x), \quad b > 0 \end{aligned}$$

- ▶ v **obou** případech míra polohy **reaguje**

## charakteristiky variability

- ▶ měří nestejnost (**variabilitu**) hodnot spojité veličiny
- ▶ obecně pro míru variability  $s(x)$

$$s(a + x) = s(x),$$

$$s(b \cdot x) = b \cdot s(x), \quad b > 0$$

- ▶ přičtením stejné konstanty  $a$  (posunutím) se charakteristika variability nezmění (nezávisí na poloze)
- ▶ vynásobení kladnou konstantou znamená, že stejnou konstantou nutno vynásobit charakteristiku variability
- ▶ **rozpětí** [range]  $R = x_{(n)} - x_{(1)}$
- ▶ **kvartilové rozpětí** [quartile range]  $R_Q = Q_3 - Q_1$

## směrodatná odchylka

- ▶ rozptyl měří průměrný čtverec vzdálenosti od průměru
- ▶ **směrodatná odchylka** [std. deviation]: odmocnina z rozptylu  
[SMODCH.VÝBĚR][sd(x)]

$$s_x = \sqrt{s_x^2}$$

- ▶ zcela vyhovuje požadavkům na míru variability
- ▶ výhoda směrodatné odchylky: stejný fyzikální rozměr jako původní data
- ▶ výběrový rozptyl z *třídních* četností: Sheppardova korekce (jsou-li všechny intervaly délky  $h$ ):

$$\text{odečti } \frac{h^2}{12}$$

## rozptyl (variance)

- ▶ (výběrový) **rozptyl** (variance) [variance] [VAR.VÝBĚR][var(x)] (nevyhovuje druhému požadavku, místo toho:  $s_{a+b \cdot x}^2 = b^2 \cdot s_x^2$ )

$$s_x^2 = \frac{1}{n-1} ((x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2)$$

$$= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left( \sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2 \right)$$

$$= \frac{1}{n-1} \sum_{j=1}^k n_j (x_j^* - \bar{x})^2 = \frac{1}{n-1} \left( \sum_{j=1}^k n_j x_j^{*2} - n \cdot \bar{x}^2 \right)$$

- ▶ nechť  $x_1 = 1, x_2 = 3, x_3 = 8$ , pak je  $\bar{x} = (1 + 3 + 8)/3 = 12/3 = 4$

$$s_x^2 = \frac{1}{3-1} ((1-4)^2 + (3-4)^2 + (8-4)^2) = \frac{26}{2} = 13 \doteq 3,6^2$$

## příklad – věk matek

- ▶ rozpětí:  $R = 38 - 18 = 20$
- ▶ kvartilové rozpětí:  $R_Q = 28 - 23 = 5$
- ▶ rozptyl

$$s^2 = \frac{1}{98} \left( (26^2 + 35^2 + \dots + 21^2 + 23^2) - 99 \cdot \left( \frac{2544}{99} \right)^2 \right)$$

$$= 16,97 \doteq 4,12^2$$

- ▶ směrodatná odchylka je 4,12

▶ Var. řada věku matek

## příklad – věk matek 2

- ▶ pomocí třídnicích četností

$$s^2 = \frac{1}{98} \left( (5 \cdot 19^2 + 27 \cdot 22^2 + \dots + 2 \cdot 37^2) - 99 \cdot \left( \frac{2547}{99} \right)^2 \right) = 16,36 = (4,05)^2$$

- ▶ navíc Sheppardova korekce

$$s^2 = 16,36 - \frac{3^2}{12} = (3,95)^2$$

## normované charakteristiky rozptýlenosti

- ▶ dosud zavedené charakteristiky variability závisejí na volbě měřítka (např. délka v m nebo v km)
- ▶ hledáme charakteristiky nezávislé na měřítku, nutně *poměrové* měřítko, *kladné* hodnoty
- ▶ umožní **porovnání** z různých souborů
- ▶ **variační koeficient** [sd(x)/mean(x)]

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

- ▶ **(Giniho) koeficient koncentrace**

$$G = \frac{\Delta}{2\bar{x}} \left( = \frac{2 \sum_{i=1}^n i \cdot x_{(i)}}{n \sum_{i=1}^n x_i} - \frac{n+1}{n} \right)$$

například měří nerovnoměrnost příjmů, velikostí územních jednotek, souvisí s plochou u Lorenzovy křivky

## střední odchylka

- ▶ **střední odchylka** [mean deviation]: průměr odchylek od mediánu (někdy od průměru) [mean(abs(x-median(x)))]

$$d = \frac{1}{n} \sum_{i=1}^n |x_i - \tilde{x}|$$

- ▶ **střední diference**: průměr vzájemných vzdáleností všech  $n^2$  dvojic

$$\begin{aligned} \Delta &= \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n |x_i - x_j| \\ &= \frac{2}{n^2} \sum_{j>i} (x_{(j)} - x_{(i)}) \end{aligned}$$

## z-skór, standardizace

- ▶ variační koeficient  $v$ , Giniho koeficient  $G$  – příklady bezrozměrných veličin (zásluhou průměru ve jmenovateli závisí  $G$  i  $v$  na posunutí!)
- ▶ z-skóry [STANDARDIZE(x;průměr(x);smodch.výběr(x))]  
\*[(x-mean(x))/sd(x)] nebo [c(scale(x))]

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

- ▶ dostaneme nulový průměr ( $\bar{z} = 0$ ), jednotkový rozptyl ( $s_z = 1$ )
- ▶ z-skóry jsou bezrozměrné  $\Rightarrow$  umožní hodnotit vlastnosti nezávislé na poloze a variabilitě, např. tvar rozdělení
- ▶  $x_1 = 1, x_2 = 2, x_3 = 3 \Rightarrow \bar{x} = 2, s_x = 1$   
 $z_1 = \frac{1-2}{1} = -1, z_2 = \frac{2-2}{1} = 0, z_3 = \frac{3-2}{1} = 1$

## charakteristiky tvaru: šikmost

- ▶ invariantní vůči posunutí i změně měřítka:

$$\gamma(a + x) = \gamma(x)$$

$$\gamma(b \cdot x) = \gamma(x) \quad b > 0$$

- ▶ **šikmost**  $\sqrt{b_1}$  – průměr z 3. mocnin z-skórů

$$[\text{SKEW}()] \quad [\text{mean}(\text{scale}(x)^3)]$$

$$\sqrt{b_1} = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^3$$

- ▶ pro symetrický histogram  $\sqrt{b_1}$  blízké nule
- ▶ doprava protažený histogram pro  $\sqrt{b_1} \gg 0$
- ▶ doleva protažený histogram pro  $\sqrt{b_1} \ll 0$

## charakteristiky tvaru: špičatost

- ▶ **špičatost**  $b_2$  – průměr ze 4. mocnin z-skórů

$$(\text{někdy se odečítá } 3) \quad [\text{KURT}()] \quad [\text{mean}(\text{scale}(x)^4)]$$

$$b_2 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^4$$

- ▶ někdy se počítají odhady populační šikmosti a špičatosti jinak (Excel:  $s_x$  jinak, Fisherovo  $g_1, g_2$  – pro zajímavost)

$$g_1 = \frac{\sqrt{n(n-1)}}{n-2} \sqrt{b_1}, \quad g_2 = \frac{(n+1)(n-1)}{(n-2)(n-3)} \left( b_2 - \frac{3(n-1)}{n+1} \right)$$

- ▶ šikmost a špičatost slouží k hodnocení, zda lze předpokládat *normální rozdělení* (bude zavedeno později)

## přehled závislostí

- ▶ abychom mohli vyšetřovat závislost, musíme na jedné statistické jednotce měřit aspoň dva znaky
- ▶ postupy (i grafické) závisí na měřících obou znaků
  - ▶ kvalitativní – kvalitativní (vzdělání – pracovní zařazení)
  - ▶ kvalitativní – kvantitativní (vzdělání – roční příjem)
  - ▶ kvantitativní – kvantitativní (věk – roční příjem)
- ▶ zatím popisné charakteristiky a grafy, prokazování závislosti později

## kvalitativní – kvalitativní


- ▶ kvalitativní data – znak v nominálním (ordinálním) měřítku
- ▶ hodnoty vyjadřujeme pomocí četností
- ▶ dva znaky – četnosti možných **dvojic hodnot**  $n_{ij}$  (**sdržené četnosti**)
- ▶ zapisujeme do **kontingenční tabulky** [contingency table]  $[\text{table}(x,y)]$  nebo  $[\text{xtabs}(\sim x+y)]$
- ▶ doplňujeme **marginální četnosti** [marginal frequencies]
  - ▶ součty po řádcích a po sloupcích
  - ▶ četnosti jednotlivých hodnot každého ze znaků zvlášť
- ▶ oba znaky nula-jedničkové – kontingenční tabulka  $2 \times 2$ , **čtyřpolní tabulka** [fourfold table]

### příklad – vzdělání matek (pozor na orientaci grafu!)

vzdělání	porodnice		celkem
	Praha	venkov	
základní	23	11	34
střední	30	17	47
VŠ	17	1	18
celkem	70	29	99

vzdělání	porodnice		celkem
	Praha	venkov	
základní	32,9 %	37,9 %	34,3 %
střední	42,8 %	58,6 %	47,5 %
VŠ	24,3 %	3,5 %	18,2 %
celkem	100 %	100 %	100 %



### kvalitativní – kvantitativní


- ▶ podle kvalitativní proměnné rozdělíme hodnoty kvantitativní proměnné do dílčích souborů
- ▶ porovnáme charakteristiky dílčích souborů (zejména charakteristiky polohy) mezi sebou, pokud se hodně liší, svědčí to pro závislost
- ▶ celkový průměr = vážený průměr dílčích souborů
- ▶ celkový rozptyl = vážený průměr rozptylů + vážený rozptyl průměrů (přesně jen pro populační rozptyly s  $n$  ve jmenovateli)
- ▶ snáze jako **rozklad součtu čtverců**

### příklad – vzdělání matek (pozor na orientaci)

vzdělání	porodnice		celkem
	Praha	venkov	
základní	23	11	34
střední	30	17	47
VŠ	17	1	18
celkem	70	29	99

vzdělání	porodnice		celkem
	Praha	venkov	
základní	67,6 %	32,4 %	100 %
střední	63,8 %	36,2 %	100 %
VŠ	94,4 %	6,6 %	100 %
celkem	70,7 %	29,3 %	100 %



### příklad: platy u tří skupin zaměstnanců

skup.	příjem	$n_j$	$\bar{x}_j$	$s_j$	$s_j^2$
žlutí	200 150	2	175,00	35,4	1250,0
modří	80 70 60 60	4	67,50	9,6	91,7
černí	20 20 18 18 15 15 10 10	8	15,75	4,0	16,2
celkem	746	14	53,29	57,7	3334,4

$$\bar{x} = \frac{2 \cdot 175,0 + 4 \cdot 67,50 + 8 \cdot 15,75}{2 + 4 + 8} = 53,29$$

$$s^2 = 3334,4 > \frac{2 \cdot 1250,0 + 4 \cdot 91,7 + 8 \cdot 16,2}{2 + 4 + 8} = 214,0$$

- ▶ nevážený (nesmyslný) průměr by byl 86,08!
- ▶ rozptyl celkem je mnohem větší, než jsou rozptyly ve skupinách
- ▶ příčina: nestejně průměry

## rozklad součtu čtverců

- ▶ velikost kolísání **všech** platů (celková variabilita):

$$SST = (200 - 53,29)^2 + (150 - 53,29)^2 + (80 - 53,29)^2 + \dots + (10 - 53,29)^2 = 43\,346,86$$

- ▶ velikost kolísání **uvnitř** skupin:

$$SSE = (200 - 175)^2 + (150 - 175)^2 + (80 - 67,5)^2 + \dots + (10 - 15,75)^2 = 1\,638,5$$

- ▶ kolísání průměrů (**mezi** skupinami):

$$SSA = 2 \cdot (175 - 53,29)^2 + 4 \cdot (67,5 - 53,29)^2 + 8 \cdot (15,75 - 53,29)^2 = 41\,708,36$$

- ▶ kontrola:  $1\,638,5 + 41\,708,36 = 43\,346,86$

## rozklad součtu čtverců obecně


- ▶  $x_{ij}$   $j$ -tá hodnota v  $i$ -té skupině (plat  $j$ -té osoby v  $i$ -té skupině)
- ▶  $n_i$  počet hodnot v  $i$ -té skupině,  $k$  počet skupin
- ▶  $\bar{x}_{i\bullet}$  průměr v  $i$ -té skupině (průměrný plat v  $i$ -té skupině)
- ▶  $\bar{x}_{\bullet\bullet}$  celkový průměr (průměr všech platů)

$$\begin{aligned} SST &= \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_{\bullet\bullet})^2 \\ &= \sum_{i=1}^k n_i (\bar{x}_{i\bullet} - \bar{x}_{\bullet\bullet})^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_{i\bullet})^2 \\ &= SSA + SSE \end{aligned}$$

## kvantitativní – kvantitativní


[plot(iq~zn7,data=lq,col=1+divka,pch="+")]

záporná korelace



$r = -0,69$

kladná korelace



$r = 0,45$

## popis závislosti spojitých veličin

- ▶ (výběrová) **kovariance** [covariance] [cov(vek.o,vek.m)]

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- ▶ zřejmě je  $s_{xx} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x}) = s_x^2$ ,  $s_{yy} = s_y^2$
- ▶ (Pearsonův, momentový) **korelační koeficient** [(Pearson, product-moment) correlation coefficient]
- ▶ lze zapsat pomocí z-skórů [cor(vek.o,vek.m)]

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

## příklad: hmotnost a délka dětí (24. týden věku)

- ▶ délka [cm]:  $\bar{x} = 68,5$   $s_x = 3,28$
- ▶ hmotnost [g]:  $\bar{y} = 7690$ ,  $s_y = 845$
- ▶ kovariance [cm · g]:  $s_{xy} = 1257$
- ▶ korelační koeficient:  $r = \frac{1257}{3,28 \cdot 845} = 0,45$
- ▶ hmotnost [kg]:  $\bar{y} = 7,69$   $s_y = 0,845$
- ▶ kovariance [cm · kg]:  $s_{xy} = 1,257$
- ▶ korelační koeficient:  $r = \frac{1,257}{3,28 \cdot 0,845} = 0,45$
- ▶ které charakteristiky závisí na použitém měřítku?

## vlastnosti Pearsonova korelačního koeficient

- ▶ vypovídá o směru závislosti
- ▶ při  $r < 0$  s rostoucím  $x$  v průměru  $y$  klesá (např. IQ a známky)
- ▶ při  $r > 0$  s rostoucím  $x$  v průměru  $y$  roste (např. váha a výška)
- ▶ platí  $-1 \leq r \leq 1$
- ▶  $|r| = 1$  jedině tehdy, když body  $[x; y]$  leží na přímce
- ▶ vzájemné nezávislosti  $x, y$  odpovídají  $r$  blízká nule (upřesníme!)
- ▶ nemusí zachytit křivočarou (nelineární) závislost

## charakteristiky polohy v geografii/demografii

- ▶ často známe jen průměry v dílčích souborech a četnosti: průměry se použijí jako  $x_j^*$ , četnosti standardně
- ▶ příklad: věk nových profesorů a docentů UK 2002: 41 profesorů, průměrný věk 51,1 ( $n_1 = 41$ ,  $x_1^* = 51,1$ ) 77 docentů, průměrný věk 47,8 ( $n_2 = 77$ ,  $x_2^* = 47,8$ ) celkový průměr (**vážený průměr**):  
[weighted.mean(c(51.1,47.8),c(41,77))]

$$\frac{41 \cdot 51,1 + 77 \cdot 47,8}{41 + 77} = 48,9$$

nikoliv [mean(c(51.1,47.8))]

$$\frac{51,1 + 47,8}{2} = 49,4$$

## charakteristiky polohy v geografii/demografii (2)

- ▶ **geografický střed**
  - ▶ bod
  - ▶ průsečík průměrné zeměpisné šířky a průměrné zeměpisné délky; průměry vážené velikostí sledovaného jevu
- ▶ **geografický medián** – obdoba mediánu,
  - ▶ čára, která rozděluje geografické objekty do dvou disjunkčních skupin
  - ▶ hodnocená vlastnost určí váhy objektů
  - ▶ uspořádání hodnocení znaků dáno zvolenou geografickou vlastností (např. zeměpisnou délkou)



## míry nerovnoměrnosti

- ▶ **Giniho index** charakterizuje nerovnoměrnost rozdělení bohatství (příjmů, ...) jediným číslem  $G = \Delta / (2\bar{x})$
- ▶ průměrný rozdíl v bohatství vztažený k dvojnásobku průměru
- ▶ mají-li všichni stejně ( $x_{(1)} = \dots = x_{(n)} > 0$ ), je nutně  $\Delta = 0$  a tedy  $G = 0$
- ▶ má-li jeden všechno, ostatní nic ( $0 = x_{(1)} = \dots = x_{(n-1)} < x_{(n)} = a$ ), pak je

$$\bar{x} = \frac{a}{n} \quad \Delta = \frac{2(n-1)a}{n^2}$$

$$G = \frac{2(n-1)a}{n^2} \cdot \frac{n}{2a} = \frac{n-1}{n}$$

- ▶ Lorenzova křivka je jemnějším nástrojem

## příklad: tolary (rozdělení příjmů)

jaké procento nejchudších získá **desetinu** celkového bohatství? četnosti 99 osob (celkový měsíční příjem je 1687)

$x_j$	10	11	12	13	14	15	16	17	18	19	20		
$n_j$	7	14	16	10	6	3	9	3	1	5	3		
$x_j$	21	22	24	26	27	28	32	35	36	40	43	45	47
$n_j$	4	3	3	1	2	1	1	1	2	1	1	1	1

sčítejme příjmy nejchudších, dokud nenasčítáme 10 % z 1687

$$(7 \cdot 10 + 8 \cdot 11) / 1687 = 158 / 1687 = 0,0937 = 9,37 \%$$

$$(7 \cdot 10 + 9 \cdot 11) / 1687 = 169 / 1687 = 0,1002 = 10,02 \%$$

u jaké části z 99 osob jsme sčítali příjmy?

$$(7 + 8) / 99 = 15 / 99 = 0,152 = 15,2 \%$$

$$(7 + 9) / 99 = 16 / 99 = 0,162 = 16,2 \%$$

## příklad: tolary (rozdělení příjmů)

jaké procento nejchudších získá **polovinu** celkového bohatství? četnosti (celkový měsíční příjem je 1687)

$x_j$	10	11	12	13	14	15	16	17	18	19	20		
$n_j$	7	14	16	10	6	3	9	3	1	5	3		
$x_j$	21	22	24	26	27	28	32	35	36	40	43	45	47
$n_j$	4	3	3	1	2	1	1	1	2	1	1	1	1

sčítejme příjmy nejchudších, dokud nenasčítáme 50 % z 1687

$$(7 \cdot 10 + \dots + 9 \cdot 16 + 17) / 1687 = 836 / 1687 = 0,4956 = 49,56 \%$$

$$(7 \cdot 10 + \dots + 9 \cdot 16 + 2 \cdot 17) / 1687 = 853 / 1687 = 0,5056 = 50,56 \%$$

u jaké části z 99 osob jsme sčítali příjmy?

$$(7 + \dots + 9 + 1) / 99 = 66 / 99 = 0,6667 = 66,67 \%$$

$$(7 + \dots + 9 + 2) / 99 = 67 / 99 = 0,6768 = 67,68 \%$$

## příklad: tolary (rozdělení příjmů)

jaké procento získají čtyři (tj. asi 4 %) nejbohatší resp. nejchudší? četnosti (celkový měsíční příjem je 1687)

$x_j$	10	11	12	13	14	15	16	17	18	19	20		
$n_j$	7	14	16	10	6	3	9	3	1	5	3		
$x_j$	21	22	24	26	27	28	32	35	36	40	43	45	47
$n_j$	4	3	3	1	2	1	1	1	2	1	1	1	1

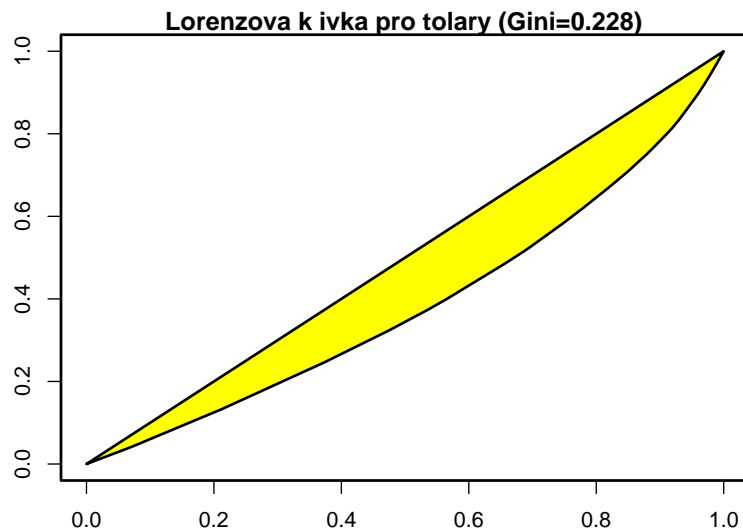
sečteme příjmy oněch čtyř nejbohatších

$$(47 + 45 + 43 + 40) / 1687 = 175 / 1687 = 0,1037 = 10,37 \%$$

čtyři nejbohatší tedy dostanou přes 10 % bohatství, kdežto čtyři nejchudší dostanou

$$(4 \cdot 10) / 1687 = 40 / 1687 = 0,0237 = 2,37 \%$$

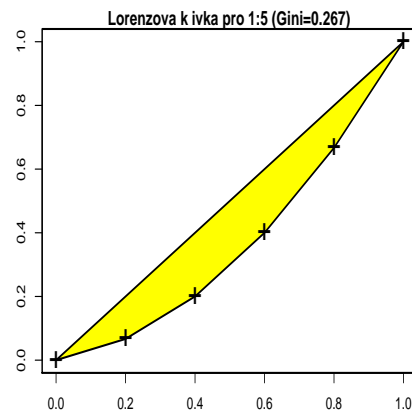
## Lorenzova křivka (Tolary)



## umělý příklad

$x_1, \dots, x_5: 1, 2, 3, 4, 5$

$j$	$j/n$	$x_{(j)}$	$X_j$	$X_j/X_n$
0	0,0		0	0,000
1	0,2	1	1	0,067
2	0,4	2	3	0,200
3	0,6	3	6	0,400
4	0,8	4	10	0,667
5	1,0	5	15	1,000



## Lorenzova křivka

- ▶ variační řada:  $0 < x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$  [sort(x)]
- ▶ kumulativní součty pro  $j = 0, 1, \dots, n$  [cumsum(sort(x))]  
(kolik patří celkem  $j$  nejchudším)

$$X_0 = 0 \quad X_j = x_{(1)} + x_{(2)} + \dots + x_{(j)} = \sum_{i=1}^j x_{(i)}$$

- ▶ úsečkami spojit body  $[j/n; X_j/X_n]$ ,  $0 \leq j \leq n$
- ▶ zajímá nás plocha nad touto lomenou čarou a pod úhlopříčkou jednotkového čtverce
- ▶ plocha měří nerovnoměrnost rozdělení nějakého zdroje
- ▶ kdyby dostal každý stejně, bude velikost plochy nulová
- ▶ Giniho koeficient koncentrace je dvojnásobkem této plochy

## příklad - pokračování

výpočet Giniho koeficientu ( $n = 5$ )

$$\begin{aligned} 5^2 \cdot \Delta &= |1-1| + |1-2| + |1-3| + |1-4| + |1-5| \\ &\quad + |2-1| + |2-2| + |2-3| + |2-4| + |2-5| \\ &\quad + |3-1| + |3-2| + |3-3| + |3-4| + |3-5| \\ &\quad + |4-1| + |4-2| + |4-3| + |4-4| + |4-5| \\ &\quad + |5-1| + |5-2| + |5-3| + |5-4| + |5-5| \\ &= 10 + 7 + 6 + 7 + 10 \end{aligned}$$


$$\Delta = 40/25 = 1,6$$

$$\bar{x} = 3$$

$$G = \frac{1,6}{2 \cdot 3} = \frac{1,6}{6} = 0,267$$

## Lorenzova křivka počet hejtmanů v krajích ČR

- ▶ v každém kraji je stejně hejtmanů, proto postupné součty rovnoměrně rostou, totéž platí pro  $X_j/X_n$
- ▶ lomená čára Lorenzovy křivky přejde v úsečku a plocha zmizí
- ▶ průměrná diference je nulová (všechny rozdíly  $|x_i - x_j|$  u počtu hejtmanů jsou nulové)




## příklad: kraje ČR ke konci roku 2006

kraj $i$	obyvatel $y_i$	rozloha[km <sup>2</sup> ] $n_i$	hustota na km <sup>2</sup> $x_i$
Hlavní město Praha	1 188 126	496,1	2 395,0
Středočeský kraj	1 175 254	11 014,7	106,7
Jihočeský kraj	630 006	10 056,9	62,6
Plzeňský kraj	554 537	7 561,1	73,3
Karlovarský kraj	304 602	3 314,6	91,9
Ústecký kraj	823 265	5 334,5	154,3
Liberecký kraj	430 774	3 163,0	136,2
Královéhradecký kraj	549 643	4 758,4	115,5
Pardubický kraj	507 751	4 518,6	112,4
Vysočina	511 645	6 795,6	75,3
Jihomoravský kraj	1 132 563	7 196,3	157,4
Olomoucký kraj	639 894	5 266,8	121,5
Zlínský kraj	589 839	3 963,5	148,8
Moravskoslezský kraj	1 249 290	5 427,0	230,2
celkem	10 287 189	78 867,0	130,4


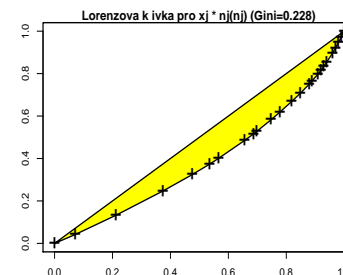
▶ Jdi zpět ▶ Jdi zpět ke grafu ▶ Jdi zpět k teorii

## Lorenzova křivka (obyvatelé – kraje)



## Lorenzova křivka pro tolarý ještě jinak

- ▶ spousta hodnot proměnné tolarý se opakuje, mohli jsme použít četnosti
- ▶ hodnota  $x_{(j)}$  se vyskytuje  $n_j$ krát
  - ▶ o  $10 \cdot 7 = 70$  tolarů se rozdělilo 7 „nejchudších“ osob
  - ▶ o  $11 \cdot 14 = 154$  tolarů se rozdělilo 14 druhých „nejchudších“
  - ▶ ...
  - ▶ posledních 47 tolarů připadlo jedinému nejbohatšímu



## případ s vahami - příklad

- ▶ nerovnoměrnost rozmístění obyvatel v republice, ale údaje jen podle krajů
- ▶ potřebovali bychom pro každý jednotlivý km<sup>2</sup> znát počet obyvatel zde žijících
- ▶ známe jen počty obyvatel  $y_i$  v krajích a rozlohu krajů  $n_i$
- ▶ předpokládáme rovnoměrné rozmístění uvnitř kraje, tedy  $x_i = y_i/n_i$  obyvatel na každý km<sup>2</sup> v  $i$ -tém kraji
- ▶ každou takovou hustotu  $x_i$  musíme započítat  $n_i$ krát
- ▶ celková plocha  $n = n_1 + \dots + n_{14} (= N_{14})$
- ▶ průměrný počet obyvatel na km<sup>2</sup>


$$\bar{x} = \frac{\sum_i n_i x_i}{\sum_i n_i} = \frac{\sum_i n_i (y_i/n_i)}{n} = \frac{\sum_i y_i}{n} = \bar{y}$$

▶ Jdi zpět k tabulce

3. přednáška 15. října 2007

Statistika (MD360P03Z, MD360P03U) ak. rok 2007/2008

## Lorenzova křivka: obyvatelé okresů, vztaheno k rozloze




▶ Jdi zpět ke grafu krajů

3. přednáška 15. října 2007

Statistika (MD360P03Z, MD360P03U) ak. rok 2007/2008

## Lorenzova křivka: obyvatelé krajů, vztaheno k rozloze



▶ Jdi ke grafu okresů

▶ Jdi zpět k tabulce

3. přednáška 15. října 2007

Statistika (MD360P03Z, MD360P03U) ak. rok 2007/2008

## poznámky

- ▶ hrubší hodnocení (kraje, nikoliv okresy) znamená **menší** hodnotu Giniho indexu!
- ▶ nezáleží na zvolených jednotkách
- ▶ na vodorovné ose jde o umístění v řadě od nejchudších k nejbohatším
- ▶ označme kumulativní součty  $N_i = \sum_{j=1}^i n_j$
- ▶ na svislé ose jde o podíl na bohatství
- ▶ označme kumulativní součty od nejchudších  $Y_i = \sum_{j=1}^i y_j$
- ▶ pro zajímavost:  $N_k = n$ , rozděljuje se bohatství  $Y_k$
- ▶ ve všech případech je **pořadí** sčítanců dáno pořadím „hustot“  $x_i = \frac{y_i}{n_i}$  (např. obyvatel/rozloha)

3. přednáška 15. října 2007

Statistika (MD360P03Z, MD360P03U) ak. rok 2007/2008

## výpočet v případě vah

- ▶ kumulativní součty  $N_i = \sum_{j=1}^k n_j$ ,  $Y_i = \sum_{j=1}^k Y_j$
- ▶ střední diference průměrných počtů obyvatel na km<sup>2</sup> (hustot)

$$\Delta = \frac{1}{n^2} \sum_{i=1}^k \sum_{j=1}^k n_i n_j |x_i - x_j| = \frac{1}{(\sum n_t)^2} \sum_{i=1}^k \sum_{j=1}^k n_i n_j \left| \frac{y_i}{n_i} - \frac{y_j}{n_j} \right|$$

$$= \frac{1}{n^2} \sum_{i=1}^k \sum_{j=1}^k |n_j y_i - n_i y_j| = \frac{2}{n^2} \sum_{i=1}^{k-1} (N_i Y_{i+1} - N_{i+1} Y_i)$$

$$G = \frac{\Delta}{2\bar{y}} = \sum_{i=1}^{k-1} \left( \frac{N_i}{N_k} \frac{Y_{i+1}}{Y_k} - \frac{N_{i+1}}{N_k} \frac{Y_i}{Y_k} \right)$$

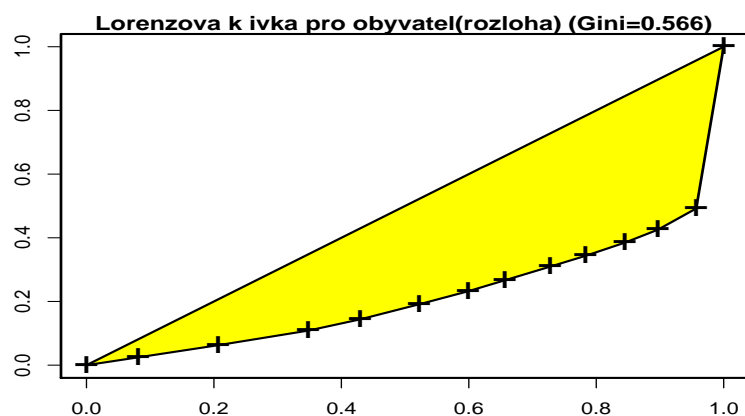
- ▶ Lorenzova křivka spojuje body  $\left[ \frac{N_i}{N_k}; \frac{Y_i}{Y_k} \right]$

▶ Jdi zpět k tabulce dat

## příklad Pavlík, Kühnl: str. 114 (okresy střečdočeského kraje)

Okres <i>i</i>	plocha [km <sup>2</sup> ] <i>n<sub>i</sub></i>	obyvatel <i>y<sub>i</sub></i>	hustota na km <sup>2</sup> <i>x<sub>i</sub></i>
BN	1443	88288	61,2
RA	930	56489	60,7
PB	1629	106266	65,2
KH	937	81890	87,4
MB	1067	109766	102,9
NB	881	94377	107,1
BE	662	79764	120,5
KO	819	99408	121,4
PZ	634	77940	122,9
ME	713	96104	134,8
PH	597	94328	158,0
KL	692	154445	223,2
AB	496	1175522	2370,0
celkem	11500	2314587	201,3

## příklad Pavlík, Kühnl: str. 114



## možné příští úlohy statistické indukce

- ▶ na hracích kostkách A a B padala šestka nestejně často:
  - na kostce A v 17 ze 100 pokusů
  - na kostce B v 41 ze 100 pokusů
- ▶ je pravděpodobnost šestky rovna 1/6?
  - ▶ teorie pravděpodobnosti odvodí teoretickou hodnotu
  - ▶ matematická statistika odhadne, prověří představu teorie
- ▶ je kostka symetrická, tj. mají všechny stěny kostky stejnou pravděpodobnost?
- ▶ kolik potřebujeme nezávislých hodů, abychom s požadovanou spolehlivostí poznali, že je kostka nesymetrická?
- ▶ liší se mezi sebou kostky A a B?
- ▶ vše založeno na modelu **populace – výběr** [population, sample]

## populace a výběr

- ▶ model **populace – výběr** umožňuje zobecnění na celou populaci z hodnot zjištěných na vybraných statistických jednotkách (výběr)
- ▶ **populace (základní soubor)** – velký soubor, jehož je zpracováván soubor (**výběr**) reprezentativním vzorkem
- ▶ **reprezentativnost** – frekvence výskytu důležitých doprovodných znaků ve výběru odpovídá jejich frekvenci v populaci
- ▶ reprezentativnosti nejlépe dosáhneme tak, že použijeme **prostý náhodný výběr**, kdy každá  $n$ -tice prvků populace má stejnou šanci (pravděpodobnost) do výběru se dostat
- ▶ na základě výběru tvrdíme něco o populaci

## základní pojmy

- ▶ **pokus** – dobře definovaná situace (postup), která končí jedním z řady možných výsledků (vržená kostka spadne na zem)
- ▶ **náhodný pokus** – pokus, u něhož předem nevíme, který výsledek nastane (která strana kostky padne přistě?); předpokládá se stabilita relativních četností možných výsledků
- ▶ **náhodný jev** – tvrzení o výsledku náhodného pokusu
- ▶ **pravděpodobnost** náhodného jevu  $A$  – číselné vyjádření očekávání, že výsledkem náhodného pokusu bude právě  $A$
- ▶ racionální představa: při velkém počtu opakování pokusu se relativní četnost jevu blíží k pravděpodobnosti tohoto jevu

## parametry – odhady, statistiky

- ▶ podle toho, jakou roli hraje hodnocený soubor, rozlišujeme **charakteristiky**
  - ▶ **populační**: vztažené k populaci, mnohdy jen ideální, námi představované, jsou to **parametry** modelu
  - ▶ **výběrové**: vztažené k výběru z nějaké populace, jsou to **statistiky** spočítané z výběru
- ▶ **statistika** – z výběru spočítaná hodnota (např. součet napozorovaných hodnot, průměr, Giniho index ...)
- ▶ speciálním případem statistik jsou **odhady** odpovídajících populačních **parametrů**,
- ▶ příkladem dvojice odhad – parametr je dvojice relativní četnost – pravděpodobnost (např. 17/100 vers. 1/6)
- ▶ statistiky se používají při **statistické indukci** (statistickém rozhodování) [statistical inference (decisions)]

## klasická pravděpodobnost (Laplace)

- ▶ **jistý jev** (nastává vždy) lze rozdělit na  $M$  *stejně pravděpodobných* neslučitelných (disjunktních) **elementárních jevů** (symetrie)
- ▶ každý jev lze složit z těchto **elementárních jevů**
- ▶ je celkem  $M_A$  **příznivých** jevu  $A$  (je z nich složen)
- ▶ **klasická definice pravděpodobnosti** (metoda výpočtu)

$$P(A) = \frac{M_A}{M}$$

- ▶ **klasickou pst lze použít jen někdy!** (Sportka, Sazka)

## příklad: hrací kostka

- ▶ idealizovaná symetrická hrací kostka
  - ▶ homogenní
  - ▶ přesná krychle
  - ▶ těžiště uprostřed
  - ▶ každá strana má stejnou pravděpodobnost
- ▶  $A$  – padne šestka,  $B$  – padne sudé číslo
- ▶  $M = 6$
- ▶  $M_A = 1$ , tedy  $P(A) = 1/6$
- ▶  $M_B = 3$ , tedy  $P(B) = 3/6 = 1/2$

## počet kombinací

[KOMBINACE( $n$ ;  $k$ )][choose( $n$ ,  $k$ )]

- ▶ **kombinační číslo**  $\binom{n}{k}$  (čti „ $n$  nad  $k$ “)
- ▶ počet  $k$ -prvkových podmnožin množiny o  $n$  prvcích nezávisle na jejich pořadí

$$\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n \cdot (n-1) \cdots (n-k+1)}{k \cdot (k-1) \cdots 2 \cdot 1}$$

- ▶ kolika způsoby si mohu z pěti knížek vybrat dvě na dovolenou:

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

- ▶ kolika způsoby si z oněch pěti mohu vybrat tři knihy? (10)

## faktoriál

[FAKTORIÁL( $n$ )][factorial( $n$ )]

- ▶ **faktoriál**  $n! = n \cdot (n-1) \cdots 2 \cdot 1$   $0! = 1$
- ▶ kolika způsoby lze uspořádat za sebou  $n$  rozlišitelných prvků
- ▶ příklady:
  - ▶  $5! = 5 \cdot 4 \cdot 3 \cdot 2 \cdot 1 = 120$
  - ▶  $1! = 1$
- ▶ kolika způsoby lze uspořádat za sebou 14 krajů ČR:  
 $14! = 14 \cdot 13 \cdot 12 \cdots 2 \cdot 1 = 87\,178\,291\,200 = 8,7 \cdot 10^{10}$

## příklad: losování otázek (1)

- ▶ student *neumí* 5 otázek, *umí* 10 otázek
- ▶ losuje se dvojice otázek z oněch 15 otázek
- ▶ pravděpodobnost  $P(A)$ , že student nezná ani jednu z vylosovaných:
- ▶ elementární jevy: první losovaná otázka – 15 možností, druhá jen 14 možností, nezáleží na pořadí, tedy dělit 2 (tedy počet kombinací)

$$M = \binom{5+10}{2} = \binom{15}{2} = \frac{15!}{2!13!} = \frac{15 \cdot 14}{2 \cdot 1} = 105$$

- ▶ příznivé elementární jevy: vylosuje se obě z pěti, které neumí

$$M_A = \binom{5}{2} \binom{10}{0} = \frac{5 \cdot 4}{2 \cdot 1} \cdot 1 = 10 \Rightarrow P(A) = \frac{10}{105} = 9,5 \%$$





## idealizovaný příklad

- ▶  $A$  – jednička ze statistiky,  $P(A) = 0,3$
- ▶  $B$  – jednička z matematiky,  $P(B) = 0,2$
- ▶  $A \cap B$  – jednička z obou předmětů,  $P(A \cap B) = 0,1$
- ▶ jsou jevy  $A, B$  nezávislé? (jsou jedničky ze dvou předmětů nezávislé?) NE, protože  $0,3 \cdot 0,2 \neq 0,1$
- ▶ jaká je pst jedničky ze statistiky, když už je z matematiky?

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{0,1}{0,2} = 0,5$$

- ▶ pst jedničky z matematiky, když už je ze statistiky:  
 $P(B|A) = 0,1/0,3 = 1/3$
- ▶ pravděpodobnost, že aspoň jedna jednička:

$$P(A \cup B) = P(A) + P(B) - P(A \cap B) = 0,3 + 0,2 - 0,1 = 0,4$$

## rozdělení náhodné veličiny

- ▶ **náhodná veličina** – číselně vyjádřený výsledek náhodného pokusu
- ▶ **diskrétní rozdělení** (pro četnosti) určeno seznamem možných hodnot a jejich pravděpodobnostmi:

$$x_1, x_2, \dots$$


$$P(X = x_1), P(X = x_2), \dots$$

- ▶ **spojité rozdělení** (pro spojité měřtko) určeno **distribuční funkcí**

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

nebo **hustotou**

$$f_X(x) = \frac{d}{dx} F_X(x), \quad F_X(x) = \int_{-\infty}^x f_X(t) dt$$

věk matek ( $n=4838$ )


- ▶ velká populace, spojité veličina – intervaly pro třídění mohou být krátké, obálce histogramu relativních četností odpovídá **hustota**  $f_X(x)$  [density]
- ▶ podobně kumulativním relativním četnostem odpovídá **distribuční funkce** [distribution function]
- ▶ bezprostředním výběrovým protějškem distribuční funkce je **empirická distribuční funkce**

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

- ▶  $x_1^* < x_2^* < \dots < x_m^*$  existující různé hodnoty  $n_1, n_2, \dots, n_m$  jejich četnosti ( $n = \sum_j n_j$ )  
 $F_n(x)$  je schodovitá funkce, v bodě  $x_j^*$  má skok  $n_j/n$

## kumulativní distribuční funkce (tolary)

skoky odpovídají četnostem, např. ve 12 je skok z 0,21 na 0,37 o 16/99=0,16



	tolary																				
$x_j^*$	10	11	12	13	14	15	16	17	18	19	20										
$n_j$	7	14	16	10	6	3	9	3	1	5	3										
$N_j$	7	21	37	47	53	56	65	68	69	74	77										
$x_j^*$	21	22	24	26	27	28	32	35	36	40	43	45	47								
$n_j$	4	3	3	1	2	1	1	1	2	1	1	1	1								
$N_j$	81	84	87	88	90	91	92	93	95	96	97	98	99								

## charakteristiky rozdělení náhodné veličiny (1)

- ▶ **střední hodnota** náhodné veličiny  $X$  (populační průměr)
- ▶ je to **vážený průměr možných hodnot**
- ▶ vahami jsou pravděpodobnosti hodnot

$$\mu_X = E X = x_1 \cdot P(X = x_1) + x_2 \cdot P(X = x_2) + \dots = \sum_j x_j \cdot P(X = x_j)$$

- ▶ operátor  $E$  (expectation) aplikovaný na náhodnou veličinu  $X$  spočítá vážený průměr jejích hodnot, vahami jsou u diskrétního rozdělení pravděpodobnosti těchto hodnot
- ▶ pro spojitě rozdělení

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

## příklad diskrétního rozdělení: známky u zkoušky

$X, Y$  známky ze dvou předmětů

známka $k$	1	2	3	4
$P(X = k)$	0,3	0,4	0,2	0,1
$P(Y = k)$	0,3	0,3	0,2	0,2

- ▶ z tabulky *nic* nepoznáme o případné závislosti  $X, Y$
- ▶ jak jedním číslem charakterizovat úroveň známek?
- ▶ obyčejný průměr možných hodnot by  $X, Y$  nerozlišil
- ▶ použijme **vážený průměr**, kde vahami známek jsou **pravděpodobnosti možných hodnot**
- ▶ dostaneme tak **střední hodnoty  $X$  a  $Y$  (populační průměry)**

$$\mu_X = 1 \cdot 0,3 + 2 \cdot 0,4 + 3 \cdot 0,2 + 4 \cdot 0,1 = 2,1$$

$$\mu_Y = 1 \cdot 0,3 + 2 \cdot 0,3 + 3 \cdot 0,2 + 4 \cdot 0,2 = 2,3$$

- ▶ **střední hodnota funkce  $Y = g(X)$**  náhodné veličiny  $X$  vážený průměr **funkčních hodnot**

$$E Y = E g(X) = \sum_k g(x_k) P(X = x_k)$$

resp. pro spojitě rozdělení

$$E Y = E g(X) = \int_{-\infty}^{\infty} g(x) f(x) dx$$

- ▶ **populační medián  $\tilde{\mu}$**  spojitě rozdělení

$$F_X(\tilde{\mu}) = P(X \leq \tilde{\mu}) = 0,5$$

$\tilde{x}$  číslo, které dělí možné hodnoty náhodné veličiny na dva stejně pravděpodobné intervaly hodnot větších a menších

## příklad diskrétního rozdělení: známka u zkoušky

známka $k$	1	2	3	4	$\mu$	$\sigma^2$	$\sigma$
$P(X = k)$	0,3	0,4	0,2	0,1	2,1	0,89	0,943
$P(Y = k)$	0,3	0,3	0,2	0,2	2,3	1,21	1,100

- ▶ jedním číslem charakterizovat kolísání známek (**variabilitu**)
- ▶ **(populační) rozptyl = vážený průměr čtverců** vzdáleností od střední hodnoty
- ▶ vahami jsou pravděpodobnosti

$$\sigma_X^2 = (1 - 2,1)^2 \cdot 0,3 + (2 - 2,1)^2 \cdot 0,4 + (3 - 2,1)^2 \cdot 0,2 + (4 - 2,1)^2 \cdot 0,1 = 0,89 = 0,943^2$$

$$\sigma_Y^2 = (1 - 2,3)^2 \cdot 0,3 + (2 - 2,3)^2 \cdot 0,3 + (3 - 2,3)^2 \cdot 0,2 + (4 - 2,3)^2 \cdot 0,2 = 1,21 = 1,1^2$$

(populační) rozptyl náhodné veličiny  $X$ 

- ▶ vážený průměr čtverců vzdáleností možných hodnot od střední hodnoty

$$\begin{aligned}\sigma_X^2 &= E(X - \mu_X)^2 \\ &= (x_1 - \mu_X)^2 P(X = x_1) + (x_2 - \mu_X)^2 P(X = x_2) + \dots \\ &= \sum_j (x_j - \mu_X)^2 P(X = x_j)\end{aligned}$$

$$\sigma_X^2 = E(X - \mu_X)^2 = \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx$$

- ▶ **(populační) směrodatná odchylka** odmocnina z (populačního) rozptylu

$$\sigma_X = \sqrt{\sigma_X^2}$$

## vlastnosti střední hodnoty a rozptylu

$X, Y$  – náhodné veličiny,  $a, b$  konstanty,  $b > 0$

$$\mu_{a+X} = E(a + X) = a + EX = a + \mu_X$$

$$\mu_{b \cdot X} = E(b \cdot X) = b \cdot EX = b \cdot \mu_X$$

$$\mu_{X+Y} = E(X + Y) = EX + EY = \mu_X + \mu_Y$$

▶ Návrat k průměru  $\sigma_{a+X}^2 = \sigma_X^2, \quad \sigma_{a+X} = \sigma_X$

$$\sigma_{b \cdot X}^2 = b^2 \sigma_X^2, \quad \sigma_{b \cdot X} = |b| \sigma_X$$

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

▶ Návrat k rozptylu  $\sigma_{X,Y} = E(X - \mu_X)(Y - \mu_Y)$  **kovariance**  $X, Y$

$$\begin{aligned}&= (x_1 - \mu_X)(y_1 - \mu_Y)P(X = x_1, Y = y_1) \\ &+ (x_1 - \mu_X)(y_2 - \mu_Y)P(X = x_1, Y = y_2) + \dots\end{aligned}$$

(sčítá se přes všechny možné dvojice)

## nezávislé náhodné veličiny

- ▶ připomeňme: náhodné jevy  $A, B$  jsou nezávislé, když

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

- ▶ náhodné veličiny  $X, Y$  jsou **nezávislé**, když pro **všechny dvojice** možných hodnot  $(x_i, y_j)$  platí

$$P(X = x_i, Y = y_j) = P(X = x_i) \cdot P(Y = y_j)$$

- ▶  $X$  a  $Y$  jsou tedy nezávislé, jsou-li nezávislé jevy  $A = \{\text{tvrzení o } X\}$  a  $B = \{\text{tvrzení o } Y\}$
- ▶ jsou-li  $X, Y$  nezávislé, pak

$$\sigma_{X,Y} = 0, \quad \text{tedy } \sigma_{X+Y}^2 = \sigma_X^2 + \sigma_Y^2$$

- ▶ pro **nezávislé** náhodné veličiny platí: **rozptyl součtu = součet rozptylů**

## (populační) korelační koeficient

- ▶ Pearsonův korelační koeficient

$$r_{x,y} = \frac{s_{xy}}{s_x s_y}$$

- ▶ výběrová kovariance dána vztahem (str. 59)

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

- ▶ populační protějšek

$$\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

- ▶  $\rho_{XY}$  má stejné vlastnosti jako  $r_{xy}$ , zejména platí  $|\rho_{XY}| \leq 1$
- ▶ pro **nezávislé** náhodné veličiny  $X, Y$  je vždy  $\rho_{XY} = 0$

## alternativní rozdělení

- ▶ diskrétní, s jediným parametrem  $\pi$  (nikoliv Ludolfovo číslo)
- ▶  $P(X=1) = \pi$ ,  $P(X=0) = 1 - \pi$  ( $0 < \pi < 1$ )
- ▶  $X$  – kolikrát v jednom pokusu došlo k události, která má pravděpodobnost  $\pi$  (jen dvě možné hodnoty: 0 nebo 1)
- ▶ **střední hodnota** (populační průměr)

$$\mu_X = 1 \cdot P(X=1) + 0 \cdot P(X=0) = \pi$$

- ▶ (populační) **rozptyl**

$$\begin{aligned} \sigma_X^2 &= (1 - \mu_X)^2 P(X=1) + (0 - \mu_X)^2 P(X=0) \\ &= (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) \\ &= (1 - \pi)^2 \pi + \pi^2 (1 - \pi) = \pi(1 - \pi) \end{aligned}$$

## idealizovaný příklad: známky u zkoušky

sdužené a **marginální** pravděpodobnosti

X	Y				P(X = k)
	1	2	3	4	
1	0,15	0,10	0,05	0,00	0,3
2	0,10	0,15	0,10	0,05	0,4
3	0,05	0,05	0,05	0,05	0,2
4	0,00	0,00	0,00	0,10	0,1
	0,3	0,3	0,2	0,2	1,0

$$\begin{aligned} \sigma_{X,Y} &= (1 - 2,1)(1 - 2,3) \cdot 0,15 + (1 - 2,1)(2 - 2,3) \cdot 0,10 + \dots \\ &\quad + (4 - 2,1)(3 - 2,3) \cdot 0,00 + (4 - 2,1)(4 - 2,3) \cdot 0,10 = 0,57 \end{aligned}$$

$$\rho_{X,Y} = \frac{0,57}{0,943 \cdot 1,1} = 0,55 \quad \Rightarrow \quad X \text{ a } Y \text{ jsou závislé}$$

binomické rozdělení  $bi(n, \pi)$  (1)

- ▶ diskrétní rozdělení s parametry  $n, \pi$  ( $0 < \pi < 1$ )
- ▶  $n$  **nezávislých** pokusů
- ▶ v každém zdar s pravděpodobností  $\pi$ , nezdar s pstí  $1 - \pi$
- ▶ **celk. počet zdarů**  $X$  má binomické rozdělení s parametry  $n, \pi$
- ▶ zapisujeme  $X \sim bi(n, \pi)$
- ▶  $X$  je součet  $n$  **nezávislých** náhodných veličin  $X_i$  ( $X_i =$  počet zdarů v  $i$ -tém pokusu) každé  $X_i$  má alternativní rozdělení s parametrem  $\pi$
- ▶ z vlastnosti střední hodnoty součtu náh. veličin:  $\mu_X = n\pi$
- ▶ z vlastnosti rozptylu součtu **nezávislých** náhodných veličin

$$\sigma_X^2 = n\pi(1 - \pi)$$

binomické rozdělení  $bi(n, \pi)$  (2)

- ▶ pravděpodobnosti možných hodnot

$$P(X = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$$

- ▶ pst, že v **daných**  $k$  pokusech zdar  $Z$ , v ostatních nezdar  $N$

$$\underbrace{ZZ \dots Z}_k \underbrace{NN \dots N}_{n-k} \text{ s pstí } \pi^k (1 - \pi)^{n-k}$$

- ▶ zvolíme  $k$  míst pro zdar  $Z$ , na ostatních místech nezdar  $N$ , počet možností:

$$\binom{n}{k} = \frac{n!}{k!(n-k)!} = \frac{n(n-1) \dots (n-k+1)}{k(k-1) \dots 2 \cdot 1}$$

## příklad: kouření

- ▶ víme, že mezi dvacetiletými muži je (řekněme) 35 % kuřáků (např. je-li 70 tisíc dvacetiletých, pak je mezi nimi asi 24 500 kuřáků, ale nevíme, kteří to jsou)
- ▶ vybereme náhodně 60 dvacetiletých mužů,  $X$  – počet kuřáků mezi nimi, tedy  $X \sim bi(60, 0,35)$
- ▶

$$\mu_X = 60 \cdot 0,35 = 21 \quad \sigma_X^2 = 60 \cdot 0,35 \cdot 0,65 = 13,65 = (3,7)^2$$

- ▶ ukázky pravděpodobností možných hodnot

[BINOMDIST(15;60;0,35;0)] [dbinom(15,60,0,35)]

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

## příklad: zkoušky

- ▶  $C$  – zdar = udělat zkoušku,  $P(C) = 0,8$
- ▶ zkoušku dělá  $n = 10$  studentů stejně připravených (u všech stejná pravděpodobnost  $\pi$ ), studenti neopisují (nezávislost)
- ▶ pst, že zkoušku udělá nějakých 9 studentů

$$P(X = 9) = \binom{10}{9} \cdot 0,8^9 \cdot 0,2^1 = 10 \cdot 0,8^9 \cdot 0,2^1 = 0,268$$

- ▶ pst, že právě jeden student (nějaký) zkoušku neudělá

$$P(Y = 1) = \binom{10}{1} \cdot 0,2^1 \cdot 0,8^9 = 10 \cdot 0,2^1 \cdot 0,8^9 = 0,268$$

- ▶ pst, že zkoušku udělá **daných** 9 studentů: 0,0268

Poissonovo rozdělení  $Po(\lambda)$  (1)

- ▶ diskrétní rozdělení (zákon vzácných jevů),  $Y \sim Po(\lambda)$
- ▶  $Y$  – počet výskytů jevu ve zvolené časové (prostorové, plošné ...) jednotce
- ▶  $\lambda > 0$  – jediný parametr, intenzita výskytu jevu (jak často se v průměru vyskytuje ve zvolené jednotce)

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

- ▶ střední hodnota, (populační) rozptyl

$$\mu_Y = \lambda, \quad \sigma_Y^2 = \lambda$$

- ▶ u binomického rozdělení bylo  $\mu_X > \sigma_X^2$ , zde rovnost

Poissonovo rozdělení  $Po(\lambda)$  (2)

- ▶ parametr  $\lambda$  znamená hustotu na jednotku plochy (populační průměr počtu případů na jednotku)
- ▶ změníme-li jednotku plochy, změní se parametr: při počítání pravděpodobností toho, kolikrát najdeme případ na trojnásobku původní jednotky (trojnásobné ploše, ve trojnásobném čase ...), bude novým parametrem  $3\lambda$
- ▶ analogicky pro jiné kladné násobky
- ▶ aproximace:  $X \sim bi(n, \pi)$ ,  $n$  velké,  $\pi$  malé ( $\mu_X = n \cdot \pi$ ) pak pravděpodobnosti hodnot  $X$  lze aproximovat (přibližně vyjádřit) pomocí pravděpodobností hodnot  $Y \sim Po(n \cdot \pi)$
- ▶ Poissonovo rozdělení  $Po(n \cdot \lambda)$  aproximuje binomické  $bi(n, \pi)$

## souvislost binomického a Poissonova rozdělení

- ▶ s jakou pravděpodobností **neudělá** 12 z 50 stejně připravených studentů zkoušku? (pst neúspěchu = 0,2)
  - ▶ binomické rozdělení  $bi(50, 0,2)$   
[BINOMDIST(12;50;0,2)] [dbinom(12,50,0,2)]
- $$P(X = 12) = \binom{50}{12} \cdot 0,2^{12} \cdot 0,8^{38} = 0,103$$
- ▶ Poissonovo rozdělení  $Po(50 \cdot 0,2) = Po(10)$   
[POISSON(12;10;0)] [dpois(12,10)]

$$P(Y = 12) = \frac{10^{12}}{12!} e^{-10} = 0,095$$

## příklady Poissonova rozdělení


- ▶ do pasti padá za noc v průměru 8 brouků ( $\lambda = 8$ )
- ▶ s jakou pravděpodobností jich tam ráno najdeme 10?  
[POISSON(10;8;0)] [dpois(10,8)]

$$P(Y = 10) = \frac{8^{10}}{10!} e^{-8} = 0,099$$

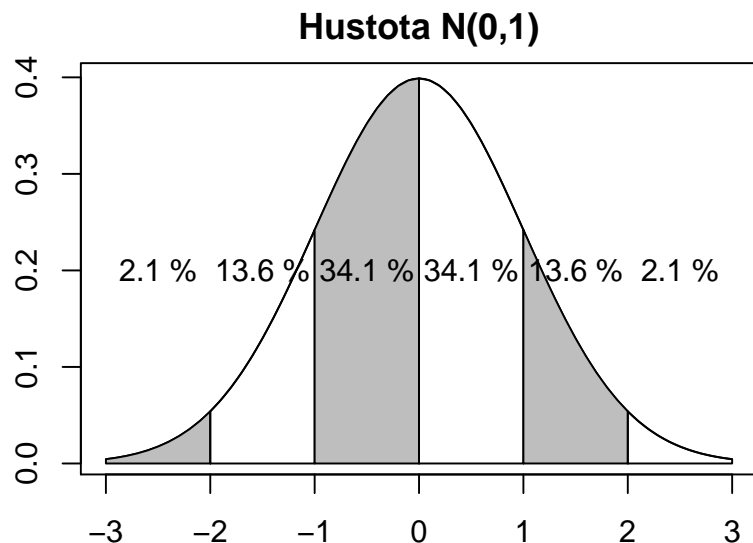
- ▶ vezmeme-li past s polovičním obvodem, očekáváme poloviční průměr za noc ( $\lambda = 4$ )

$$P(Y = 10) = \frac{4^{10}}{10!} e^{-4} = 0,005$$

$$P(Y = 5) = \frac{4^5}{5!} e^{-4} = 0,156$$

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

- ▶ spojité rozdělení, symetrické okolo střední hodnoty  $\mu$
- ▶ maximální hodnota hustoty je úměrná  $1/\sigma$  ( $\frac{1}{\sqrt{2\pi\sigma^2}} \doteq \frac{0,4}{\sigma}$ )
- ▶ model vzniku: součet velkého počtu nepatrných příspěvků

normované normální rozdělení  $Z \sim N(0,1)$ 

## příklady pravděpodobností o normálním rozdělení

- ▶ pro  $X \sim N(\mu, \sigma^2)$  platí

$$\mu_X = E X = \mu \quad \sigma_X^2 = E (X - \mu_X)^2 = \sigma^2$$

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

▶

$$P(|Z| < c) = P\left(\left|\frac{X - \mu}{\sigma}\right| < c\right) = P(|X - \mu| < c \cdot \sigma)$$

- ▶ tedy

$$P(|X - \mu| < 1,00 \sigma) = 0,68, \text{ tj. } 68 \%$$

$$P(|X - \mu| < 1,96 \sigma) = 0,95, \text{ tj. } 95 \%$$


$$P(|X - \mu| < 2,00 \sigma) = 0,9545, \text{ tj. } 95,45 \%$$

$$P(|X - \mu| < 3,00 \sigma) = 0,9973, \text{ tj. } 99,73 \%$$

normované normální rozdělení  $Z \sim N(0,1)$ 

tabelováno:

- ▶ hustota  $\varphi(z)$   
[NORMDIST(z;0;1)] [dnorm(z)]
- ▶ distribuční funkce  $\Phi(z) = P(Z \leq z)$   
[NORMSDIST(z)] [pnorm(z)]
- ▶ **kritické hodnoty**  $z(\alpha)$ :  $P(Z \leq z(\alpha)) = \Phi(z(\alpha)) = 1 - \alpha$   
[NORMSINV(z)] [qnorm(z)]



## zajímavé kritické hodnoty

$$z(0,025) = 1,96 \text{ tj. } P(Z > 1,96) = 2,5 \%$$

$$z(0,025) = 1,96 \text{ tj. } P(Z < -1,96) = 2,5 \%$$

$$z(0,025) = 1,96 \text{ tj. } P(|Z| > 1,96) = 5 \%$$

$$z(0,005) = 2,58 \text{ tj. } P(Z > 2,58) = 0,5 \%$$

$$z(0,005) = 2,58 \text{ tj. } P(Z < -2,58) = 0,5 \%$$

$$z(0,005) = 2,58 \text{ tj. } P(|Z| > 2,58) = 1 \%$$

$$z(0,050) = 1,64 \text{ tj. } P(Z > 1,64) = 5 \%$$

$$z(0,050) = 1,64 \text{ tj. } P(Z < -1,64) = 5 \%$$

$$z(0,050) = 1,64 \text{ tj. } P(|Z| > 1,64) = 10 \%$$

výpočet pravděpodobností pro  $Z \sim N(0, 1)$ 


- ▶ u spojitého rozdělení je  $P(X < x) = P(X \leq x)$ , tedy i u  $Z$
- ▶  $Z \sim N(0, 1)$ ,  $a < b$ , pak  $P(a < Z < b) = \Phi(b) - \Phi(a)$
- ▶ odvození: jevy ( $Z \leq a$ ) a ( $a < Z \leq b$ ) jsou neslučitelné (tvrzení nemohou platit současně) jejich sjednocením je jev ( $Z \leq b$ ), proto

$$P(Z \leq b) = P(Z \leq a) + P(a < Z \leq b)$$

$$\Phi(b) = \Phi(a) + P(a < Z \leq b)$$

- ▶ příklad:  $P(1 < Z < 2) = \Phi(2) - \Phi(1) = 0,977 - 0,841 = 0,136$ , jak bylo na obrázku

`[NORMSDIST(2)-NORMSDIST(1)]`     `[pnorm(2)-pnorm(1)]`

Postup výpočtu  $P(1 < Z < 2)$  ( $Z \sim N(0, 1)$ ) pomocí tabelované funkce  $\Phi(z) = F_Z(z) = P(Z \leq z)$ výpočet pro  $X \sim N(\mu, \sigma^2)$ 

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

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

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

**příklad:**  $X \sim N(136,1, 6,4^2)$  (výšky 10letých hochů v roce 1951)

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

tedy v rozmezí 135 cm až 140 cm bylo asi 35,3 % hochů

## pohodlnější možnost

- ▶  $X \sim N(136,1, 6,4^2)$
- ▶ počítáme  $P(134,5 < X < 140,5)$
- ▶ Excel i R nabízejí možnost dosadit skutečné parametry normálního rozdělení
- ▶ druhým parametrem je **směrodatná odchylka**
- ▶ Excel (nepřehlédněte, že nejde o NORMSDIST!):  
`[NORMDIST(140,5;136,1;6,4;1)-NORMDIST(134,5;136,1;6,4;1)]`
- ▶ R:  
`[pnorm(140.5,136.1,6.4)-pnorm(134.5,136.1,6.4)]`



## populace a výběr

- ▶ populaci charakterizujeme pomocí parametrů rozdělení, případně typu rozdělení
- ▶ výsledek měření na náhodně vybraném prvku populace – náhodná veličina
- ▶ skutečné hodnoty parametrů neznáme
  - ▶ chceme je odhadnout
  - ▶ chceme rozhodnout o platnosti tvrzení (hypotézy) o parametrech
- ▶ jako výběr si představujeme několik **nezávislých** náhodných veličin se stejným rozdělením a neznámými parametry
  - ▶ parametry odhadujeme na základě výběru
  - ▶ o hypotézách rozhodujeme na základě výběru
- ▶ příklady
  - ▶ střední hodnotu náhodné veličiny (populační průměr) odhadujeme pomocí výběrového průměru
  - ▶ rozptyl náhodné veličiny odhadujeme pomocí výběrového rozptylu

## variabilita výběrového průměru

- ▶ pro rozptyl **nezávislých** náhodných veličin platí [Vlastnosti](#)

$$\sigma_{\bar{X}+Y}^2 = \sigma_{\bar{X}}^2 + \sigma_Y^2 \quad \sigma_{b \cdot X}^2 = b^2 \sigma_X^2$$

- ▶ proto je

$$\sigma_{\bar{X}}^2 = \sigma_{\frac{1}{n} \sum_{i=1}^n X_i}^2 = \frac{1}{n^2} n \sigma^2 = \frac{\sigma^2}{n}$$

- ▶ průměr  $\bar{X}$  má tedy rozptyl  $n$ -krát menší, než jednotlivá pozorování
- ▶ **střední chyba** průměru = směrodatná odchylka průměru

$$\text{S.E.}(\bar{X}) = \frac{\sigma}{\sqrt{n}}$$

## chování výběrového průměru

- ▶ necht  $X_1, X_2, \dots, X_n$  jsou nezávislé náhodné veličiny s **libovolným stejným rozdělením** se střední hodnotou  $\mu$  a rozptylem  $\sigma^2$ , tj. **náhodný výběr** z onoho rozdělení

$$\text{▶ průměr } X_1, X_2, \dots, X_n: \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

- ▶ připomeňme vlastnosti střední hodnoty [Vlastnosti](#)


$$\mu_{X+Y} = \mu_X + \mu_Y, \quad \mu_{b \cdot X} = b \cdot \mu_X$$

- ▶ proto je

$$\mu_{\bar{X}} = \mu_{\frac{1}{n} \sum_{i=1}^n X_i} = \frac{1}{n} \cdot \mu_{\sum_{i=1}^n X_i} = \frac{1}{n} \sum_{i=1}^n \mu_{X_i} = \frac{1}{n} n \mu = \mu$$

- ▶  $\mu_{\bar{X}} = \mu$ , tj.  $\bar{X}$  je **nestranný odhad** parametru  $\mu$

## příklad: věk matek

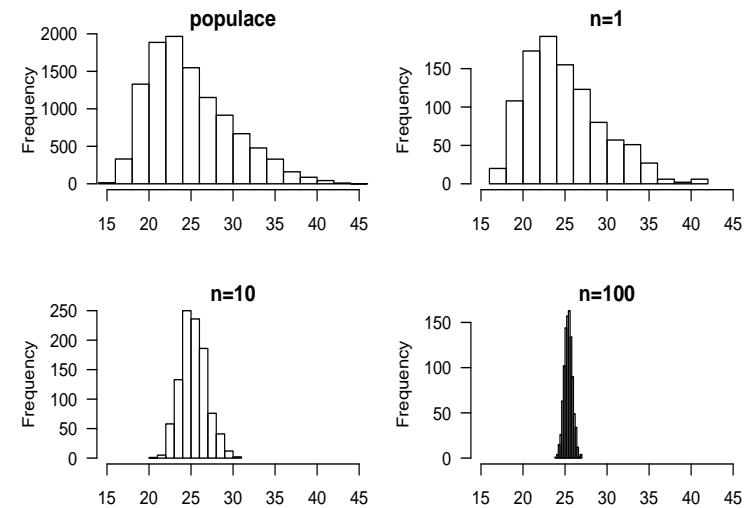


## příklad: věk matek

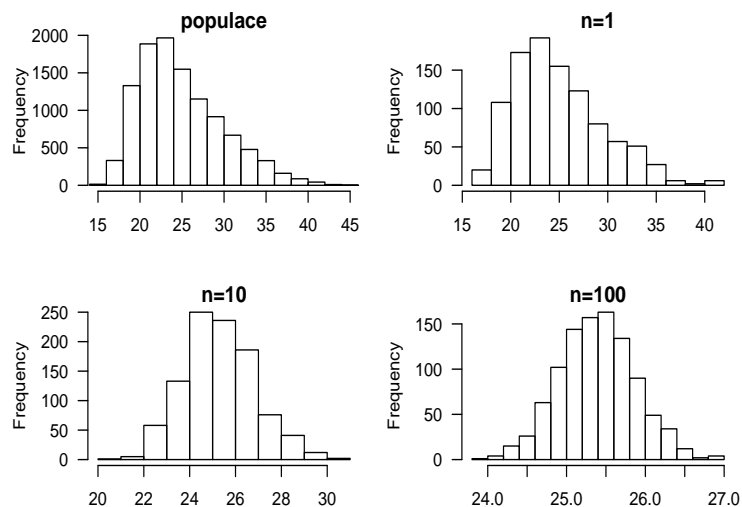
- ▶ výjimečný umělý příklad, kdy známe celou populaci
- ▶ populace obsahuje 10 916 hodnot
- ▶ rozdělení věku je výrazně nesymetrické
- ▶ prováděn výběr rozsahu  $n$ , vždy spočítán průměr
- ▶  $N$ krát opakovaně provedeno (spočítáno  $N = 1000$  průměrů)
- ▶ spočítány charakteristiky z  $N$  průměrů jako výchozích hodnot, (modře charakteristiky celé populace nebo hodnoty odvozené)

$n$	průměr	sm. odch.	$\sigma/\sqrt{n}$	šikmost	špičatost
1	25.43	4.62	4.94	0.74	0.29
10	25.35	1.54	1.56	0.28	-0.04
100	25.39	0.48	0.49	0.08	-0.05
(populace)	$\mu = 25.40$	$\sigma = 4.94$	4.94	0.77	0.19

## příklad: histogram populace a histogramy výběrů šířky intervalů stejné



## příklad: histogram populace a histogramy výběrů šířky intervalů přizpůsobené variabilitě



## příklad: shrnutí

- ▶ průměry kolísají kolem populačního průměru  $\mu$
- ▶ směrodatné odchylky klesají s rostoucím  $\sqrt{n}$
- ▶ šikmost a špičatost se s rostoucím  $n$  blíží k nule
- ▶ je naděje, že s rostoucím  $n$  je histogram podobnější hustotě normálního rozdělení – projev *centrální limitní věty*

## centrální limitní věta


- ▶ vlastnost součtu nezávislých náhodných veličin se stejným rozdělením (populační průměr  $\mu$ , popul. rozptyl  $\sigma^2$ )
- ▶ průměr je součet dělený počtem sčítanců  
⇒ pro průměr platí CLV také
- ▶ standardizovaný součet (průměr)  $n$  nezávislých náhodných veličin lze pro velké  $n$  aproximovat normálním rozdělením  $N(0, 1)$

$$Z = \frac{\sum_{i=1}^n X_i - n \cdot \mu}{\sigma \sqrt{n}} = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$$

▶ CLV pro četnosti

- ▶ pro velká  $n$  se výběrový průměr chová, jako by šlo o výběr z normálního rozdělení, a to bez ohledu na výchozí rozdělení

$$\bar{X} \sim N(\mu, \sigma^2/n)$$

100 intervalů spolehlivosti ( $n = 100$ ,  $1 - \alpha = 95\%$ )  
(v 7 případech interval neobsahuje  $\mu$ )interval spolehlivosti pro populační průměr  $\mu$ 

- ▶ pro nezávislé náhodné veličiny  $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  platí

$$\bar{X} \sim N(\mu, \sigma^2/n)$$

- ▶ proto je  $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$

- ▶ použijeme kritickou hodnotu

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

- ▶ hodnota parametru  $\mu$  je tedy s pstí  $1 - \alpha$  pokryta intervalem

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

- ▶ lze použít pro velká  $n$  i bez požadavku na normální rozdělení

## příklad: IQ vysokoškoláků

- ▶ u  $n = 16$  náhodně vybraných studentů jisté fakulty byla zjištěna hodnota IQ
- ▶ metoda měření IQ je konstruována tak, že je  $\sigma = 15$
- ▶ vyšel průměr  $\bar{x} = 110$
- ▶ co lze říci o populačním průměru všech studentů oné velké fakulty?
- ▶ 95% interval spolehlivosti ( $z(0,025) = 1,96$ ):

$$\left(110 - \frac{15}{4} \cdot 1,96; 110 + \frac{15}{4} \cdot 1,96\right) = (102,65; 117,35)$$

- ▶ skutečný populační průměr  $\mu$  (všech studentů oné fakulty) leží s 95% pravděpodobností mezi 102,65 a 117,35
- ▶  $\mu$  leží s 90% pravděpodobností mezi 103,83 a 116,17

vlastnosti intervalu spolehlivosti pro  $\mu$ 

- ▶ délka intervalu roste s požadovanou spolehlivostí
  - ▶ 90% interval (103,83; 116,17) má délku 12,34
  - ▶ 95% interval (102,65; 117,35) má délku 14,70
- ▶ délka intervalu klesá s rostoucím počtem pozorování  $n$ 
  - ▶ pro  $n = 16$  má 95% interval (102,65; 117,35) délku 14,70
  - ▶ pro  $n = 16 \cdot 4 = 64$  má 95% interval (106,325; 113,675) délku 7,35, tedy poloviční
- ▶ kolik potřebujeme pozorování, aby měl 95% interval délku  $2\delta$ ?

$$\frac{\sigma}{\sqrt{n}}z(\alpha/2) = \delta \quad \Rightarrow \quad n = \left(\frac{\sigma}{\delta}z(\alpha/2)\right)^2$$

- ▶ v příkladu s IQ požadujeme  $\delta = 1$ :

$$n = \left(\frac{15}{1}1,96\right)^2 \doteq 864$$

## příklad: výška postav

- ▶ studenti odhadovali výšku přednášejícího; předpokládejme, že nestranně a nezávisle na sobě
- ▶  $n = 22$ ,  $\bar{x} = 172,4$ ,  $s_x = 4,032$
- ▶ z tabulek:  $t_{21}(0,05) = 2,080$

$$\left(172,4 - \frac{4,032}{\sqrt{22}} \cdot 2,080; 172,4 + \frac{4,032}{\sqrt{22}} \cdot 2,080\right) \\ (170,6; 174,2)$$

- ▶ skutečná výška je s pravděpodobností 95 % někde mezi 170,7 cm a 174,2 cm
- ▶  $z(0,025) = 1,96$

interval spolehlivosti pro  $\mu$  (neznámé  $\sigma$ )

- ▶ neznáme-li  $\sigma$ , nahradíme je pomocí (výběrová směr. odchylka)

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

- ▶ interval spolehlivosti pro  $\mu$ :

$$\left(\bar{X} - \frac{S}{\sqrt{n}}t_{n-1}(\alpha); \bar{X} + \frac{S}{\sqrt{n}}t_{n-1}(\alpha)\right)$$

- ▶ použití kritické hodnoty  $t_{n-1}(\alpha)$  Studentova  $t$ -rozdělení místo kritické hodnoty  $z(\alpha/2)$  je penalizací za to, že neznámou směrodatnou odchylku  $\sigma$  jsme nahradili jejím odhadem  $S$
- ▶ platí totiž  $t_{n-1}(\alpha) > z(\alpha/2)$ , s rostoucím  $n$  se rozdíl zmenšuje

## centrální limitní věta pro četnosti

- ▶ co říká CLV? [▶ CLV](#)
- ▶ absolutní četnost  $Y$ 
  - ▶  $Y$  – součet nezávislých veličin s alternativním rozdělením
  - ▶ populační průměr  $X_i$  je  $\pi$
  - ▶ populační rozptyl  $X_i$  je  $\pi(1 - \pi)$
  - ▶  $Y = \sum_{i=1}^n X_i$
  - ▶  $Y \sim \text{bi}(n, \pi)$ , proto přibližně  $Y \sim N(n\pi, n\pi(1 - \pi))$
- ▶ relativní četnost  $f = Y/n$ 
  - ▶  $f$  – průměr nezávislých veličin s alternativním rozdělením
  - ▶  $f \sim N(\pi, \pi(1 - \pi)/n)$

## příklad: počet studentek

- ▶ za zkušenosti je známo, že mezi uchazeči o studium bývá 45 % dívek
- ▶ s jakou pravděpodobností bude při 500 přihláškách počet dívek mezi 200 a 220 (včetně)?
- ▶  $Y \sim \text{bi}(500, 0,45)$  má  $\mu_Y = 500 \cdot 0,45 = 225$ ,  
 $\sigma_Y^2 = 500 \cdot 0,45 \cdot 0,55 = 123,75$ , tedy  $\sigma_Y = 11,1$

$$P(200 \leq Y \leq 220) \doteq \Phi\left(\frac{220,5 - 225}{11,1}\right) - \Phi\left(\frac{199,5 - 225}{11,1}\right)$$

- ▶ hledaná pravděpodobnost je přibližně 33,2 % (přesně 33,3 %)  
[NORMDIST(220,5;225;11,1243;1)  
-NORMDIST(199,5;225;11,1243;1)]  
[pnorm(220.5,500\*0.45,sqrt(500\*0.45\*0.55))  
-pnorm(199.5,500\*0.45,sqrt(500\*0.45\*0.55))]  
[BINOMDIST(220;500;0,45;1)-BINOMDIST(199;500;0,45;1)]  
[pbinom(220,500,0.45)-pbinom(199,500,0.45)]

## příklad: hody s hrací kostkou

- ▶ odhadujeme pravděpodobnost šestky
- ▶ kostka A:  $n = 100$ ,  $n_A = 17$ ,  $f_A = 0,17$

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

**(0,10; 0,24)**

- ▶ kostka B:  $n = 100$ ,  $n_B = 41$ ,  $f_B = 0,41$

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

**(0,31; 0,51)**

- ▶ důležitý rozdíl: u kostky A patří  $1/6 = 0,167$  do intervalu spolehlivosti; u kostky B nikoliv; může to něco znamenat?

interval spolehlivosti pro podíl (pravděpodobnost)  $\pi$ 

- ▶  $\pi$  – podíl prvků populace s danou vlastností
- ▶  $\pi$  – pst, s jakou takový prvek vylosujeme
- ▶ počet prvků náhodně vybraných s onou vlastností  $Y \sim \text{bi}(n, \pi)$
- ▶ střední chyba relativní četnosti  $Y/n = f$   
= směrodatná odchylka relativní četnosti  $f$   
= odmocnina z rozptylu relativní četnosti  $f$  je tedy  $\sqrt{\frac{\pi(1-\pi)}{n}}$
- ▶ pravděpodobnost  $\pi$  neznáme, odhadneme ji pomocí  $f$
- ▶ odtud je přibližný 95% interval spolehlivosti pro  $\pi$

$$\left(f - 1,96 \cdot \sqrt{\frac{f(1-f)}{n}}; f + 1,96 \cdot \sqrt{\frac{f(1-f)}{n}}\right)$$

- ▶ skutečná pst  $\pi$  je tedy s 95% pstí v uvedeném rozmezí
- ▶ existuje přesnější (pracnější) postup

## proč testování hypotéz

- ▶ připomeňme 95% intervaly spolehlivosti pro šestku u kostek:
  - ▶ kostka A: (0,10; 0,24)
  - ▶ kostka B: (0,31; 0,51)
- ▶ znamená něco, když  $1/6 = 0,167$  leží či neleží v 95% intervalu spolehlivosti?
- ▶ nelze bezpečně poznat, že kostka A není falešná nebo že kostka B je falešná
- ▶ intervaly spolehlivosti určily rozmezí, kde by skutečná pravděpodobnost šestky měla být, jejich spolehlivost je velká, ale omezená
- ▶ musíme připustit, že jsme mohli mít smůlu, že se v našich pokusech náhodou realizovaly málo pravděpodobné možnosti, přestože k takové smůle dochází jen zřídka
- ▶ potřebujeme **standardizovaná pravidla**, jak rozhodovat

## hypotézy a možná rozhodnutí

- ▶ možné statistické **hypotézy**
  - ▶ **(nulová) hypotéza**  $H_0$ : – zjednodušuje situaci, zpravidla se jí snažíme vyvrátit, abychom věcně něco prokázali: porovnávané populace se **neliší**, vyšetřované znaky jsou **nezávislé** . . .  
tedy žádný (tj. **nulový**) rozdíl, žádná (tj. **nulová**) závislost
  - ▶ **alternativa**  $H_1$ : (**alternativní hypotéza**) – opak nulové hypotézy, zpravidla to, co chceme věcně dokázat
- ▶ možná **rozhodnutí**
  - ▶ **zamítnout**  $H_0$  pokud naše data svědčí proti  $H_0$
  - ▶ **nezamítnout**  $H_0$  (přijmout  $H_0$ ) pokud *není dost důvodů*  $H_0$  zamítnout
- ▶ hypotéza – tvrzení o **populaci**
- ▶ rozhodujeme na základě dat z **výběru**
- ▶ nelze zaručit bezchybnost rozhodnutí

## schéma rozhodování

rozhodnutí	$H_0$ platí	$H_0$ neplatí
$H_0$ zamítnout	<b>chyba 1. druhu</b> ( $pst \leq \alpha$ ) hladina testu	správné rozhodnutí ( $pst 1 - \beta$ ) síla testu
$H_0$ nezamítnout (přijmout)	správné rozhodnutí ( $pst \geq 1 - \alpha$ )	chyba 2. druhu ( $pst \beta$ )

- ▶ volíme řádek
- ▶ nevíme, který sloupec platí

## chyby v rozhodování

- ▶ nelze zaručit bezchybnost rozhodnutí, mohou nastat chyby:
  - ▶ **chyba 1. druhu**, když zamítneme platnou hypotézu  $H_0$
  - ▶ **chyba 2. druhu**, když nepoznáme, že hypotéza  $H_0$  neplatí a nezamítneme ji (přijmeme ji)
- ▶ nechceme příliš často *chybně* zamítnat  $H_0$  (tedy falešně něco věcně prokazovat)
- ▶ proto se snažíme chybě 1. druhu pokud možno vyvarovat, nelze ji vyloučit
- ▶ **hladina testu**  $\alpha$  = maximální přípustná pravděpodobnost chyby 1. druhu (zpravidla  $\alpha = 0,05$ , tj.  $\alpha = 5\%$ )
- ▶ **síla testu** = pravděpodobnost správného zamítnutí neplatné hypotézy

## klasický postup při rozhodování

- ▶ zvolit (nulovou) hypotézu  $H_0$ , alternativu  $H_1$
- ▶ zvolit hladinu testu  $\alpha$
- ▶ zvolit metodu rozhodování (který test použít)
- ▶ z dat spočítat testovou statistiku  $T$  a porovnat ji s tabelovanou kritickou hodnotou (bude ještě: porovnat  $p$ -hodnotu s hladinou  $\alpha$ )
- ▶ **kritický obor** – množina těch výsledků pokusu (např. hodnot  $T$ ), kdy budeme hypotézu zamítnat
- ▶ když padne statistika  $T$  do **kritického oboru**, pak hypotézu zamítnout (zpravidla, když  $T \geq t_0$ ,  $t_0$  – kritická hodnota)

## příklad: padá na kostce šestka příliš často?

- ▶ chceme na 5% hladině prokázat, že pravděpodobnost šestky na dané kostce je větší, než by měla být (tj. větší než  $1/6$ )
- ▶  $H_0 : P(\text{padne šestka}) = 1/6 \quad (\pi = \pi_0)$
- ▶  $H_1 : P(\text{padne šestka}) > 1/6 \quad (\pi > \pi_0)$
- ▶ provedeme  $n = 100$  pokusů,  $Y$  je počet šestek
- ▶ co svědčí pro neplatnost hypotézy? Je to situace, kdy „šestka padá mnohem častěji, než by měla padat za  $H_0$ “
- ▶ **tvar kritického oboru:** hypotézu zamítat, když  $Y \geq y_0$
- ▶ za platnosti  $H_0$  má počet šestek  $Y$  rozdělení  $bi(n, 1/6)$
- ▶ **velikost kritického oboru:**  $y_0$  zvolíme tak, abychom hypotézu za její platnosti zamítali s pravděpodobností nejvýše  $\alpha$ , tj.

$$P_0(Y \geq y_0) \leq \alpha$$

## příklad: síla testu

- ▶ **síla testu** = pst, že hypotézu zamítneme, když ona neplatí
- ▶ při 100 hodech hypotézu na 5% hladině zamítáme, je-li  $Y \geq 24$
- ▶ necht' je ve skutečnosti  $\pi = 1/4$ , pak hypotézu zamítneme (výsledek pokusu padne do kritického oboru) s pstí

$$P(Y \geq 24) = \sum_{k=24}^{100} \binom{100}{k} \left(\frac{1}{4}\right)^k \left(1 - \frac{1}{4}\right)^{100-k} = 0,629$$

- ▶ pro  $\pi = 0,25$  je tedy síla testu 62,9 %
- ▶ pro  $\pi = 0,3$  je podobně síla testu rovna 92,4 %
- ▶ pro  $\pi = 0,2$  je podobně síla testu rovna 18,9 %

příklad: jak zvolit kritickou hodnotu  $y_0$ ?

- ▶ některé pravděpodobnosti pro  $Y \sim bi(100, 1/6)$

$y_0$	20	21	22	23	<b>24</b>	25
$P(Y \geq y_0)$	0,220	0,152	0,100	0,063	<b>0,038</b>	0,022

- ▶ podmínku  $P(Y \geq y_0) \leq 0,05$  splňuje  $y_0 = 24$
- ▶ padne-li ve 100 nezávislých hodech kostkou aspoň 24 šestek, budeme na **5% hladině zamítat hypotézu**, že pst šestky je  $1/6$  **ve prospěch alternativy**, že pst šestky je větší než  $1/6$  (dáno zvolenou alternativou)
- ▶ na kostce A nám padlo 17 šestek, hypotézu **nezamítáme**, to ale neznamená, že bychom hypotézu prokázali
- ▶ na kostce B nám padlo 41 šestek, hypotézu **zamítáme**
- ▶ pro  $\alpha = 10\%$  bychom zvolili  $y_0 = 22$ , bylo by však větší riziko zamítnutí platné hypotézy

rozhodování pomocí  $p$ -hodnoty

- ▶  **$p$ -hodnota**  $p$  je nejmenší  $\alpha$ , při kterém  $H_0$  z daných dat ještě zamítáme
- ▶  $p$ -hodnota  $p$  je za platnosti  $H_0$  spočítaná *pravděpodobnost* výsledků stejně nebo *méně příznivých* pro  $H_0$
- ▶  **$H_0$  zamítáme právě tehdy, když je  $p \leq \alpha$**
- ▶  $p$ -hodnotu počítají moderní počítačové programy
- ▶ existují úlohy, kdy se rozhoduje pouze podle  $p$ -hodnoty (např. Fisherův exaktní test ve čtyřpolní tabulce)
- ▶ statistické rozhodování: spočítat k  $T$  odpovídající  $p$ -hodnotu a porovnat ji s  $\alpha$

příklad: rozhodování pomocí  $p$ -hodnoty

- ▶ snažíme se prokázat, že šestka padá příliš často ( $H_1 : \pi > 1/6$ )
- ▶ kritický obor:  $Y \geq y_0 = 24$
- ▶ padlo nám  $Y = 17$ , proto (psti binomického rozdělení)

$$p = P(Y \geq 17) = \sum_{k=17}^{100} \binom{100}{k} \left(\frac{1}{6}\right)^k \left(1 - \frac{1}{6}\right)^{100-k} = 0,506$$

$$= 1 - P(Y \leq 16) \quad [1-\text{BINOMDIST}(16;100;1/6;1)]$$

- ▶ protože 50,6 % > 5 %, hypotézu nemůžeme na 5% hladině zamítnout, nemůžeme tvrdit, že pst šestky je větší než 1/6
- ▶ neprokázali jsme však, že by hypotéza platila
- ▶ na kostce B:  $p = P(Y \geq 41) = 1 - P(Y \leq 40) = 7,4 \cdot 10^{-9}$   
[1-pbinom(40,100,1/6)]

## příklad: kostka a oboustranná alternativa

- ▶ chceme ověřit, zda je kostka v pořádku
- ▶ pokusíme se prokázat, že šestka padla příliš často nebo příliš zřídka (**oboustranná alternativa**)
- ▶  $H_0 : P(\text{padne šestka}) = 1/6 \quad (\pi = \pi_0)$
- ▶  $H_1 : P(\text{padne šestka}) \neq 1/6 \quad (\pi \neq \pi_0)$
- ▶ proti hypotéze svědčí malé *nebo* velké hodnoty  $Y$
- ▶ pst chyby 1. druhu  $\alpha$  rozdělíme na dvě poloviny:  $\alpha/2$  pro příliš malé  $Y$ ,  $\alpha/2$  příliš velké  $Y$

## příklad: kostka, oboustranná alternativa

$y_0$	8	9	10	...	24	25	26
$P(Y \leq y_0)$	0,010	0,021	0,043	...	0,978	0,988	0,994
$P(Y \geq y_0)$	0,996	0,990	0,979	...	0,038	0,022	0,012
$P(Y = y_0)$	0,006	0,012	0,021	...	0,016	0,010	0,006

- ▶  $\alpha/2 = 0,025$  ( $\alpha/2 = 0,05$ )
- ▶  $H_0$  zamítneme, když bude  $Y \leq 9$  *nebo* když bude  $Y \geq 25$
- ▶ skutečná pst chyby 1. druhu bude  $0,021 + 0,022 = 0,043$
- ▶ [pbinom(9,100,1/6)+(1-pbinom(24,100,1/6))]  
[BINOMDIST(9;100;1/6;1)  
+ 1-BINOMDIST(24;100;1/6;1)]
- ▶ hodnoty v rozmezí 10 až 24 (včetně mezí) nnesvědčí proti  $H_0$

## oboustranná alternativa (přibližně)

- ▶  $H_0 : \pi = \pi_0$ , např.  $P(\text{padne šestka}) = 1/6$
  - ▶  $H_1 : \pi \neq \pi_0$ , např.  $P(\text{padne šestka}) \neq 1/6$
  - ▶ proti alternativě svědčí  $Y$  hodně daleko od  $\mu_Y = n\pi_0$  (počítáme za platnosti hypotézy), tj. rel. četnost  $f = Y/n$  daleko od  $\pi_0$
  - ▶ zavedeme
- $$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{f - \pi_0}{\sqrt{\pi_0(1 - \pi_0)}} \sqrt{n}$$
- ▶ hypotézu zamítneme, bude-li  $Z$  daleko od nuly:  $|Z| \geq z(\alpha/2)$
  - ▶ pro  $\alpha = 5\%$  zamítáme hypotézu, je-li  $|Z| \geq 1,96$
  - ▶  $z_A = 0,089$  (nezamítneme),  $y_B = 6,529$  (zamítneme)



## změnila se za deset roků výška desetiletých hochů?

- ▶ v roce 1951 byla průměrná výška desetiletých hochů 136,1 cm (zjištěno z velkého výběru o tisících měření)
- ▶ v roce 1961 bylo změřeno 15 náhodně vybraných desetiletých hochů: 127 130 133 136 136 138 139 139 139 140 141 142 147 149 151
- ▶  $\bar{X} = 139,13$  cm,  $n = 15$
- ▶ znamená to, že za těch deset roků jsou desetiletí opravdu vyšší?
- ▶ stačí k důkazu, že 10 hochů je větších než 136,1 cm a jen 5 menších než 136,1 cm?
- ▶ stačí k důkazu, že nový průměr je o 3 cm vyšší?

## souvislost s intervalem spolehlivosti

- ▶ připomeňme interval spolehlivosti pro  $\mu$

$$\bar{X} - \widehat{S.E.}(\bar{X}) \cdot t_{n-1}(\alpha) < \mu < \bar{X} + \widehat{S.E.}(\bar{X}) \cdot t_{n-1}(\alpha)$$

$$\bar{X} - \frac{s_x}{\sqrt{n}} t_{n-1}(\alpha) < \mu < \bar{X} + \frac{s_x}{\sqrt{n}} t_{n-1}(\alpha)$$

- ▶ lze přepsat jako

$$|T| = \left| \frac{\bar{X} - \mu}{s_x} \sqrt{n} \right| < t_{n-1}(\alpha)$$

- ▶  $H_0 : \mu = \mu_0$  tedy **nezamítáme** na hladině  $\alpha$  při oboustranné alternativě, právě když  $\mu_0$  leží v  $100(1 - \alpha)\%$  intervalu spolehlivosti
- ▶ **interval spolehlivosti obsahuje takové hodnoty  $\mu_0$ , které bychom jako hypotézu nezamítli**

test o střední hodnotě  $\mu$  normálního rozdělení

- ▶ předpokládáme  $X_1, X_2, \dots, X_n \sim N(\mu, \sigma^2)$ , nezávislé
- ▶  $\sigma > 0$  odhadneme pomocí  $s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$
- ▶ rozptyl  $\bar{X}$  odhadneme pomocí  $s_x^2/n$ , střední chyba  $\bar{X}$  (odmocnina z rozptylu) je tedy  $S.E.(\bar{X}) = s_x/\sqrt{n}$
- ▶  $H_0 : \mu = \mu_0$  ( $\mu_0$  známá konstanta)

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

statistika  $T$  má za  $H_0$  Studentovo  $t$ -rozdělení s  $n - 1$  st. vol.

- ▶ kdy hypotézu  $H_0$  zamítáme (kritický obor):
  - ▶  $H_1 : \mu \neq \mu_0$  (oboustranná alternativa)  $|T| \geq t_{n-1}(\alpha)$
  - ▶  $H_1 : \mu > \mu_0$  (jednostranná alternativa)  $T \geq t_{n-1}(2\alpha)$
  - ▶  $H_1 : \mu < \mu_0$  (jednostranná alternativa)  $T \leq -t_{n-1}(2\alpha)$

příklad: výšky desetiletých hochů ( $\sigma^2$  neznámé)

- ▶ kritický obor:  $\bar{X}$  se příliš liší od  $\mu_0$  ve směru zvolené alternativy
- ▶ spočítáme `[t.test(hosi,mu=136.1,alternative="greater")]`

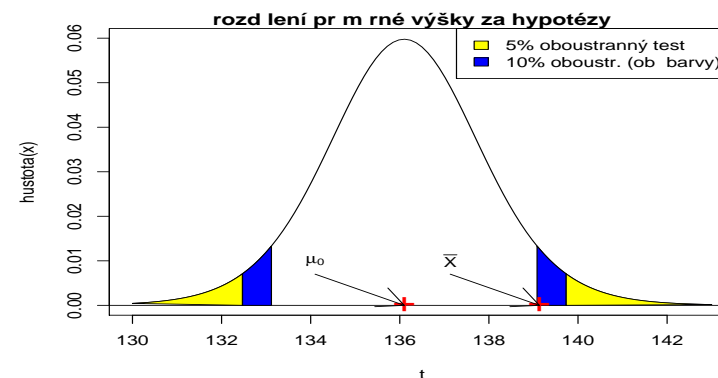
$$T = \frac{139,13 - 136,1}{6,56} \sqrt{15} = 1,79$$

- ▶ na 5% hladině při jednostranné alternativě  $\mu > \mu_0$  hypotézu zamítáme, neboť  $t_{14}(0,10) = 1,76$  ( $p = 4,7\%$ )
- ▶ na 5% hladině jsme **prokázali**, že výška desetiletých vzrostla
- ▶ na 5% hladině při oboustranné alternativě hypotézu nezamítáme, neboť  $t_{14}(0,05) = 2,14$  ( $p = 9,5\%$ )
- ▶ 95% int. spolehlivosti pro populační průměr výšek hochů: (135,5; 142,8)

## použití Excelu

přednáška	Excel	hoši
průměr	Stř. hodnota	139,13
střední chyba	Chyba stř. hodnoty	1,693
medián	Medián	139
modus	Modus	139
s	Směr. odchylka	6,56
s <sup>2</sup>	Rozptyl výběru	42,98
špičatost	Špičatost	0,006
šikmost	Šikmost	0,090
rozpětí	Rozdíl max-min	24
minimum	Minimum	127
maximum	Maximum	151
součet	Součet	2087
rozsah výběru n	Počet	15
pol. šířka int. spol.	Hladina spol.	3,63


- ▶  $139,13 - 3,63 = 135,50$
- ▶  $139,13 + 3,63 = 142,76$
- ▶ 95% interval spolehlivosti: (135,5; 142,8)
- ▶  $\mu_0 = 136,1$  je v int. spolehlivosti
- ▶ při oboustranné alternativě jsme nezamítli  $H_0$

kritický obor pro  $\bar{X}$ 

- ▶ při jednostr. alternativě  $\mu > \mu_0$  je 5% kritický obor označen oběma barvami na pravé straně

## porovnání dvou populací (dvouvýbětový t-test)

- ▶ příklad: liší se desetileté dívky výškou postavy od desetiletých hochů?
- ▶ výšky hochů známe,  $\bar{X} = 139,13$  cm,  $s_x = 6,56$ ,  $n_x = 15$
- ▶ výšky dívek: 131, 132, 135, 141, 141, 141, 141, 142, 143, 146, 146, 151
- ▶  $\bar{Y} = 140,83$ ,  $s_y = 5,84$ ,  $n_y = 12$



## dvouvýbětový t.test

- ▶ lze předpokládat, že výšky náhodně vybraných hochů mají normální rozdělení

$$X_i \sim N(\mu_x, \sigma^2), \quad \text{nezávislé, } i = 1, \dots, n_x$$

- ▶ lze předpokládat, že výšky náhodně vybraných dívek mají normální rozdělení

$$Y_i \sim N(\mu_y, \sigma^2), \quad \text{nezávislé, } i = 1, \dots, n_y$$

- ▶ předpoklad stejných rozptylů bývá splněn, lze jej ověřit
- ▶ musí jít o **nezávislé** náhodné výběry, nelze např. vybírat sourozenecké dvojice nebo opakovaně měřit stejnou osobu

## porovnání středních hodnot nezávislých výběrů

- ▶  $H_0 : \mu_x = \mu_y$  (není rozdíl, **nulová** hypotéza)  
zřejmě totéž jako  $\mu_x - \mu_y = 0$  (nulový rozdíl stř. hodnot)  
(hoši a dívky se v deseti letech co do výšky neliší)
- ▶ možné alternativy
  - ▶  $H_1 : \mu_x \neq \mu_y$  (není-li důvod k jednostranné alternativě)
  - ▶  $H_1 : \mu_x > \mu_y$  (bylo cílem dokázat, že hoši jsou větší než dívky)
  - ▶  $H_1 : \mu_x < \mu_y$  (bylo cílem dokázat, že hoši jsou menší než dívky)
- ▶ rozhodování založeno na porovnání průměrů  $\bar{X}$  a  $\bar{Y}$ ; čím více se liší „správným směrem“, tím spíše zamítnout hypotézu
- ▶ je třeba porovnat s mírou přesnosti, s jakou rozdíl průměrů  $\bar{X} - \bar{Y}$  odhadne skutečný rozdíl populačních průměrů  $\mu_x - \mu_y$

## kritický obor

- ▶ o hypotéze  $H_0 : \mu_1 = \mu_2$  se rozhoduje pomocí

$$T = \frac{\bar{X} - \bar{Y}}{\widehat{S.E.}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{s} \sqrt{\frac{n_1 n_2}{n_1 + n_2}}$$

- ▶  $H_1 : \mu_x \neq \mu_y$  zamítáme pokud  $|T| \geq t_{n_1+n_2-2}(\alpha)$
- ▶  $H_1 : \mu_x > \mu_y$  zamítáme pokud  $T \geq t_{n_1+n_2-2}(2\alpha)$
- ▶  $H_1 : \mu_x < \mu_y$  zamítáme pokud  $T \leq -t_{n_1+n_2-2}(2\alpha)$
- ▶ výšky desetiletých:  $T = -0,70 \Rightarrow$   
 $| -0,70 | < 2,06 = t_{15+12-2}(0,05)$
- ▶ na 5% hladině jsme **neprokázali** rozdíl mezi výškami desetiletých hochů a dívek ( $p = 48,8 \%$ )

[t.test(vyska~Divka,var.equal=TRUE)]

[TTEST(A14:A28;A2:A13;2;2)]

odhad  $\sigma^2$ 

- ▶ k tomu je třeba odhadnout také neznámé  $\sigma^2$  pomocí

$$s^2 = \frac{1}{n_x + n_y - 2} \left( \sum_{i=1}^{n_1} (X_i - \bar{X})^2 + \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2 \right)$$

$$= \frac{n_x - 1}{n_x + n_y - 2} s_x^2 + \frac{n_y - 1}{n_x + n_y - 2} s_y^2$$

(vážený průměr odhadů rozptylu v obou výběrech)

- ▶ výška desetiletých dětí:  $n_x = 15$ ,  $n_y = 12$ ,  $\bar{X} = 139,13$ ,  $\bar{Y} = 140,83$ ,  $s_x^2 = 42,98$ ,  $s_y^2 = 33,79$ , tudíž

$$s^2 = \frac{14}{25} \cdot 42,98 + \frac{11}{25} \cdot 33,79 = 38,94 = 6,24^2$$

## souvislost s intervalem spolehlivosti

- ▶  $\mu_1 - \mu_2 = \delta$  o kolik se liší populační průměrné výšky
- ▶ odhadem pro  $\delta$  je  $d = \bar{X} - \bar{Y} = -1,7$
- ▶ krajní body intervalu spolehlivosti pro rozdíl  $\delta$  jsou

$$(\bar{X} - \bar{Y}) \mp \widehat{S.E.}(\bar{X} - \bar{Y}) \cdot t_{n_1+n_2-2}(\alpha)$$

$H_0$  zamítáme právě tehdy, když nula **není** v int. spol. pro  $\delta$

- ▶ při porovnání výšek hochů a dívek je 95% interval pro  $\delta$

$$\left( -1,7 - 6,24 \sqrt{\frac{1}{15} + \frac{1}{12}} \cdot 2,06; -1,7 + 6,24 \sqrt{\frac{1}{15} + \frac{1}{12}} \cdot 2,06 \right)$$

$$(-6,7; 3,3)$$

## shrnutí

- ▶ důležité předpoklady
  - ▶ nezávislé výběry
  - ▶ stejné (populační) rozptyly (lze testovat)
  - ▶ normální rozdělení (lze testovat)
- ▶ existuje varianta bez předpokladu stejných rozptylů
- ▶ pro velká  $n_x, n_y$  na normalitě tolik nezáleží (CLV)
- ▶ je-li problém s normalitou, lze použít jiný test (Mann-Whitney)

## problém nestejných rozptylů

- ▶ předpoklad o stejném rozptylu v obou souborech nemusí být ve skutečnosti splněn, lze jej ověřit porovnáním odhadů rozptylu  $F$ -testem  $F = \frac{s_x^2}{s_y^2}$
- ▶ hypotéza  $H_0 : \sigma_x^2 = \sigma_y^2$  se proti  $H_1 : \sigma_x^2 \neq \sigma_y^2$  zamítá, když je
 
$$\text{buď } F = \frac{s_x^2}{s_y^2} \geq F_{n_1-1, n_2-1}(\alpha/2) \text{ nebo } \frac{1}{F} = \frac{s_y^2}{s_x^2} \geq F_{n_2-1, n_1-1}(\alpha/2)$$
- ▶ vlastně se větší odhad rozptylu dělí menším odhadem, k tomu se musí zvolit správné pořadí stupňů volnosti a hladina
- ▶ příklad výšky desetiletých dětí:
 
$$F = \frac{42,98}{38,94} = 1,27 < F_{14,11}(0,025) = 3,36$$
- ▶ [var.test(vyska~Divka)]

## provedení v MS Excelu (stejné rozptyly)

přednáška	Excel	Soubor 1	Soubor 2
průměr	Stř. hodnota	139.133	140.833
rozptyl	Rozptyl	42.981	33.788
rozsah výběru	Pozorování	15	12
spol. odhad rozpt.	Společný rozptyl	38.936	
$H_0 : \mu_1 - \mu_2 =$	Hyp. rozdíl stř. hodnot	0	
stupně vol.	Rozdíl	25	
$T$	t stat	-0.733	
$p$ jednostr. testu	$P(T \leq t)$ (1)	0.244	jen někdy!
$t_{n_1+n_2-2}(2\alpha)$	t krit (1)	1.708	
$p$ oboustr. testu	$P(T \leq t)$ (2)	0.488	
$t_{n_1+n_2-2}(\alpha)$	t krit (2)	2.060	

při oboustranné alternativě nelze nulovou hypotézu zamítnout

## MS Excel: Dvouvýběrový F-test pro rozptyly

přednáška	Excel	Soubor 1	Soubor 2
průměr	Stř. hodnota	139.13	140.83
rozptyl	Rozptyl	42.98	33.79
rozsah	Pozorování	15	12
stupně vol.	Rozdíl	14	11
$F$	F	1.27	
$p$	$P(F \leq f)$ (1)	0.349	
	F krit (1)	2.739	

**pozor** Excel pracuje špatně: uvádí kritickou hodnotu a  $p$ -hodnotu pro jednostrannou alternativu odvozenou z hodnoty statistiky  $F$ ; při oboustranné alternativě je třeba  $p$ -hodnotu vynásobit dvěma ve skutečnosti je  $P(F > 1,27) = 0,349$ , takže  $p = 2 \cdot 0,349 = 0,698$  pro oboustrannou alternativu mělo být použito  $F_{14,11}(0,025) = 3,359$

## provedení v MS Excelu (nestejně rozptyly)

		Soubor 1	Soubor 2
průměr	Stř. hodnota	139.133	140.833
rozptyl	Rozptyl	42.981	33.788
rozsah	Pozorování	15	12
$H_0 : \mu_1 - \mu_2 =$	Hyp. rozdíl stř. hodnot	0	
stupně vol. $f$	Rozdíl	25	
$T$	t stat	-0.713	
$p$ jednostr. testu	$P(T \leq t)$ (1)	0.241	
$t_f(2\alpha)$	t krit (1)	1.708	
$p$ oboustr. testu	$P(T \leq t)$ (2)	0.482	
$t_f(\alpha)$	t krit (2)	2.060	

při oboustranné alternativě nelze nulovou hypotézu zamítnout

## příklad: výška rodičů

- ▶ rozhodnout o tvrzení, že populační průměr výšek otců je právě o 10 cm větší než populační průměr výšek matek
- ▶ otcové:  $\bar{Y} = 179,26, s_Y = 6,78, n_1 = 99$   
matky:  $\bar{Z} = 166,97, s_Z = 6,11, n_2 = 99$
- ▶ otcové jsou (ve výběru) v průměru o  $\bar{Y} - \bar{Z} = 12,29$  cm vyšší
- ▶ směrodatná odchylka **rozdílů** je 8,14 (méně, než kdyby byly výšky rodičů nezávislé ...  $6,78^2 + 6,11^2 = 9,13^2$ )
- ▶ **střední chyba** rozdílu průměrů je  $8,14 / \sqrt{99} = 0,819$
- ▶ rozhodneme podle statistiky **[t.test(vyska.o-vyska.m,mu=10)]**

$$T = \left| \frac{12,29 - 10}{0,819} \right| = 2,801 > 1,984 = t_{98}(0,05) \quad p = 0,6 \%$$

## párové testy

- ▶ není-li předpoklad **nezávislosti** porovnávaných výběrů splněn, dá dvouvýběrový t-test nesprávný výsledek
- ▶ typické porušení předpokladu nezávislosti je u párových dat
  - ▶ měření na stejných objektech ve dvou různých časech
  - ▶ měření na stejných objektech před zásahem a po něm (ošetření)
  - ▶ měření na rodičích
- ▶ postup
  - ▶ spočítají se a hodnotí rozdíly (změny)
  - ▶ přejde se k úloze s jediným výběrem
  - ▶ mají-li rozdíly normální rozdělení, pak párový t-test

## Mannův-Whitneyův (Wilcoxonův) test

pořadová obdoba dvouvýběrového t-testu

- ▶ porovnáváme stejný kvantitativní znak ve dvou populacích
- ▶ máme dva **nezávislé** výběry z těchto populací
- ▶ co když nelze předpokládat normální rozdělení?
- ▶ nechtě  $X_1, \dots, X_{n_1}$  a  $Y_1, \dots, Y_{n_2}$  jsou **nezávislé** výběry ze spojitého rozdělení (například věk matek, střední délka života mužů při narození ve dvou skupinách zemí, potratovost ...)
- ▶  $H_0$  tvrdí, že obě rozdělení jsou stejná (mezi populacemi není rozdíl, zpravidla nás zajímá, že není rozdíl v mírách polohy)
- ▶ speciálně to znamená, že **populační mediány** jsou shodné
- ▶ postup založen na pořadí bez ohledu na výběr
- ▶ idea: kdyby nebyl mezi populacemi rozdíl, byla by takto zjištěná průměrná pořadí v obou výběrech podobná

## příklad: potraty na 1000 obyv. (Čechy vers. Morava)

v roce 2003

kraj	Pha	Stč	Jč	PI	KV	Ús	Lb
potratovost	4,03	4,02	4,11	4,70	5,65	5,80	4,98
pořadí	7	6	8	10	12	13	11

kraj	HK	Par	Vys	JM	OI	ZI	MS
potratovost	4,33	3,38	3,57	3,70	3,65	3,42	3,87
pořadí	9	1		4	3	2	5

- ▶  $H_0$  : shoda populací (zejm. mediánů),  $H_1$  : neshoda
- ▶ nejasné, kam patří kraj Vysočina; vynecháme jej
- ▶ průměrné pořadí českých krajů:  $77/9=8,56$   
 $W_1=7+6+8+10+12+13+11+9+1=77$
- ▶ průměrné pořadí moravských krajů:  $14/4=3,5$   
 $W_2=4+3+2+5=14$

přesný výpočet  $p$ -hodnoty Wilcoxonova testu

- ▶ zajímá nás, nakolik je náš výsledek ( $W_1 = 77$ ,  $W_2 = 14$ ) výjimečný
- ▶ máme celkem  $n_1 + n_2 = 13$  pozorování, čtyři z nich (tolik jich je v menší skupině, z Moravy) lze vybrat celkem  $\binom{13}{4} = 715$  způsoby
- ▶ kolik z těchto způsobů vede k tak extrémně nesterjým průměrným pořadím?
- ▶ budeme hledat, kolik čtveřic označených za moravské by dalo v součtu nejvýš 14, jak nám doopravdy vyšlo
- ▶ vždy platí  $W_1 + W_2 = (n_1 + n_2)(n_1 + n_2 + 1)/2 = 91$  (součet čísel  $1 + 2 + \dots + n_1 + n_2$ )
- ▶ stačí zabývat se jedinou ze statistik  $W_1$ ,  $W_2$ , zpravidla tou pro menší výběr

přibližné rozhodování ( $n_1, n_2$  desítky)

- ▶  $W_1, W_2$  součty pořadí,  $W_1$  standardizujeme

$$Z = \frac{W_1 - n_1(n_1 + n_2 + 1)/2}{\sqrt{n_1 n_2 (n_1 + n_2 + 1)/12}}$$

- ▶ za hypotézy (není rozdíl mezi populacemi) je použitím centrální limitní věty  $Z \sim N(0, 1)$
- ▶ hypotézu zamítáme, je-li  $|Z| \geq z(\alpha/2)$
- ▶ náš příklad: [wilcox.test(potr~Cechy)]

$$Z = \left| \frac{77 - 9 \cdot 14/2}{\sqrt{9 \cdot 4 \cdot 14/12}} \right| = 2,16 > 1,96 = z(0,05/2) \quad p = 3,1 \%$$

- ▶ na 5% hladině jsme prokázali rozdíl

## přehled možných čtveřic v nichž je součet pořadí nejvýš 14 (čtveřice vybíráme z čísel 1, 2, ..., 13)

1	1	1	1	1	1	1	1	1	1	1	2	1	1
2	2	2	2	2	2	3	2	2	2	3	3	2	2
3	3	3	4	3	4	4	3	4	5	4	4	3	4
4	5	6	5	7	6	5	8	7	6	6	5	9	8
10	11	12	12	13	13	13	14	14	14	14	14	15	15


- ▶ nejvýš 14 mohl být součet pořadí za platnosti hypotézy s pravděpodobností  $p_1 = 12/715 = 0,01678$
- ▶ protože máme oboustrannou alternativu, musíme vzít v úvahu také situaci, kdy by byla na Moravě velká pořadí,  $p$ -hodnotu nutno zdvojnásobit:  $p = 24/715 = 3,4 \%$

## příklad: klesá potratovost? (párový $t$ -test zde nevhodný) potratů na 100 těhotenství

$Y_i$	$Z_i$	$X_i$	$R_i^+$
24,7	23,1	1,6	4
25,7	23,6	2,1	6
31,6	27,9	3,7	12
24,3	22,2	2,1	7
26,8	23,4	3,4	11
30,6	27,9	2,7	10
21,1	21,5	-0,4	1
23,5	26,0	-2,5	8
26,9	24,3	2,6	9
22,5	23,9	-1,4	3
23,1	21,2	1,9	5
24,9	25,7	-0,8	2

- ▶ použijeme údaje z 12 okresů v letech 2000 ( $Y_i$ ) a 2001 ( $Z_i$ )
- ▶ hypotéza  $H_0$  : v obou letech potratovost stejná, rozdíly dány náhodným kolísáním;  $H_1$  : potratovost klesá (jednostranná alt.)
- ▶ za  $H_0$  by rozdíly měly kolísat **symetricky kolem nuly**
- ▶ za  $H_1$  by měly převládat kladné rozdíly, spíše velké
- ▶ průměrné pořadí z 8 kladných rozdílů: 8 (součet  $W = 64$ ), průměrné pořadí ze 4 záporných rozdílů 3,5 (součet 14)

## příklad: klesá potratovost?



## párový Wilcoxonův (Wilcoxon signed rank) test

- ▶ necht'  $(Y_1, Z_1) \dots, (Y_n, Z_n)$  **nezávislé** dvojice, rozdíly  $X_i = Y_i - Z_i$  mají **spojité** rozdělení
- ▶  $H_0$  :  $Y_i, Z_i$  mají stejné rozdělení (populace jsou stejné)
- ▶ mají-li  $Y_i, Z_i$  stejné rozdělení, pak rozdíly  $X_i = Y_i - Z_i$  jsou symetricky rozděleny kolem nuly
- ▶ postup
  - ▶ vyloučit nulové hodnoty  $X_i$  (tedy shodné hodnoty  $Y_i, Z_i$ ), podle toho případně zmenšit  $n$
  - ▶ určit pořadí  $R_i^+$  **absolutních hodnot**  $|X_i| = |Y_i - Z_i|$
  - ▶ určit  $W$ , tj. součet pořadí původně kladných hodnot  $X_i$
  - ▶ podle  $W$  rozhodnout

## rozhodování

- ▶ na základě centrální limitní věty lze použít

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

- ▶ hypotézu o shodě zamítneme, bude-li  $|Z| \geq z(\alpha/2)$
- ▶ při jednostranné alternativě porovnat  $Z$  a  $z(\alpha)$
- ▶ pro malý počet dvojic (do deseti) raději použít tabulky
- ▶ příklad ( $W = 64$ ,  $n = 12$ , jinak přesně je  $p = 2,6\%$ )

$$Z = \frac{64 - 12 \cdot 13/4}{\sqrt{12 \cdot 13 \cdot 25/24}} = 1,961 > 1,645 = z(0,05), p = 2,5\%$$

## poznámky k výpočtu

- ▶ nezapomenout vyloučit nulové rozdíly
- ▶ shodným absolutním hodnotám rozdílům přiřadíme jejich průměrné pořadí
- ▶ Excel nám v takovém případě moc nepomůže, protože řeší problém shod nestandardně, např.:

$X_i$	4	-2	5	2	-6	-4	2	7
$ X_i $	4	2	5	2	6	4	2	7
$R_i^+$	4,5	2	6	2	7	4,5	2	8
Excel	4	1	6	1	7	4	1	8

- ▶ v tabulce patrné nestandardní chování Excelu
- ▶ `[wilcox.test(pokles,alternative="greater")]`

## párový znaménkový (sign) test

- ▶ hodnotí pouze **počet** kladných a záporných rozdílů, nezáleží na tom, jak jsou rozdíly velké (slabší test než Wilcoxonův)
- ▶  $H_0$ :  $Y_i, Z_i$  mají stejné rozdělení; za hypotézy očekáváme, že počty kladných a záporných  $X_i$  jsou podobné
- ▶ označme  $Y$  počet kladných  $X_i$  z celkem  $n$  nenulových, za hypotézy  $Y \sim \text{bi}(n, 1/2)$
- ▶ přibližné rozhodování (centrální limitní věta)

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

- ▶ při jednostranné alternativě porovnáme  $Z$  a  $z(\alpha)$

## poznámky

- ▶ pro znaménkový test není třeba znát hodnoty  $Y_i, Z_i$ , stačí vědět, která z možností  $Y_i > Z_i$ ,  $Y_i < Z_i$ ,  $Y_i = Z_i$  nastala
- ▶ náš příklad o možném poklesu potratovosti ( $n = 12$ ,  $Y = 8$ )

$$Z = \frac{2 \cdot 8 - 12}{\sqrt{12}} = 1,155, \quad p = P(Z > 1,155) = 0,124$$


- ▶ při malých hodnotách  $n$  (do 30) se doporučuje Yatesova korekce

$$Z_{\text{Yates}} = \frac{|2Y - n| - 1}{\sqrt{n}} \text{sign}(2Y - n)$$

- ▶ náš příklad (Yatesova korekce, jiným způsobem přesně  $p = 0,194$ )

$$Z = \frac{|2 \cdot 8 - 12| - 1}{\sqrt{12}} \cdot 1 = 0,866, \quad p = 1 - \Phi(0,866) = 0,193$$

## souvisí spolu výška rodičů?






## prokazování závislosti spojitých veličin

- ▶ víme, že pro nezávislé  $X, Y$  je  $\rho_{X,Y} = 0$
- ▶  $r_{xy}$  je odhadem  $\rho_{X,Y}$ ; jak daleko od nuly musí být  $r_{xy}$ , abychom na hladině  $\alpha$  prokázali závislost  $X, Y$ ?
- ▶ za předpokladu, že  $X, Y$  mají normální rozdělení (nebo počet pozorovaných dvojic  $X_i, Y_i$  je velký), hypotézu nezávislosti zamítáme pokud je  $|T| \geq t_{n-2}(\alpha)$ , kde

$$T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2}$$

## příklad: výšky rodičů



## příklad: výšky rodičů

- ▶ pro  $n = 99$  dvojic byl spočítán korelační koeficient  $r = 0,205$ ;

▶

$$T = \frac{0,205}{\sqrt{1-0,205^2}} \sqrt{97} = 2,07 > t_{97}(0,05) = 1,98$$

- ▶ na 5% hladině jsme závislost prokázali
- ▶  $t_{97}(0,01) = 2,63$ , tudíž na 1% hladině jsme závislost neprokázali
- ▶ výška zpravidla splňuje předpoklad o normálním rozdělení
- ▶ `[cor.test( vyska.m+vyska.o,data=Kojeni)]`  
`[CORREL(x;y)]` (pouze výpočet korelačního koeficientu)
- ▶ není-li normální rozdělení a nemnoho pozorování, raději použít Spearmanův korelační koeficient

## Spearmanův korelační koeficient

- ▶ místo původních hodnot  $x_i, y_i$  používá jejich pořadí  $R_i, Q_i$
- ▶ je to vlastně Pearsonův korelační koeficient použitý na pořadí
- ▶ výpočet lze upravit, zjednodušit na

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

- ▶ vhodný pro nelineární monotonní **závislost**, nevadí odlehle hodnoty
- ▶ při testování nemusí být normální rozdělení


## příklad: alkohol a úmrtnost na cirhózu

země	spotřeba	úmrtnost	$R_i$	$Q_i$	$R_i - Q_i$
Finsko	3,9	3,6	1	3	-2
Norsko	4,2	4,3	2	5	-3
Irsko	5,6	3,4	3	2	1
Holandsko	5,7	3,7	4	4	0
Švédsko	6,0	7,2	5	7	-2
Anglie	7,2	3,0	6	1	5
Belgie	10,8	12,3	7	8	-1
Rakousko	10,9	7,0	8	6	2
SRN	12,3	23,7	9	10	-1
Itálie	15,7	23,6	10	9	1
Francie	24,7	46,1	11	11	0

$$r_s = 1 - \frac{6}{11 \cdot 120} (2^2 + 3^2 + \dots) = 0,773$$

$r = 0,956$  zdánlivě mnohem těsnější závislost!

## cirhóza jater a spotřeba alkoholu




## Regrese

- ▶ na rozdíl od korelace (síla závislosti) hledáme tvar (způsob) závislosti, zajímá nás také průkaznost závislosti
- ▶ snažíme se z daných hodnot **regresorů (nezávisle proměnných)** předpovědět hodnoty **závisle proměnné** (odezvy, vysvětlované proměnné)
- ▶ snažíme se variabilitu (kolísání hodnot) odezvy vysvětlit kolísáním regresorů
- ▶ prvně v tomto smyslu F. Galton (1886) při vyšetřování závislosti výšky potomků na průměrné výšce rodičů
- ▶ Pearson, Lee (1903): potomci otců o dva palce vyšších než průměr všech otců byli v průměru jen o palec vyšší než průměr synů; dvoupalcová odchylka se nereprodukovala celá, byl patrný návrat (**regres**) k průměru

## příklad: souvisí úmrtnost se zeměpisnou šířkou?

úmrtnost na melanom na 10 000 000 obyvatel v státech USA



## regresní přímka

- ▶ chování  $Y$  (úmrtnost, mortality) co nejlépe (nejvíce) vysvětlit lineární závislostí na  $x$  (zeměpisná šířka, latitude)
- ▶ (naše představa, předpoklad:) každé zem. šířce odpovídá jakási střední úmrtnost, ta závisí na zeměpisné šířce lineárně

$$E Y_i = \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n$$

- ▶ parametry  $\beta_0, \beta_1$  odhadneme **metodou nejmenších čtverců** minimalizací přes  $\beta_0, \beta_1$  součtu čtverců „svislých“ odchylek

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

- ▶ výsledné minimum (pro  $\beta_0 = b_0, \beta_1 = b_1$ ) nazveme **reziduální součet čtverců**, tj.  $S_e = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2$

## naš příklad


[summary(lm(mortality~latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	389,19	23,81	16,34	<0,001
latitude	- 5,98	0,60	- 9,99	<0,001

- ▶ odhad závislosti:  $\widehat{\text{mortality}} = 389,19 - 5,98 \text{ latitude}$
- ▶ s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 6 osob na 10 000 000 obyvatel
- ▶ na rovníku by úmrtnost měla být 389 jednotek, ale je to extrapolace mimo rozmezí známých hodnot – sotva použitelné
- ▶ závislost je průkazná, neboť v řádku pro  $x$  (latitude) je  $p < 0,001$

## metoda nejmenších čtverců

- odhadovaná závislost:  $y = \beta_0 + \beta_1 \cdot x$  (populace)
- odhad závislosti:  $y = b_0 + b_1 \cdot x$  (výběr)
- celková plocha čtverců:  $S_e = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2$  (výběr)



## obecně

- ▶ odhadovaná závislost  $y = \beta_0 + \beta_1 x$ , odhadnutá  $y = b_0 + b_1 x$
- ▶ závislost na  $x$  prokazujeme testováním hypotézy  $H_0 : \beta_1 = 0$  (pak je  $y$  pro všechna  $x$  stejné, tedy  $y = \beta_0$ ) pomocí

$$T = \frac{b_1}{\text{S.E.}(b_1)} = \frac{b_1}{s} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- ▶ zamítáme  $H_0$  proti oboustr. alternativě, když  $|T| \geq t_{n-2}(\alpha)$
- ▶ **reziduální součet čtverců – nevysvětlená variabilita  $Y$**   
 $S_e = \sum_{i=1}^n (Y_i - (b_0 + b_1 x_i))^2$  reziduální součet čtverců  
 $s^2 = S_e / (n - 2)$  reziduální rozptyl
- ▶ **koeficient determinace** ukazuje, jaký **díl variability odezvy** (tj.  $\sum_{i=1}^n (Y_i - \bar{Y})^2$ ) jsme závislostí vysvětlili

$$R^2 = 1 - \frac{S_e}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$$

## náš příklad a tabulka analýzy rozptylu

[anova(lm(mortality~latitude))]

variabilita	st. vol. $f$	součet čtverců $SS$	prům. čtverec $MS$	$F$	$p$
model	1	36 464,20	36 464,20	99,797	<0,001
reziduální	47	17 173,07	365,38		
celkem	48	53 637,27			

- ▶ kolísání úmrtnosti vysvětlíme závislostí z 68 %, neboť je

$$R^2 = 1 - \frac{17173,07}{53637,27} = \frac{36464,20}{53637,27} = 0,680$$

## dva regresory

koef.	odhad	stř. chyba	$t$ -stat.	$p$
abs. člen	401,17	28,04	14,31	<0,001
latitude	- 5,93	0,60	- 9,82	<0,001
longitude	0,15	0,19	0,82	0,418

- ▶ pokusíme se přidat zeměpisnou délku
- ▶ není průkazné, že by koeficient u longitude byl nenulový (nezamítneme hypotézu, že koeficient je nulový)
- ▶ longitude nepřináší další informaci o mortality, kterou bychom už neměli ze známé hodnoty latitude
- ▶  $\Rightarrow$  není vhodné přidávat do modelu s latitude také longitude
- ▶ koeficient determinace  $R^2 = 0,684$  (původně 0,680)

## interpretace

- ▶ odhad byl:  $\widehat{\text{úmrtnost}} = 389,19 - 5,98 \cdot \text{šířka}$
- ▶ na 30. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 30 = 209,86$
- ▶ na 40. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 40 = 150,08$
- ▶ přechod z 30. stupně na 40. stupeň znamená **v průměru** pokles o  $10 \cdot 5,98 = 59,8$  úmrtí na 10 000 000 obyvatel
- ▶ pokusíme se predikci zlepšit přidáním další nezávisle proměnné

## podrobnější rozbor – vliv oceánu

- ▶ závislost jen pro vnitrozemské státy ( $R^2 = 59,6$  %):  
[lm(mortality~latitude,subset=Ocean==0)]

koef.	odhad	stř. chyba	$t$ -stat.	$p$
abs. člen	360,55	36,70	9,82	<0,001
latitude	- 5,485	0,904	- 6,07	<0,001

- ▶ závislost jen pro přímořské státy ( $R^2 = 78,6$  %):  
[lm(mortality~latitude,subset=Ocean==1)]

koef.	odhad	stř. chyba	$t$ -stat.	$p$
abs. člen	381,20	24,83	15,35	<0,001
latitude	- 5,491	0,640	- 8,58	<0,001

- ▶ směrnice jsou téměř stejné, abs. členy rozdílné
- ▶ v obou případech s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 5,5 osob na 10 000 000 obyvatel


## společně vnitrozemské i přímořské státy

[summary(lm(mortality~Ocean+latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,69	21,50	16,78	<0,001
ocean	20,43	4,83	4,23	<0,001
latitude	- 5,49	0,53	- 10,44	<0,001

- ▶ koeficient determinace  $R^2=0,770$
- ▶ při „stěhování“ z vnitrozemí k oceánu po rovnoběžce roste úmrtnost v průměru o 20 osob na 10 milionů obyvatel
- ▶ je to ekvivalentní vnitrozemskému stěhování o  $20,43/5,49 = 3,72$  stupňů na jih
- ▶ na každý stupeň stěhování na sever klesá úmrtnost o 5,5, pokud se nezmění vztah k oceánu

## příklad: souvisí úmrtnost s polohou?



- ▶ vnitrozemské státy:  $y=360,69-5,49 x$
- ▶ přímořské státy:  $y=(360,69+20,43)-5,49 x =381,12-5,49 x$
- ▶ lze ověřit, že přímkou mohou být rovnoběžné ( $p =99,6 \%$ )

## pozor na interpretaci odhadů (na dalším příkladu)

- ▶ závisí procento tuku dospělého muže na jeho výšce? pokud ano, tak s výškou roste nebo klesá?
- ▶ závisí na tom, jak se na úlohu díváme, co bereme v úvahu
- ▶  $\widehat{fat} = - 47,68 + 0,341 \text{ height}$   $R^2 = 11,8 \%$
- ▶  $\widehat{fat} = 16,55 - 0,244 \text{ height} + 0,504 \text{ weight}$   $R^2 = 71,4 \%$
- ▶ ve všech případech jsou koeficienty u regresorů na 5% hladině průkazně nenulové
- ▶ rozdíl je v kvalitě vyrovnání, ale zejména v interpretaci
- ▶ průměrná změna procenta tuku při jednotkové změně výšky (a **nezměněné hmotnosti** pro druhý model)

## regrese v MS Excelu 2000, 2003


	Excel 2000	označení
absolutní člen	Hranice	$b_0$
odhad	Koeficienty	$b_i$
střední chyba odhadu	Chyba střední hodnoty	S.E.( $b_j$ )
koeficient		$\sqrt{R^2}$
(mnohonásobné) korelace	Násobné R	
koeficient determinace	Hodnota spolehlivosti R	$R^2$
adjustovaný koef. det.	Nastavená hodnota spol. R	$R^2_{adj}$
resid. směr. odchylka	Chyba střední hodnoty	$s$
počet pozorování	Pozorování	$n$
počet st. volnosti	Rozdíl	

## regrese v MS Excelu 2000, 2003

- ▶ Pozor na nabízený graf „Graf s rozdělením pravděpodobnosti“: obecně **nevypovídá** o normálním rozdělení, jak by asi chtěl, bylo by třeba použít místo vysvětlované veličiny některá z reziduí
- ▶ Nabízená „Normovaná rezidua“ jsou v regresi zcela nestandardní (z-skóry běžných reziduí)

## praktické problémy: transformace


střední délka života ~ HDP (rok 1992, 33 skupin zemí z celého světa)



- ▶ v původním měřítku závislost nelineární
- ▶ logaritmování HDP hodně pomohlo, ale ještě jistě jiné vlivy
- ▶  $\log(\text{HDP})$  vysvětlí téměř 79 % variability střední délky života
- ▶ lze identifikovat státy, které se zvláště vymykají

## praktické problémy: zdánlivá závislost


počet letišť ~ délka železnic v Evropě



- ▶ v původním měřítku:  $R^2 = 78 \%$ ,  $p = 0,2 \%$
- ▶ v logaritmickém měřítku:  $R^2 = 66 \%$ ,  $p = 0,02 \%$
- ▶ logaritmické měřítko, bez Lucemburska:  $R^2 = 69 \%$ ,  $p = 1 \%$

## praktické problémy: zdánlivá závislost


počet letišť ~ délka železnic v Evropě



- ▶ počet letišť i délka železnic souvisí s velikostí země
- ▶ u letišť:  $R^2 = 86 \%$ ,  $p = 0,03 \%$
- ▶ u železnic:  $R^2 = 64 \%$ ,  $p = 0,03 \%$

## praktické problémy: zdánlivá závislost

počet letišť a délka železnic ~ plocha




- ▶ závislost v logaritmech:  $R^2 = 28\%$ ,  $p = 14\%$
- ▶ závislost v původním měřítku:  $R^2 = 12\%$ ,  $p = 36\%$
- ▶ relativní počet letišť nesouvisí s relativní délkou železnic

## příklad: je výběr reprezentativní?

- ▶ bylo provedeno šetření mezi ženami ve věku 18 až 50 roků
- ▶ mezi 498 náhodně oslovenými ženami bylo celkem 180 žen svobodných, 239 žen vdaných, 75 žen rozvedených a 4 ovdovělé
- ▶ stejné údaje v procentech: 36,14 % svobodných, 47,99 % vdaných, 15,06 % rozvedených, 0,80 % ovdovělých
- ▶ je známo, že v celé populaci žen v ČR uvedeného věkového rozpětí je 34,27 % svobodných, 52,02 % vdaných, 12,50 % rozvedených a 1,20 % ovdovělých
- ▶ lze výběr považovat za reprezentativní?

## praktické problémy: časová řada

vývoj HDP v ČR – pozorování tvoří časovou řadu



- ▶ po sobě jsou pozorování nejsou nezávislá
- ▶ je patrný vliv čtvrtletí (rezidua vpravo)
- ▶ na pravém grafu patrný vliv „balíčku“

## multinomické rozdělení

- ▶ zobecnění binomického rozdělení na  $k$ -tici náhodných veličin  $X_1, \dots, X_k$
- ▶ parametry  $n, \pi_1, \dots, \pi_k$  ( $0 < \pi_j < 1$ ,  $\pi_1 + \dots + \pi_k = 1$ )
- ▶  $n$  **nezávislých** pokusů
- ▶ v každém pokusu **právě jeden** z  $k$  možných výsledků
- ▶  $j$ -tý výsledek s pravděpodobností  $\pi_j$
- ▶  $X_j$  – počet pokusů, v nichž nastal  $j$ -tý možný výsledek, tedy nutně

$$X_1 + \dots + X_k = n$$

## příklady multinomického rozdělení

- ▶ předvolební průzkum
  - ▶  $n$  – počet tázaných
  - ▶  $\pi_j$  – skutečný podíl voličů  $j$ -té strany v populaci
  - ▶  $X_j$  – počet (četnost) voličů  $j$ -té strany ve výběru
- ▶ hody hrací kostkou
  - ▶  $n$  – počet hodů
  - ▶  $\pi_1, \dots, \pi_6$  – pravděpodobnosti jednotlivých stran kostky
  - ▶  $X_1, \dots, X_6$  – absolutní četnosti jednotlivých stran kostky
- ▶ krevní skupiny
  - ▶  $n=4$  (skupiny 0, A, B, AB)
  - ▶  $\pi_0, \pi_A, \pi_B, \pi_{AB}$  – psti skupin 0, A, B, AB
  - ▶  $X_0, X_A, X_B, X_{AB}$  – počty osob se skupinami 0, A, B, AB

## příklad: hrací kostka A

- ▶ test **jednoduché** hypotézy
- ▶  $n = 100$  hodů kostkou
- ▶  $X_1 = 12, X_2 = 21, X_3 = 14, X_4 = 15, X_5 = 21, X_6 = 17$
- ▶ hypotéza  $H_0 : \pi_1 = \dots = \pi_6 = 1/6$  dá očekávané četnosti  $n\pi_1 = \dots = n\pi_6 = 100/6 = 16,67$  (vždy více než 5)

$$\chi^2 = \frac{(12 - 16,67)^2}{16,67} + \dots + \frac{(17 - 16,67)^2}{16,67} = 4,16$$

- ▶  $\chi^2 < \chi_5^2(0,05) = 11,07, \quad p = 52,7 \%$
- ▶ neprokázali jsme, že by kostka nebyla symetrická
- ▶  $[\text{chisq.test}(c(12,21,14,15,21,17),p=\text{rep}(1,6)/6)]$

## vlastnosti multinomického rozdělení

- ▶ každá složka má binomické rozdělení:  $X_j \sim \text{bi}(n, \pi_j)$
- ▶ střední hodnota:  $\mu_{X_j} = n\pi_j$ , rozptyl:  $\sigma_{X_j}^2 = n\pi_j(1 - \pi_j)$
- ▶ (pro zajímavost) kovariance:  $\text{cov}(X_j, X_t) = -n\pi_j\pi_t \quad j \neq t$
- ▶ asymptotická vlastnost **chí-kvadrát** (velká  $n, n\pi_j \geq 5$ )

$$\chi^2 = \sum_{j=1}^k \frac{(X_j - n\pi_j)^2}{n\pi_j} \sim \chi_{k-1}^2$$

- ▶  $X_j$  – **empirické četnosti**,  
 $n\pi_j$  – **očekávané (teoretické) četnosti**

## příklad: hrací kostka B (1)

- ▶  $n = 100$  hodů kostkou
- ▶  $X_1 = 15, X_2 = 16, X_3 = 7, X_4 = 6, X_5 = 15, X_6 = 41$
- ▶ hypotéza  $H_0 : \pi_1 = \dots = \pi_6 = 1/6$  dá očekávané četnosti  $n\pi_1 = \dots = n\pi_6 = 100/6 = 16,67$

$$\chi^2 = \frac{(15 - 16,67)^2}{16,67} + \dots + \frac{(41 - 16,67)^2}{16,67} = 48,32$$

- ▶  $\chi^2 > \chi_5^2(0,05) = 11,07$
- ▶ zřejmě je nutno zamítnout hypotézu, že kostka je symetrická
- ▶ na 5% hladině jsme prokázali, že není symetrická



příklad: hrací kostka B (2), jiná  $H_0$ 

- ▶  $n = 100$  hodů kostkou
- ▶  $X_1 = 15, X_2 = 16, X_3 = 7, X_4 = 6, X_5 = 15, X_6 = 41$
- ▶ nulová hypotéza:  $\pi_1 = \dots = \pi_5 = 1/10, \pi_6 = 5/10 = 1/2$
- ▶ očekávané četnosti za hypotézy:  
 $n\pi_1 = \dots = n\pi_5 = 100/10 = 10, n\pi_6 = 100/2 = 50$

$$\chi^2 = \frac{(15 - 10)^2}{10} + \dots + \frac{(15 - 10)^2}{10} + \frac{(41 - 50)^2}{50} = 12,72$$

- ▶  $\chi^2 > \chi_5^2(0,05) = 11,07$
- ▶ zřejmě je nutno zamítnout i tuto hypotézu  
[chisq.test(c(15,16,7,6,15,41),p=c(1,1,1,1,1,5)/10)]

## příklad: hrací kostka B (3) (použit jen část informace)

- ▶  $n = 100$  hodů kostkou
- ▶  $X_6 = 41$
- ▶ nulová hypotéza:  $\pi_6 = 5/10 = 1/2$
- ▶ hypotéza o psti jediného z možných výsledků (pst šestky) – binomické rozdělení
- ▶ dříve jsme určili přibližný 95% interval spolehlivosti pro pravděpodobnost šestky: (0,31; 0,51)
- ▶ 1/2 je v tomto intervalu, na 5% hladině **nelze** zamítnout  
[binom.test(41,100)]

## příklad: je výběr reprezentativní?

- ▶ provedeme test hypotézy, že pravděpodobnosti čtyř skupin žen jsou rovny procentům v populaci

	svobodné	vdané	rozvedené	ovdovělé	celkem
populace	34,27 %	52,02 %	12,50 %	1,20 %	100 %
výběr	180	239	75	4	498
výběr (rel.)	36,14 %	47,99 %	15,06 %	0,80 %	100 %
oček. čet.	170,69	259,07	62,26	5,99	498
přínos	0,51	1,55	2,61	0,66	5,33

$$\frac{(180 - 170,69)^2}{170,69} + \frac{(239 - 259,07)^2}{259,07} + \frac{(75 - 62,26)^2}{62,26} + \frac{(4 - 5,99)^2}{5,99}$$

- ▶ výsledná hodnota chí-kvadrát je  $\chi^2 = 5,33$ , ale  $\chi_3^2(0,05) = 7,81$
- ▶ neprokázali jsme, že by výběr nebyl reprezentativní, můžeme jej za reprezentativní považovat

test homogenity  $r$  výběrů

- ▶ například, zda mají kostky A, B stejné šestice psti (ať už je ta šestice jakákoliv)
- ▶  $X_{i1}, \dots, X_{ik}$   $i$ -tý výběr z multinomického rozdělení s parametry  $n_{i\bullet}, \pi_{i1}, \dots, \pi_{ik}$  ( $i = 1, \dots, r$ )
- ▶  $H_0$ : pravděpodobnosti jsou ve všech srovnávaných populacích stejné:  $\pi_{i1} = \pi_1, \dots, \pi_{ik} = \pi_k$  (nezávisí na populaci)
- ▶ četnosti uspořádáme do kontingenční tabulky
  - ▶  $n_{ij}$  – počet  $j$ -tých výsledků v  $i$ -tém výběru
  - ▶  $n_{i\bullet} = \sum_j n_{ij}$  jsou řádkové marginální četnosti (rozsahy výběrů)
  - ▶  $n_{\bullet j} = \sum_i n_{ij}$  jsou sloupcové marginální četnosti (četnosti možných výsledků bez ohledu na výběr)
  - ▶  $n = \sum_i n_{i\bullet} = \sum_j n_{\bullet j} = \sum_i \sum_j n_{ij}$  je celkový počet pozorování

test homogenity  $r$  výběrů

- ▶ neznámé pravděpodobnosti  $\pi_j$  odhadneme pomocí marginálních relativních četností  $n_{\bullet j}/n$
- ▶ očekávané četnosti tak budou  $o_{ij} = n_{i\bullet} \frac{n_{\bullet j}}{n} = \frac{n_{i\bullet} n_{\bullet j}}{n}$
- ▶ empirické četnosti porovnáme s četnostmi očekávanými

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

- ▶ platí-li hypotéza, má výsledná statistika  $\chi^2$ -rozdělení  $\chi^2_{(r-1)(k-1)}$
- ▶ hypotézu o shodě pravděpodobností v  $r$  populacích zamítáme, je-li  $\chi^2 \geq \chi^2_{(r-1)(k-1)}(\alpha)$
- ▶ je třeba, aby očekávané četnosti byly dost velké, aspoň 5

## mají obě kostky stejné šestice pravděpodobností?

- ▶ empirické četnosti (kontingenční tabulka)

A	12	21	14	15	21	17	100
B	15	16	7	6	15	41	100
	27	37	21	21	36	58	200

- ▶ očekávané četnosti (za hypotézy):  $27 \cdot 100 / 200 = 13,5, \dots$

A	13,5	18,5	10,5	10,5	18	29	100
B	13,5	18,5	10,5	10,5	18	29	100
	27	37	21	21	36	58	200

- ▶

$$\chi^2 = \frac{(12 - 13,5)^2}{13,5} + \frac{(21 - 18,5)^2}{18,5} + \dots + \frac{(41 - 29)^2}{29} = 18,13$$

- ▶

$$\chi^2 > 11,07 = \chi^2_5(0,05), \quad p = 0,3 \%$$

- ▶ hypotézu o shodě pstí na kostkách A a B **zamítáme**

## příklad – vzdělání matek

vzdělání	porodnice		celkem
	Praha	venkov	
základní	23	11	34
střední	30	17	47
VŠ	17	1	18
celkem	70	29	99

$$\chi^2 = 6,12, \quad p = 4,7 \%$$

- ▶ kdyby rozdělení vzdělání bylo všude stejné, očekáváme tři možnosti v poměru 34:47:18 (marg. četnosti!), celkem 99
- ▶ pražských 70 matek by stejný poměr dalo při **očekávaných** četnostech  $70 \cdot 34 / 99 = 24,0$ , resp.  $70 \cdot 47 / 99 = 33,2$  resp.  $70 \cdot 18 / 99 = 12,7$
- ▶ podobně pro matky z venkova dostaneme 9,96, po zaokrouhlení 10,0, pro další četnosti 13,8 resp. 5,3

## příklad: předvolební průzkum

zprávy TV XY	strana		celkem
	A	B	
sledoval	11	4	15
nesledoval	6	9	15
celkem	17	13	30

zprávy TV XY	strana		celkem
	A	B	
sledoval	73 %	27 %	100 %
nesledoval	40 %	60 %	100 %
celkem	57 %	43 %	100 %

zprávy TV XY	strana		celkem
	A	B	
sledoval	65 %	31 %	50 %
nesledoval	35 %	69 %	50 %
celkem	100 %	100 %	100 %

- ▶ 30 voličů bylo dotázáno, které ze dvou stran dají přednost
- ▶ souvisí odpovědi se sledováním večerních zpráv na dané TV stanici?
- ▶ znamená něco nestejně zastoupení příznivců stran u těch, kteří sledovali?
- ▶ znamenají něco nestejně podíly těch, kteří sledovali mezi příznivci dvou stran?

## test nezávislosti kvalitativních znaků

- ▶ vyšetřujeme **současně** dva znaky v nominálním měřítku u  $n$  nezávislých statistických jednotek
- ▶  $n_{ij}$  je počet jednotek, kde je současně  $i$ -tá hodnota prvního znaku a  $j$ -tá hodnota druhého znaku
- ▶ celkem je  $i$ -tá hodnota prvního znaku u  $n_{i\bullet} = \sum_j n_{ij}$  jednotek,  $j$ -tá hodnota druhého znaku u  $n_{\bullet j} = \sum_i n_{ij}$  jednotek
- ▶ kdyby byly znaky nezávislé, byl by pro každou hodnotu jednoho znaku poměr mezi četnostmi hodnot druhého znaku podobný, proto očekávané četnosti jsou  $o_{ij} = \frac{n_{i\bullet} \cdot n_{\bullet j}}{n}$  (podmíněně psti stejné)
- ▶ výpočet  $\chi^2$  a jeho hodnocení stejné jako u homogenity

## příklad: souvisí plánované těhotenství se vzděláním?

vzdělání	plánované		celkem	vzdělání	plánované		celkem
	ne	ano			ne	ano	
základní	20	14	34	základní	58,8 %	42,1 %	100 %
střední	16	31	47	střední	34,0 %	66,0 %	100 %
VŠ	5	13	18	VŠ	27,8 %	72,2 %	100 %
celkem	41	58	99	celkem	41,4 %	58,6 %	100 %

- ▶ je souvislost mezi odpověďmi o plánovaném těhotenství a vzděláním matek?
- ▶ kdyby byly znaky nezávislé, byly by podmíněně pravděpodobnosti pro jednotlivá vzdělání stejné, tedy jejich odhady by byly podobné
- ▶ test vlastně porovnává procenta u jednotlivých vzdělání
- ▶ chí-kvadrát test porovnává skutečně zjištěné četnosti s tím, jaké četnosti bychom v průměru očekávali, kdyby platila nulová hypotéza

## příklad: plánovaná těhotenství

skutečné četnosti (očekávané četnosti)

vzdělání	plánované		celkem
	ne	ano	
základní	20 (14,08)	14 (19,92)	34
střední	16 (19,46)	31 (27,54)	47
VŠ	5 (7,46)	13 (10,54)	18
celkem	41	58	99

- ▶ odhad pravděpodobnosti, že má matka základní vzdělání:  $\hat{P}(\text{vzdel} = \text{zakladni}) = 34/99$
- ▶ odhad pravděpodobnosti, že jde o plánované těhotenství:  $\hat{P}(\text{tehot} = \text{plan}) = 58/99$
- ▶ **jsou-li** vzdělání a plánovanost **nezávislé**, pak  $P((\text{vzdel} = \text{zakladni}) \cap (\text{tehot} = \text{plan})) = P(\text{vzdel} = \text{zakladni}) \cdot P(\text{tehot} = \text{plan}) \doteq (34/99) \cdot (58/99)$
- ▶ očekávaný počet matek se základním vzděláním a plánovaným těhotenstvím (**za platnosti nulové hypotézy**) odhadneme:  $99 \cdot (34/99) \cdot (58/99) = 34 \cdot 58/99 \doteq 19,92$

## příklad: plánovaná těhotenství

skutečné četnosti (očekávané četnosti)

vzdělání	plánované		celkem
	ne	ano	
základní	20 (14,08)	14 (19,92)	34
střední	16 (19,46)	31 (27,54)	47
VŠ	5 (7,46)	13 (10,54)	18
celkem	41	58	99

$$\chi^2 = \frac{(20 - 14,08)^2}{14,08} + \frac{(14 - 19,92)^2}{19,92} + \frac{(16 - 19,46)^2}{19,46} + \frac{(31 - 27,54)^2}{27,54} + \frac{(5 - 7,46)^2}{7,46} + \frac{(13 - 10,54)^2}{10,54} = 6,68$$

## příklad: souvisí plánované těhotenství se vzděláním?

- u každé matky zjišťovány dva znaky: dosažené vzdělání, zda těhotenství plánováno

vzdělání	nevěsta			celkem
	základní	střední	VŠ	
neplánováno	20 (14,1)	16 (19,5)	5 (7,5)	41
plánováno	14 (19,9)	31 (27,5)	13 (10,5)	58
celkem	34	47	18	99

- kdyby nebyla závislost, u každého vzdělání by bylo stejné procento plánovaných těhotenství, totiž  $58/99=58,6\%$ 
  - u zákl. vzdělání  $x/34 = 58/99$  tedy  $x = 34 \cdot 58/99 = 19,9$
  - u středního vzdělání  $x/47 = 58/99$  tedy  $x = 47 \cdot 58/99 = 27,5$
  - u vysokošolaček  $x/18 = 58/99$  tedy  $x = 18 \cdot 58/99 = 10,5$
- všechny očekávané četnosti jsou dostatečně velké

$$\chi^2 = 6,68 > 5,99 = \chi_2^2(0,05), \quad p = 3,5\%$$

## příklad: vzdělání snoubenců

ženich	nevěsta			celkem
	základní	střední	VŠ	
základní	24	12	3	39
střední	7	24	3	34
VŠ	3	9	15	27
celkem	34	45	21	100

- u 100 náhodně vybraných snoubenců bylo zjištěno vzdělání (základní = základní nebo neúplné střední)
- lze považovat vzdělání snoubenců za nezávislá?
- jsou četnosti dost velké?
- nejmenší očekávané četnost (při nezávislosti):  $27 \cdot 21/100 = 5,67$

## příklad: vzdělání snoubenců

ženich	nevěsta			celkem
	základní	střední	VŠ	
základní	24 (13,2)	12 (17,6)	3 (8,2)	39
střední	7 (11,6)	24 (15,3)	3 (7,1)	34
VŠ	3 (9,2)	9 (12,2)	15 (5,7)	27
celkem	34	45	21	100

- $\chi^2 = 43,2 > \chi_4^2(0,05) = 9,5$ ,  $p < 0,1\%$
- na 5 % hladině jsme prokázali závislost
- vzdělání snoubenců nelze považovat za nezávislá
- četnosti na diagonále jsou větší, než očekáváme za nezávislosti
- četnosti daleko od diagonály (velký rozdíl ve vzdělání) jsou menší, než očekáváme za nezávislosti

## čtyřpolní tabulka

speciální případ kontingenční tabulky

$a$	$b$	$a + b$
$c$	$d$	$c + d$
$a + c$	$b + d$	$n$

- sílu závislosti** lze měřit  $\phi$ -koeficientem [phi coefficient] (čtyřpolní korelační koeficient)

$$\phi = \frac{ad - bc}{\sqrt{(a+b)(c+d)(a+c)(b+d)}}$$

- $\phi$  je (jako každý korelační koeficient) mezi  $-1$  a  $1$

pro	11	4	15	vyjde
	6	9	15	
	17	13	30	

$$\phi = \frac{11 \cdot 9 - 4 \cdot 6}{\sqrt{15 \cdot 15 \cdot 17 \cdot 13}} = 0,34$$

## příklad: předvolební průzkum

- ▶  $\phi > 0$  znamená, že četnosti na hlavní diagonále (indexy 1,1 a 2,2) převládají nad četnostmi na vedlejší diagonále (indexy 1,2 a 2,1)

TV XY	strana		celkem
	A	B	
sledoval	11	4	15
nesledoval	6	9	15
celkem	17	13	30

- ▶ v našem příkladu

vychází  $\phi = 0,34 > 0$   
(tedy kladné), protože je  $11 \cdot 9 > 6 \cdot 4$

## čtyřpolní tabulka – prokazování závislosti

- ▶ chí-kvadrát porovnávající teoretické a očekávané četnosti lze upravit na tvar

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

- ▶ nezávislost se na hladině  $\alpha$  zamítá, je-li  $\chi^2 \geq \chi_1^2(\alpha)$
- ▶ příklad (předvolební průzkum)

$$\chi^2 = \frac{30 \cdot (11 \cdot 9 - 4 \cdot 6)^2}{15 \cdot 15 \cdot 17 \cdot 13} = 3,39 = 30 \cdot 0,34^2$$

- ▶ závislost jsme na 5% hladině neprokázali, neboť

$$3,39 < 3,84 = \chi_1^2(0,05), \quad p = 6,5 \%$$

## malé očekávané četnosti ve čtyřpolní tabulce

- ▶ stále je třeba, aby byly očekávané četnosti dost velké ( $\geq 5$ )
- ▶ **Yatesova korekce** umožní rozhodnutí i při menších četnostech tím, že zmenší čitatele

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

- ▶ nezávislost se zamítá, je-li opět  $\chi_{\text{Yates}}^2 \geq \chi_1^2(\alpha)$
- ▶ **Fisherův exaktní test** počítá přímo  $p$ -hodnotu

## příklad: souvislost délky kojení a plánování těhotenství

těhot.	Praha a venkov			venkov		
	neplán.	plán.	celkem	neplán.	plán.	celkem
ve 24. t. nekojí	35	36	71	13	9	22
ve 24. t. kojí	6	22	28	1	6	7
celkem	41	58	99	14	15	29

- ▶ bez ohledu na místo:  $\chi^2 = 6,43$ ,  $p = 1,1 \%$ ,  
 $\chi_{\text{Yates}}^2 = 5,33$ ,  $p = 2,1 \%$  (nejm. četnost  $41 \cdot 28/99 = 11,6$ )  
Fisherův exaktní test:  $p = 1,3 \%$
- ▶ venkov:  $\chi^2 = 4,27$ ,  $p = 3,9 \%$ ,  
 $\chi_{\text{Yates}}^2 = 2,66$ ,  $p = 10,3 \%$  (nejm. četnost  $14 \cdot 7/29 = 3,4$ )  
Fisherův exaktní test:  $p = 8,0 \%$

## Simpsonův paradox

dílčí tabulky mohou ukazovat na závislost jiného směru, než jejich součet

venkov	A	B	celkem	město	A	B	celkem
sledoval	34	5	39	sledoval	4	29	33
nesledoval	28	2	30	nesledoval	6	35	42
celkem	62	7	69	celkem	10	64	74

$$\phi_{\text{venkov}} = -0,10 \quad \phi_{\text{město}} = -0,04$$

celkem	A	B	celkem
sledoval	38	34	72
nesledoval	34	37	71
celkem	72	71	143

$$\phi_{\text{celkem}} = 0,05$$

- ▶ po spojení dvou tabulek se záporným  $\phi$ -koeficientem vyšla tabulka s kladným  $\phi$ -koeficientem

## závislost mezi nula-jedničkovým a kvantitativním znakem

- ▶ dva nezávislé výběry, např. hoši  $X_1, \dots, X_{n_0}$  a dívky  $X_{n_0+1}, \dots, X_{n_0+n_1}$ , vždy normální rozdělení jako pro dvouvýběrový t-test
- ▶ otázka: jak silně souvisí sledovaná vlastnost a pohlaví?
- ▶ označme pohlaví formálně  $Y_i = 0$  pro chlapce a  $Y_i = 1$  pro děvčata
- ▶ korelační koeficient  $r_{X,Y}$  mezi těmito veličinami se dá zapsat také jako

$$r_{\text{bis}} = \frac{\bar{X}_1 - \bar{X}_0}{S} \sqrt{\frac{n_0 n_1}{n(n-1)}}$$

- ▶  $S$  je směrodatná odchylka spočítaná bez ohledu na pohlaví,  $n = n_0 + n_1$  je celkový počet měření v obou výběrech
- ▶  $r_{\text{bis}}$  **bodově-biseriální korelační koeficient**

## příklad: výška desetiletých

- ▶ stejná data jako dvouvýběrový test (data ze str. 170)

$$\bar{X}_0 = 139,13, \quad n_0 = 15$$

$$\bar{X}_1 = 140,83, \quad n_1 = 12$$

$$S^2 = 38,18, \quad S = 6,18$$

▶

$$r_{\text{bis}} = \frac{140,83 - 139,13}{6,18} \sqrt{\frac{15 \cdot 12}{15 + 12}} = 0,493$$

- ▶  $H_0$  : nezávislost
- ▶ má-li  $X$  normální rozdělení, lze použít stejný test, jako u korelačního koeficientu; je to ekvivalentní dvouvýběrovému t-testu (při stejných populačních rozptylech)

## přehled korelačních koeficientů

- ▶ základním je (momentový) Pearsonův

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

- ▶ když místo hodnot  $x_i, y_i$  dosadíme jejich pořadí  $R_i, Q_i$ , dostaneme (pořadový) Spearmanův korelační koeficient

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

- ▶ je-li jedna z veličin nula-jedničková, vyjde biseriální korelační koeficient  $r_{\text{bis}}$
- ▶ jsou-li obě veličiny nula-jedničkové, dostaneme  $\phi$ -koeficient (čtyřpolní korelační koeficient)

## přehled testů o populačních mírách polohy

rozdělení	normální	spojité
populační parametr (o čem je hypotéza)	populační průměr	populační medián
jeden výběr	jednovýběrový $t$ -test	znaménkový Wilcoxon
výběr dvojic	párový $t$ -test	znaménkový Wilcoxon
dva nezávislé výběry	dvouvýběrový $t$ -test	Mann-Whitney

## ukázka zadání/1

▶ **Statistika (zadání úloh ke zkoušce, ak. rok 2007/08)** 7

Napište svoje jméno a příjmení, studovaný obor a dnešní datum:

- ▶ 1. Alternativní (nula-jedničkové) rozdělení. Uveďte příklad, spočítejte střední hodnotu.
- ▶ 2. Kolika způsoby lze ze 14 krajů zvolit 5 krajů, v nichž má být proveden výzkum? S jakou pravděpodobností bude vybrán Liberecký kraj, když výběr byl proveden losováním?
- ▶ 3. K následujícím hodnotám spočítejte popisné statistiky:  
1 8 2 3 6

$$\bar{x} = \quad \tilde{x} = \quad s_x =$$

## organizace zkoušení

- ▶ zkouším jen předem zapsané studenty (jinak jen výjimečně, je-li volné místo), a to v PUA (Alb. 6) nebo v B5 (Viničná 7)
- ▶ studenti FTVS se hlásí na volná místa emailem; volná místa se poznají tak, že počet přihlášených je menší než v SIS uvedená kapacita
- ▶ student musí již mít zápočet
- ▶ každý student dostane vlastní písemné zadání
- ▶ výpočty lze provádět v Excelu, v R nebo na vlastní kalkulačce; jiné pomůcky nejsou dovoleny
- ▶ student bude mít možnost ústně odpovídat na dotazy
- ▶ budu se ptát na základní věci i mimo písemně položené otázky

## ukázka zadání/2

- ▶ 4. Určete pravděpodobnost, že náhodná veličina s rozdělením  $N(\mu = 2, \sigma^2 = 1)$  nabude hodnoty v mezích od  $-3$  do  $0$ .  
 $p =$
- ▶ 5. Na 5% hladině se pokuste prokázat rozdíl mezi hochy ( $x$ ) a dívkami ( $y$ ) v hmotnosti ve 24. týdnu:

$x$	7	8	8	8	7	9	6	7	8	7
$y$	8	9	8	8	8	9	9	7	9	8

$$t = \quad p =$$

Slovní odpověď:

## ukázka zadání/3

- ▶ 6. U náhodně vybraných dvacetiletých mužů byla zjištěna jejich výška a váha. Popište lineární závislost váhy na výšce a rozhodněte o její průkaznosti.

y	86	49	78	80	69	78	114	87	93	92
x	194	171	168	186	172	182	187	190	188	188

Rovnice nalezené přímky:

Koeficient determinace:

Slovní odpověď:

- ▶ 7. Souvisí preference volebních stran s pohlavím voliče?

	A	B	celkem
muži	26	13	
ženy	19	30	
celkem			

$$\chi^2 = \quad p =$$

Slovní odpověď:

## několik slov zkoušce

- ▶ cílem zkoušení je zjistit, do jaké míry studentka či student zvládl obsah přednášky
- ▶ důležité jsou základní pojmy, myšlenkové konstrukce, nikoliv detaily
- ▶ u vzorečků je jejich smysl důležitější, než symboly
- ▶ dám přednost správnému smyslu pomocí nepřesně volených slov před nesprávně kombinovanými přesnými termíny (i když na jedničku to pak asi nebude)
- ▶ netoužím někoho do zkoušky vyhodit (přidělal bych si práci), ale nechci nikomu ubližovat tím, že by u zkoušky prošel i bez těch nezákladnějších znalostí