

## Základy biostatistiky

statistika:

- **popisná** (data stručně popsat, něco z dat „vydolat“)
- **induktivní** (tvrdit něco nového, zobecnit na větší soubor, záleží na interpretaci)

příklady dat:

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

1

## Popisné statistiky

statistika: též funkce pozorovaných hodnot

$x_1, x_2, \dots, x_n$  zjištěné hodnoty

$x_1^*, x_2^*, \dots, x_m^*$  možné hodnoty (různé)

$n_1, n_2, \dots, n_m$  četnosti hodnot

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

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

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

kumulativní četnosti - nutno aspoň ordinální měřítko

**histogram:** grafické znázornění četností  
plocha (výška) obdélníku úměrná četnosti (relativní četnosti – jiné měřítko)  
podobně **výsečový diagram**

3

**znak** - vlastnost měřená na objektu (statistické jednotce): délka, barva, ...

možná **měřítka**:

- **nominální** (porodnice, pohlaví) seznam všech rozlišitelných hodnot, **faktor**
- **ordinální** (vzdělání matky, ..., stupeň bolesti) hodnoty nominálního uspořádány, **uspořádaný faktor**
- **intervalové** (rok narození, teplota v °C) stejné vzdálenosti sousedních hodnot, o kolik se liší?
- **poměrové** (hmotnost, výška, věk) srovnání se zvolenou jednotkou, kolikrát je větší?


číselné **veličiny** (zápis hodnot znaků):

- **spojité:** intervalové, poměrové (ordinální) měřítko
- **diskrétní:** četnosti hodnot v nominálním nebo ordinálním měřítku

2

příklad **kojení** (vzdělání matky):

vzděl.	zákl.	maturita	VŠ	celkem
$x_j^*$	1	2	3	
$n_j$	34	47	18	99
$n_j/n$	0,343	0,475	0,182	1,000
$n_j/n$	34,3 %	47,5 %	18,2 %	100 %
$N_j$	34	81	99	



4


dvojice znaků –  
 možnost porovnání či zkoumání závislosti  
 (kontingenční tabulka)  
 v procentech v dané skupině (pro danou hodnotu jednoho znaku)

**příklad kouření u mužů**

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

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




(zdola: nekuřák, bývalý kuřák, kuřák, silný kuřák)


histogram u **spojité** veličiny – **třídění**: všechny hodnoty z daného intervalu  $(t_{j-1}, t_j)$  nahradíme prostřední hodnotou  $x_j^* = (t_{j-1} + t_j)/2$

**hmotnost dětí (příklad děti)**

$j$	$x_j^*$	$t_j$	$n_j$	$n_j/n$	$N_j$	$N_j/n$
1	7750	8000	42	0,026	42	0,026
2	8250	8500	104	0,063	146	0,089
3	8750	9000	173	0,106	319	0,195
4	9250	9500	225	0,138	544	0,333
5	9750	10000	315	0,193	859	0,526
6	10250	10500	257	0,157	1116	0,683
7	10750	11000	210	0,129	1326	0,812
8	11250	11500	133	0,081	1459	0,893
9	11750	12000	88	0,054	1547	0,947
10	12250	12500	47	0,029	1594	0,976
11	12750	13000	28	0,017	1622	0,992
12	13250	$\infty$	11	0,007	1633	1,000




**kumulativní četnosti** ukazují vždy podíl dětí, jejichž hmotnost je **nejvýše** rovna  $t_j$



**empirická distribuční funkce**: relativní četnost hodnot, které jsou nejvýše  $x$

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




$x$  – výšky desetiletých hochů  
 $y$  – výšky desetiletých dívek

$i$	1	2	3	4	5	6	7	8
$x_i$	130	140	136	141	139	133	149	151
$y_i$	135	141	143	132	146	146	151	141

$i$	9	10	11	12	13	14	15	
$x_i$	139	136	138	142	127	139	147	
$y_i$	141	131	142	141				



## uspořádaný seznam hodnot

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

**pořadí** na které místo se dané pozorování v uspořádaném seznamu dostane (při shodě průměrné pořadí)

**míry polohy:**  $\mu(a + bX) = a + b\mu(X)$

- průměr**

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

- medián** (dolní a horní polovina hodnot)

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

- minimum, maximum**

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

- variační průměr**

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

9

- p-tý percentil** (dolních 100p % hodnot)

$$r = [(n+1)p] \quad \text{celá část } (n+1)p \\ q = (n+1)p - r \quad \text{zlomková část } (n+1)p$$

$$x_p = (1-q)x_{(r)} + qx_{(r+1)}$$


- dolní kvartil** (oddělí dolní čtvrtinu)

$$Q_1 = x_{1/4}$$

- horní kvartil** (oddělí dolní tři čtvrtiny)

$$Q_3 = x_{3/4}$$

krabicový diagram



10

výšky dívek

$j$	1	2	3	4	5	6	7	8
$y_j^*$	131	132	135	141	142	143	146	151
$n_j$	1	1	1	4	1	1	2	1
poř.	1	2	3	5,5	8	9	10,5	12

$$\bar{y} = \frac{1}{12}(131 + 132 + \dots + 151) = 140,83$$

$$\tilde{y} = \frac{1}{2}(y_{(6)} + y_{(7)}) = \frac{1}{2}(141 + 141) = 141$$

$$r = [(12+1)/4] = 3 \quad q = (12+1)/4 - 3 = 1/4$$

$$Q_1 = \frac{3}{4}y_{(3)} + \frac{1}{4}y_{(4)} = 0,75 \cdot 135 + 0,25 \cdot 141 = 136,5$$

$$Q_3 = 0,25 \cdot 143 + 0,75 \cdot 146 = 145,25$$

$$s_y^2 = \frac{1}{11} \left( (131 - 140,83)^2 + \dots + (151 - 140,83)^2 \right) \\ \doteq 33,788$$

$$s_y = \sqrt{33,788} \doteq 5,813$$

$$R = 151 - 131 = 20$$

$$R_Q = 145,25 - 136,5 = 8,75$$

vztah mužů ke kouření (základní vzdělání):

$$H = \frac{14}{117} \log \frac{14}{117} + \dots + \frac{78}{117} \log \frac{78}{117} = 1,000689$$

ostatní: 1,025939; 1,109783; 1,217334

11

**míry variability** (měřítka)

$$\sigma(a + bX) = b\sigma(X) \quad (b > 0)$$

- směrodatná odchylka**

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

- rozptyl**  $s_x^2$  (nesplňuje vztah)

- rozpětí**  $R = x_{\max} - x_{\min}$

- kvartilové rozpětí**  $R_Q = Q_3 - Q_1$

- variační koeficient**

porovnání variability při různých úrovních

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

- entropie** (nejistota nominální)


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

(nezávisí na označení hodnot)

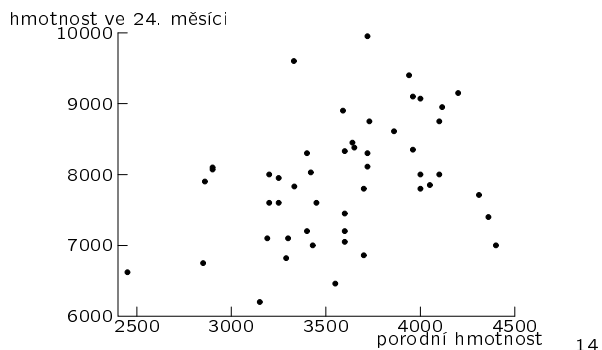
12

## další grafická znázornění

- srovnání souborů dat



- závislost spojitých veličin (bodový diagram)



**z-skór** (normovaná veličina)

$$z_i = \frac{x_i - \bar{x}}{s_x}$$

platí  $\bar{z} = 0$ ,  $s_z = 1 \Rightarrow$

vyšetřováním  $z$  hodnotíme jiné vlastnosti, na poloze a variabilitě nezávislé

- šikmost

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

- špičatost

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


(někdy bez odečítání 3)

$g_1, g_2$  se používají k posouzení normality

13




## další grafická znázornění

- normální diagram
  - k ověřování předpokladu **normálního** rozdělení (častý předpoklad)
  - srovnání bodů s přímkou



$$g_1 = 0,521, \quad g_2 = -0,321$$

15



$$g_1 = -0,893, g_2 = 3,511$$

$$g_1 = 0,760, g_2 = 0,013$$

16

## Pravděpodobnost $P(B)$

- objektivní číselné vyjádření „naděje“, že nastane  $B$
- modelový protějšek relativní četnosti
- vlastnosti psti
  - $0 \leq P(B) \leq 1$
  - $P(\Omega) = 1, P(\emptyset) = 0$
  - $B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$
  - $P(B \cup D) = P(B) + P(D) - P(B \cap D)$
  - $B \subset D \Rightarrow P(B) \leq P(D)$
  - $P(\bar{B}) = 1 - P(B)$
- **klasická definice psti:**  $m$  stejně pravděpodobných elementárních jevů,  $m_B$  příznivých  $B$

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


## Náhodné jevy

- **náhodný pokus** výsledek nejistý, při opakování stabilita frekvence možných výsledků
- **náhodný jev** tvrzení o výsledku náhodného pokusu, podmnožiny množiny  $\Omega$
- **jistý jev**  $\Omega$  nastává vždy
- **nemožný jev**  $\emptyset$  nenastává nikdy
- **podjev:**  $B \subset D$  znamená  $B \Rightarrow D$
- **jev opačný:**  $\bar{D} \Leftrightarrow$  neplatí  $D$
- **průnik jevů**  $B \cap D$  nastaly oba jevy
- **sjednocení jevů**  $D \cup B$  nastal aspoň jeden
- **neslučitelné jevy**  $B \cap D = \emptyset$


17

18


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




$$B \cap D = \emptyset \Rightarrow P(B \cup D) = P(B) + P(D)$$



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



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



19

20

příklad **rodina**: tři sourozenci, celkem 8 elementárních jevů  $\omega_1, \dots, \omega_8$

$\omega_i$	$D$	$B$	$B \cap D$	$B \cup D$	$C$
$(m, m, m)$					+
$(f, m, m)$	+	+	+	+	+
$(m, f, m)$		+		+	+
$(f, f, m)$	+			+	+
$(f, f, f)$	+			+	
$(m, f, f)$					
$(f, m, f)$	+			+	
$(m, m, f)$		+		+	

$D$  nejmladší je dívka,  $P(D) = 4/8 = 1/2$   
 $B$  v rodině je jediná dívka,  $P(B) = 3/8$   
 $B \cap D$  jediná dívka je nejmladší,  $P(B \cap D) = 1/8$   
 $P(B \cup D) = P(B) + P(D) - P(B \cap D) = \frac{3}{8} + \frac{4}{8} - \frac{1}{8} = \frac{6}{8}$   
 $C$  nejstarší je hoch,  $P(C) = 4/8 = 1/2$   
 Když víme, že nejstarší je hoch ( $C$ ), jaká je pak pst, že nejmladší je dívka ( $D$ )?

$$\boxed{2/4 = 1/2}$$

**stejně**, jako když jsme nic nevěděli  
 pst jevu  $D$  **nezávisí** na tom, zda platí  $C$

**nezávislost**: pst jevu  $D$  nezávisí na tom, zda  $B$  nastal či nenastal:  $D, B$  **nezávislé jevy**  
**podmíněná pst** (pst  $D$  za podmínky  $B$ )

$$P(D|B) = \frac{P(D \cap B)}{P(B)} = \frac{m_{D \cap B}}{m_B} = \frac{m_{D \cap B}/m}{m_B/m}$$

**nezávislost**  $D, B$

$$P(D \cap B) = P(D)P(B)$$

příklad **rodina**:

$$P(B \cap D) = \frac{1}{8} \neq \frac{3}{8} \cdot \frac{4}{8} = P(B)P(D) \Rightarrow B, D \text{ závislé}$$

$$P(B|D) = \frac{P(B \cap D)}{P(D)} = \frac{1/8}{4/8} = \frac{1}{4}$$

$$P(B|\bar{D}) = \frac{P(B \cap \bar{D})}{P(\bar{D})} = \frac{2/8}{4/8} = \frac{1}{2}$$

$$P(B) = \frac{3}{8}$$

**HWE** (zákon Hardyův-Weinbergův)

- diploidní populace
- na daném lokusu dvě alely:  $A, a$
- pst alely  $A$  v populaci  $p$
- pst alely  $a$  v populaci  $q = 1 - p$
- nezávislé sdružování alel znamená

$$P(AA) = P(A)P(A) = p^2$$

$$P(aa) = P(a)P(a) = q^2$$

$$P(Aa) = P(A)P(a) + P(a)P(A) = 2pq$$

**děti** (otitidy a záněty HCD)

	HCD	bez HCD	celkem
bez otitidy	5168	2088	7256
otitida	2747	163	2910
celkem	7915	2251	10166

	HCD	bez HCD	celkem
bez otitidy	0,508	0,205	0,714
otitida	0,270	0,016	0,286
celkem	0,779	0,221	1,000

podmíněno HCD

	HCD	bez HCD	celkem
bez otitidy	0,653	0,928	0,714
otitida	0,347	0,072	0,286
celkem	1,000	1,000	1,000

	HCD	bez HCD
bez otitidy		
otitida		

### děti (otitidy a záněty HCD)

	HCD	bez HCD	celkem
bez otitidy	5168	2088	7256
otitida	2747	163	2910
celkem	7915	2251	10166

	HCD	bez HCD	celkem
bez otitidy	0,508	0,205	0,714
otitida	0,270	0,016	0,286
celkem	0,779	0,221	1,000

podmíněno otitidou

	HCD	bez HCD	celkem
bez otitidy	0,712	0,288	1,000
otitida	0,944	0,056	1,000
celkem	0,779	0,221	1,000

	HCD	bez HCD
bez otitidy		
otitida		

25

předpoklad:

- $H_1, \dots, H_k$  neslučitelné
- sjednocení  $H_1, \dots, H_k$  – jev jistý

vzorec pro úplnou pst

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

Bayesův vzorec

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

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

$H_1, \dots, H_k$  – hypotézy

$P(H_1), \dots, P(H_k)$  – apriorní psti

$P(H_1|C), \dots, P(H_k|C)$  – aposteriorní psti

26

příklad **děti**  $C$  – otitida

$H_j$  – výskyt zánětu HCD

$H_j$	$P(H_j)$	$P(C H_j)$	součin
bez HCD	0,221	0,072	0,016
jednou HCD	0,223	0,276	0,061
opakovaně HCD	0,555	0,376	0,208
součet	1,000		0,286

$$P(C) = 0,286$$

$$P(H_3|C) = \frac{0,376 \cdot 0,555}{0,286} = 0,728$$

pst opakovaného zánětu HCD u otitid

	$P(H_3 C) = 0,728$
--	--------------------

pst opakovaného zánětu HCD u všech

	$P(H_3) = 0,555$
--	------------------

pst opakovaného zánětu HCD u NEotitid

	$P(H_3 \bar{C}) = 0,485$
--	--------------------------

27

příklad: senzitivita, specifická testu

- $D, \bar{D}$  – nemocná/zdravá osoba
- $P, \bar{P}$  – pozitivní/negativní výsledek testu
- $P(P|D)$  – **senzitivita** testu (0,98)
- $P(\bar{P}|\bar{D})$  – **specifická** testu (0,99)
- $P(D)$  – **incidence** nemoci (apriorní pst) (0,001)

$$P(D|P) = \frac{P(P|D)P(D)}{P(P|D)P(D) + P(P|\bar{D})P(\bar{D})}$$

$$= \frac{0,98 \cdot 0,001 + 0,01 \cdot 0,999}{0,00098 + 0,01097} = 0,089$$

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

28

**Příklad rodina**  
náhodná veličina – počet děvčat

**náhodná veličina**

- číselně vyjádřený výsledek náhodného pokusu
- každému elementárnímu jevu přiřadíme reálné číslo
- **diskrétní rozdělení**
  - možné hodnoty  $x^*$
  - psti hodnot  $P(x_j^*)$  (pstní funkce)
- **spojité rozdělení**
  - interval možných hodnot
  - hustota  $f(x)$

$\omega_i$	$x_i$	$x_i - \mu_X$	$(x_i - \mu_X)^2$	$x_j^*$
$(m, m, m)$	0	-1,5	2,25	0
$(m, m, f)$	1	-0,5	0,25	1
$(m, f, m)$	1	-0,5	0,25	
$(f, m, m)$	1	-0,5	0,25	
$(f, f, m)$	2	0,5	0,25	2
$(f, m, f)$	2	0,5	0,25	
$(m, f, f)$	2	0,5	0,25	
$(f, f, f)$	3	1,5	2,25	3
součet	12	0,0	6,00	

$j$	$x_j^*$	$m_j$	$P(X = x_j^*)$
1	0	1	1/8
2	1	3	3/8
3	2	3	3/8
4	3	1	1/8
součet		8	8/8

**distribuční funkce**  $F_X(x) = P(X \leq x)$

- diskrétní rozdělení  $F(x) = \sum_{t \leq x} P(X = t)$
  - spojité rozdělení  $F(x) = \int_{-\infty}^x f(t) dt$   
zřejmě pak:
- $$f(x) = \frac{dF(x)}{dx}$$
- vlastnosti distribuční funkce

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


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

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

$$P(X \leq x_2) = P(X \leq x_1) + P(x_1 < X \leq x_2)$$

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

geometrický význam **distribuční funkce**



$$P(X \leq x_2) = P(X \leq x_1) + P(x_1 < X \leq x_2)$$

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






příklad pro **diskrétní** rozdělení  
rozdělení počtu děvčat  $X$

$$f(x) \geq 0$$

$$\int_{-\infty}^{\infty} f(x) dx = 1$$

$j$	$x_j^*$	$m_j$	$P(X = x_j^*)$	$F_X(x_j^*)$
1	0	1	1/8	1/8
2	1	3	3/8	4/8
3	2	3	3/8	7/8
4	3	1	1/8	8/8
součet		8	8/8	



33

34

**střední hodnota  $\mu$**

- míra polohy, **populační průměr**
- vážený průměr možných hodnot
- diskrétní:  $\mu_X = \sum_j x_j^* P(X = x_j^*)$
- spojitě  $\mu_X = \int_{-\infty}^{\infty} x f(x) dx$
- metoda výpočtu se značí  $E X$

příklad **rodina**


$j$	$m_j$	$x_j^*$	$P(X = x_j^*)$	$x_j^* \cdot P(X = x_j^*)$
1	1	0	0,125	0,000
2	3	1	0,375	0,375
3	3	2	0,375	0,750
4	1	3	0,125	0,375
součet			1,000	1,500

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


$$= 0 \cdot 0,125 + 1 \cdot 0,375 + 2 \cdot 0,375 + 3 \cdot 0,125$$

$$= 1,5$$

**$p$ -kvantil  $x_p$**



**kritická hodnota  $x(\alpha)$**



$$x_{1-\alpha} + x(\alpha) = 1$$

$$x_p + x(1-p) = 1$$

35

36

## rozptyl $\sigma^2$ ( $\sigma$ směr. odchylka)

- míra variability, **populační rozptyl**
- velikost kolísání kolem střední hodnoty
- metoda výpočtu se značí  $\text{var } X$
- pomocí střední hodnoty

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

- diskrétní  $\sigma^2 = \sum_j (x_j^* - \mu_X)^2 P(X = x_j^*)$

$j$	$x_j^*$	$p_j$	$x_j^* - \mu_X$	$(x_j^* - \mu_X)^2$	$(x_j^* - \mu_X)^2 p_j$
1	0	0,125	-1,5	2,25	0,28150
2	1	0,375	-0,5	0,25	0,09375
3	2	0,375	0,5	0,25	0,09375
4	3	0,125	1,5	2,25	0,28150
$\Sigma$		1,000	0,0		0,75000

$$\begin{aligned} \sigma_X^2 &= (0 - 1,5)^2 \cdot 0,125 + (1 - 1,5)^2 \cdot 0,375 \\ &\quad + (2 - 1,5)^2 \cdot 0,375 + (3 - 1,5)^2 \cdot 0,125 \\ &= 0,75 \\ \sigma_X &= \sqrt{0,75} = 0,866025 \end{aligned}$$

37

## sružené rozdělení:

zajímáme se o **společné** chování dvojice (trojice, ...) náhodných veličin, tedy chování **náhodného vektoru**

### Příklad rodina

$X$  počet děvčat v rodině s třemi dětmi

$Y$  počet děvčat mezi dvěma staršími dětmi

$Z$  počet hochů v rodině s třemi dětmi

$\omega_i$	$x_i$	$y_i$	$z_i$
$(m, m, m)$	0	0	3
$(m, m, f)$	1	1	2
$(m, f, m)$	1	1	2
$(f, m, m)$	1	0	2
$(f, f, m)$	2	1	1
$(f, m, f)$	2	1	1
$(m, f, f)$	2	2	1
$(f, f, f)$	3	2	0

rozdělení náhodného vektoru  $(X, Y)$

proč nemá smysl uvažovat **vektor**  $(X, Z)$ ?

38

## sružené rozdělení:

popisuje **společné chování** veličin pomocí jejich **sruženého** rozdělení:

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

**marginální** rozdělení – chování jedné veličiny

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

**kovariance** vyjadřuje závislost náh. veličin:

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

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

zřejmě platí  $\text{cov}(X, X) = \text{var } X$

**nezávislost** náhodných veličin:

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

$X, Y$  – nezávislé  $\Rightarrow \sigma_{X,Y} = 0$

(nikoliv obráceně)

### Příklad rodina

$X$  počet děvčat v rodině s třemi dětmi

$Y$  počet děvčat mezi dvěma staršími dětmi

$x_i^*$	$y_j^*$			celkem
	0	1	2	
0	0,125	0	0	0,125
1	0,125	0,250	0	0,375
2	0	0,250	0,125	0,375
3	0	0	0,125	0,125
celkem	0,250	0,500	0,250	1,000

$$\mu_X = 0 \cdot 0,125 + 1 \cdot 0,375 + 2 \cdot 0,375 + 3 \cdot 0,125 = 1,5$$

$$\mu_Y = 0 \cdot 0,250 + 1 \cdot 0,500 + 2 \cdot 0,250 = 1$$

$X, Y$  – závislé, např.  $0,25 \cdot 0,125 \neq 0,125$

výpočet kovariance  $\sigma_{XY} = \text{cov}(X, Y)$ :

$$\begin{aligned} \sigma_{XY} &= (0 - 1,5) \cdot (0 - 1) \cdot 0,125 \\ &\quad + (1 - 1,5) \cdot (0 - 1) \cdot 0,125 \\ &\quad + (1 - 1,5) \cdot (1 - 1) \cdot 0,250 \\ &\quad + (2 - 1,5) \cdot (1 - 1) \cdot 0,250 \\ &\quad + (2 - 1,5) \cdot (2 - 1) \cdot 0,125 \\ &\quad + (3 - 1,5) \cdot (2 - 1) \cdot 0,125 \\ &= 0,5 \end{aligned}$$

39

40

## střední hodnota $X$ (mean value)

$$\begin{aligned}\mu_X &= \mathbf{E} X \\ &= \sum_j x_j^* \mathbf{P}(X = x_j^*) \\ &= \int_{-\infty}^{\infty} x f_X(x) dx\end{aligned}$$

střední hodnota  $Y = g(X)$

$$\begin{aligned}\mu_Y &= \mathbf{E} g(X) \\ &= \sum_j g(x_j^*) \mathbf{P}(X = x_j^*) \\ &= \int_{-\infty}^{\infty} g(x) f_X(x) dx\end{aligned}$$

rozptyl  $X$  (variance, (standard deviation)<sup>2</sup>)

$$\begin{aligned}\sigma_X^2 &= \text{var } X = \mathbf{E} (X - \mu_X)^2 \\ &= \sum_j (x_j^* - \mu_X)^2 \mathbf{P}(X = x_j^*) \\ &= \int_{-\infty}^{\infty} (x - \mu_X)^2 f_X(x) dx\end{aligned}$$

kovariance  $X$  a  $Y$  (covariance)

$$\begin{aligned}\sigma_{X,Y} &= \text{cov}(X, Y) = \mathbf{E} (X - \mu_X)(Y - \mu_Y) \\ &= \sum_{i,j} (x_i^* - \mu_X)(y_j^* - \mu_Y) \mathbf{P}(X = x_i^*, Y = y_j^*) \\ &= \int_{-\infty}^{\infty} (x - \mu_X)(y - \mu_Y) f_{X,Y}(x, y) dx dy\end{aligned}$$

41

vlastnosti populačního průměru a rozptylu

$$\begin{aligned}\mu_{\alpha+\beta X} &= \alpha + \beta \mu_X, \\ \sigma_{\alpha+\beta X}^2 &= \beta^2 \sigma_X^2, \\ \sigma_{\alpha+\beta X} &= |\beta| \sigma_X, \\ \mu_{X+Y} &= \mu_X + \mu_Y, \\ \sigma_{X+Y}^2 &= \sigma_X^2 + \sigma_Y^2 + 2\sigma_{XY}.\end{aligned}$$

ukázka důkazu:

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

jsou-li  $X, Y$  **nezávislé**, pak

$$\begin{aligned}\sigma_{XY} &= 0 \\ \sigma_{X+Y}^2 &= \sigma_X^2 + \sigma_Y^2\end{aligned}$$

**normování** náhodné veličiny  $X$

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

42

vlastnosti nezávislé na  $\mu_X, \sigma_X^2$ :  
(populační) **korelační koeficient**  
(correlation coefficient)

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

(populační) **šikmost** náhodné veličiny  $X$   
(skewness)

$$\begin{aligned}\gamma_1 &= \mathbf{E} \left( \frac{X - \mu_X}{\sigma_X} \right)^3 \\ &= \frac{\mathbf{E} (X - \mu_X)^3}{\sigma_X^3}\end{aligned}$$

(populační) **špičatost** náhodné veličiny  $X$   
(kurtosis, někdy se neodečítá 3)

$$\begin{aligned}\gamma_2 &= \mathbf{E} \left( \frac{X - \mu_X}{\sigma_X} \right)^4 - 3 \\ &= \frac{\mathbf{E} (X - \mu_X)^4}{\sigma_X^4} - 3\end{aligned}$$

43

## Důležitá diskrétní rozdělení

**alternativní** (nula-jedničkové) rozdělení

- *zdar* nebo *nezdar*
- $\mathbf{P}(X = 1) = \pi, \mathbf{P}(X = 0) = 1 - \pi, (0 < \pi < 1)$
- $\mathbf{E} X = 1 \cdot \pi + 0 \cdot (1 - \pi) = \pi$
- $\text{var } X = (1 - \pi)^2 \cdot \pi + (0 - \pi)^2 \cdot (1 - \pi) = \pi(1 - \pi)$


**binomické rozdělení**  $Y \sim \text{bi}(n, \pi)$

- $n$  **nezávislých** pokusů
- $\mathbf{P}(\text{zdar}) = \pi, \mathbf{P}(\text{nezdar}) = 1 - \pi, (0 < \pi < 1)$
- $Y$  je počet zdarů v těchto pokusech
- $\mathbf{P}(Y = k) = \binom{n}{k} \pi^k (1 - \pi)^{n-k}, \quad k = 0, 1, \dots, n$
- $Y = \sum_{i=1}^n X_i, X_i$  – zda zdar v  $i$ -tém pokusu
- $\mathbf{E} Y = \mathbf{E} (\sum_{i=1}^n X_i) = \sum_{i=1}^n \mathbf{E} X_i = n\pi$
- $\text{var } Y = \text{var} (\sum_{i=1}^n X_i) = \sum_{i=1}^n \text{var } X_i$   
=  $n\pi(1 - \pi)$  (nezávislost  $X_i!$ )

44

**Poissonovo** rozdělení  $X \sim \text{Po}(\lambda)$

- zákon vzácných (řídkých) jevů
- kolikrát nastal jev během jednotkového časového intervalu, na jednotkové ploše, v jednotkovém objemu ...
- $P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 0, 1, \dots$
- $E X = \lambda, \text{ var } X = \lambda$
- pro velké  $n$  a malé  $\pi$  lze rozdělení  $\text{bi}(n, \pi)$  aproximovat pomocí rozdělení  $\text{Po}(n\pi)$
- $\text{bi}(10, 0,1)$  (hůlky) vers.  $\text{Po}(1)$  (tečky)




45

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

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}},$$

$$E X = \mu, \text{ var } X = \sigma^2$$



$$N(0, 1): \varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}, \quad \Phi(x) = \int_{-\infty}^x \varphi(t) dt$$

$$X \sim N(\mu, \sigma^2), \text{ pak}$$

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

- $V$  má **logaritmicko-normální** rozdělení:

$$\ln V \sim N(\mu, \sigma^2)$$

- aproximace binomického rozdělení  $\text{bi}(n, \pi)$  pomocí  $N(n\pi, n\pi(1-\pi)) \quad (n\pi(1-\pi) > 9)$

46

- kritické hodnoty normálního rozdělení

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

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

- kritické hodnoty Studentova  $t$  rozdělení

$$T \sim t(k) : P(|T| > t_k(\alpha)) = \alpha$$

$\alpha$	0,10	0,05	0,01
$z(\alpha/2)$	1,645	1,960	2,576
$t_{100}(\alpha)$	1,660	1,984	2,626
$t_{20}(\alpha)$	1,725	2,086	2,845
$t_5(\alpha)$	2,015	2,571	4,032

- kritické hodnoty Fisherova  $F$  rozdělení

$$F \sim F(k, m) : P(F > F_{k,m}(\alpha)) = \alpha$$


- kritické hodnoty rozdělení chí-kvadrát

$$X^2 \sim \chi^2(k) : P(X^2 > \chi_k^2(\alpha)) = \alpha$$


$$\chi_1^2(0,05) = 1,960^2 = 3,841$$

47

srovnání normálního a Studentova rozdělení  
čárkovaně  $t(1)$ , tečkovaně  $t(10)$ ,  
plná čára  $N(0, 1)$ )



srovnání binomického a normálního rozdělení  
 $\text{bi}(60, 1/6)$ ,  $\text{bi}(60, 3/6)$ ,  $\text{bi}(60, 4/6)$ )



48

## populace – výběr

- **populace (základní soubor)**

soubor jednotek, o jejichž hromadných vlastnostech chceme vypovídat (všechny možné výsledky pokusu, všichni hoši zvoleného věku, všichni čolci v rybníčku)  
 ⇒ rozdělení náhodné veličiny

- **výběr**

náhodně vybraná část populace, kterou vyšetřujeme, vzorek populace

- **náhodný výběr**

nezávislé náhodné veličiny se stejným rozdělením (neměřené na výběru)

- **parametr**

neznámé číslo popisující nějaký rys populace, charakteristika rozdělení náh. vel.

- **statistika**

funkce náhodného výběru

- **odhad**

statistika použitá k odhadu parametru

49

- $X_1, \dots, X_n$  nezávislé, stejné rozdělení  
 $E X_i = \mu$  populační průměr  
 $var X_i = \sigma^2$  populační rozptyl

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

- $E \bar{X} = \mu$  výběrový průměr je **nestranným** odhadem populačního

- $var \bar{X} = \frac{\sigma^2}{n} = (S.E.(\bar{X}))^2$   
 $n$ -krát menší, než u jednoho pozorování!

- u **normálního** rozdělení:  $X_i \sim N(\mu, \sigma^2)$

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

- **interval spolehlivosti** pro  $\mu$ :

$$(\bar{X} - S.E.(\bar{X})z(\alpha/2), \bar{X} + S.E.(\bar{X})z(\alpha/2))$$





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

- požadujeme int. spolehlivosti šířky  $2c\sigma$ :

$$n \geq \left( \frac{z(\alpha/2)}{c} \right)^2$$

50

### příklad děti (věk matek) (100 průměrů)




51

průměrný věk matek v opak. výběrech:

rozsah výběru $n$	průměr průměrů	směr. odch. průměrů	šikmost průměrů	špičatost průměrů
1	26,42	5,182	0,529	-0,679
10	25,56	1,475	0,140	-0,771
100	25,30	0,529	0,027	-0,303
1000	25,40	0,158	-0,040	-0,284
populace	25,40	4,943	0,773	0,192

95% intervaly spolehlivosti ( $n = 100$ ):



52

## statistické rozhodování

- **nulová hypotéza  $H_0$**   
tvrzení o populaci (parametru), o jehož platnosti chceme rozhodnout, zpravidla zamítnout
- **alternativní hypotéza  $H_1$**  (alternativa)  
zbývající možnost (k  $H_0$ )
- **kritický obor**  
možné výsledky pokusu, kdy  $H_0$  zamítáme
- **obor přijetí**  
možné výsledky pokusu, kdy  $H_0$  nezamítáme
- **chyba prvního druhu**  
rozhodnutí zamítnout  $H_0$ , když platí  $H_0$
- **chyba druhého druhu**  
rozhodnutí nezamítnout  $H_0$ , když platí  $H_1$
- **hladina testu  $\alpha$**  (zpravidla 5 %, 1 %)  
maximální dovolená pst chyby prvního druhu

53


rozhodnutí	skutečnost	
	$H_0$ platí	$H_0$ neplatí
$H_0$ zamítnout (reject)	chyba 1. druhu ( $\leq \alpha$ )	správné rozhodnutí ( $1 - \beta$ )
$H_0$ nezamítnout (accept)	správné rozhodnutí ( $\geq 1 - \alpha$ )	chyba 2. druhu ( $\beta$ )

- hladina testu  $\alpha$  se volí před pokusem (aby nezávisela na jeho výsledku)
- **síla testu  $1 - \beta$**   
pravděpodobnost zamítnutí neplatné  $H_0$
- kritický obor zpravidla popsán pomocí statistiky (např.  $|T| \geq t_{n-1}(\alpha)$ )
- **dosažená hladina testu  $p$**  ( $p$  value)  
za platnosti  $H_0$  určená pst, že dostaneme statistiku, která stejně nebo ještě méně podporuje  $H_0$  (nejmenší hladina  $\alpha$ , na které lze ještě  $H_0$  zamítnout),  
např.  $p = P(|T| \geq t)$ , kde  $t$  je skutečně realizovaná hodnota statistiky  $Z$
- $H_0$  se **zamítá**, když  $p \leq \alpha$

54

rozhodování o populačním průměru normálního rozdělení se známým rozptylem

- $X_1, \dots, X_n \sim N(\mu, \sigma^2)$  **nezávislé**
- $\sigma > 0$  známe
- $H_0 : \mu = \mu_0$  (dané číslo)
- platí-li  $H_0$ , pak
 
$$Z = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \sim N(0, 1)$$
- $H_1 : \mu \neq \mu_0 \Rightarrow$  kritický obor:  
 $|Z|$  velké, tj.  $|Z| \geq z(\alpha/2)$
- $H_1 : \mu > \mu_0$ : zamítnout pro  $Z \geq z(\alpha)$
- $H_1 : \mu < \mu_0$ : zamítnout pro  $Z \leq -z(\alpha)$



55

příklad **výšky** desetiletých hochů ([cm])

130	140	136	141	139
133	149	151	139	136
138	142	127	139	147

$\sigma = 6,4$  (známo z dřívějších),  $\alpha = 0,05$   
 $H_0 : \mu = 136,1$  (před 10 lety),  $H_1 : \mu \neq 136,1$

$$\bar{x} = \frac{1}{15} (130 + 140 + \dots + 147) = 139,133$$

$$z = \frac{139,133 - 136,1}{6,4} \sqrt{15} = 1,835$$


$|z| < z(0,05/2) = 1,960$   
 $\Rightarrow H_0$  nelze na 5% hladině zamítnout  
 ale  $|z| \geq z(0,10/2) = 1,645$   
 $\Rightarrow H_0$  se na 10% hladině zamítá

$p = P(|Z| \geq 1,835) = 0,067$   
 dosažená hladina ( $p$  value) je 6,7 %


**jednostranná alternativa** (předem!):

$H_1 : \mu > 136,1$ :  $z \geq 1,645$  na 5 % zamítnout  
 $p = P(Z \geq 1,835) = 0,033 (< 0,05)$

56



a) Hustota Z za platnosti  $H_0$




b) Hustota  $\bar{X}$  při  $H_0$  a při  $H_1 : \mu = 140, \sigma = 6,4$

**síla testu  $1 - \beta$**

pravděpodobnost, že zamítneme nulovou hypotézu, když testovaný parametr je roven ... (závisí na skutečné hodnotě parametru)

příklad **výšky**,  $n = 15, \mu_0 = 136,1, \sigma = 6,4$



**volba rozsahu výběru:** pro  $\mu_1$  požadujeme sílu  $1 - \beta$ :

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

aby pro  $\mu_1 = 140$  byla síla 90 % ( $z(0,1) = 1,282$ ), bude třeba aspoň

$$n \geq \left( \frac{1,96 + 1,282}{140 - 136,1} \right)^2 6,4^2 = 28,3$$

$$\begin{aligned} \text{S.E.}(\bar{X}) &= \sqrt{\frac{6,4^2}{15}} = 1,6525 \Rightarrow 136,1 - 1,6525 \cdot 1,96 = 132,86 \\ &\Rightarrow 136,1 + 1,6525 \cdot 1,96 = 139,34 \end{aligned}$$

**jednovýběrový t test**

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

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

- statistika

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

- $H_1 : \mu \neq \mu_0$  zamítnat při  $|T| \geq t_{n-1}(\alpha)$
- $H_1 : \mu > \mu_0$  zamítnat při  $T \geq t_{n-1}(2\alpha)$
- $H_1 : \mu < \mu_0$  zamítnat při  $T \leq -t_{n-1}(2\alpha)$
- interval spolehlivosti pro  $\mu$

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

případ neznámého rozptylu ( $H_1 : \mu \neq 136,1$ )

$$\begin{aligned} \sum_{i=1}^n (x_i - \bar{x})^2 &= \sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2 \\ &= 130^2 + \dots + 147^2 - 15 \cdot 139,133^2 \\ &= 601,733 \\ s^2 &= \frac{601,733}{15 - 1} \\ &= 42,981 = 6,556^2 \\ t &= \frac{139,133 - 136,1}{6,556} \sqrt{15} \\ &= 1,792 \end{aligned}$$

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

95% interval spolehlivosti ( $t_{14}(0,05) = 2,145$ ):

$$\left( 139,133 - \frac{6,556}{\sqrt{15}} \cdot 2,145, 139,133 + \frac{6,556}{\sqrt{15}} \cdot 2,145 \right) \\ (135,5, 142,8)$$

**jednostranná alternativa  $H_1 : \mu > 136,1$ :**

$$\begin{aligned} t &\geq t_{14}(2 \cdot 0,05) = 1,761 \quad \text{zamítnout } H_0 (\alpha = 5\%) \\ t &< t_{14}(2 \cdot 0,01) = 2,624 \quad \text{nezamítnout } H_0 (\alpha = 1\%) \\ p &= \text{P}(T > t) = 0,0474 \quad (4,74 \%) \end{aligned}$$

## pst výskytu jevu (binomické rozdělení)

- $n$  **nezávislých** opakování dílčího pokusu
- v každém „zdar“ s pstí  $\pi$
- počet zdarů  $Y \sim \text{bi}(n, \pi)$

- odhad  $\pi$ :  $\hat{\pi} = \frac{Y}{n}$  (relativní četnost)

$$E \hat{\pi} = \pi, \quad \text{var } \hat{\pi} = \frac{\pi(1-\pi)}{n} = (\text{S.E.}(\hat{\pi}))^2$$

- intervalový odhad pro  $\pi$  (přibližný)

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

- $H_0 : \pi = \pi_0$ :

$$Z = \frac{Y - n\pi_0}{\sqrt{n\pi_0(1-\pi_0)}} = \frac{\hat{\pi} - \pi_0}{\text{S.E.}(\hat{\pi})}$$

- $H_1 : \pi \neq \pi_0$ : zamítnout  $|Z| \geq z(\alpha/2)$

- $H_1 : \pi > \pi_0$ : zamítnout  $Z \geq z(\alpha)$

- $H_1 : \pi < \pi_0$ : zamítnout  $Z \leq -z(\alpha)$

61

## příklad kalous

z 50 případů dal kalous ve 33 případech přednost infikované myši před neinfikovanou

$Y$  – počet „zdarů“,  $n = 50$ ,  $\pi$  – pst, že zvolí infikovanou  $\Rightarrow Y$  má **binomické rozdělení**

za  $H_0 : \pi = 1/2$  (myši se neliší)  $Y \sim \text{bi}(50, 1/2)$

**alternativní hypotéza**:  $H_1 : \pi > 1/2$ :

**kritický obor**: velká hodnota  $Y$  (velké  $\hat{\pi}$ )

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

s opravou na spojitost (NCSS):

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

**dosažená hladina**: za  $H_0$  počítaná pst, že dostaneme výsledek aspoň tolik odporující nulové hypotéze, jako ve skutečném pokusu:

$$\begin{aligned} p &= P(Y \geq 33) \\ &= \sum_{k=33}^{50} \binom{50}{k} 0,5^k (1-0,5)^{50-k} \\ &= 0,0164 \\ &= P(Y > 32) \quad (\text{NCSS, Prob. Calc.}) \end{aligned}$$

62

## dvouvýběrový $t$ test

- $n_X$  **nezávislých** pozorování  $X$
- $n_Y$  **nezávislých** pozorování  $Y$
- tyto výběry **nezávislé**
- rozptyly  $\sigma_X^2, \sigma_Y^2$  shodné (odhady  $S_X^2, S_Y^2$  podobné, lze ověřit)
- normální rozdělení v obou výběrech (lze ověřit pro velká  $n_X, n_Y$ , jinak podle zkušenosti)

- společný odhad rozptylu

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

- statistika

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

- $H_0 : \mu_X = \mu_Y$  zamítnout ve prospěch alternativy  $H_1 : \mu_X \neq \mu_Y$ :

$$|T| \geq t_{n_X+n_Y-2}(\alpha)$$

63

## příklad výšky dětí (opět [cm])

hoši:  $n_x = 15, \bar{x} = 139,133, s_x^2 = 42,981$

dívky:  $n_y = 12, \bar{y} = 140,833, s_y^2 = 33,788$

$H_0$ : shodné populační průměry,  $H_1$ : neshodné

$$\begin{aligned} s^2 &= \frac{14}{25} 42,981 + \frac{11}{25} 33,788 \\ &= 38,936 \end{aligned}$$

odhad  $\text{S.E.}(\bar{X} - \bar{Y})$ :

$$\sqrt{38,936 \frac{15+12}{15 \cdot 12}} = \sqrt{5,8404} = 2,4167$$

$$\begin{aligned} t &= \frac{139,133 - 140,833}{\sqrt{38,936}} \sqrt{\frac{15 \cdot 12}{15+12}} \\ &= \frac{-1,7}{2,4167} = -0,703 \end{aligned}$$

$$|t| < t_{25}(0,05) = 2,0595 \Rightarrow$$

na 5% hladině nezamítat

$$p = 0,488$$

95% int. spol. pro rozdíl popul. průměrů:

$$\begin{aligned} &(-1,700 - 2,4167 \cdot 2,0595, \quad -1,700 + 2,4167 \cdot 2,0595) \\ &(-6,7, \quad 3,3) \end{aligned}$$

nula je intervalem pokryta

64



## dvouvýběrový Wilcoxonův (Mann-Whitney)

hoši	dívky	pořadí
127		1
130		2
	131	3
	132	4
133		5
	135	6
136 136		7,5
138		9
139 139 139		11
140		13
141	141 141 141 141	16
142	142	19,5
	143	21
	146 146	22,5
147		24
149		25
151	151	26,5

### • test Mannův-Whitneyův

(dvouvýběrový Wilcoxonův)

- nahradí pozorování jejich pořadími
- dva nezávislé výběry rozsahu  $n_X, n_Y$
- spojitá rozdělení
- hypotéza: rozdělení jsou stejná, pak jsou výběry „dobře promíchané“
- určí pořadí všech (promíchaných)
- kritický obor: různá průměrná pořadí
- $W_X$  součet pořadí hodnot  $X$

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

- shodu zamítne pokud  $|Z| \geq z(\alpha/2)$  (přibližný test)
- citlivý vůči posunutí, nikoliv vůči nestejně variabilitě

65

$$w_x = 1 + 2 + 5 + 2 \cdot 7,5 + 9 + 3 \cdot 11 + 13 + 16 + 19,5 + 24 + 25 + 26,5 = 189$$

$$w_y = 3 + 4 + 6 + 4 \cdot 16 + 19,5 + 21 + 2 \cdot 22,5 + 26,5 = 189$$

$$z = \frac{189 - 15 \cdot (15 + 12 + 1)/2}{\sqrt{15 \cdot 12(15 + 12 + 1)/12}} = -1,025$$

$$p = 0,3055$$

NCSS:  $z = -1,029$  (korekce na shody)


$$p = 0,3036$$

přesně:  $p = 0,3149$

66

### • test Kolmogorovův-Smirnovův

- porovná empirické distribuční funkce
- citlivý vůči všem neshodám



67

### párové testy

- $(U_1, V_1), \dots, (U_n, V_n)$  **nezávislé** dvojice (možná závislých) náhodných veličin
- výhodná je těsná závislost uvnitř dvojic
- $X_i = U_i - V_i$  (označení rozdílů)  $X_1, \dots, X_n$  mají **stejně** rozdělení
- **párový t test**
  - **normální** rozdělení:  $X_i \sim N(\mu, \sigma^2)$
  - $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
  - $T = \frac{\bar{X}}{S.E.(\bar{X})} = \frac{\bar{X}}{S} \sqrt{n} = \frac{\bar{U} - \bar{V}}{S.E.(\bar{U} - \bar{V})}$
  - $H_0: \mu = 0$  (pak je  $\mu_U = \mu_V$ )
  - ve prospěch  $H_1: \mu \neq 0$ , když  $|T| \geq t_{n-1}(\alpha)$
  - ve prospěch  $H_1: \mu < 0$ , když  $T \leq -t_{n-1}(2\alpha)$
  - ve prospěch  $H_1: \mu > 0$ , když  $T \geq t_{n-1}(2\alpha)$
  - **jednovýběrový t test** pro  $X_i = U_i - V_i$

68

**příklad:** výšky rodičů (párová pozorování!)

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

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

(10,67; 13,92)
- 99% interval spolehlivosti: (10,14; 14,44)

69

### • znaménkový test

- stačí znát znaménka rozdílů  $U_i - V_i$
- pozorování s  $U_i = V_i$  se zpravidla vynechají
- $Y$  – počet kladných znamének
- $H_0$  : rozdělení  $U$  a  $V$  jsou stejná, pak je nutně  $Y \sim \text{bi}(n, 1/2)$
- $H_0$  zamítáme pro velká nebo malá  $Y$ :

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

### • jednovýběrový Wilcoxonův test

- nutné **symetrické** rozdělení  $U_i - V_i$
- vyloučíme případy  $U_i = V_i$
- určíme pořadí  $R_i^+$  hodnot  $|U_i - V_i|$
- $W$  součet pořadí, kde  $U_i > V_i$

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

70

**příklad** rozdíly dvou metod učení nazpaměť:

5, -1, 2, 3, -1, 4, 3, -3

### • znaménkový test

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

$$z = \frac{|5 - 8/2| - 0,5}{\sqrt{8/4}} = 0,3536 \quad p = 0,7237$$

### • Wilcoxonův test

(předpokládáme symetrii)

$u_i - v_i$	5	-1	2	3	-1	4	3	-3
$r_i^+$	8	1,5	3	5	1,5	7	5	5

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

$$z = \frac{28 - 8 \cdot 9/4}{\sqrt{8 \cdot 9 \cdot 17/24}} = \frac{10}{\sqrt{51}} = 1,4$$

$$p = 0,1614$$

71

### permutační testy - dva výběry

- $H_0$  : identické rozdělení v obou populacích
- **příklad hnojení**
  - $x$ : 50,45,42,54 (klasicky)
  - $y$ : 59,56,58,51,52 (nově)
  - $H_0$  stejné výnosy
  - $H_1$  výnosy jsou nesterjné
- porovnejme průměry:

$$\bar{x} - \bar{y} = 47,75 - 55,2 = -7,45$$

- celkem  $\binom{9}{4} = 126$  permutací – možností, kolikrát vybrat 4 hodnoty  $x$  z 9 hodnot
  - mezi nimi jsou 4 takové, že rozdíl průměrů nejvýše  $-7,45$ , což je 3,17 %
  - při oboustranné alternativě další dvě kombinace, kdy rozdíl aspoň 7,45, což je 1,59 % permutací, celkem

$$p = \frac{4 + 2}{126} = \frac{6}{126} = 0,0476 \quad (4,76 \%)$$

72

x				y				$\bar{x} - \bar{y}$	$w_x$	
50	45	42	54	59	56	58	51	52	-7,45	
3	2	1	6	9	7	8	4	5		10
*	*	*					*		-8,80	10
*	*	*						*	-8,35	11
	*	*					*	*	-7,90	12
*	*	*	*						-7,45	12
	*	*	*				*		-7,00	13
	*	*	*					*	-6,55	14
*	*	*	*		*			*	-6,55	13
	*	*	*		*	*		*	-6,10	14
	...				...					
*	*			*			*	*	-0,70	19
		*			*	*	*	*	-0,25	20
		*	*	*	*	*	*	*	-0,25	21
		*	*	*	*	*	*	*	-0,25	20
	*			*	*	*	*	*	-0,25	20
	*		*	*	*	*	*	*	-0,25	18
*		*	*	*	*	*	*	*	-0,25	20
*	*		*	*	*	*	*	*	-0,25	19
		*	*	*	*	*	*	*	0,20	21
		*	*	*	*	*	*	*	0,20	21
	...				...					
		*	*	*	*	*	*	*	6,50	27
		*	*	*	*	*	*	*	6,95	28
*				*	*	*	*	*	6,95	27
				*	*	*	*	*	7,40	28
				*	*	*	*	*	7,85	29
			*	*	*	*	*	*	8,75	30

**permutační testy - jeden výběr**

**příklad učení nazpaměť**

- $H_0$  : rozdělení je symetrické kolem nuly
- rozdíly dvou metod učení nazpaměť:
  - 5, -1, 2, 3, -1, 4, 3, -3    průměr = 1,5
- pokud jsou obě metody ekvivalentní, pak mají rozdíly náhodná znaménka
- případnou nulu lze předem vyloučit
- pro znaménka celkem  $2^8 = 256$  možností
- ideál pro průměr 0
- v 27 případech průměr aspoň 1,5, v 27 případech průměr nejvýše -1,5
- dosažená hladina je rovna pravděpodobnosti, že aspoň stejně tak daleko od hypotézy, jako skutečná data

$$p_{\text{perm}} = \frac{4+2}{126} = 0,0476 \quad p_W = \frac{4+4}{126} = 0,0635$$

$$t = -2,5238 \quad p = 0,0396$$

$$p_{\text{perm}} = \frac{27+27}{256} = \frac{54}{256} = 0,2109 \quad (21,09 \%)$$

	data								$\bar{x}$	$w$
x	5	-1	2	3	-1	4	3	-3		
r	8	1,5	3	5	1,5	7	5	5		
1	-5	-1	-2	-3	-1	-4	-3	-3	-2,75	0
2	-5	-1	-2	-3	1	-4	-3	-3	-2,50	1,5
3	-5	1	-2	-3	-1	-4	-3	-3	-2,50	1,5
4	-5	-1	2	-3	-1	-4	-3	-3	-2,25	3
5	-5	1	-2	-3	1	-4	-3	-3	-2,25	3
			...							
18	-5	1	-2	-3	-1	-4	-3	3	-1,75	6,5
19	5	-1	-2	-3	-1	-4	-3	-3	-1,50	8
			...							
27	-5	1	-2	-3	1	-4	-3	3	-1,50	8
28	5	-1	-2	-3	1	-4	-3	-3	-1,25	9,5
			...							
229	-5	1	2	3	-1	4	3	3	1,25	26,5
230	5	-1	2	3	-1	4	3	-3	1,50	28
231	5	-1	2	3	-1	4	-3	3	1,50	28
232	5	-1	2	3	1	-4	3	3	1,50	27,5
233	5	-1	2	-3	-1	4	3	3	1,50	28
234	5	1	2	3	-1	-4	3	3	1,50	27,5
235	5	1	-2	3	1	4	3	-3	1,50	28
236	5	1	-2	3	1	4	-3	3	1,50	28
237	5	1	-2	-3	1	4	3	3	1,50	28
238	-5	1	2	3	1	4	3	3	1,50	28
239	5	-1	2	3	1	4	3	-3	1,75	29,5
			...							
255	5	1	2	3	-1	4	3	3	2,50	34,5
256	5	1	2	3	1	4	3	3	2,75	36


$$p_{\text{perm}} = \frac{27+27}{256} = 0,2109$$

$$p_W = \frac{25+25}{256} = 0,1953$$


$$t = 1,5 \quad p = 0,1773$$

**příklad: játra**

pět míst na řece, vždy vyloveno po 7 rybách, zjišťována koncentrace mědi v játrech liší se tato místa svým znečištěním?



logaritmování stabilizuje rozptyl:



## analýza rozptylu jednoduchého třídění

- $Y_{11}, \dots, Y_{1n_1} \sim N(\mu_1, \sigma^2)$   
 $Y_{21}, \dots, Y_{2n_2} \sim N(\mu_2, \sigma^2)$   
 $\dots$   
 $Y_{k1}, \dots, Y_{kn_k} \sim N(\mu_k, \sigma^2)$

- **nezávislé** výběry

(shodné rozptyly, normální rozdělení)

- $H_0: \mu_1 = \dots = \mu_k$  ( $= \mu$ )

$H_1$ : neplatí  $H_0$

- rozklad součtu čtverců

$$\sum \sum (Y_{it} - \bar{Y}_{\bullet\bullet})^2 = \sum n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \sum \sum (Y_{it} - \bar{Y}_{i\bullet})^2$$


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

$$\begin{aligned} S_T &= S_A + S_e \\ f_T &= f_A + f_e \\ (n-1) &= (k-1) + (n-k) \end{aligned}$$

- $H_0$  zamítnout, je-li

$$F_A = \frac{S_A/f_A}{S_e/f_e} \geq F_{f_A, f_e}(\alpha)$$

77



78

- **model** (měření = úroveň + chyba)

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

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

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

- **mnohonásobná srovnání**

(které dvojice  $\mu_i$  (resp.  $\alpha_i$ ) se liší?)

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

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

(nutnost zachovat zvolenou hladinu testu)

- **ověření shody rozptylů**

– Leveneův test

– Bartlettův test (normalita!)

79

### tabulka analýzy rozptylu

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

### příklad játra


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

místo	počet	průměr	efekt	směr. odchylka
A	7	0,569	0,206	0,312
B	7	0,484	0,121	0,279
C	7	0,496	0,133	0,318
D	7	-0,063	-0,426	0,290
E	7	0,329	-0,034	0,144
celkem	35	0,363	0,000	0,104

$$q_{5,30}(0,05) \sqrt{\frac{0,0762}{2} \left( \frac{1}{7} + \frac{1}{7} \right)} = 4,10 \cdot 0,104 = 0,426$$

$-0,063 + 0,426 = 0,363 \Rightarrow$  na 5% hladině se liší místo D od každého z míst A, B, C

80



vzděl.	$n_i$	prům. věk	stř. chyba	souč. poř.	prům. poř.
zákl.	34	23,412	0,638	1025	30,15
mat.	47	26,278	0,543	2618	55,70
VŠ	18	28,50	0,877	1307	72,61
celk.	99	25,697		4 950	50

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

$$\chi^2_2(0,05) = 5,99$$

$$p < 0,0001$$

### Kruskalův-Wallisův test

- zobecnění dvouvýběrového Wilcoxonova testu (pořadí místo původních hodnot)
- předpoklady:
  - $k$  nezávislých výběrů
  - spojitá rozdělení
  - $H_0$ : rozdělení jsou stejná
- $T_i$  - součet pořadí v  $i$ -tém výběru

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

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

### porovnání populačních měr polohy

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

### vyšetřování závislosti

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

příklady:

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

## Korelace a regrese

### • korelace

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

### • regrese

- udává **jak** závisí střední hodnota **spojité** veličiny  $Y$  na nezávisle proměnné (proměnných)  $x$
- **nesymetrická** vlastnost
- lze použít k **prokazování** existence závislosti **závisle** proměnné  $Y$  na **nezávisle** proměnné  $x$
- umožňuje **předpovídat** hodnotu  $Y$  pro zvolenou hodnotu  $x$

85

## korelační koeficient

- (populační) korelační koeficient  $\rho_{XY}$ 
  - $|\rho_{XY}| \leq 1$
  - pro nezávislé  $X, Y$  je  $\rho_{XY} = 0$
  - měří sílu **lineární** závislosti

- (výběrový) korelační koeficient  $r_{xy}$ 
  - pro test nutno **normální** rozdělení

$$r_{XY} = \frac{S_{XY}}{\sqrt{S_X^2 S_Y^2}} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}}$$

$$S_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

- $H_0: \rho_{XY} = 0$  se na hladině  $\alpha$  zamítá:

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


- **Spearmanův** korelační koeficient

- měří sílu **monotonní** závislosti
- založen na **pořadích**  $R_i, Q_i$  hodnot  $X_i, Y_i$

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


86

### příklad tuk




výška vers. hmotnost

$$\begin{aligned} r &= 0,643 & (0,654) \\ t &= 5,814 & (5,921) \\ p &< 0,0001 & (p < 0,0001) \end{aligned}$$



výška vers. diast. tlak

$$\begin{aligned} r &= -0,145 & (-0,018) \\ t &= -1,019 & (-0,124) \\ p &= 0,3135 & (0,9017) \end{aligned}$$



puls vers. hmotnost

$$\begin{aligned} r &= -0,245 & (-0,241) \\ t &= -1,752 & (-1,701) \\ p &= 0,0862 & (0,0955) \end{aligned}$$

87

## Fisherova Z transformace

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

- příklad **děti**: porodní délka, hmotnost
  - dívky:  $r_1 = 0,5687$ ,  $n_1 = 51$

$$z_1 = \frac{1}{2} \log \frac{1+0,5687}{1-0,5687} = 0,6456$$

- hoši:  $r_2 = 0,5967$ ,  $n_2 = 49$ ,  $z_2 = 0,6880$

- test shody

$$z^* = \frac{0,6456 - 0,6880}{\sqrt{\frac{1}{51-3} + \frac{1}{49-3}}} = -0,2055.$$

srovnej se  $z(0,05/2) = 1,960$ ,  $p = 0,8376$

- 95% interval spolehlivosti pro  $\rho_1$

$$\begin{aligned} &\left(0,6456 - \frac{1,960}{\sqrt{51-3}}, \quad 0,6456 + \frac{1,960}{\sqrt{51-3}}\right) \\ &\quad (0,363, \quad 0,929) \\ &\left(\frac{e^{2 \cdot 0,363} - 1}{e^{2 \cdot 0,363} + 1}, \quad \frac{e^{2 \cdot 0,929} - 1}{e^{2 \cdot 0,929} + 1}\right) \\ &\quad (0,348, \quad 0,730) \end{aligned}$$

88


## regrese (původ pojmu)

- tendence (návrat) k průměrnosti
  - F. Galton (1886): Family likeness in stature. Proc. Roy. Soc. XL, 42
  - F. Galton (1886): Regression towards mediocrity in hereditary stature. Journ. Anthropol. Inst. XV, 246
- uvažujme otce, jejichž výška je rovna průměrné výšce generace **všech** otců; průměrná výška synů těchto otců bude rovna průměrné výšce **všech** synů
- uvažujme otce o 10 cm **vyšší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen asi o 5 cm **vyšší**, než průměrná výška generace synů
- uvažujme otce o 10 cm **nižší**, než je průměrná výška generace otců: průměrná výška synů těchto otců bude jen o asi 5 cm **nižší**, než průměrná výška generace synů

89

## regresní přímka

- odhadovaná závislost:  $EY = \beta_0 + \beta_1 x$
- k daným  $x_1, \dots, x_n$  zjistíme  $Y_1, \dots, Y_n$ 
  - nezávislá** pozorování
  - stejný** rozptyl  $\sigma^2$
  - normální** rozdělení (pro testy)
- $b_0, b_1$  – odhady metodou **nejmenších čtverců**: minimalizovat 
$$\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$



90

- odhad závislosti  $EY = \beta_0 + \beta_1 x$

$$\hat{Y} = b_0 + b_1 x$$

- $b_1$  – odhad směrnice  $\beta_1$ , odhad změny střední hodnoty závisle proměnné  $Y$  při **jednotkové změně** nezávisle proměnné  $x$

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

- reziduální součet čtverců:

$$S_e = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2 = \sum_{i=1}^n U_i^2$$

- reziduální rozptyl

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

- koeficient determinace** (podíl variability  $Y$  vysvětlené uvažovanou závislostí)

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

- nezávislost  $EY$  na  $x$  znamená  $H_0: \beta_1 = 0$

$$T = \frac{b_1}{\text{S.E.}(b_1)} \quad |T| \geq t_{n-2}(\alpha)$$

91

**příklad** závislost procenta tuku FAT na výšce HEIGHT u mladých mužů

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

předpověď:  $\hat{Y}_i = -53,870 + 0,379 x_i$ ,

tedy  $\widehat{\text{FAT}} = -53,870 + 0,379 \cdot \text{HEIGHT}$

(na každý centimetr výšky *v průměru* 0,379 procentního hodu)

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

$$R^2 = \frac{362,54}{2676,95} = 1 - \frac{2314,41}{2676,95} = 0,135$$

92

## mnohonásobná lineární regrese

- závislost na dvou nezávisle proměnných
- pozorování  $(x_1, v_1, Y_1), \dots, (x_n, v_n, Y_n)$
- $Y_1, \dots, Y_n$  jsou **nezávislé** náhodné veličiny
- stejný rozptyl  $\sigma^2$
- normální rozdělení  $Y_i$  pro dané  $x_i, v_i$
- střední hodnoty  $Y_i$  vysvětleny pomocí  $x_i, v_i$

$$E Y_i = \beta_0 + \beta_1 x_i + \beta_2 v_i$$

- $b_0, b_1, b_2$  – odhady parametrů  $\beta_0, \beta_1, \beta_2$
- $b_1$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $x$  a **nezměněné** hodnotě  $v$
- $b_2$  – odhad změny střední hodnoty  $Y$  při **jednotkové** změně  $v$  a **nezměněné** hodnotě  $x$
- $U_i$  – reziduum

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

93

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

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

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

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

uvažujeme závislost  $E Y = \beta_0 + \beta_1 x + \beta_2 v$

- $H_0: \beta_2 = 0$  (k vysvětlení  $Y$  stačí  $x$ )  
 $T_2 = \frac{b_2}{S.E.(b_2)}$ , zamítnat pro  $|T_2| \geq t_{n-3}(\alpha)$
- $H_0: \beta_1 = 0$  (k vysvětlení  $Y$  stačí  $v$ )  
 $T_1 = \frac{b_1}{S.E.(b_1)}$ , zamítnat pro  $|T_1| \geq t_{n-3}(\alpha)$
- $H_0: \beta_1 = \beta_2 = 0$  (nezáv. ani na  $x$  ani na  $v$ )

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

94

### příklad závislost FAT na HEIGHT a WEIGHT

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

- při **stejně výšce** očekáváme na každý kg hmotnosti o 0,6 proc. bodu více tuku
- u mužů, kteří se liší výškou o 10 cm a **mají stejnou hmotnost** očekáváme, že ti vyšší mají v průměru o 2,6 proc. bodu **méně** tuku

variabilita	součet čtverců	st. vol.	prům. čtverec	$F$	$p$
regrese	1833,11	2	916,55	51,050	<0,001
rezid.	843,85	47	17,95		
celk.	2676,95	49	(54,63)		

$$R^2 = \frac{1833,11}{2676,95} = 1 - \frac{843,85}{2676,95} = 0,685$$

95

## $\chi^2$ testy

- pro znaky v **nominálním** měřítku
- příklady**
  - krevní skupiny A, B, AB, 0 u  $n$  osob
  - počty dětí narozených v jednotlivých měsících
  - počty matek se základním, středním, vysokoškolským vzděláním
- multinomické** rozdělení
  - v dílčím pokusu  $k$  možných výsledků  $A_1, \dots, A_k$  (neslučitelné)
  - $\pi_j$  je pst, že vyjde  $A_j$  ( $\sum \pi_j = 1$ )
  - $n$  **nezávislých** dílčích pokusů
  - $N_j$  – počet dílčích pokusů, kdy  $A_j$
  - $(N_1, \dots, N_k)$  má multinomické rozdělení s parametry  $n, \pi_1, \dots, \pi_k$
  - samotné  $N_j$  má binomické rozdělení
- pravděpodobnost**  $N_1 = n_1, \dots, N_k = n_k$

$$\frac{n!}{n_1! \dots n_k!} \pi_1^{n_1} \dots \pi_k^{n_k}$$

96



- hlavní vlastnost (pokud  $n\pi_j \geq 5$  pro  $\forall j$ )

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

má přibližně rozdělení  $\chi^2(k-1)$

- **test shody**  $H_0: \pi_1 = \pi_1^0, \dots, \pi_k = \pi_k^0$   
(pravděpodobnosti dány **jednoznačně**)
  - platí-li  $H_0$ , očekáváme četnosti blízké hodnotám  $n\pi_j^0$ :

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

- $H_0$  zamítáme, je-li  $X^2 \geq \chi_{k-1}^2(\alpha)$
- $N_j$  experimentální četnost
- $n\pi_j^0$  **teoretická** četnost
- statistika  $X^2$  porovnává experimentální a teoretické četnosti

97

### příklad **měsíce**

počty studentů biologie narozených v jednotlivých měsících

### hypotéza:

děti se rodí během roku **rovnoměrně**

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

$$X^2 = 7,4115 < \chi_{12-1}^2(0,05) = 19,675 \quad p = 0,765$$

98

### kontingenční tabulka

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

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

- **nezávislost** znaků: pro všechna  $i, j$

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

- teoretické četnosti (protějšek  $N_{ij}$ )

$$o_{ij} = n \cdot P(\widehat{A}_i) \cdot P(\widehat{B}_j) = n \cdot \frac{N_{i\bullet}}{n} \cdot \frac{N_{\bullet j}}{n} = \frac{N_{i\bullet} \cdot N_{\bullet j}}{n}$$

- $H_0$ : znaky jsou **nezávislé**

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

- nezávislost se zamítá pro  $X^2 \geq \chi_{(r-1)(c-1)}^2(\alpha)$
- musí být  $o_{ij} \geq 5 \forall (i, j)$

99

### příklad **Baden**

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

- barva očí  $r = 3$
- barva vlasů  $c = 4$
- $n = 6800$
- $o_{11} = 2811 \cdot 2829/6800 = 1169$
- $o_{12} = 2811 \cdot 2632/6800 = 1088$
- $o_{13} = \dots$

$$X^2 = \frac{(1768 - 1169)^2}{1169} + \frac{(807 - 1088)^2}{1088} + \dots$$

$$= 1073,5$$

$$> \chi_6^2(0,05) = 12,5916$$

$$p < 0,0001$$

závislost je na každé rozumné hladině **prokázána**

100

- test **homogenity**

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

- příklad **krevní skupiny**

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

$$\chi^2 = \frac{(121 - 353 \cdot 239/717)^2}{353 \cdot 239/717} + \dots = 11,742$$

- $\chi^2_{3}(0,05) = 7,815$   $p = 0,008$
- nejmenší teoretická četnost:  
 $353 \cdot 63/717 = 31,02 > 5$

101

### McNemarův test (test symetrie)

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

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

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

102

### příklad **stromy**

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

- stav týchž stromů ve dvou sezónách
- celkem 100 stromů

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

- $\chi^2_{3}(0,05) = 7,8147$   $p = 0,3597$
- rozdíl mezi sezónami jsme neprokázali

103

### čtyřpolní tabulka

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

- speciální případ kontingenční tabulky pro  $r = c = 2$
- test nezávislosti/homogenity

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

zamítá se pro  $X^2 \geq \chi^2_1(\alpha) = z(\alpha/2)^2$

- **Yatesova korekce**

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

- **Fisherův faktoriálový (exaktní) test**
  - počítá přímo dosaženou hladinu  $p$
  - malé četnosti nevadí

104

## příklad hraboš

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

- souvisí spolu nákazy dvěma parazity?

- nulová hypotéza: **nezávislost**

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

$p = 0,0006$

- **ale:**  $15 \cdot 31 / 515 = 0,9 < 5$
- **Yates:**  $\chi^2 = 8,187$   $p = 0,0042$
- **Fisherův test:**  $p = 0,0092$
- na 5% hladině závislost **prokázána**

105

## jak použijeme statistiku

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

106

## dvojitý původ dat

- **plánovaný** (organizovaný) **pokus**
  - aktivně zasahujeme
  - fixujeme okolnosti (stálá teplota, světelný režim)
  - nastavujeme úroveň zvoleného faktoru (dva živné roztoky)
  - jedincům náhodně přiřazujeme ošetření
  - zjistíme-li rozdíl, známe jeho příčinu
- **šetření** (sledování dění)
  - pouze sledujeme, nezasahujeme
  - rozdělení do skupin nemůžeme ovlivnit
  - rozdíl mezi skupinami může být způsoben matoucí (confounding) veličinou, která souvisí s rozdělením do skupin i s měřeným znakem
  - příklad: plánované těhotenství na vzdělání matky, matoucí je věk matky

107

## jaké úlohy řešíme

- **popsat stav**
  - poloha (průměr, medián, kvartily, . . .)
  - variabilita (směr. odchylka, rozptyl, kvartilové rozpětí)
  - závislost (korelační koeficient, Spearmanův korelační koeficient)
  - tvar rozdělení (šikmost, špičatost)
- **prokázat vliv ošetření**
  - změna polohy ( $t$  testy, ANOVA)
  - změna variability (Levene,  $F$  test, Bartlettův test)
  - jiná změna (Kolmogorov-Smirnov)
- **prokázat závislost**
  - obě spojitá (korelační koeficient)
  - spojitá na kvalitativní (ANOVA)
  - obě kvalitativní (kontingenční tabulka)
- **popsat závislost** spojitých – regrese

108

## výběr metody

- jakou úlohu řešíme?
- jsou výběry nezávislé?
  - z organizace pokusu
- lze předpokládat normální rozdělení?
  - ze zkušenosti
  - lze ověřovat (ve skupinách pozorování, z reziduí)
  - lze soudit z grafu (normální diagram)
- je rozptyl stálý?
  - lze ověřovat (ve skupinách pozorování, z reziduí)
  - lze soudit z grafu (normální diagram)

109

## volba nulové a alternativní hypotézy

- $H_0$  zjednodušuje model
  - populace se neliší (výběry se liší jen náhodně)
  - veličiny jsou nezávislé
  - $H_0$  zpravidla chceme vyvrátit
- $H_1$  je opak nulové hypotézy
  - zpravidla obsahuje tvrzení, které chceme dokázat
  - pokud existuje jednostranná alternativní hypotéza, musíme ji zvolit **před pokusem** na základě úvah, které **nejsou** založeny na použitých datech
- pouze zamítnutím  $H_0$  něco dokazujeme

110