

Statistika

(MD360P03Z, MD360P03U)
ak. rok 2013/2014

Karel Zvára

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

(naposledy upraveno 7. ledna 2014)



1. přednáška

- ▶ úvod, přehled témat
- ▶ co a jak zjišťujeme, měřítka, veličina
- ▶ histogram, třídění
- ▶ variační řada, pořadí
- ▶ medián, kvartily, percentily
- ▶ průměr, vážený průměr
- ▶ modus

literatura

- ▶ K. Zvára: Základy statistiky v prostředí R, Karolinum, Praha 2013 (edice Biomedicínská statistika IV)
Karolinum (Celetná 18), Lípová 6, Neoluxor (Václ. nám 41)
- ▶ K. Zvára: Biostatistika, Karolinum, Praha 1998, 2000, 2001, 2003, 2006, 2008 (pozor na jiné značení)
- ▶ Z. Pavlík, K. Kühnl: Úvod do kvantitativních metod pro geografii, SPN Praha, 1981
- ▶ slajdy přednášky na adrese
<http://www.karlin.mff.cuni.cz/~zvara>
- ▶ může dojít k drobným úpravám slajdů před přednáškou i po ní

cvičení, zápočet, zkouška

- ▶ cvičení v počítačové učebně PUA (suterén Albertov 6) nebo v učebně B5 (Viničná 7)
- ▶ MS Excel **funkce Excelu**
- ▶ volně šiřitelný program R (<http://cran.r-project.org/>) **funkce R**
- ▶ (aktivní účast na cvičení, maximálně dvě absence) & (napsání zápočtového testu) ⇒ zápočet
- ▶ obsah cvičení více přizpůsoben studovanému oboru
- ▶ přednášky jsou formulovány obecněji
- ▶ znalosti ze cvičení nemusí u zkoušky stačit!
- ▶ zkouška kombinovaná (písemná s počítačem i ústní), zápočet **musí** zkoušce **předcházet**; přihlašování ke zkoušce přes SIS

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, chyba 2. druhu, hladina významnosti testu, síla testu, p -hodnota)
- ▶ některé testy (o populačním průměru či průměrech, populačním podílu či podílech, nezávislosti, regresních koeficientech)
- ▶ regrese, kontingenční (čtyřpolní) tabulky

příklad statistického zjišťování I

- ▶ zjišťování se týká mužů středního věku (populace, základní soubor)
- ▶ v souboru je 80 kuřáků a 120 nekuřáků (výběr)
- ▶ 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
- ▶ dotazy na populaci (základní soubor):
Co mají tyto údaje společného? Čím se údaje v jednotlivých podskupinách liší? Souvisí kouření a vzdělání? Souvisí příjem se vzděláním? Souvisí váha s výškou? Je tato souvislost stejná, jako v zemi XY?

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, délka školní docházky)
- ▶ přihlížíme k délce praxe v oboru
- ▶ přihlížíme k věku a pohlaví
- ▶ Co mají tyto údaje společného? Čím se údaje liší?

co a jak měříme (zjišťujeme)

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

měřítko

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

měřítka (stručnější dělení)

- ▶ **kvalitativní**: nula-jedničkové, nominální, často i ordinální
- ▶ u kvalitativního měřítka se zpravidla udávají **četnosti** jednotlivých hodnot (kolikrát která hodnota nastala)
- ▶ **kvantitativní** (spojité): intervalové, poměrové, někdy ordinální (není spojité)
- ▶ hodnoty v kvantitativním měřítku – čísla
- ▶ zařazení znaku k určitému měřítku může záviset na účelu šetření (např. barva nominální pro biologa, pro fyzika přinejmenším ordinální, možná dokonce poměrové)

veličina

- ▶ číselně vyjádřený výsledek měření (zjišťování)
- ▶ číselné hodnoty znaků v intervalovém a 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**)
- ▶ charakteristiky (statistiky) mají jedním číslem vyjádřit danou vlastnost
- ▶ Kdo je vyšší – dvanáctiletí hoši nebo dvanáctileté dívky? (potřebujeme výšky **všech** dvanáctiletých hochů charakterizovat **jediným** číslem, které má vyjádřit **úroveň** výšek, podobně pro dívky)

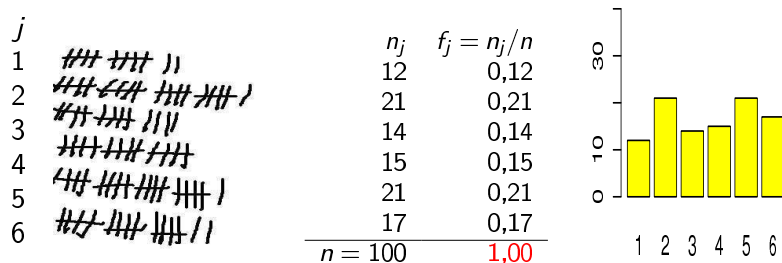
příklad: 100 hodů kostkou

počty puntíků na kostce 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

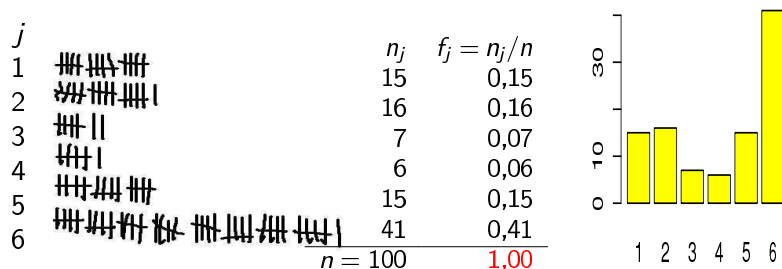
zpracování četností (kostka A)

čárkovací metoda, absolutní a relativní četnosti, barplot pro znak v kvalitativním měřítku



zpracování četností (kostka B)

čárkovací metoda, absolutní a relativní četnosti, barplot pro znak v kvalitativním měřítku



hody kostkou jako hromadný jev

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

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
```

- ▶ spojité hodnoty pouze zaokrouhleny na celá čísla
- ▶ Umíme něco užitečného z dat vytáhnout?
- ▶ Můžeme si rychle udělat představu?
- ▶ Můžeme tyto údaje porovnat s daty 10 let starými?
- ▶ Umíme vhodným číslem charakterizovat úroveň a variabilitu?

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

histogram pro znak v kvantitativním měřítku

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



třídění, třídění četnosti

jak jsme k histogramu dospěli

- ▶ spojité veličina s velkým počtem naměřených hodnot
- ▶ obor hodnot rozdělíme na k nepřekrývajících se tříd (intervalů), nejlépe stejné délky (ale ne vždy je to praktické či možné)
- ▶ všechna pozorování z daného intervalu nahradíme zástupnou hodnotou (zpravidla středem intervalu) x_j^* ($x_1^* < \dots < x_k^*$)
- ▶ zjistíme (absolutní) četnosti n_1, \dots, n_k jednotlivých tříd
- ▶ kumulativní četnost N_j udává počet hodnot v dané třídě a třídách předcházejících ($1 \leq j \leq k$) `cumsum()`

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

věk matek – třídní četnosti


$k = 7, n = 99$

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
celkem	–	99	1,000	–	–

► Jdi k mířám polohy věku matek

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

```
hist(věk.m,seq(17,38,by=3),col="yellow")
```



příklad: tolary

měsíční příjmy 99 osob ve fiktivní měně

```

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

velmi nepřehledná informace

příklad: tolary

variační řada = hodnoty jsou **uspořádané**

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	

přehlednější informace

budou užitečné četnosti hodnot?

třídění při nestejně dlouhých intervalech

- ▶ někdy jsou data nepravidelně rozmístěna
- ▶ zpravidla jsou soustředěna u levého okraje rozmezí 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; na svislou osu se pak nanáší **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

třídí četnosti (hustota = četnost na jednotku délky intervalu/ n)

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

příklad (tolary): histogram

na svislé ose je hustota (celková plocha obdélníků = 1)



plocha obdélníka = délka intervalu × hustota

variční řada, pořadí

- ▶ x_1, x_2, \dots, x_n původní (neuspořádaná) data – hodnoty znaku uvedené v původním pořadí, bez ohledu na případná opakování
- ▶ **variční řada** (uspořádaný výběr) sort(x)

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$$

data v měřítku aspoň ordinálním uspořádána tak, aby hodnoty neklesaly; proto **závorky u indexů**

- ▶ **pořadí** [rank] – umístění pozorování ve variční řadě; shodným hodnotám dáváme průměrné pořadí rank(x)

▶ příklad

x_j	32	25	27	25	31	23	28
pořadí R_j	7	2,5	4	2,5	6	1	5

- ▶ v Excelu má funkce RANK() poněkud jiný význam, lze použít opravu na shody (viz nápovědu pro RANK)

výběrové charakteristiky polohy: medián

- ▶ snaha charakterizovat úroveň číselné veličiny (malé či velké hodnoty) jediným číslem
- ▶ medián je číslo, které dělí data na dvě stejně velké části: větších hodnot a menších hodnot
- ▶ medián je ve variční řadě uprostřed (**prostřední** hodnota)
- ▶ **medián** [median] označení \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 variční řady**
- ▶ 5, 3, 4, 9, 6 $\tilde{x} = 5$ (3 < 4 < 5 < 6 < 9)

kvartily, percentily

- ▶ **dolní (horní) kvartil** Q_1 (Q_3) [lower (upper) quartile] vyděluje čtvrtinu nejmenších (největších) hodnot od ostatních
- ▶ **percentil** [percentile] x_p vyděluje 100p % nejmenších hodnot od ostatních
- ▶ konkrétní výpočet percentilu může být složitý
 - ▶ 100p nemusí být celé číslo
 - ▶ v datech se mohou čísla opakovat
- ▶ výpočet percentilů – mnoho vzorečků (další požadavky)
- ▶ kvartil – speciální případ percentilu:
 $Q_1 = x_{1/4} = x_{0,25}$, $Q_3 = x_{3/4} = x_{0,75}$
`quantile(x, probs=c(1/4, 3/4))`
- ▶ medián je také percentil, totiž $x_{0,5}$, podobně minimum ($p = 0$) a maximum ($p = 1$)
- ▶ `fivenum(x)` podobné příkazu `quantile(x, probs=0:4/4)`
- ▶ 1., 5. a 9. **decil** jsou vhodné k popisu rozdělení příjmů

výpočet percentilů (jako v R), jen pro ilustraci

jedna z možných definic – Gumbel(1939)

- ▶ k danému p se najde celé číslo k splňující

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

- ▶ tedy $k = \lfloor 1 + (n-1) \cdot p \rfloor$ ($\lfloor x \rfloor$ znamená celou část z x)
- ▶ provede se lineární interpolace mezi $x_{(k)}$ a $x_{(k+1)}$:

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

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

($\{x\}$ znamená zlomkovou část x , o kolik přesahuje celé číslo)

- ▶ např. pro $n = 99$, $p = 0,25$ (věk matek) bude


$$k = \lfloor 1 + (99 - 1) \cdot 0,25 \rfloor = \lfloor 1 + 24,5 \rfloor = \lfloor 25,5 \rfloor = 25$$

$$q = 25,5 - 25 = 0,5$$

$$Q_1 = x_{0,25} = (1 - 0,5) \cdot x_{(25)} + 0,5 \cdot x_{(26)} = 23$$

krabicový diagram (boxplot)

věk 99 matek



- ▶ grafické znázornění mediánu, kvartilů, minima, maxima, případně „odlehklých“ pozorování
- ▶ tykadlo sahá od kvartilu k co nejvzdálenějšímu pozorování, ale takovému, aby délka tykadla byla nejvýše $\frac{3}{2}(Q_3 - Q_1)$

příklad: toлары

$$\begin{aligned} \tilde{x} &= x_{0,5} = 14 & x_0 &= 10 & x_1 &= 47 \\ p &= 3/4, k = \lfloor 1 + 98 \cdot 3/4 \rfloor = \lfloor 74,5 \rfloor = 74, q = 74,5 - 74, \\ \Rightarrow Q_3 &= (1 - 0,5) \cdot 19 + 0,5 \cdot 20 = 19,5, & Q_1 &= 12 \\ (Q_3 - Q_1) \cdot 1,5 &= 7,5 \cdot 1,5 = 11,25, & 19,5 + 11,25 &= 30,75 \end{aligned}$$

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	



další míry polohy: průměr

- ▶ **průměr** [mean] (kdyby bylo všech n hodnot stejných)
 $\text{mean}(x)$

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

- ▶ pomocí četností **vážený průměr**: [weighted mean]

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

- ▶ obecně **vážený průměr** s vahami w_1, \dots, w_k hodnot x_1^*, \dots, x_k^* (váhy nutně nezáporné: $w_j \geq 0, \sum_{j=1}^k w_j > 0$)

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

příklad: HDP zemí V4 v roce 2010

obyvatelé v tisících, HDP na obyvatele v tisících PPT (standard kupní síly)

země	obyvatel	HDP	součin	podíl obyv.
CZ	10 517,247	19,4	204 034,59	16,33 %
HU	9 976,062	15,8	157 621,78	15,49 %
PL	38 441,588	15,3	588 156,30	59,58 %
SK	5 477,038	18,0	98 586,68	8,50 %
celkem	64 411,935	68,5	1 048 399,35	

- ▶ průměr (nevážený): $68,5/4 = 17,125$
- ▶ vážený průměr (vahami počet obyvatel): $1048399,35/64411,935 \doteq 16,276$
- ▶ vážený průměr (vahami podíl obyvatel): 16,276
- ▶ každý nenulový násobek vah vede ke stejnému váženému průměru
- ▶ který průměr vypovídá správně (rozumně)?


modus

- ▶ **modus** \hat{x} [mode] nejčastější hodnota
- ▶ modus lze počítat také pro nominální či ordinální měřtko, ale jako míru polohy jej lze interpretovat jen do jisté míry u ordinálního měřítka
- ▶ např. příjem v tolarech:

x_j	10	11	12	13	14	15	16	17	18	19	20	21
n_j	7	14	16	10	6	3	9	3	1	5	3	4
- ▶ maximální četnost 16 nastává pro příjem 12 dolarů
- ▶ modus je tedy $\hat{x} = 12$
- ▶ modus nemusí být určen jednoznačně
- ▶ v příkladu nejsou chudí, neboť nikdo nemá příjem pod 60 % z mediánu ($0,6 \cdot \tilde{x} = 0,6 \cdot 14 = 8,4$)

příklad (tolary): porovnání tří měr polohy

zpravidla je $\text{mean} \geq \text{median} \geq \text{modus}$



2. přednáška

- ▶ vlastnosti charakteristik polohy
- ▶ vlastnosti charakteristik variability
- ▶ rozptyl, směrodatná odchylka
- ▶ střední odchylka, střední diference
- ▶ z-skór, standardizace
- ▶ šikmost, špičatost
- ▶ korelační koeficient
- ▶ Giniho koeficient koncentrace
- ▶ geografický střed, geografický medián

vlastnosti charakteristik polohy

- ▶ charakteristiky (míry) polohy mají měřit úroveň kvantitativního (spojitého) znaku (velký – malý, hodně – málo, ...)
- ▶ **posunutí:** změníme-li všechny hodnoty x_i tak, že přidáme ke každé stejnou konstantu a , změní se o tutéž konstantu také charakteristika polohy
- ▶ **změna měřítka:** 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
- ▶ obecně pro míru polohy $\mu(x)$ platí

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

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

charakteristiky variability

- ▶ měří rozptýlení (nestejnost, **variabilitu**) hodnot číselné veličiny
- ▶ obecně pro míru variability $\sigma(x)$ by mělo platit:

$$\begin{aligned}\sigma(a + x) &= \sigma(x), & (\text{srovnej s } \mu(a + x) &= a + \mu(x)) \\ \sigma(b \cdot x) &= b \cdot \sigma(x), \quad b > 0, & (\text{srovnej s } \mu(b \cdot x) &= b \cdot \mu(x))\end{aligned}$$

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

rozptyl (variance)

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

$$\begin{aligned}s_x^2 &= \frac{1}{n-1} ((x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2) \\ &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2 \right) \\ &= \frac{1}{n-1} \sum_{j=1}^k n_j (x_j^* - \bar{x})^2 = \frac{1}{n-1} \left(\sum_{j=1}^k n_j x_j^{*2} - n \cdot \bar{x}^2 \right)\end{aligned}$$

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

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

směrodatná odchylka

- ▶ rozptyl měří průměrný čtverec vzdálenosti od průměru
- ▶ polovina průměrného čtverce vzájemné závislosti:

$$s_x^2 = \frac{1}{2n(n-1)} \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)^2$$

- ▶ **směrodatná odchylka** (standardní odchylka)[std. deviation]: odmocnina z rozptylu **SMODCH.VÝBĚR** **sd(x)**

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

- ▶ zcela vyhovuje požadavkům na míry variability
- ▶ výhoda směrodatné odchylky: stejný fyzikální rozměr jako původní data
- ▶ výběrový rozptyl počítaný z *třídnic* četností (Sheppardova korekce: mají-li intervaly délku h , odečti $h^2/12$)

příklad – tolary

- ▶ rozpětí: $R = 47 - 10 = 37$
- ▶ kvartilové rozpětí: $R_Q = 19,5 - 12 = 7,5$
- ▶ rozptyl

$$\begin{aligned} s^2 &= \frac{1}{98} \left((10^2 + 10^2 + \dots + 45^2 + 47^2) - 99 \cdot \left(\frac{1687}{99} \right)^2 \right) \\ &= \frac{1}{98} \left((7 \cdot 10^2 + 14 \cdot 11^2 + \dots + 45^2 + 47^2) - 99 \cdot \left(\frac{1687}{99} \right)^2 \right) \\ &= 65,080 \doteq 8,067^2 \end{aligned}$$

- ▶ směrodatná odchylka je 8,067

▶ Var. řada tolary

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 difference** [mean difference]: průměr vzájemných vzdáleností všech n^2 dvojic **mean(abs(outer(x,x,"-")))**

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

příklad pro $x < - c(1, 3, 8)$

► **střední odchylka**

$$d = (|1 - 3| + |3 - 3| + |8 - 3|) / 3 = 7/3 \doteq 2,33$$

`mean(abs(x - median(x)))`

► **střední diference** tabulka rozdílů:

0	-2	-7
2	0	-5
7	5	0

$$\Delta = \frac{1}{3 \cdot 3} (0 + 2 + 7 + 2 + 0 + 5 + 7 + 5 + 0) = \frac{28}{9} \doteq 3,11$$

$$\Delta = \frac{2}{3 \cdot 3} ((8 - 1) + (8 - 3) + (3 - 1)) = \frac{2(7 + 5 + 2)}{9} \doteq 3,11$$

`Delta = mean(abs(outer(x, x, "-")))`

normované charakteristiky rozptýlenosti

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

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

- **(Giniho) koeficient koncentrace** `reldist::gini(x)`

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

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

z-skór, standardizace

- variační koeficient v , Giniho koeficient G jsou 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-skór nezávisí na posunutí ani na změně měřítka
- 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 [skewness]

- ▶ invariantní vůči posunutí i změně měřítka:

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

proto použijeme z-skóry

- ▶ **šikmost** $\sqrt{b_1}$ – průměr z 3. mocnin z-skórů
`SKEW()` `mean(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 [kurtosis]

- ▶ **špičatost** b_2 – průměr ze 4. mocnin z-skórů
 (někdy se odečítá 3) `KURT()` `mean(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)

příklad: souvisí emise CO₂ s HDP?

údaje o zemích EU z roku 2010



Lze charakterizovat sílu závislosti číslem?

měření síly závislosti

- ▶ měříme dva znaky v kvantitativním měřítku:
(x_i, y_i), $i = 1, \dots, n$ (např. HDP jako x_i , emise CO₂ jako y_i)
- ▶ závislosti na fyzikálním měřítku se vyhneme použitím z-skórů
- ▶ (výběrový) **korelační koeficient**

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

- ▶ klasicky se definuje $r_{xy} = \frac{s_{xy}}{s_x s_y}$, kde


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

je (výběrová) **kovariance**

- ▶ platí $-1 \leq r \leq 1$

příklad: souvisí emise CO₂ s HDP?

údaje o zemích EU z roku 2010



$r = 0,79$ (bez Lucemburska jen $r = 0,52$)

charakteristiky polohy v geografii/demografii

- ▶ místo x můžeme označovat měřené hodnoty jako y , princip pojmů je stejný, označení je jen konvence
- ▶ často známe jen průměry a četnosti v dílčích souborech:
průměry se označí jako y_j^* , četnosti opět n_j
- ▶ příklad: věk nových profesorů a docentů UK 2002:
41 profesorů, průměrný věk 51,1 ($n_1 = 41$, $y_1^* = 51,1$)
77 docentů, průměrný věk 47,8 ($n_2 = 77$, $y_2^* = 47,8$)
průměr nových habilitovaných akademických pracovníků
(vážený průměr):

$$\text{weighted.mean}(c(51.1,47.8),c(41,77))$$

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

nikoliv

$$\text{mean}(c(51.1,47.8))$$

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

charakteristiky polohy v geografii/demografii (2)

▶ geografický střed


- ▶ bod
- ▶ průsečík průměrné zeměpisné šířky a průměrné zeměpisné délky; průměry vážíme velikostí sledovaného jevu

▶ geografický medián – obdoba mediánu,

- ▶ čára, která rozděluje geografické objekty do dvou disjunktních souvislých skupin stejné velikosti
- ▶ hodnocená vlastnost určí velikost objektů (např. počet obyvatel územní jednotky)
- ▶ uspořádání hodnocení znaků dáno zvolenou geografickou vlastností (např. zeměpisnou délkou)

příklad: geografický střed obyvatel ČR

použijeme jen údaje o krajích, □ – střed obyvatel (△ – velikost kraje)



příklad: geografický střed obyvatel ČR

použijeme jen údaje o krajích ČR v roce 2006

Zkratka	kraj	rozloha	obyvatel	šířka	délka
1	A	Praha	49609	1188126	50,08 14,42
2	S	Středočeský	1101473	1175254	50,08 14,42
3	C	Jihočeský	1005688	630006	48,98 14,47
...
14	T	Moravskoslezský	542698	1249290	49,84 18,32

▶ šířka

$$\frac{1188126 \cdot 50,08 + 1175254 \cdot 50,08 + \dots + 1249290 \cdot 49,84}{1188126 + 1175254 + \dots + 1249290} = 49,84$$

▶ délka

$$\frac{1188126 \cdot 14,42 + 1175254 \cdot 14,42 + \dots + 1249290 \cdot 18,32}{1188126 + 1175254 + \dots + 1249290} = 15,59$$


příklad: geografický medián

sčítáme obyvatele postupně od západu na východ, poslední je v západní polovině Liberecký kraj L, ve východní polovině je první kraj Vysočina označený symbolem J

	délka	obyvatel	součet	podíl
K	12,87504	304602	304602	0,02960984
P	13,36667	554537	859139	0,08351543
U	14,03333	823265	1682404	0,16354361
A	14,41667	1188126	2870530	0,27903930
S	14,41667	1175254	4045784	0,39328372
C	14,46667	630006	4675790	0,45452553
L	15,06528	430774	5106564	0,49640033
J	15,58333	511645	5618209	0,54613646
H	15,66667	549643	6167852	0,59956631
E	15,77583	507751	6675603	0,64892392
B	16,63333	1132563	7808166	0,75901843
M	17,25119	639894	8448060	0,82122142
Z	17,66667	589839	9037899	0,87855866
T	18,31117	1249290	10287189	1,00000000

příklad: geografický střed obyvatel ČR

použijeme jen údaje o krajích, □ – střed obyvatel (△ – velikost kraje)



3. přednáška

- ▶ Giniho koeficient koncentrace
- ▶ Lorenzova křivka
- ▶ Theilův index

Giniho koeficient koncentrace

(místo x nyní píšeme y)

- ▶ **Giniho koeficient koncentrace** charakterizuje jediným číslem nerovnoměrnost rozdělení (bohatství, příjmů, ...)

$$G = \Delta / (2\bar{y})$$

- ▶ průměrný rozdíl v bohatství vztažený k dvojnásobku průměru
- ▶ mají-li všichni stejně ($y_{(1)} = \dots = y_{(n)} > 0$), je nutně $\Delta = 0$ a tedy $G = 0$
- ▶ má-li jeden všechno, ostatní nic ($0 = y_{(1)} = \dots = y_{(n-1)} < y_{(n)} = 100$), pak je

$$\bar{y} = \frac{100}{n} \qquad \Delta = \frac{2(n-1)100}{n^2}$$

$$G = \frac{2(n-1)100}{n^2} \cdot \frac{n}{2 \cdot 100} = \frac{n-1}{n} \xrightarrow{n \rightarrow \infty} 1$$

- ▶ Lorenzova křivka bude jemnějším nástrojem

příklad: rozloha lesů zemí V4 v tisících ha

- ▶ CZ 2657 HU 2039 PL 9319 SK 1938
- ▶ průměrná rozloha je $\bar{y} = 3988,25$ (tisíce ha)

	CZ	HU	PL	SK
CZ	0	618	-6662	719
HU	-618	0	-7280	101
PL	6662	7280	0	7381
SK	-719	-101	-7381	0

- ▶ střední diference (tisíce ha)


$$\Delta = \frac{0 + 618 + 6662 + \dots + 7381 + 0}{4 * 4} = 2845,125$$

- ▶ Giniho koeficient (ten je bezrozměrný!)

$$G = \frac{\Delta}{2\bar{y}} = \frac{2845,125}{2 \cdot 3988,25} = 0,357$$

příklad: podíl z celkové rozlohy lesů zemí V4

- ▶ CZ 16,7 % HU 12,8 % PL 58,4 % SK 12,1 %
- ▶ totéž v pořadí o nejmenšího podílu
SK 12,1 % HU 12,8 % CZ 16,7 % PL 58,4 %
- ▶ postupné součty (kumulativní relativní četnosti)
SK 12,1 % HU 24,9 % CZ 41,6 % PL 100, %
- ▶ polovina na lesy nejchudších (SK, HU) má čtvrtinu lesů



Lorenzova křivka

- ▶ vodorovná osa: postupné načítání jednotek od nejchudších, jako díl celku
- ▶ svislá osa: postupné načítání bohatství (části zdroje) od nejchudších, jako díl celku
- ▶ zajímá nás plocha nad touto lomenou čarou a pod úhlopříčkou jednotkového čtverce
- ▶ plocha měří nerovnoměrnost rozdělení nějakého zdroje
- ▶ kdyby dostala každá jednotka stejně, bude velikost plochy nulová
- ▶ kdyby všechno dostala jediná z n jednotek, lomená čára bude nulová až do $(n-1)/n$; pro $n \rightarrow \infty$ je $(n-1)/n \rightarrow 1$, plocha = dolní trojúhelník
- ▶ **dvojnásobek** této plochy (= Giniho koeficient koncentrace) porovnává tuto plochu s plochou dolního trojúhelníku

Lorenzova křivka, shrnutí konstrukce

(pozor na rozlišování velikosti písmen y a Y !!!!!!!)

- ▶ variační řada: $0 \leq y_{(1)} \leq y_{(2)} \leq \dots \leq y_{(n)}$ `sort(y)`
- ▶ kumulativní součty pro $j = 0, 1, \dots, n$ `cumsum(sort(y))`
(kolik celkem patří j nejchudším)

$$Y_{(0)} = 0 \quad Y_{(j)} = y_{(1)} + y_{(2)} + \dots + y_{(j)} = \sum_{i=1}^j y_{(i)}$$

- ▶ úsečkami spojit body $[j/n; Y_{(j)}/(\sum_{i=1}^n y_i)]$, $0 \leq j \leq n$,
 j/n – díl populace $Y_{(j)}/(\sum_{i=1}^n y_i)$ – díl bohatství
- ▶ `n = length(y)`
- ▶ `Y = c(0, cumsum(sort(y)))`
- ▶ `plot((0:n)/n, Y/sum(y), pch=3, asp=1)`
- ▶ `lines((0:n)/n, Y/sum(y))`
- ▶ `lines(0:1, 0:1); abline(h=0:1, v=0:1, lty=3)`


příklad: plochy lesů V4 s přihlédnutím k rozloze zemí

země	rozloha	lesy	zalesnění	rel. rozloha	rel. lesy
CZ	78 865	26 570	33,7 %	15,1 %	16,7 %
HU	89 608	20 390	22,8 %	17,2 %	12,8 %
PL	304 255	93 190	30,6 %	58,4 %	58,4 %
SK	48 105	19 380	40,3 %	9,2 %	12,1 %
celkem	520 833	159 530	30,6 %	100,0 %	100,0 %

- ▶ Nakolik jsou nerovnoměrně rozmístěny lesy na území V4?
- ▶ každému čtverečnímu km přidělíme příslušný díl, např. v CZ je to 0,337 km², v HU podobně 0,228 km²)
- ▶ v HU tak přibude 89 608krát hodnota 0,228, v PL 304 255krát hodnota 0,306 atd.
- ▶ při pravidelném přidávání splynou jednotlivé body pro danou zemi v úsečku
- ▶ průmět úsečky na osu x = relativní rozloha; průmět na osu y = relativní plocha lesů; pořadí dáno zalesněním

příklad: Lorenzova křivka hustoty zalesnění

body: postupně se načítá rel. velikost zemí (osa X) a rel. plocha lesů (osa Y)
v pořadí HU, PL, CZ, SK (např. PL má 58,4 % celkové rozlohy i 58,4 % plochy lesů)



co jsme zjistili (zobecnění příkladu)

- ▶ neznáme plochu lesa na jednotlivých čtverečních km
- ▶ známe průměrnou plochu lesa na km² v každé zemi ($y_i^{\text{prům}}$)
- ▶ průměrnou plochu opakujeme tolikrát, kolik km² má daná země (četnost), tj. vážíme počtem km² (x_i)
- ▶ známe tedy celkovou plochu lesů v každé zemi ($y_i = x_i y_i^{\text{prům}}$)
- ▶ pořadí zemí dáno průměrnou plochou lesa na km² (hustotou lesa) jednotlivých zemí ($y_1^{\text{prům}} \leq y_2^{\text{prům}} \leq \dots \leq y_k^{\text{prům}}$)
- ▶ přírůstky souřadnic bodů:
 - ▶ vodorovně: relativní rozloha dané země (mezi všemi zeměmi)

$$\frac{x_i}{\sum_{\ell} x_{\ell}}$$

- ▶ svisle: relativní plocha lesů (mezi všemi lesy)

$$\frac{y_i}{\sum_{\ell} y_{\ell}} = \frac{x_i y_i^{\text{prům}}}{\sum_{\ell} x_{\ell} y_{\ell}^{\text{prům}}}$$

orientačně shrnutí výpočtu v případě vah (Lorenz, Gini)

(stále předpokládáme $y_1^{\text{prům}} \leq \dots \leq y_k^{\text{prům}}$)

- ▶ kumulativní součty
 $X_j = \sum_{i=1}^j x_i$, $X_0 = 0$, $Y_j = \sum_{i=1}^j y_i = \sum_{i=1}^j x_i y_i^{\text{prům}}$, $Y_0 = 0$
- ▶ Lorenzova křivka spojuje body $\left[\frac{X_j}{X_k}; \frac{Y_j}{Y_k} \right]$, $j = 0, 1, \dots, k$
- ▶ střední diference průměrných počtů obyvatel na km² (hustot)

$$\begin{aligned} \Delta &= \frac{1}{X_k^2} \sum_{i=1}^k \sum_{j=1}^k x_i x_j \left| y_i^{\text{prům}} - y_j^{\text{prům}} \right| = \frac{2}{X_k^2} \sum_{i=2}^k \sum_{j=1}^{i-1} x_i x_j \left(\frac{y_i}{x_i} - \frac{y_j}{x_j} \right) \\ &= \frac{2}{X_k^2} \sum_{i=2}^k \sum_{j=1}^{i-1} (x_j y_i - x_i y_j) = \dots = \frac{2}{X_k^2} \sum_{i=1}^{k-1} (X_i Y_{i+1} - X_{i+1} Y_i) \end{aligned}$$

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

- ▶ při výpočtu G se použijí relativní kumulativní podíly x i y

poznámky

- ▶ nezáleží na zvolených fyzikálních jednotkách (např. km vers. ha)
- ▶ ve všech případech je **pořadí** sčítanců dáno pořadím „hustot“ $y_i^{\text{prům}} = \frac{y_i}{x_i}$ (např. lesy/rozloha), tj. $y_1^{\text{prům}} \leq \dots \leq y_k^{\text{prům}}$
- ▶ na svislé ose jde o podíl stat. jednotky na bohatství
- ▶ na vodorovné ose jde o podíl velikosti stat. jednotky s daným bohatstvím mezi všemi jednotkami
- ▶ hrubší hodnocení (např. kraje, nikoliv okresy) znamená **menší** hodnotu Giniho koeficientu! (obecně, lze dokázat)
- ▶ velikost poklesu Giniho koeficientu po hrubším hodnocení není snadné vyjádřit (vysvětlit)

příklad: příjmy 14 osob ve 3 skupinách, Giniho koeficient

skupina	příjem y_i	n_i	průměr	Gini
A	200 150	2	175,00	0,07142857
B	80 70 60 60	4	67,50	0,06481481
C	20 20 18 18 15 15 10 10	8	15,75	0,1309524
celk.	746	14	53,29	0,5090004

skupinové průměry: $G = 0,485$, původní data: $G = 0,509$

```
prijem=c(200,150,...)
```

```
Skup = factor(c(rep("A",2),rep("B",4),rep("C",8)))
```

```
ni=table(Skup)
```

```
prumery = tapply(prijem,Skup,mean)
```

```
require(reldist)
```

```
gini(prijem) #0.5090004
```

```
gini(prumery,ni) #0.4848717
```

```
tapply(prijem,Skup,gini)
```

Použití průměrů (včetně jejich četností) snížilo G

Theilův index

- ▶ y_1, \dots, y_n bohatství jednotlivých subjektů (např. jednotky)

$$T = \frac{1}{n} \sum_{i=1}^n \frac{y_i}{\bar{y}} \ln \left(\frac{y_i}{\bar{y}} \right)$$

- ▶ vážený průměr hodnot $\ln(y_i/\bar{y})$, váhy y_i/\bar{y} , součet vah je n
- ▶ měří nerovnoměrnost (variabilitu) rozdělení bohatství
- ▶ souvisí s pojmem Shannonovy entropie (nejistota v teorii informace, diverzita)

$$S = - \sum_{i=1}^n \frac{y_i}{\sum_{\ell} y_{\ell}} \ln \left(\frac{y_i}{\sum_{\ell} y_{\ell}} \right)$$

- ▶ maximální hodnota entropie S_{\max} je pro $y_1 = y_2 = \dots = y_n$
- ▶ lze dokázat, že $T = S_{\max} - S$ a $T \leq \ln(n)$
- ▶ čím větší nerovnoměrnost, tím větší T (stejně jako Giniho koeficient)

příklad: příjmy 14 osob

skupina	příjem y_i	n_i	průměr
A	200 150	2	175,00
B	80 70 60 60	4	67,50
C	20 20 18 18 15 15 10 10	8	15,75
celk.	746	14	53,29

$$T = \frac{1}{18} \left(\frac{200}{53,29} \ln \left(\frac{200}{53,29} \right) + \dots + \frac{10}{53,29} \ln \left(\frac{10}{53,29} \right) \right) = 0,450$$

prijem=c(200,150,80,70,60,60,20,20,18,18,15,15,10,10)

library(ineq)

Theil(prijem)

Co kdybychom znali jen průměry a počty hodnot ve skupinách?

Theilův index po skupinách

- ▶ y_{ij} příjem j -tého v i -té skupině s n_i jedinci, $i = 1, \dots, k$
- ▶ celkem $n = \sum_{i=1}^k n_i$ jedinců
- ▶ $\bar{y}_i = (1/n_i) \sum_{j=1}^{n_i} y_{ij}$ průměr v i -té skupině
- ▶ $\bar{y} = (1/n) \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij} = (1/n) \sum_{i=1}^k n_i \bar{y}_i$ celkový průměr
- ▶ T Theilův index spočítaný ze všech n hodnot
- ▶ T_i Theilův index uvnitř i -té skupiny,
- ▶ T^B Theilův index variability mezi skupinami (jednotlivé hodnoty nahradíme dílčími průměry)

$$T_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \frac{y_{ij}}{\bar{y}_i} \ln \left(\frac{y_{ij}}{\bar{y}_i} \right) \quad T^B = \frac{1}{n} \sum_{i=1}^k n_i \frac{\bar{y}_i}{\bar{y}} \ln \left(\frac{\bar{y}_i}{\bar{y}} \right)$$

- ▶ platí $T = T^B + T^W$, kde T^W je vážený průměr T_i

$$T^W = \sum_{i=1}^k \frac{n_i \bar{y}_i}{n \bar{y}} T_i$$

příklad: příjmy 14 osob ve 3 skupinách

skupina	příjem y_i	n_i	průměr	T_i
A	200 150	2	175,00	0,010239
B	80 70 60 60	4	67,50	0,007421
C	20 20 18 18 15 15 10 10	8	15,75	0,030270
celk.	746	14	53,29	0,450220

$$T^B = \frac{1}{14} \left(2 \cdot \frac{175,00}{53,29} \ln \left(\frac{175,00}{53,29} \right) + 4 \cdot \frac{67,50}{53,29} \ln \left(\frac{67,50}{53,29} \right) + 8 \cdot \frac{15,75}{53,29} \ln \left(\frac{15,75}{53,29} \right) \right) = 0,437618$$

$$T^W = \frac{350}{746} 0,010239 + \frac{270}{746} 0,007421 + \frac{126}{746} 0,030270 = 0,012602$$

$T^B/T = 0,437618/0,450220 = 0,972$, tudíž nerovnoměrnost příjmů je z 97,2 % dána nerovnoměrností mezi skupinami

poznámky

- ▶ Theilův index T lze rozložit na součet dvou složek
 - ▶ index průměrů T^B , který charakterizuje nerovnoměrnost (různost) dílčích (skupinových) průměrů
 - ▶ index T^W , který charakterizuje průměrnou vnitřní nerovnoměrnost uvnitř skupin
- ▶ nutně platí nerovnost $T^B \leq T$, tj. nerovnoměrnost mezi skupinami nemůže být větší, než celková nerovnoměrnost
- ▶ podobně celkový Giniho koeficient nemůže být větší, než Giniho koeficient průměrů, ale jejich rozdíl nelze tak snadno vyjádřit, jako v případě Theilova indexu je T^W (vážený průměr dílčích indexů)

4. přednáška

- ▶ pravděpodobnost
- ▶ podmíněná pravděpodobnost
- ▶ náhodná veličina
- ▶ střední hodnota
- ▶ rozptyl
- ▶ nezávislost
- ▶ korelace

základní pojmy

- ▶ **pokus** – dobře definovaná situace (postup), která končí jedním z řady možných výsledků (vržená kostka spadne na pevnou podložku)
- ▶ **náhodný pokus** – pokus, u něhož předem nevíme, který výsledek nastane (která strana kostky padne příště?); 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
- ▶ **pravděpodobnost** by tedy měla mít **stejně hlavní vlastnosti** jako **relativní četnost**

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)

$$P(A) = \frac{M_A}{M} \quad \left(= \frac{\text{počet příznivých}}{\text{počet možných}} \right)$$

- ▶ **klasickou pst lze použít jen někdy!** (Sportka, Sazka)
- ▶ nelze použít např.:
 - ▶ dostuduje resp. nedostuduje
 - ▶ dostuduje s vyznamenáním, dostuduje bez vyznamenání, nedostuduje

příklad: hrací kostka

- ▶ idealizovaná symetrická hrací kostka
 - ▶ homogenní materiál
 - ▶ 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 $P(B) = 3/6 = 1/2$
- ▶ **POZOR NA NESPRÁVNOU INTERPRETACI:**
 - ▶ celkem stokrát hodíme kostkou ($n = 100$)
 - ▶ dvacetkrát padne šestka ($n_A = 20$)
 - ▶ poměr $\frac{n_A}{n} = \frac{20}{100} = 0,2$ je jen **odhad** pravděpodobnosti jevu A , že padne šestka, nikoliv pravděpodobnost sama

pomůcky k výpočtu pravděpodobnosti: 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:

$$14! = 14 \cdot 13 \cdot 12 \cdots 2 \cdot 1 = 87\,178\,291\,200 = 8,7 \cdot 10^{10}$$
- ▶ $8.71782912e+10$

pomůcky k výpočtu pravděpodobnosti: 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 (tj. nezávisle na pořadí vybraných prvků)

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

- ▶ 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)
- ▶ kolika způsoby mohu uložit pět knížek do knihovny? (120, záleží na pořadí!)

příklad: losování otázek (1)

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

$$M_A = \binom{5}{0} \binom{10}{2} = 1 \cdot \frac{10 \cdot 9}{2 \cdot 1} = 45 \Rightarrow P(A) = \frac{45}{105} = 42,9 \%$$

příklad: losování otázek (2)

- ▶ pravděpodobnost $P(B)$, že zná *právě* jednu otázku

$$M_B = \binom{5}{1} \binom{10}{1} = 5 \cdot 10 = 50 \Rightarrow P(B) = \frac{50}{105} = 47,6 \%$$

- ▶ pravděpodobnost $P(C)$, že zná *obě* otázky (*právě dvě*)

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

- ▶ pravděpodobnost $P(D)$, že zná *aspoň jednu* otázku

$$M_D = M_B + M_C = 50 + 10 = 60 \Rightarrow P(D) = \frac{60}{105} = 57,1 \%$$


- ▶ kontrola: $M_D + M_A = M$

pravidla pro pravděpodobnost (1)

- ▶ **sjednocení** jevů $A \cup B$: platí **A nebo B**
(alespoň jeden z jevů A, B , mohou být pravdivá obě tvrzení)
- ▶ **průnik** $A \cap B$: platí **A a současně B** (oba jevy A, B současně)

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

- ▶ Vennův diagram (plocha odpovídá pravděpodobnosti)



$A \cup B$ = celá vybarvená plocha

$P(A) = 0,42$ = zelená + šedivá plocha

$P(B) = 0,24$ = žlutá + šedivá plocha

$P(A \cap B) = 0,16$ = šedivá plocha

$P(A) + P(B) =$ (zelená + šedivá)

+ (žlutá + šedivá)

$P(A \cup B) = 0,42 + 0,24 - 0,16 = 0,50$

pravidla pro pravděpodobnost (2)

- ▶ \bar{A} **jev opačný** k jevu A nastává právě tehdy, když nenastává jev A

$$P(A) + P(\bar{A}) = 1$$

- ▶ Ω – **jev jistý** nastává vždy, $P(\Omega) = 1$
- ▶ \emptyset – **jev nemožný** nenastává nikdy, je jevem opačným k jevu jistému, $P(\emptyset) = 0$
- ▶ **neslučitelné jevy**: nemohou nastat nikdy současně, navzájem se vylučují; jejich průnikem je jev nemožný; pro neslučitelné jevy platí


$$P(A \cup B) = P(A) + P(B)$$

podmíněná pravděpodobnost

- ▶ **podmíněná pravděpodobnost** pravděpodobnost jevu A , když už jev B nastal:

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

- ▶ Vennův diagram



$P(B) = 0,24$ = žlutá + šedivá plocha

$P(A \cap B) = 0,16$ = šedivá plocha

$P(A|B)$ = šedivá vzhledem k (žlutá + šedivá)

$P(A|B) = 0,16/0,24 = 0,67$, ale

$P(A) = 0,42$

vyšlo $P(A|B) > P(A)$


jiný může vyjít také $P(A|B) < P(A)$

nezávislost náhodných jevů

- ▶ **nezávislé jevy**: výskyt jednoho jevu **neovlivní pravděpodobnost** výskytu druhého
- ▶ (definice **nezávislosti** náhodných jevů $A, B, P(B) > 0$):

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

- ▶ Vennův diagram



$P(A) = 0,60 = \text{zelená} + \text{šedivá}$
 $P(B) = 0,40 = \text{žlutá} + \text{šedivá plocha}$
 $P(A \cap B) = 0,24 = \text{šedivá plocha}$
 $P(A|B) = \text{šedivá vzhledem k (žlutá + šedivá)}$
 $P(A|B) = 0,24/0,40 = 0,60$
 $P(A) \cdot P(B) = P(A \cap B)$
 $\Rightarrow A \text{ a } B \text{ jsou nezávislé}$

idealizovaný příklad

náhodně vybraný student ...

- ▶ A – jednička ze statistiky, $P(A) = 0,3$
- ▶ B – jednička z matematiky, $P(B) = 0,2$
- ▶ $A \cap B$ – jednička z obou předmětů, $P(A \cap B) = 0,1$
- ▶ pravděpodobnost, že je aspoň jedna jednička:

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

- ▶ 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:
 $P(B|A) = 0,1/0,3 = 1/3$

rozdělení náhodné veličiny

- ▶ **náhodná veličina** – číselně vyjádřený výsledek náhodného pokusu
- ▶ **distribuční funkce** $F_X(x)$ náhodné veličiny X určuje pro každé x pravděpodobnost, že náhodná veličina **nepřekročí** číslo x :

$$\boxed{F_X(x) = P(X \leq x)}$$

($F_X(x)$ je neklesající, zprava spojitá)

- ▶ **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 měřítka) určeno **hustotou**

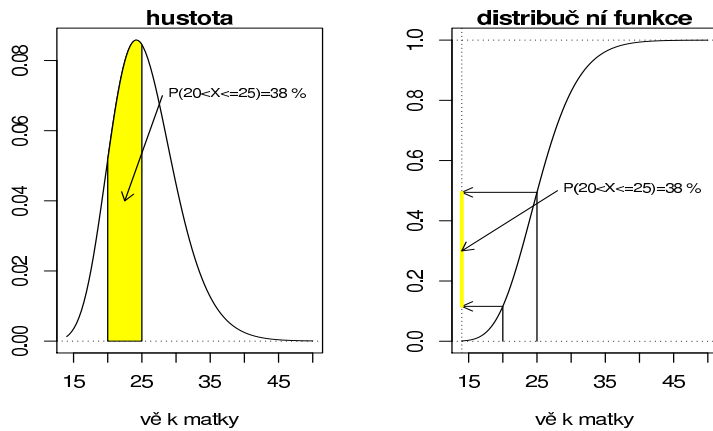
$$f_X(x) = \frac{d}{dx} F_X(x), \quad F_X(x) = \int_{-\infty}^x f_X(t) dt$$

věk matek (n=4838)



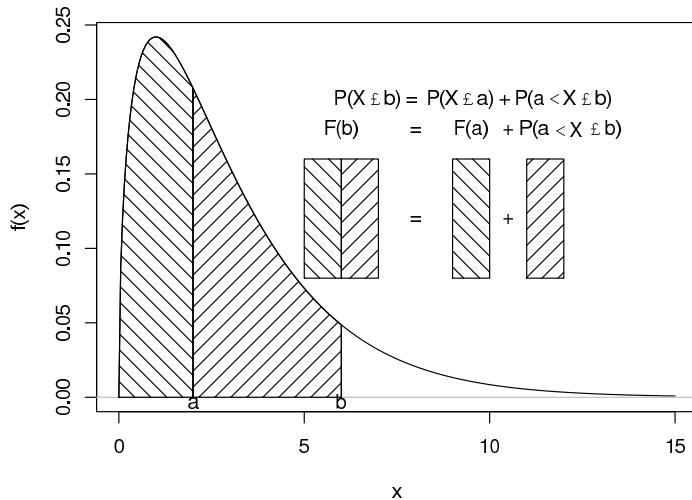
představme si histogram založený na věku v hodinách a na rostoucím počtu matek, obálka bude docela hladká

- ▶ velká populace, spojitá veličina – intervaly pro třídění mohou být krátké, obálka histogramu **relativních četností** odpovídá v idealizované představě **hustota** $f_X(x)$ [density]
- ▶ podobně **kumulativním relativním četnostem** odpovídá **distribuční funkce** [distribution function]



distribuční funkce v bodech $a < b$

jevy $X \leq a$ a $a < X \leq b$ jsou neslučitelné, jejich sjednocení dá jev $X \leq b$



použití distribuční fce (obecně)

- ▶ $F(x)$ je pravděpodobnost, že náhodná veličina X je menší než x (nebo stejná): $F(x) = P(X \leq x)$
- ▶ je-li $a < b$, pak náhodný jev ($X \leq a$) je **podjev** náhodného jevu ($X \leq b$), proto je pak

$$F(a) = P(X \leq a) \leq P(X \leq b) = F(b)$$

(distribuční funkce je **neklesající**)

- ▶ náhodný jev ($X \leq b$) je sjednocení disjunktních jevů ($X \leq a$) a ($a < X \leq b$), proto platí

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

což je totéž, jako


$$F(b) = F(a) + P(a < X \leq b)$$

$$P(a < X \leq b) = F(b) - F(a)$$

- ▶ bezprostředním **výběrovým protějškem** distribuční funkce (jejím odhadem) 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



empirická distribuční funkce (tolary)

skoky odpovídají četnostem, např. ve 12 je skok z 0,212 na 0,374 o $16/99=0,162$



	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

příklad: počty bodů na hrací kostce

- ▶ n -krát hodíme symetrickou kostkou
- ▶ počet bodů na symetrické kostce Y je náhodná veličina
- ▶ 1, 2, ..., 6 jsou možné hodnoty
- ▶ každá hodnota má pravděpodobnost $1/6$
- ▶ $n = 100$, četnosti např. 13, 14, 15, 21, 14, 23
- ▶ $\bar{y} = (13 \cdot 1 + 14 \cdot 2 + 15 \cdot 3 + 21 \cdot 4 + 14 \cdot 5 + 23 \cdot 6) / 100 \doteq 3,78$
- ▶ vážený průměr hodnot 1, 2, ..., 6, vahami jsou relativní četnosti 0,13, 0,14, 0,15, 0,21, 0,14, 0,23
- ▶ každá relativní četnost odhaduje pravděpodobnost $1/6$
- ▶ nahraďme náhodné relativní četnosti odpovídajícími nenáhodnými pravděpodobnostmi
- ▶ dostaneme nenáhodnou **střední hodnotu** náh. veličiny Y

$$\mu_Y = E Y = \frac{1}{6} \cdot 1 + \frac{1}{6} \cdot 2 + \frac{1}{6} \cdot 3 + \frac{1}{6} \cdot 4 + \frac{1}{6} \cdot 5 + \frac{1}{6} \cdot 6 = \frac{21}{6} = 3,5$$

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
$P(Y = k)$	0,2	0,3	0,3	0,2

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

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

$$\mu_Y = 1 \cdot 0,2 + 2 \cdot 0,3 + 3 \cdot 0,3 + 4 \cdot 0,2 = 2,5$$

charakteristiky rozdělení náhodné veličiny (1)

- ▶ **střední hodnota** μ_X 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
- ▶ u diskrétního rozdělení jsou vahami pravděpodobnosti těchto hodnot
- ▶ pro spojité rozdělení

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

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

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

resp. pro spojité rozdělení

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

- ▶ **populační medián** $\tilde{\mu}$ spojitého 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

(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

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

příklad diskrétního rozdělení: známka u zkoušky

známka k	1	2	3	4	μ	σ^2	σ
$P(X = k)$	0,3	0,4	0,2	0,1	2,1	0,89	0,943
$P(Y = k)$	0,2	0,3	0,3	0,2	2,5	1,05	1,025

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

$$\begin{aligned} \sigma_X^2 &= (1 - 2,1)^2 \cdot 0,3 + (2 - 2,1)^2 \cdot 0,4 \\ &\quad + (3 - 2,1)^2 \cdot 0,2 + (4 - 2,1)^2 \cdot 0,1 = 0,89 \doteq 0,943^2 \\ \sigma_Y^2 &= (1 - 2,5)^2 \cdot 0,2 + (2 - 2,5)^2 \cdot 0,3 \\ &\quad + (3 - 2,5)^2 \cdot 0,3 + (4 - 2,5)^2 \cdot 0,2 = 1,05 \doteq 1,025^2 \end{aligned}$$

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

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

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

(vzpomeň si: $(a + b)^2 = a^2 + 2ab + b^2$)

• Návrat k rozptylu $\sigma_{XY} = E(X - \mu_X)(Y - \mu_Y)$ **kovariance** X, Y
 $= (x_1 - \mu_X)(y_1 - \mu_Y)P(X = x_1, Y = y_1)$
 $+ (x_1 - \mu_X)(y_2 - \mu_Y)P(X = x_1, Y = y_2) + \dots$
 (sčítá se přes všechny možné dvojice)

5. přednáška

- ▶ (populační) kovariance a korelace
- ▶ binomické rozdělení
- ▶ normální rozdělení
- ▶ populace a výběr
- ▶ CLV (centrální limitní věta)
- ▶ výběrový průměr
- ▶ interval spolehlivosti pro stř. hodnotu
- ▶ CLV pro četnosti
- ▶ interval spolehlivosti pro pravděpodobnost

příklad: známky ($V = X + Y, \sigma_V^2 \neq \sigma_X^2 + \sigma_Y^2$)

X	Y				celkem	sružené rozdělení X, Y
	1	2	3	4		
1	0,10	0,10	0,10	0,00	0,30	marginální rozdělení X
2	0,10	0,15	0,10	0,05	0,40	
3	0,00	0,05	0,10	0,05	0,20	
4	0,00	0,00	0,00	0,10	0,10	
celkem	0,20	0,30	0,30	0,20	1,00	marginální rozdělení Y

vlastnosti náhodné veličiny V :

$$\begin{aligned} \mu_V &= 2 \cdot 0,10 + 3 \cdot (0,10 + 0,10) + 4 \cdot (0,10 + 0,15 + 0,00) \\ &\quad + 5 \cdot (0,10 + 0,05) + 6 \cdot (0,05 + 0,10) + 7 \cdot (0,05) + 8 \cdot 0,10 \\ &= 4,6 = \mu_X + \mu_Y = 2,1 + 2,5 \end{aligned}$$

$$\begin{aligned} \sigma_V^2 &= (2 - 4,6)^2 \cdot 0,10 + (3 - 4,6)^2 \cdot 0,20 + (4 - 4,6)^2 \cdot 0,25 \\ &\quad + (5 - 4,6)^2 \cdot 0,15 + (6 - 4,6)^2 \cdot 0,15 + (7 - 4,6)^2 \cdot 0,05 \\ &\quad + (8 - 4,6)^2 \cdot 0,10 = 3,04 \neq \sigma_X^2 + \sigma_Y^2 = 0,89 + 1,05 = 1,94 \end{aligned}$$

příklad: známky, výpočet kovariance

X	Y			
	1	2	3	4
1	0,10	0,10	0,10	0,00
2	0,10	0,15	0,10	0,05
3	0,00	0,05	0,10	0,05
4	0,00	0,00	0,00	0,10

sdružené pravděpodobnosti

$$\begin{aligned}\sigma_{XY} &= (1 - 2,1) \cdot (1 - 2,5) \cdot 0,10 + (1 - 2,1) \cdot (2 - 2,5) \cdot 0,10 \\ &\quad + (1 - 2,1) \cdot (3 - 2,5) \cdot 0,10 + (1 - 2,1) \cdot (4 - 2,5) \cdot 0,00 \\ &\quad + \dots \\ &\quad + (4 - 2,1) \cdot (3 - 2,5) \cdot 0,00 + (4 - 2,1) \cdot (4 - 2,5) \cdot 0,10 \\ &= 0,55 \\ \sigma_V^2 &= 3,04 = 0,89 + 1,05 + 2 \cdot 0,55 = \sigma_X^2 + \sigma_Y^2 + 2 \cdot \sigma_{X,Y}\end{aligned}$$

modelové pojmy a jejich empirické protějšky

- ▶ pravděpodobnost $P(A)$ vers. relativní četnost n_A/n
- ▶ střední hodnota μ_X vers. (výběrový) průměr \bar{x}
- ▶ (populační) rozptyl σ_X^2 vers. (výběrový) rozptyl s_X^2
- ▶ (populační) směrodatná odchylka σ_X vers. (výběrová) směrodatná odchylka
- ▶ (populační) kovariance σ_{XY} vers. (výběrová) kovariance s_{xy} (viz slajd 49)

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

- ▶ (populační) korelační koeficient $\rho_{X,Y}$ (teprve bude) vers. (výběrový) korelační koeficient r_{xy} (viz slajd 49)

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

nezavislost náhodných veličin

- ▶ ze **sdruženého** rozdělení $P(X = x_i, Y = y_j)$ vždy můžeme spočítat **marginální** rozdělení (viz např. slajd 101)

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

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

- ▶ náhodné veličiny X, Y jsou **nezávislé**, jsou-li nezávislé všechny náhodné jevy A, B , kde A je tvrzení o X a B je tvrzení o Y
- ▶ k nezávislosti X, Y stačí, když je

$$P(X = x_i, Y = y_j) = P(X = x_i) \cdot P(Y = y_j) \quad \text{všechna } x_i, y_j$$

tj. z marginálních rozdělení lze obnovit sdružené rozdělení

- ▶ platí tvrzení: jsou-li X, Y nezávislé, **potom** je nutně $\sigma_{XY} = 0$

příklad: známky jsou známky X a Y nezávislé?

X	Y				celkem
	1	2	3	4	
1	0,10	0,10	0,10	0,00	0,30
2	0,10	0,15	0,10	0,05	0,40
3	0,00	0,05	0,10	0,05	0,20
4	0,00	0,00	0,00	0,10	0,10
celkem	0,20	0,30	0,30	0,20	1,00

zřejmě je například

$$P(X = 1, Y = 1) = 0,10 \neq P(X = 1) \cdot P(Y = 1) = 0,3 \cdot 0,2 = 0,06$$

nebo

$$P(X = 3, Y = 1) = 0,00 \neq P(X = 3) \cdot P(Y = 1) = 0,2 \cdot 0,2 = 0,04$$

náhodné veličiny X, Y **nemohou být nezávislé**, proto jsou **závislé**

populační korelační koeficient

- ▶ kovariance σ_{XY} je modelovým protějškem výb. kovariance s_{xy}
- ▶ podobně jako výběrový korelační koeficient r_{xy} je **populační korelační koeficient** ρ_{XY} definován pomocí kovariance σ_{XY} a směrodatných odchylek σ_X, σ_Y

$$r_{xy} = \frac{s_{xy}}{s_x s_y}, \quad \rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

- ▶ jsou-li X, Y nezávislé, **pak** je nutně $\rho_{XY} = 0$
- ▶ vždy platí $-1 \leq \rho_{XY} \leq 1$
- ▶ příklad se známkami:

$$\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} = \frac{0,55}{0,943 \cdot 1,025} \doteq 0,569$$

známky jsou nutně závislé, neboť $\rho_{XY} \neq 0$

alternativní rozdělení (Bernoulliovo, nula-jedničkové)

nabývá dvou **číselných** hodnot

- ▶ diskrétní, s jediným parametrem π (nikoliv Ludolfovo číslo)
- ▶ $P(X = 1) = \pi, \quad P(X = 0) = 1 - \pi \quad (0 < \pi < 1)$
- ▶ X – kolikrát v jednom pokusu došlo k události, která má pravděpodobnost π (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**

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

binomické rozdění $bi(n, \pi)$

- ▶ zapisujeme $Y \sim bi(n, \pi)$
- ▶ diskrétní rozdění s parametry n, π ($0 < \pi < 1$)
- ▶ model binomického rozdění (**důležité**)
 - ▶ n **nezávislých** pokusů
 - ▶ v každém zdar s pravděpodobností π , nezdar s $1 - \pi$
 - ▶ **celk. počet zdarů** Y má binomické rozdění s parametry n, π
- ▶ Y je součet n **nezávislých** náhodných veličin X_1, X_2, \dots, X_n ($X_i =$ počet zdarů v i -tém pokusu) každé X_i má alternativní rozdění s parametrem π
- ▶ z vlastnosti střední hodnoty součtu náh. veličin: $\mu_Y = n\pi$
- ▶ z vlastnosti rozptylu součtu **nezávislých** náhodných veličin

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

binomické rozdění

 $bi(n, \pi)$

- ▶ pravděpodobnosti možných hodnot $dbinom(k, n, p)$

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

- ▶ 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, Y – počet kuřáků mezi nimi, tedy $Y \sim bi(60, 0,35)$
- ▶ populační průměr, rozptyl (směrodatná odchylka):

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

- ▶ ukázky pravděpodobností možných hodnot

$BINOMDIST(15; 60; 0,35; 0)$ $dbinom(15, 60, 0,35)$

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

normální (Gaussovo) rozdělení $N(\mu, \sigma^2)$ graf hustoty $N(\mu, \sigma^2)$ pro $\sigma = 2$ 

- ▶ spojité rozdělení, symetrické okolo střední hodnoty μ
- ▶ 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

příklady pravděpodobností o normálním rozdělení

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

$$\mu_X = E X = \mu$$

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

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

$\Phi(z) = P(Z \leq y)$ je distribuční funkce $N(0, 1)$

- ▶

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

- ▶ tedy

$$P(|X - \mu| < 1,00 \sigma) = 0,683, \text{ tj. } 68,3 \%$$

$$P(|X - \mu| < 2,00 \sigma) = 0,954, \text{ tj. } 95,4 \%$$

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

$$P(|X - \mu| < 3,00 \sigma) = 0,997, \text{ tj. } 99,7 \%$$

poznámky

- ▶ Y má **logaritmicko normální rozdělení**, když $\log(Y)$ má normální rozdělení (koncentrace, hustoty ...)
- ▶ zajímavé kvantily: $q_{\text{norm}}(0.975)$

$$z(0,975) = 1,96 \text{ tj. } P(Z > 1,96) = 2,5 \%$$

$$z(0,975) = 1,96 \text{ tj. } P(Z < -1,96) = 2,5 \%$$

$$z(0,975) = 1,96 \text{ tj. } P(|Z| > 1,96) = 5 \%$$

$$z(0,995) = 2,58 \text{ tj. } P(Z > 2,58) = 0,5 \%$$

$$z(0,995) = 2,58 \text{ tj. } P(Z < -2,58) = 0,5 \%$$

$$z(0,995) = 2,58 \text{ tj. } P(|Z| > 2,58) = 1 \%$$

$$z(0,950) = 1,64 \text{ tj. } P(Z > 1,64) = 5 \%$$

$$z(0,950) = 1,64 \text{ tj. } P(Z < -1,64) = 5 \%$$

$$z(0,950) = 1,64 \text{ tj. } P(|Z| > 1,64) = 10 \%$$

příklad: mladí volejbalisti

- ▶ předpoklad: výška desetiletých chlapců: $N(141,5, 7^2)$
- ▶ Jaký díl populace desetiletých chlapců má výšku aspoň 149 cm, aby o ně měl zájem trenér volejbalu? (předpokládáme, že výšku určujeme s přesností na centimetr)

$$\begin{aligned} P(X > 148,5) &= 1 - P(X \leq 148,5) \\ &= 1 - P\left(\frac{X - 141,5}{7} \leq \frac{148,5 - 141,5}{7}\right) = 1 - P\left(\frac{X - 141,5}{7} \leq 1\right) \\ &= 1 - \Phi(1) = 1 - 0,841 = 0,159 \end{aligned}$$

- ▶ Jaký díl této populace má výšku v rozmezí od 142 do 148 cm?

$$\begin{aligned} P(141,5 < X < 148,5) &= P(X < 148,5) - P(X < 141,5) \\ &= 0,841 - 0,5 = 0,341 \end{aligned}$$

(Proč je $P(X < 141,5) = 0,5$?)

6. přednáška

- ▶ populace a výběr
- ▶ reprezentativnost a rozsah výběru
- ▶ chování výběrového průměru
- ▶ centrální limitní věta
- ▶ interval spolehlivosti

populace a výběr

- ▶ populaci (základní soubor) charakterizujeme pomocí parametrů rozdělení, případně typu rozdělení
- ▶ výsledkem měření na **náhodně vybraném** prvku populace (základního souboru) je **náhodná veličina**
- ▶ skutečné hodnoty parametrů neznáme
 - ▶ chceme parametry odhadnout
 - ▶ chceme rozhodnout o platnosti tvrzení (hypotézy) o parametrech nebo o typu rozdělení
- ▶ jako výběr si představujeme několik **nezávislých** náhodných veličin se stejným rozdělením (možná s neznámými parametry), tj. měření téže vlastnosti na různých objektech
 - ▶ 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



příklady

- ▶ volební preference
 - ▶ populace: všichni oprávnění voliči (jejich preferovaná strana)
 - ▶ výběr: respondenti, kteří odpověděli (odpovědi respondentů)
 - ▶ hodnocená vlastnost: podíly voličů jednotlivých stran
 - ▶ hodnocený parametr: π_1, \dots, π_k psti jednotlivých stran
 - ▶ odhad parametru: relativní četnosti voličů jednotlivých stran ve výběru
- ▶ výšky desetiletých hochů
 - ▶ populace: všichni desetiletí hoši (jejich výšky)
 - ▶ výběr: změřených desetiletých hoši (jejich výšky)
 - ▶ hodnocený znak: výška postavy náhodně vybraného chlapce
 - ▶ hodnocený parametr: **populační průměr** μ
 - ▶ odhad parametru: výběrový průměr, interval spolehlivosti pro μ
- ▶ **závěr:** při opakovaném pořizení výběru dostaneme po každé jiný odhad, odhad je tedy **náhodný**

vlastnosti výběru

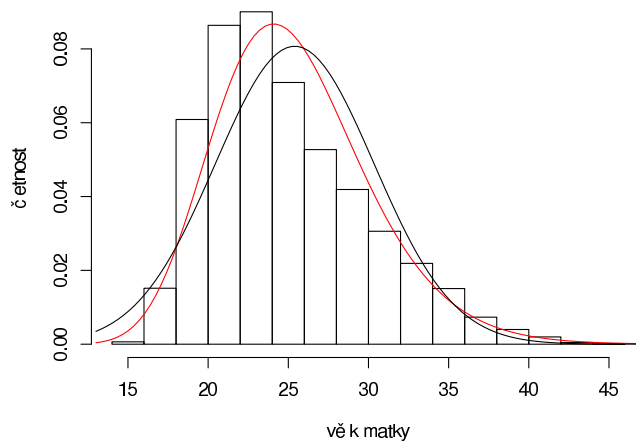
- ▶ **reprezentativnost výběru**
 - ▶ schopnost reprezentovat celou populaci
 - ▶ ve vlastnostech, které mohou souviset s daným šetřením, má složení výběru zhruba odpovídat složení populace
 - ▶ např. podíl žen, podíl vysokoškoláků, podíl důchodců ...
 - ▶ není-li výběr reprezentativní, jsou odhady vychýlené, nejsou nestranné, odhadují něco jiného, než chceme
 - ▶ např. reprezentační mužstvo jistě není reprezentativním výběrem organizovaných fotbalistů
- ▶ **rozsah výběru**
 - ▶ počet vyšetřovaných (např. dotazovaných) jednotek
 - ▶ ovlivní variabilitu odhadů, jejich kolísání
 - ▶ neovlivní reprezentativnost výběru či nestrannost odhadů
- ▶ reprezentativnost a rozsah výběru jsou různé vlastnosti
- ▶ dobrý střelec má všechny zásahy v terči blízko sebe (malá variabilita odhadu)
- ▶ pokud vzduchovka zanáší, i dobrý střelec střílí mimo střed terče (vychýlení)

vlastnosti výběru jako střelba do terče

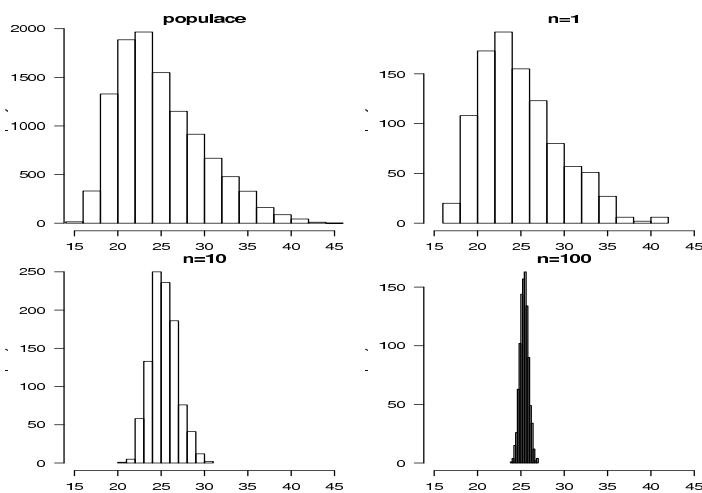


příklad: věk matek

černě hustota normálního rozdělení, červeně hustota logaritmicke-normalního rozdělení



příklad: histogram populace a histogramy průměrů

šířky intervalů stejné, variabilita průměrů s rostoucím n klesá

chování výběrového průměru z náhodného výběru

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

- ▶ **průměr** X_1, X_2, \dots, X_n :

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

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

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

- ▶ proto pro střední hodnotu výběrového průměru platí

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

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

variabilita výběrového průměru

- ▶ pro rozptyl **nezávislých** náhodných veličin platí ▶ Vlastnosti

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

- ▶ proto je

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

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

$$\boxed{\text{S.E.}(\bar{X}) = \frac{\sigma}{\sqrt{n}}} \quad \text{Standard Error (of Mean, S.E.M.)}$$

- ▶ **střední chyba odhadu** nějakého parametru = směrodatná odchylka tohoto odhadu

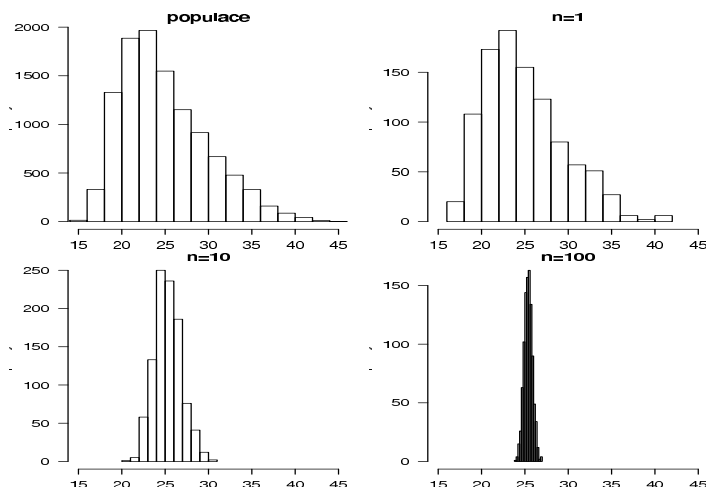
příklad: věk matek

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

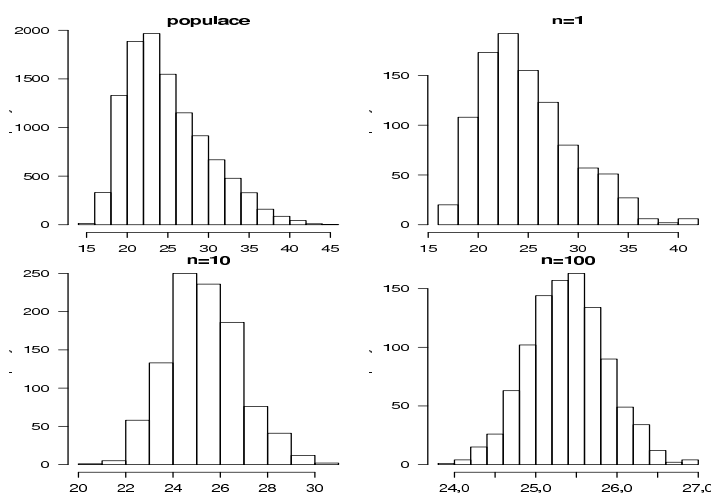
n	průměr	sm. odch.	σ/\sqrt{n}
1	25,43	4,62	4,94
10	25,35	1,54	1,56
100	25,39	0,48	0,49
populace	$\mu = 25,40$	$\sigma = 4,94$	4,94

příklad: histogram populace a histogramy průměrů

šířky intervalů stejné, variabilita průměrů s rostoucím n klesá



příklad: histogram populace a histogramy výběrů

šířky intervalů přizpůsobené variabilitě, s rostoucím n se zlepšuje normalita

příklad: shrnutí

- ▶ spočítány charakteristiky z $B = 1000$ průměrů jako výchozích hodnot, (modře charakteristiky celé populace nebo hodnoty z nich odvozené)

n	průměr	sm. odch.	σ/\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

- ▶ průměry kolísají kolem populačního průměru μ
- ▶ směrodatné odchylky s rostoucí hodnotou \sqrt{n} klesají
- ▶ 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 (CLV)

- ▶ vlastnost součtu nezávislých náhodných veličin se stejným rozdělením (s populačním průměrem μ , popul. rozptylem σ^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 $N(0, 1)$

▶ CLV pro četnosti

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

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

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

interval spolehlivosti pro populační průměr μ

- ▶ 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 $Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$
- ▶ použijeme kvantil rozdělení $N(0, 1)$ (neboť $Z \sim N(0, 1)$)

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

- ▶ hodnota neznámého parametru μ je s pravděpodobností $1 - \alpha$ pokryta intervalem

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

- ▶ vzhledem k centrální limitní větě lze použít pro velká n i bez požadavku na normální rozdělení X_i

100 intervalů spolehlivosti ($n = 100$, $1 - \alpha = 95\%$)

$\mu = 25,398$ je populační průměr věku 10 916 matek
v 7 případech interval **nepřekrývá** μ
(realizace náhodné veličiny s rozdělením $bi(100, 0,05)$)

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 ($z(0,975) = 1,96$):

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

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

vlastnosti intervalu spolehlivosti pro μ

- ▶ 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 $n = 4 \cdot 16 = 64$ má 95% interval (106,325; 113,675) délku 7,35, tedy poloviční ($1/\sqrt{4} = 1/2$)
- ▶ kolik potřebujeme pozorování, aby měl 95% interval délku 2δ ?

$$\frac{\sigma}{\sqrt{n}} z(1 - \alpha/2) = \delta \quad \Rightarrow \quad n = \left(\frac{\sigma}{\delta} z(1 - \alpha/2) \right)^2$$

- ▶ v příkladu s IQ požadujeme $\delta = 5$:

$$n = \left(\frac{15}{5} 1,96 \right)^2 \doteq 35$$

interval spolehlivosti pro μ (neznámé σ)

- ▶ neznáme-li σ , nahradíme je pomocí výběrové směr. odchylky

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

- ▶ interval spolehlivosti pro μ :

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

- ▶ použití kritické hodnoty $t_{n-1}(1 - \alpha/2)$ Studentova t -rozdělení místo kritické hodnoty $z(1 - \alpha/2)$ je penalizací za to, že neznámou směrodatnou odchylku σ jsme nahradili jejím odhadem S
- ▶ platí totiž $t_{n-1}(1 - \alpha/2) > z(1 - \alpha/2)$, s rostoucím n se rozdíl zmenšuje
- ▶ délku intervalu spolehlivosti určuje zejména střední chyba průměru, tedy S/\sqrt{n}

příklad: výška postavy

- ▶ studenti odhadovali výšku přednášejícího; předpokládáme, že nestranně a nezávisle na sobě
- ▶ $n = 22$, $\bar{x} = 172,4$, $s_x = 4,032$
- ▶ z tabulek: $t_{21}(0,975) = 2,080$

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

- ▶ \Rightarrow skutečná výška je s pravděpodobností 95 % někde mezi 170,6 cm a 174,2 cm
- ▶ podobně (170,9; 173,9) je 90% interval spolehlivosti resp. (170,0; 174,8) je 99% interval spolehlivosti
- ▶ Jak byste reagovali na tvrzení přednášejícího, že měří 174 cm?

centrální limitní věta pro četnosti

- ▶ co říká CLV? CLV
- ▶ mějme n nezávislých opakování pokusu, kde sledovaný jev (zdar) nastane s pravděpodobností π
- ▶ absolutní četnost Y
 - ▶ Y – součet nezávislých veličin X_i s alternativním rozdělením
 - ▶ $Y = \sum_{i=1}^n X_i$
 - ▶ populační průměr X_i je π
 - ▶ populační rozptyl X_i je $\pi(1 - \pi)$
 - ▶ $Y \sim \text{bi}(n, \pi)$, proto podle CLV pro velká n platí přibližně

$$Y \sim N(n\pi, n\pi(1 - \pi))$$

- ▶ relativní četnost $f = \frac{Y}{n} = \frac{1}{n} \sum_{i=1}^n X_i$
 - ▶ f – průměr nezávislých veličin s alternativním rozdělením
 - ▶ $f \sim N(\pi, \pi(1 - \pi)/n)$

příklad: počet studentek

- ▶ zkušenost: 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)
```

interval spolehlivosti pro podíl (pravděpodobnost) π

- ▶ π – podíl prvků populace s danou vlastností
- ▶ π – 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 , tedy $\sqrt{\frac{\pi(1-\pi)}{n}}$
- ▶ pravděpodobnost π neznáme, odhadneme ji pomocí f
- ▶ odtud je přibližný 95% interval spolehlivosti pro π

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

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

příklad: hody s hrací kostkou

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

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

(0,10; 0,24)

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

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

(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?

Statistika (MD360P03Z, MD360P03U) ak. rok 2013/2014 6. přednáška 18. listopadu 2013 139(226)

statistická indukce testování hypotéz p -hodnota test o podílu (o psti) π jednovýběrový test

7. přednáška

- ▶ statistická indukce
- ▶ testování hypotéz
- ▶ p -hodnota
- ▶ test o podílu (o psti) π

Statistika (MD360P03Z, MD360P03U) ak. rok 2013/2014 7. přednáška 25. listopadu 2013 140(226)

statistická indukce testování hypotéz p -hodnota test o podílu (o psti) π jednovýběrový test

populace a výběr

- ▶ populaci (základní soubor) charakterizujeme pomocí parametrů rozdělení, případně typu rozdělení
- ▶ výsledkem měření na **náhodně vybraném** prvku populace (základního souboru) je **náhodná veličina**
- ▶ skutečné hodnoty parametrů neznáme
 - ▶ chceme parametry odhadnout
 - ▶ chceme rozhodnout o platnosti tvrzení (hypotézy) o parametrech nebo o typu rozdělení
- ▶ jako výběr si představujeme několik **nezávislých** náhodných veličin se stejným rozdělením (možná s neznámými parametry), tj. měření téže vlastnosti na různých objektech
 - ▶ 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

Statistika (MD360P03Z, MD360P03U) ak. rok 2013/2014 7. přednáška 25. listopadu 2013 141(226)

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 $1/6 \doteq 0,167$ 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, spolehlivost intervalů 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

proč testování hypotéz

- ▶ V příkladu o IQ studentů jisté fakulty jsme dostali 95% interval spolehlivosti pro populační průměr tvaru (102,65; 117,35). Jak rozhodnout o pravdivosti tvrzení, že studenti této fakulty jsou inteligentnější, než běžná populace?
- ▶ V příkladu o výšce přednášejícího jsme dostali 95% interval spolehlivosti pro populační průměr tvaru (170,6; 174,2). Jak hodnotit prohlášení přednášejícího, že měří 174 cm?
- ▶ potřebujeme **standardizovaná pravidla**, jak rozhodovat
- ▶ nulová hypotéza – tvrzení o **populaci** (základním souboru)
- ▶ rozhodujeme na základě dat z **výběru**
- ▶ nelze zaručit bezchybnost rozhodnutí

hypotézy a možná rozhodnutí

- ▶ možné statistické **hypotézy**
 - ▶ **(nulová) hypotéza** H_0 : – zjednodušuje situaci, porovnávané populace se **neliší**, vyšetřované znaky jsou **nezávislé** ... (u soudu: obviněný je nevinný) tedy žádný (tj. **nulový**) rozdíl, žádná (tj. **nulová**) závislost
 - ▶ zpravidla se snažíme H_0 vyvrátit, abychom věcně něco prokázali (výjimkou je ověřování předpokladů či test dobré shody)
 - ▶ **alternativa** H_1 : (**alternativní hypotéza**) – opak nulové hypotézy, zpravidla to, co chceme věcně dokázat
 - ▶ volba co je H_0 je pevně spojena s testem, nezávisí na nás; volíme H_0 , ta nabídne test
- ▶ možná **rozhodnutí**
 - ▶ **zamítnout** H_0 pokud naše data svědčí proti H_0 (u soudu: obviněného odsoudit)
 - ▶ **nezamítnout** H_0 (přijmout H_0) pokud *není dost důvodů* H_0 zamítnout (není dost důvodů k odsouzení)

chyby v rozhodování

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

schéma rozhodování

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

- ▶ na základě dat volíme rozhodnutí (řádek)
- ▶ nevíme, která skutečnost (který sloupec) platí

klasický postup při rozhodování

- ▶ zvolit (nulovou) hypotézu H_0 , alternativu H_1
- ▶ zvolit hladinu testu α (zpravidla 5%)
- ▶ zvolit metodu rozhodování (který test použít)
- ▶ z dat spočítat testovou statistiku T a porovnat ji s tabelovanou kritickou hodnotou (ještě pohodlnější bude: porovnat ρ -hodnotu s hladinou α)
- ▶ **kritický obor** – množina těch výsledků pokusu (např. hodnot T), kdy budeme hypotézu zamítat
- ▶ když padne statistika T do **kritického oboru**, pak hypotézu zamítnout (zpravidla, když $T \geq t_0$, kde t_0 je kritická hodnota)

příklad: padá na kostce šestka příliš často?

Franta si svoji kostku možná nějak vylepšil

- ▶ 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 v nich
- ▶ co svědčí pro neplatnost hypotézy? Je to situace, kdy „šestka padá mnohem častěji, než by měla padat za H_0 “
- ▶ **tvar kritického oboru**: hypotézu zamítnat, když $Y > y_0$
- ▶ 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 α , tj.

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

příklad: jak zvolit kritickou hodnotu y_0 ?

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

y_0	19	20	21	22	23	24
$P_0(Y > y_0)$	0,220	0,152	0,100	0,063	0,038	0,022

- ▶ podmínku $P_0(Y > y_0) \leq 0,05 = \alpha$ splňuje $y_0 = 23$
- ▶ padne-li ve 100 nezávislých hodech kostkou více než 23 šestek, budeme na **5% hladině zamítnat 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 $y_0 = 21$, bylo by však větší riziko zamítnutí platné hypotézy

příklad: síla testu

- ▶ **síla testu** = pst, že hypotézu zamítneme, když ona neplatí
- ▶ při 100 hodech hypotézu na 5% hladině zamítáme, je-li $Y > 23$
- ▶ nechť je ve skutečnosti $\pi = 1/4$, pak hypotézu zamítneme (výsledek pokusu padne do kritického oboru) s pstí


$$P(Y > 23) = \sum_{k=24}^{100} \binom{100}{k} \left(\frac{1}{4}\right)^k \left(1 - \frac{1}{4}\right)^{100-k} = 0,629$$

$$1 - \text{BINOMDIST}(23; 100; 1/4; 1) \quad 1 - \text{pbinom}(23, 100, 1/4)$$

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

příklad: síla testu

závislost síly testu nulové hypotézy $H_0 : \pi = 1/6$ proti jednostranné alternativě $H_1 : \pi > 1/6$



Statistika (MD360P03Z, MD360P03U) ak. rok 2013/2014 7. přednáška 25. listopadu 2013 151(226)

statistická indukce testování hypotéz p -hodnota test o podílu (o psti) π jednovýběrový test

rozhodování pomocí p -hodnoty

- ▶ p -hodnota p je nejmenší α , při kterém z daných dat nulovou hypotézu H_0 ještě zamítáme
- ▶ p -hodnota p je za platnosti H_0 spočítaná pravděpodobnost výsledků stejně nebo méně příznivých pro H_0 , než ten, který opravdu nastal
- ▶ 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 α
- ▶ nulovou hypotézu zamítnout, je-li $p \leq \alpha$

Statistika (MD360P03Z, MD360P03U) ak. rok 2013/2014 7. přednáška 25. listopadu 2013 152(226)

statistická indukce testování hypotéz p -hodnota test o podílu (o psti) π jednovýběrový test

příklad: rozhodování pomocí p -hodnoty

- ▶ snažíme se prokázat, že šestka padá příliš často ($H_1 : \pi > 1/6$)
- ▶ hypotéza $H_0 : \pi = 1/6$, kritický obor: $Y > y_0 = 23$
- ▶ na kostce A padlo 17 šestek, proto (psti binomického rozdělení)

$$p = P_0(Y \geq 17) = \sum_{k=17}^{100} \binom{100}{k} \left(\frac{1}{6}\right)^k \left(1 - \frac{1}{6}\right)^{100-k} = 0,506$$

$$= 1 - P_0(Y \leq 16) \quad \text{1-BINOMDIST(16;100;1/6;1)}$$

- ▶ protože $50,6\% > 5\%$, hypotézu nemůžeme na 5% hladině zamítnout, nemůžeme tvrdit, že psti šestky je větší než $1/6$
- ▶ neprokázali jsme však, že by hypotéza platila
- ▶ na kostce B padlo 41 šestek

$$p = P_0(Y \geq 41) = 1 - P_0(Y \leq 40) = 7,4 \cdot 10^{-9}$$

hypotézu zamítáme $\text{1-pbinom}(40, 100, 1/6)$

Statistika (MD360P03Z, MD360P03U) ak. rok 2013/2014 7. přednáška 25. listopadu 2013 153(226)

příklad: kostka a oboustranná alternativa

- ▶ chceme ověřit, zda je kostka v pořádku
- ▶ pokusíme se prokázat, že pst šestky je větší než $1/6$ (pak šestka padá příliš často) **nebo** je menší než $1/6$ (padá 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 α rozdělíme na dvě poloviny: $\alpha/2$ pro příliš malé Y , $\alpha/2$ příliš velké Y

příklad: kostka, oboustranná alternativa

y_0	9	10	11	...	23	24	25
$P_0(Y < y_0)$	0,010	0,021	0,043	...	0,937	0,62	0,978
$P_0(Y > y_0)$	0,979	0,957	0,922	...	0,038	0,022	0,012
$P_0(Y = y_0)$	0,012	0,021	0,035	...	0,025	0,016	0,010

- ▶ $\alpha = 0,05$, tj. $\alpha/2 = 0,025$ (resp. $\alpha = 0,1$, tj. $\alpha/2 = 0,05$)
- ▶ H_0 zamítneme, když bude $Y < 10$ *nebo* když bude $Y > 24$
- ▶ skutečná pst chyby 1. druhu bude $0,021 + 0,022 = 0,043$
- ▶ $\text{pbinom}(9, 100, 1/6) + (1 - \text{pbinom}(24, 100, 1/6))$
 $\text{BINOMDIST}(9; 100; 1/6; 1) +$
 $1 - \text{BINOMDIST}(24; 100; 1/6; 1)$
- ▶ hodnoty v rozmezí 10 až 24 (včetně mezí) nesvědčí 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* hypotéze svědčí Y hodně daleko od $\mu_Y = n\pi_0$ (počítáme za platnosti hypotézy), tj. rel. četnost $f = Y/n$ daleko od π_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:
 $|Z| \geq z(1 - \alpha/2)$
- ▶ pro $\alpha = 5\%$ zamítáme hypotézu, je-li $|Z| \geq 1,96$
- ▶ $Y_A = 17$, $z_A = 0,089$, $p = 92,9\%$ (nezamítneme)
95% int- spol. (0,10; 0,24) překrývá hodnotu $1/6 \doteq 0,167$
- ▶ $Y_B = 41$, $z_B = 6,529$, $p < 0,01\%$ (zamítneme)
95% int- spol. (0,31; 0,51) nepřekrývá hodnotu $1/6 \doteq 0,167$

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 (výšky v cm): 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 po deseti letech jsou desetiletí opravdu vyšší?
- ▶ co je výška desetiletých hochů? (**populační průměr**)
- ▶ stačí k důkazu, že 10 hochů je větších než 136,1 cm a jen 5 menších než 136,1 cm?
- ▶ stačí k důkazu skutečnost, že nový **výběrový** průměr je o 3 cm větší než hypotézou předpokládaný **populační** průměr?

test o střední hodnotě μ normálního rozdělení
jednovýběrový t -test

- ▶ předpokládáme $X_1, X_2, \dots, X_n \sim N(\mu, \sigma^2)$, nezávislé
- ▶ $\sigma > 0$ odhadneme pomocí $S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}$
- ▶ rozptyl \bar{X} odhadneme pomocí S^2/n , střední chybu \bar{X} odhadneme jako $\widehat{S.E.}(\bar{X}) = S/\sqrt{n}$
- ▶ $H_0 : \mu = \mu_0$ (μ_0 známá konstanta)

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

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

souvislost s intervalem spolehlivosti

- ▶ připomeňme interval spolehlivosti pro μ

$$\bar{X} - \frac{S}{\sqrt{n}} t_{n-1}(1 - \alpha/2) < \mu < \bar{X} + \frac{S}{\sqrt{n}} t_{n-1}(1 - \alpha/2)$$

$$\bar{X} - \widehat{S.E.}(\bar{X}) \cdot t_{n-1}(1 - \alpha/2) < \mu < \bar{X} + \widehat{S.E.}(\bar{X}) \cdot t_{n-1}(1 - \alpha/2)$$

- ▶ lze přepsat jako

$$|T| = \left| \frac{\bar{X} - \mu}{S} \sqrt{n} \right| < t_{n-1}(1 - \alpha/2)$$

- ▶ $H_0 : \mu = \mu_0$ tedy **nezamítáme** na hladině α při oboustranné alternativě, právě když μ_0 leží v $100(1 - \alpha)\%$ intervalu spolehlivosti
- ▶ **interval spolehlivosti obsahuje takové hodnoty μ_0 , které bychom jako hypotézu nezamítli**

příklad: výšky desetiletých hochů


- ▶ máme $H_0 : \mu = \mu_0 = 136,1$, $H_1 : \mu > \mu_0 = 136,1$
- ▶ kritický obor: \bar{X} se příliš liší od μ_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 $t_{14}(0,95) = 1,76$ ($p = 4,7\%$)
- ▶ na 5% hladině jsme **prokázali**, že výška desetiletých vzrostla
- ▶ 95% int. spolehlivosti pro populační průměr výšek hochů: jednostranný: $(136,2; \infty)$, oboustranný $(135,5; 142,8)$
- ▶ na 5% hladině při oboustranné alternativě bychom hypotézu nezamítli, neboť $t_{14}(0,975) = 2,14$ ($p = 9,5\%$)

ověření normality

- ▶ nulová hypotéza H_0 : data mají normální rozdělení
- ▶ graficky: představu dá **normální diagram** (probability plot): porovná ideální představu na ose x se skutečností na ose y
- ▶ Shapiro-Wilkův test hodnotí normální diagram



```
qqnorm(vysky);
qqline(vysky)
```

```
shapiro.test(vysky)
W = 0.9663
p-value = 0.7998
```

H_0 : data mají normální rozdělení jsme nezamítli ($p > 0,05$), normální rozdělení můžeme **předpokládat**

použití Excelu (Analýza dat, Popisná statistika)


přednáška	Excel	hoši	
průměr	Stř. hodnota	139,13	
střední chyba	Chyba stř. hodnoty	1,693	▶ $139,13 - 3,63 = 135,50$
medián	Medián	139	
modus	Modus	139	▶ $139,13 + 3,63 = 142,76$
s	Směr. odchylka	6,56	
s^2	Rozptyl výběru	42,98	▶ 95% interval spolehlivosti: (135,5; 142,8)
špičatost	Špičatost	0,006	
šikmost	Šikmost	0,090	
rozpětí	Rozdíl max-min	24	▶ $\mu_0 = 136,1$ je v int. spolehlivosti
minimum	Minimum	127	
maximum	Maximum	151	▶ při oboustranné alternativě jsme nezamítli H_0
součet	Součet	2087	
rozsah výběru n	Počet	15	
pol. šířka int. spol.	Hladina spol.	3,63	

8. přednáška

- ▶ dvouvýběrový t -test
- ▶ Mannův-Whitneyův test

porovnání dvou populací (dvouvýběrový t -test)

- ▶ příklad: liší se desetileté dívky výškou postavy od desetiletých hochů? (tvrzení o **všech** dětech)
- ▶ výběr 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
- ▶ $\bar{y} = 140,83$, $s_y = 5,84$, $n_y = 12$

dvouvýběrový t -test

výšky desetiletých dětí

- ▶ 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

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

- ▶ μ_x (resp. μ_y) charakterizuje výšky všech chlapců (dívek)
- ▶ předpoklad stejných rozptylů bývá splněn, lze jej ověřit
- ▶ musí jít o **nezávislé** náhodné výběry, nelze např. vybírat sourozencké dvojice nebo opakovaně měřit stejnou osobu

dvouvýběrový t-test

- ▶ $H_0 : \mu_x = \mu_y$ (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)
 - ▶ $H_1 : \mu_x > \mu_y$ (cílem dokázat, že hoši jsou větší než dívky)
 - ▶ $H_1 : \mu_x < \mu_y$ (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 $\mu_x - \mu_y$

odhad σ^2

- ▶ je třeba odhadnout také neznámé σ^2 pomocí

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

$$= \frac{n_x - 1}{n_x + n_y - 2} S_x^2 + \frac{n_y - 1}{n_x + n_y - 2} S_y^2$$

(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

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

kritický obor

- ▶ o hypotéze $H_0 : \mu_x = \mu_y$ se rozhoduje pomocí

$$T = \frac{\bar{X} - \bar{Y}}{\widehat{\text{S.E.}}(\bar{X} - \bar{Y})} = \frac{\bar{X} - \bar{Y}}{S} \sqrt{\frac{n_x n_y}{n_x + n_y}}$$

- ▶ $H_1 : \mu_x \neq \mu_y$ zamítáme pokud $|T| \geq t_{n_x+n_y-2}(1 - \alpha/2)$
- ▶ $H_1 : \mu_x > \mu_y$ zamítáme pokud $T \geq t_{n_x+n_y-2}(1 - \alpha)$
- ▶ $H_1 : \mu_x < \mu_y$ zamítáme pokud $T \leq -t_{n_x+n_y-2}(1 - \alpha)$
- ▶ výšky desetiletých: $t = -0,70 \Rightarrow$
 $| -0,70 | < 2,06 = t_{15+12-2}(0,975)$
- ▶ na 5% hladině jsme **neprokázali** rozdíl mezi výškami desetiletých hochů a dívek ($p = 48,8 \%$)

t.test(vyska~Hoch, var.equal=TRUE)

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

souvislost s intervalem spolehlivosti

- ▶ $\mu_x - \mu_y = \delta$ (o kolik se liší populační průměry)
- ▶ odhadem pro δ je $d = \bar{X} - \bar{Y} = -1,7$
- ▶ krajní body intervalu spolehlivosti pro δ jsou

$$(\bar{X} - \bar{Y}) \pm \widehat{S.E.}(\bar{X} - \bar{Y}) \cdot t_{n_x+n_y-2}(1 - \alpha/2)$$

$H_0 : \delta = 0$ (tj. $\mu_x = \mu_y$) zamítáme právě tehdy, když nula **není** v int. spol. pro δ

- ▶ při porovnání výšek hochů a dívek je 95% interval pro δ

$$\left(-0,7 - 6,24 \sqrt{\frac{1}{15} + \frac{1}{12}} \cdot 2,06; -0,7 + 6,24 \sqrt{\frac{1}{15} + \frac{1}{12}} \cdot 2,06 \right)$$

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

- ▶ nula **je** v intervalu, proto **nezamítáme** $H_0 : \delta = 0$

shrnutí

- ▶ důležité předpoklady
 - ▶ nezávislé výběry (dáno způsobem sběru dat)
 - ▶ stejné (populační) rozptyly (lze testovat)
 - ▶ normální rozdělení (lze testovat)
- ▶ existuje varianta bez předpokladu stejných rozptylů (Welch) (bude následovat)
 - `t.test(vyska~Hoch, var.equal=FALSE)`
 - `TTEST(A14:A28; A2:A13; 2; 3)`
- ▶ pro velká n_x, n_y na normalitě tolik nezáleží (CLV)
- ▶ je-li problém s normalitou, lze použít jiný test (dvouvýběrový Wilcoxonův, též Mannův-Whitneyův)

problém nesterajných rozptylů

- ▶ předpoklad o stejném rozptylu v obou souborech nemusí být ve skutečnosti splněn, lze jej ověřit porovnáním odhadů rozptylu F-testem založeným na $F = \frac{S_x^2}{S_y^2}$
- ▶ hypotéza $H_0 : \sigma_x^2 = \sigma_y^2$ se proti $H_1 : \sigma_x^2 \neq \sigma_y^2$ zamítá, když je
 - buď $F = \frac{S_x^2}{S_y^2} \geq F_{n_x-1, n_y-1}(1-\alpha/2)$ nebo $\frac{S_y^2}{S_x^2} \geq F_{n_y-1, n_x-1}(1-\alpha/2)$
- ▶ vlastně se větší odhad rozptylu dělí menším odhadem, k tomu se musí zvolit odpovídající pořadí stupňů volnosti a **hladina**
- ▶ příklad výšky desetiletých dětí:
 - $F = \frac{42,98}{33,79} = 1,27 < F_{14,11}(0,975) = 3,36$
- ▶ `var.test(vyska~Hoch)` `FTEST()` (???)

MS Excel: Dvouvýběrový F-test pro rozptyl

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 $F_{14,11}(0,975) = 3,359$

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
$H_0 : \mu_x - \mu_y =$	Hyp. rozdíl stř. hodnot	0	
stupně volnosti f	Rozdíl	25	
T	t stat	-0,713	
p jednostr. testu	$P(T \leq t) (1)$	0,241	
$t_f(1 - \alpha)$	t krit (1)	1,708	
p oboustr. testu	$P(T \leq t) (2)$	0,482	
$t_f(1 - \alpha/2)$	t krit (2)	2,060	

při oboustranné alternativě nelze nulovou hypotézu zamítnout

dvouvýběrový Wilcoxonův test (někdy nepřesně Mannův-Whitneyův)

pořadová obdoba dvouvýběrového t-testu

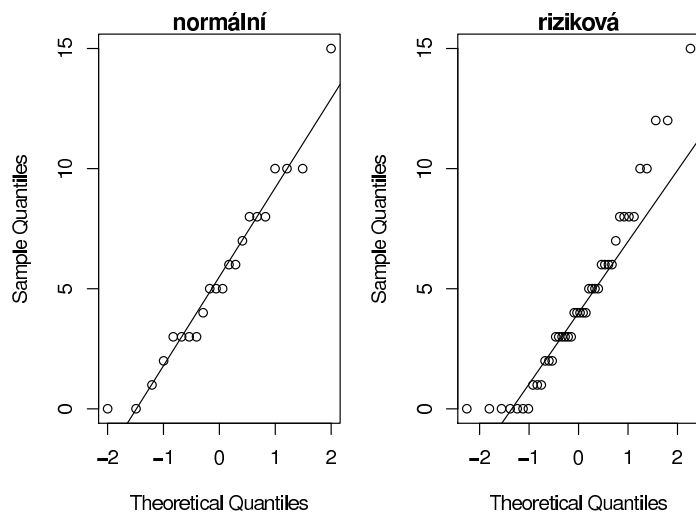
- ▶ porovnáváme stejný kvantitativní (spojitý) znak ve dvou populacích
- ▶ máme dva **nezávislé** výběry z těchto populací
- ▶ není třeba předpokládat normální rozdělení, stačí spojitě
- ▶ nechť X_1, \dots, X_{n_x} a Y_1, \dots, Y_{n_y} jsou **nezávislé** výběry ze spojitého rozdělení (například věk 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: kostky cukru

- ▶ porovnááme spotřebu cukru u 43letých mužů s rizikovým faktorem pro ICHS se spotřebou cukru 43letých mužů bez tohoto faktoru
- ▶ spotřebu (hrubě) měříme udaným počtem kostek cukru běžně spotřebovaných za den
- ▶ dvouvýběrový t-test potřebuje normální rozdělení
- ▶ Shapirův-Wilkův test:
data: normální $W = 0.9557$, $p\text{-value} = 0.4074$
data: riziková $W = 0.9246$, $p\text{-value} = 0.008537$
- ▶ dvouvýběrový t-test není vhodný, předpoklad o normálním rozdělení není udržitelny

příklad: kostky cukru

grafické ověření normality



příklad: kostky cukru

- ▶ dvě skupiny mužů středního věku (riziková, normální)
- ▶ spojitý znak měříme hrubě počtem kostek cukru na den

kostek	norm.	rizik.	celkem	pořadí	R(norm.)	R(rizik.)
0	2	7	9	5,0	10,0	35,0
1	1	3	4	11,5	11,5	34,5
2	1	3	4	15,5	15,5	46,5
3	4	6	10	22,5	90,0	135,0
4	1	5	6	30,5	30,5	152,5
5	3	4	7	37,0	111,0	148,0
6	2	4	6	43,5	87,0	174,0
7	1	1	2	47,5	47,5	47,5
8	3	4	7	52,0	156,0	208,0
10	3	2	5	58,0	174,0	116,0
12	0	2	2	61,5	0,0	123,0
15	1	1	2	63,5	63,5	63,5
celkem	22	42	64		796,5	1283,5

dvouvýběrový Wilcoxonův test

- ▶ normální: $n_x = 22$, součet pořadí $W_x = 796,5$
(průměr $\frac{796,5}{22} = 36,2$)
- ▶ riziková: $n_y = 42$, součet pořadí $W_y = 1283,5$
(průměr $\frac{1283,5}{42} = 30,5$)
- ▶ `wilcox.test(normální,riziková)`
 $W = 543,5$, $p\text{-value} = 0,2495$
- ▶ statistika W má jiný význam (Mannův-Whitneyův test)
 - ▶ uvažuje všechny dvojice mužů (normální, riziková), tj. (X_i, Y_j) ,
 $i = 1, \dots, n_x, j = 1, \dots, n_y$
 - ▶ není-li mezi dvěma populacemi, dokud pocházejí výběry (platí-li H_0) rozdíl, mělo by asi v polovině případů být $X_i > Y_j$ a v polovině případů $X_i < Y_j$
 - ▶ statistika W udává počet dvojic $X_i > Y_j$ zvětšený o polovinu počtu dvojic $X_i = Y_j$
- ▶ rozhodnutí dvouvýběrového Wilcoxonova testu a Mannova-Whitneyova testu jsou totožná

příklad: IQ dvojčat (párový t-test)

datový soubor twins v balíčku alr3

rodiče	82	90	91	115	115	129	131
pěstouni	82	80	88	108	116	117	132
rozdíl	0	10	3	7	-1	12	-1

- ▶ dvojice jednovaječných dvojčat vychovávaných odděleně
- ▶ Zavisí IQ na způsobu výchovy?
- ▶ **párová závislost**, nejde o dvouvýběrový test
- ▶ $H_0: \mu_r = \mu_p$, tj. $\mu_{\text{rozdíl}} = 0$
- ▶ jednovýběrový t-test použijeme na rozdíly
- ▶ $t = 2,097$, $p = 0,081$
- ▶ rozdíl jsme neprokázali
- ▶ 95 % int. spol. pro rozdíl $\mu_r = \mu_p$: $(-0,7; 9,3)$
- ▶ použití jednovýběrového t-testu na rozdíl párově (možná) závislých pozorování se nazývá **párový t-test**
- ▶ předpokládá se, že **rozdíly** jsou nezávislé a **mají normální rozdělení**

příklad: IQ dvojčat (znaménkový test)

rodiče	82	90	91	115	115	129	131
pěstouni	82	80	88	108	116	117	132
rozdíl	0	10	3	7	-1	12	-1

- ▶ čtyři hodnoty z šesti nenulových jsou kladné (znaménko nuly nemá smysl)
- ▶ Kdyby nezáleželo na tom, kdo dvojče vychovává, byla by pravděpodobnost kladného znaménka rovna $1/2$, použijeme test o pravděpodobnosti v binomickém rozdělení.
- ▶ (slajd 156:)

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1 - \pi_0)}} = \frac{f - \pi_0}{\sqrt{\pi_0(1 - \pi_0)}} \sqrt{n}$$

▶

$$z = \frac{4 - 6/2}{\sqrt{6/4}} = 0,816, \quad p = 0,414$$

- ▶ `binom.test(4,6,p=0.5)` je založen na přesném testu:
 $p = 0,6875$

znaménkový test obecně

- ▶ X_1, X_2, \dots, X_n nezávislé, stejně rozdělené, spojitě rozdělení
- ▶ $H_0 : P(X_i \leq x_0) = 1/2$, tj. x_0 je populační medián
- ▶ vyškrtněme pozorování shodná s x_0 , upravme n
- ▶ označme Y počet hodnot X_i menších než x_0 , platí-li H_0 , pak $Y \sim \text{bi}(n, 1/2)$
- ▶ rozhodneme o H_0 v binomickém rozdělení $\text{bi}(n, \pi)$, podle které je $\pi = 0,5$
- ▶ u párově závislých pozorování použijeme jako X_i rozdíly hodnot ve dvojicích

jednovýběrový (párový) Wilcoxonův test

(Wilcoxon signed rank test)

- ▶ X_1, X_2, \dots, X_n nezávislé, stejně rozdělené, spojitě rozdělení, které je **symetrické** kolem x_0
- ▶ $H_0 : x_0 = a$, kde a je daná hodnota, nejčastěji nula
- ▶ podobně jako u znaménkového testu se vyloučí hodnoty $X_i = a$, upraví se n
- ▶ určí se pořadí R_i^+ absolutních hodnot $|X_i - a$, sečtou se jen ta, kde je $X_i > a$

$$W = \sum_{i: X_i > a} R_i^+$$

- ▶ rozhoduje se podle W
`wilcox.test(rodice,pestouni,paired=TRUE)`

příklad: IQ dvojčat (znaménkový test)

rodice	82	90	91	115	115	129	131
pestouni	82	80	88	108	116	117	132
rozdíl	0	10	3	7	-1	12	-1
rozdíl	—	10	3	7	1	12	1
R_i^+	—	5	3	4	1,5	6	1,5

- ▶ $W = 5 + 3 + 4 + 6 = 18$ $p = 14,1 \%$
- ▶ `wilcox.test(rodice,pestouni,paired=TRUE)`
- ▶ kdybychom předpokládali normální rozdělení, použili bychom `t.test(rodice,pestouni,paired=TRUE)`


9. přednáška

- ▶ (Pearsonův) korelační koeficient
- ▶ Spearmanův korelační koeficient
- ▶ regrese
- ▶ metoda nejmenších čtverců
- ▶ testy o regresní přímce
- ▶ ověření předpokladů

příklad: výška otce a syna

data: Galton (1886), Hanley (2004), údaje v angl. palcích (1 palec = 25,4 mm)

souvisí spolu výška otce a výška jeho dospělého syna? $r = 0,505$



$$r_{xy} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

$$= \frac{1}{n-1} \sum_{i=1}^n \left(\frac{X_i - \bar{X}}{S_X} \right) \left(\frac{Y_i - \bar{Y}}{S_Y} \right)$$

prokazování závislosti spojitých veličin

- ▶ považujeme dvojice výšek X, Y (otec, syn) za náhodný výběr z populace dvojic (otec, syn)
- ▶ H_0 : náhodné veličiny X, Y jsou nezávislé
- ▶ víme, že pro nezávislé X, Y je $\rho_{XY} = 0$
- ▶ r_{xy} je odhadem ρ_{XY} ; jak daleko od nuly musí být r_{xy} , abychom na hladině α prokázali závislost X, Y ?
- ▶ za předpokladu, že X, Y mají **normální rozdělení** (nebo počet pozorovaných dvojic X_i, Y_i je velký) a **dvojice** (X_i, Y_i) jsou mezi sebou (pro různá i) **nezávislé**, hypotézu nezávislosti zamítáme pokud je $|T| \geq t_{n-2}(1 - \alpha/2)$, kde

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

- ▶ pro (otec, syn) vyšlo $t = 7,65$, $p \doteq 10^{-12}$, závislost jsme prokázali (normalitu výšek lze předpokládat)


Spearmanův korelační koeficient

- ▶ nelze-li předpokládat normalitu (nebo nejsou stovky dvojic), použijeme **Spearmanův korelační koeficient** r_S
- ▶ místo původních X_i, Y_i použijeme jejich pořadí R_i, Q_i
- ▶ r_S je 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 také pro nelineární monotonní **závislost**
- ▶ nevadí odlehle hodnoty
- ▶ při testování nemusí být normální rozdělení
- ▶ nezávislost se zamítá, je-li $|r_S| \sqrt{n-1} \geq z(\alpha/2)$ (pro n velké), jinak s využitím tabulek

příklad: emise CO₂ a HDP v EU



příklad: emise CO₂ a HDP v EU

ověření normálního rozdělení CO₂ a HDP, Shapirův-Wilksův test



$W = 0.8513$, $p\text{-value} = 0.001224$

$W = 0.7936$, $p\text{-value} = 0.0001061$

příklad: emise CO₂ a HDP v EU

- ▶ Spearmanův korelační koeficient:

```
cor.test(~emiseCO2+HDP, data=EU2010, method="spearman")
```

$r_S = 0,549$, což při $n = 27$ vede k $p = 0,003$

- ▶ nesprávně použitý (Pearsonův) korelační koeficient:

```
cor.test(~emiseCO2+HDP, data=EU2010)
```

$r_S = 0,795$, což při $n = 27$ vede k $p < 0,001$

- ▶ když vynecháme **odlehlou hodnotu** Lucemburska:

```
cor.test(~emiseCO2+HDP, data=EU2010, subset=země!="LU")
```

dostaneme $r = 0,516$, což při $n = 26$ vede k $p = 0,007$


- ▶ po vyloučení dat o Lucembursku normalitu nezamítneme
- ▶ u podobných dat (charakteristiky států, územních jednotek) je předpoklad normálního rozdělení zpravidla nepoužitelný

regrese

- ▶ na rozdíl od korelace (síla závislosti) hledáme tvar (způsob) závislosti, zajímá nás také průkaznost závislosti
- ▶ snažíme se z daných hodnot **regresorů (nezávisle proměnných, prediktorů)** předpovědět hodnoty **závisle proměnné** (odezvy, vysvětlované proměnné)
- ▶ snažíme se variabilitu (kolísání hodnot) odezvy vysvětlit závislostí na kolísajících regresorech
- ▶ 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 výška syna s výškou otce?

upravená Galtonova data, údaje v palcích



regresní přímka

- ▶ cíl: chování Y (výška syna) co nejlépe (nejvíce) vysvětlit lineární závislostí na x (výška otce)
- ▶ (naše představa, předpoklad:) každé výšce otce x_i odpovídá jakási střední výška syna $E Y_i$, ta závisí na výšce otce lineárně

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

- ▶ obecně předpokládáme, že Y_1, \dots, Y_n jsou **nezávislé** a

$$Y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2), \quad i = 1, \dots, n$$

- ▶ parametry β_0, β_1 odhadneme **metodou nejmenších čtverců** minimalizací přes β_0, β_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 $\beta_0 = b_0, \beta_1 = b_1$) se nazývá **reziduální součet čtverců**: $S_e = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2$

metoda nejmenších čtverců


na obrázku jsou pouze tři pozorování!

směrnice tvar rovnice přímky – návod, jak $k \times$ spočítat y (souřadnice bodu na přímce)

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)



naš příklad

```
summary(lm(syn~otec, data=GaltonSyn))
```

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	34,652	4,527	7,654	<0,001
otec	0,501	0,065	7,651	<0,001

- ▶ odhad závislosti: $\widehat{\text{syn}} = 34,652 + 0,501 \text{ otec}$
- ▶ s každým palcem výšky otce roste výška syna v průměru zhruba o půl palce
- ▶ jiné vyjádření: $(\widehat{\text{syn}} - \overline{\text{syn}}) = 0,501 (\text{otec} - \overline{\text{otec}})$
- ▶ Vezměme otce, jejichž výška se liší o jeden palec od průměrné výšky otců. Očekáváme, že průměrná výška jejich synů se od průměrné výšky synů bude lišit jen o půl palce.
- ▶ odchylka od průměru se reprodukuje jen z poloviny (regrese k průměru)
- ▶ závislost je průkazná, neboť v řádce pro x (otec) je $p < 0,001$

obecně

- ▶ odhadovaná závislost $y = \beta_0 + \beta_1 x$, odhadnutá $y = b_0 + b_1 x$
- ▶ závislost na x prokazuje 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 oboustranné alternativě, když $|T| \geq t_{n-2}(1 - \alpha/2)$
- ▶ regresní přímka prochází těžištěm $(\bar{x}; \bar{Y})$
- ▶ vyrovnané (vyhlazené) hodnoty:

$$\hat{Y}_i = b_0 + b_1 x_i = \bar{Y} + b_1(x_i - \bar{x})$$

rezidua

- ▶ rezidua

$$u_i = Y_i - \hat{Y}_i = Y_i - (b_0 + b_1 x_i) = (Y_i - \bar{Y}) - b_1(x_i - \bar{x})$$

- ▶ reziduální součet čtverců: nevysvětlená variabilita Y

$$S_e = \sum_{i=1}^n u_i^2 = \sum_{i=1}^n (Y_i - (b_0 + b_1 x_i))^2$$

- ▶ reziduální rozptyl: odhad σ^2

$$s^2 = S_e / (n - 2)$$

- ▶ koeficient determinace ukazuje, jaký díl variability odezvy (tj. jaký díl $\sum_{i=1}^n (Y_i - \bar{Y})^2$) jsme závislostí vysvětlili

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

naš příklad a tabulka analýzy rozptylu

`anova(lm(syn~otec, data=GaltonSyn))`

variabilita	st. vol. f	součet čtverců SS	prům. čtverec MS	F	p
model	1	279,11	279,107	58,532	<0,001
reziduální	171	815,41	4,768		
celkem	172	1 094,52			

- ▶ kolísání výšek synů vysvětlíme závislostí z 25,5 %, neboť je

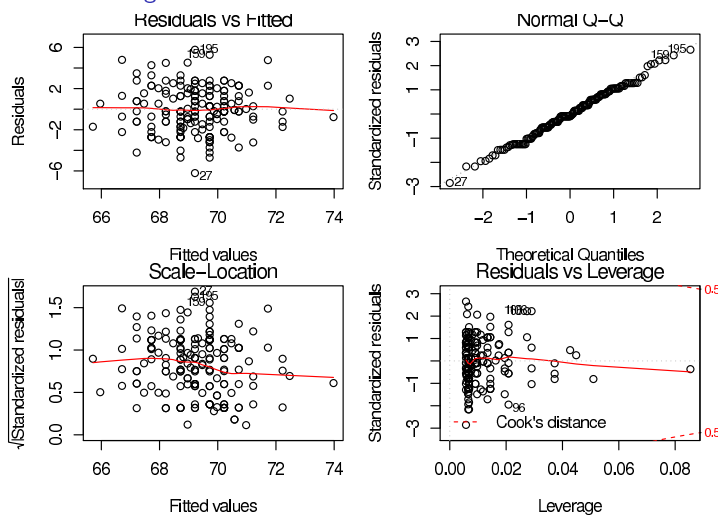
$$R^2 = 1 - \frac{815,41}{1094,52} = \frac{279,11}{1094,5} = 0,255$$

ověření splnění předpokladů

- ▶ ověření **nelze provést** jen hodnocením hodnot závisle proměnné Y_1, \dots, Y_n (např. nemají stejné střední hodnoty)
- ▶ využívají se zejména rezidua $u_i = Y_i - \hat{Y}_i$ (znaménkem opatřené vsíle vzdálenosti pozorování od přímky)
- ▶ rychlé předběžné grafické ověření pomocí funkce `plot(a)`, kde je `a = lm(Y~x)`
- ▶ ověření normality: Shapirův-Wilkův test použitý na rezidua `shapiro.test(rstandard(a))`
- ▶ stabilita rozptylu: Breuschův-Paganův test `library(lmtest); bptest(a)`
- ▶ nezávislost **po sobě jdoucích** pozorování: Durbinův-Watsonův test (např. časová řada má pozorování navzájem závislá) `library(lmtest); dwtest(a)`

příklad: výška syna a otce

`plot()` dá čtveřici grafů




příklad: výška syna a otce

- ▶ žádný graf nenaznačuje problém
- ▶ test normality: $W = 0.9935$, $p\text{-value} = 0.6445$
- ▶ stálost rozptylu: $BP = 1.6422$, $df = 1$, $p\text{-value} = 0.2$
- ▶ ani jeden test nenaznačuje problém, můžeme předpokládat normální rozdělení i konstantní rozptyl
- ▶ Durbinův-Watsonův test nemá smysl, protože pořadí napozorovaných hodnot je nahodilé, není v něm systém.

příklad: závislost produkce odpadu na HDP v EÚ

odpad v kg na osobu za rok, HDP jednotkách PPS




závislost v logaritmech je nepochybně lépe vystižena přímkou

poznámky

- ▶ **transformace** mnohdy je užitečné modelovat závislost vhodné funkce závisle proměnné na vhodné (třeba jiné) funkci nezávisle proměnné
- ▶ v případě jediné nezávisle proměnné x je koeficient determinace R^2 čtvercem korelačního koeficientu r_{xy}
- ▶ **mnohonásobná regrese**: nezávisle proměnných může být více, např. výšku syna lze vysvětlit výškou otce a výškou matky současně
- ▶ pokud data tvoří časovou řadu, předpoklad nezávislosti pozorování mezi sebou nebývá splněn (např. vývoj HDP)

příklad: vývoj starobních důchodů v ČR



na grafu patrné kolísání kolem přímky, graf reziduí to jen zdůrazňuje: je nutno použít složitější model, který přihlédne k závislosti a zřejmé periodicitě

regrese v MS Excelu 2000, 2003

	Excel 2003	označení
absolutní člen odhad	Hranice	b_0
střední chyba odhadu koeficient	Koeficienty	b_i
(mnohonásobné) korelace koeficient determinace	Chyba střední hodnoty*	S.E.(b_i)
adjustovaný koef. det.	Násobné R	$\sqrt{R^2}$
resid. směr. odchylka	Hodnota spolehlivosti R	R^2
počet pozorování	Nastavená hodnota spol. R	R^2_{adj}
počet st. volnosti	Chyba stř. hodnoty*	s
	Pozorování	n
	Rozdíl	

* pozor, dva různé pojmy označeny stejně!

10. přednáška

- ▶ multinomické rozdělení
- ▶ chí-kvadrát test dobré shody
- ▶ kontingenční tabulka
- ▶ čtyřpolní tabulka

motivační 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, 52,03 % vdaných, 12,50 % rozvedených a 1,20 % ovdovělých
- ▶ lze výběr považovat za reprezentativní co do stavu?
- ▶ odpovídají procenta výběru procentům populace, tj. je výběr **reprezentativní**?
- ▶ dostali bychom reprezentativní výběr, kdybychom hledali ženy např. v porodnici?

multinomické rozdělení

- ▶ zobecnění binomického rozdělení na k -tici náhodných veličin Y_1, \dots, Y_k
- ▶ parametry n, π_1, \dots, π_k ($0 < \pi_j < 1$, $\pi_1 + \dots + \pi_k = 1$)
- ▶ n **nezávislých** pokusů
- ▶ v každém pokusu **právě jeden** z k možných výsledků
 - ▶ možné výsledky se musí vylučovat
 - ▶ aspoň jeden z možných výsledků musí nastat
- ▶ j -tý výsledek nastává s pravděpodobností π_j
- ▶ Y_j – počet pokusů, v nichž nastal j -tý možný výsledek, tedy nutně

$$Y_1 + \dots + Y_k = n$$

příklady multinomického rozdělení

- ▶ předvolební průzkum
 - ▶ n – počet tázaných
 - ▶ π_j – skutečný podíl voličů j -té strany v populaci
 - ▶ Y_j – počet (četnost) voličů j -té strany ve výběru
- ▶ hody hrací kostkou
 - ▶ n – počet hodů
 - ▶ π_1, \dots, π_6 – pravděpodobnosti jednotlivých stran kostky
 - ▶ Y_1, \dots, Y_6 – absolutní četnosti jednotlivých stran kostky
- ▶ krevní skupiny
 - ▶ $k = 4$ (skupiny 0, A, B, AB)
 - ▶ $\pi_0, \pi_A, \pi_B, \pi_{AB}$ – pravděpodobnosti skupin 0, A, B, AB
 - ▶ Y_0, Y_A, Y_B, Y_{AB} – počty osob se skupinami 0, A, B, AB
- ▶ půjde o multinomické rozdělení, když pořídíme vzorek vědců (populaci vědců lze definovat), pokud je budeme třídit podle státní příslušnosti?

vlastnosti multinomického rozdělení

- ▶ každá jednotlivá složka Y_j má binomické rozdělení:

$$Y_j \sim \text{bi}(n, \pi_j)$$

- ▶ střední hodnota: $\mu_{Y_j} = n\pi_j$, rozptyl: $\sigma_{Y_j}^2 = n\pi_j(1 - \pi_j)$
- ▶ (pro zajímavost) kovariance: $\text{cov}(Y_j, Y_t) = -n\pi_j\pi_t$ $j \neq t$
- ▶ náhodné veličiny Y_1, \dots, Y_k jsou závislé ($Y_1 + \dots + Y_k = n$)
- ▶ asymptotická vlastnost **chi-kvadrát** (velká n , $n\pi_j \geq 5 \forall j$)

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

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

příklad: hrací kostka A

- ▶ **chí-kvadrát test dobré shody**
- ▶ $n = 100$ hodů kostkou
- ▶ $Y_1 = 12, Y_2 = 21, Y_3 = 14, Y_4 = 15, Y_5 = 21, Y_6 = 17$
- ▶ 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)

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

- ▶ $\chi^2 < \chi_5^2(0,95) = 11,07, \quad p = 52,7 \%$
- ▶ neprokázali jsme, že by kostka nebyla symetrická
- ▶ neprokázali jsme ani to, že je symetrická
- ▶ symetrii můžeme pouze **předpokládat**
- ▶ `chisq.test(c(12,21,14,15,21,17),p=rep(1,6)/6)`

příklad: hrací kostka B (1)

- ▶ $n = 100$ hodů kostkou
- ▶ $Y_1 = 15, Y_2 = 16, Y_3 = 7, Y_4 = 6, Y_5 = 15, Y_6 = 41$
- ▶ hypotéza $H_0 : \pi_1 = \dots = \pi_6 = 1/6$ dá očekávané četnosti $n\pi_1 = \dots = n\pi_6 = 100/6 = 16,67$

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

- ▶ $\chi^2 > \chi_5^2(0,95) = 11,07 \quad p < 0,0001$
- ▶ 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
- ▶ $Y_1 = 15, Y_2 = 16, Y_3 = 7, Y_4 = 6, Y_5 = 15, Y_6 = 41$
- ▶ nulová hypotéza: $\pi_1 = \dots = \pi_5 = 1/10, \pi_6 = 5/10 = 1/2$
- ▶ očekávané četnosti za hypotézy: $n\pi_1 = \dots = n\pi_5 = 100/10 = 10, n\pi_6 = 100/2 = 50$

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

- ▶ $\chi^2 > \chi_5^2(0,95) = 11,07 \quad p = 2,6 \%$
- ▶ 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
- ▶ $Y_6 = 41$
- ▶ 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)`

chí-kvadrát test dobré shody obecně

- ▶ Y_1, \dots, Y_k mají multinomické rozdělení s parametry n, π_1, \dots, π_k , kde $Y_1 + \dots + Y_k = n$ a $\pi_1 + \dots + \pi_k = 1$
- ▶ nulová hypotéza tvrdí, že pravděpodobnosti jsou rovny známým hodnotám: $\pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$
- ▶ spočítáme očekávané četnosti $o_i = n\pi_i^0$
- ▶ ověříme splnění podmínky $o_i \geq 5$
- ▶ spočítáme statistiku chí-kvadrát:

$$\chi^2 = \sum_{i=1}^k \frac{(Y_i - o_i)^2}{o_i}$$

- ▶ nulovou hypotézu zamítáme na hladině významnosti α , je-li $\chi^2 \geq \chi_{k-1}^2(1 - \alpha)$

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 %	52,03 %	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 testu dobré shody je $\chi^2 = 5,34$ ($p = 14,9 \%$), ale $\chi_3^2(0,95) = 7,81$
- ▶ neprokázali jsme, že by výběr nebyl reprezentativní, můžeme jej za reprezentativní považovat

`chisq.test(c(180,239,75,4),p=c(34.27,52.03,12.50,1.20)/100)`

příklad: vzdělání snoubenců

tabulka udává četnosti zjištěné u 100 náhodně vybraných 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

- ▶ zajímá nás, zda vzdělání ženicha a nevěsty spolu souvisí
- ▶ lze považovat vzdělání snoubenců za nezávislá?
- ▶ tabulka udává **sdružené** a z nich spočítané **marginální** četnosti
- ▶ vzdělání zde chápeme jen v nominálním měřítku
- ▶ četnosti na diagonále převládají, četnosti mimo diagonály jsou spíše menší
- ▶ vzhledem k nominálnímu měřítku nelze použít ani Spearmanův korelační koeficient

kontingenční tabulka (závislost vzdělání snoubenců)

- ▶ opět použijeme chí-kvadrát test
- ▶ očekávané četnosti vycházejí z nulové hypotézy H_0 : vzdělání jsou nezávislá (vzdělání nevěst jsou mají pravděpodobnosti nezávislé na vzdělání ženichů)
- ▶ vzdělání nevěst jsou v poměru 34 % : 45 % : 21 %
- ▶ stejný poměr by měl být např. pro 27 ženichů vysokoškoláků: 9,18 (tj. 34 % z 27) : 12,15 (tj. 45 %) : 5,67 (tj. 21 %)
- ▶ to jsou četnosti očekávané za platnosti nulové hypotézy
- ▶ podobně dostaneme očekávané četnosti pro zbývající dvě kategorie ženichů
- ▶ statistika chí-kvadrát porovná skutečně zjištěné (empirické) četnosti s četnostmi za nezávislosti očekávanými, spočítá jejich „vzdálenost“

test nezávislosti v kont. tabulce

- ▶ u n jedinců (statistických jednotek) vyšetřujeme dva znaky v nominálním měřítku (vzdělání ženicha, vzdělání nevěsty), které mají r a c možných hodnot
- ▶ označme n_{ij} počet jedinců s i -tou hodnotou prvního znaku a j -tou hodnotou druhého znaku (např. n_{12} je počet dvojic snoubenců, kdy ženich má základní vzdělání a nevěsta střední)
- ▶ spočítáme řádkové marginální četnosti n_{i+} (počet ženichů s i -tým vzděláním) a sloupcové marginální četnosti n_{+j} (počet nevěst s j -tým vzděláním)

test nezávislosti v kont. tabulce

- ▶ nulová hypotéza H_0 tvrdí, že dva znaky jsou nezávislé
- ▶ ke každé sdružené četnosti spočítáme očekávanou četnost (četnost v průměru očekávanou v případě, že platí H_0)

$$o_{ij} = \frac{n_{i+}n_{+j}}{n}$$

- ▶ ověříme podmínku $o_{ij} \geq 5$
- ▶ spočítáme statistiku chí-kvadrát

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

- ▶ určíme počet stupňů volnosti: $f = (r - 1)(c - 1)$
- ▶ nulovou hypotézu zamítneme (závislost prokážeme) na hladině významnosti α , když bude statistika chí-kvadrát příliš velká:

$$\chi^2 \geq \chi_f^2(1 - \alpha)$$

příklad: vzdělání snoubenců

v závorce jsou očekávané četnosti

ženich	nevěsta			celkem
	základní	střední	VŠ	
základní	24 (13,26)	12 (17,55)	3 (8,19)	39
střední	7 (11,56)	24 (15,30)	3 (7,14)	34
VŠ	3 (9,18)	9 (12,15)	15 (5,67)	27
celkem	34	45	21	100

- ▶ $\chi^2 = 43,2 > \chi_4^2(0,95) = 9,5$, $p < 0,1$ %
- ▶ 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
- ▶ POZOR, test nic netvrdí o shodě marginálních pstí (že rozdělení úrovně vzdělání jsou u ženichů a nevěst stejná)

test homogenity

- ▶ zjišťujeme četnosti zvoleného znaku, který nabývá c různých hodnot, za r různých podmínek (naše četnosti stran hracích kostek A a B, tedy $c = 6$ $r = 2$)
- ▶ četnosti mají za i -té podmínky multinomické rozdělení s pravděpodobnostmi $\pi_{i1}, \dots, \pi_{ic}$
- ▶ rozhodujeme o nulové hypotéze H_0 , podle které jsou parametry (pravděpodobnosti) těchto multinomických rozdělení stejné (pravděpodobnosti jedniček jsou u obou kostek stejné, pstí dvojek jsou u obou kostek stejné ...)
- ▶ označme četnost j -té hodnoty za i -té podmínky jako n_{ij}
- ▶ očekávané četnosti o_{ij} , počet stupňů volnosti f i statistika chí-kvadrát se určí formálně stejně jako u testu nezávislosti
- ▶ stejně je také rozhodování o H_0

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

-

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

- tab = matrix(c(12,15,21,16,14,7,15,6,21,15,17,41),2,6)
chisq.test(tab)

$$\chi^2 > 11,07 = \chi_5^2(0,95), \quad p = 0,3 \%$$

- hypotézu o shodě psí na kostkách A a B **zamítáme**

čtyřpolní tabulka (tabulka 2x2)

speciální případ kontingenční tabulky

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

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

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

- ϕ je (jako každý korelační koeficient) mezi -1 a 1

- například pro

VŠ	strana A	strana B	celkem
ano	11	4	15
ne	6	9	15
celkem	17	13	30

vyjde

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

čtyřpolní tabulka – prokazování závislosti

- chí-kvadrát porovnávající teoretické a očekávané četnosti čtyřpolní tabulky 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 α 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

$$3,39 < 3,84 = \chi_1^2(0,95), \quad p = 6,5 \%$$

malé očekávané četnosti ve čtyřpolní tabulce

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

- ▶ stále je třeba, aby byly očekávané četnosti dost velké (≥ 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 $\chi_{\text{Yates}}^2 \geq \chi_1^2(1 - \alpha)$
- ▶ **Fisherův exaktní test** počítá přímo p -hodnotu