


Základní, výběrový a datový soubor

Základním souborem rozumíme libovolnou neprázdnou množinu E . Prvky množiny E značíme ε a nazýváme je **objekty**. Libovolnou neprázdnou podmnožinu $\{\varepsilon_1, \dots, \varepsilon_n\}$ základního souboru E nazýváme **výběrový soubor rozsahu n** . Je-li množina $G \subseteq E$, pak symbolem $N(G)$ rozumíme **absolutní četnost** množiny G ve výběrovém souboru, tj. počet těch objektů množiny G , které patří do výběrového souboru. **Relativní četnost** množiny G ve výběrovém souboru zavedeme vztahem

$$p(G) = \frac{N(G)}{n}.$$

Ilustrace



Příklad: Základním souborem E je množina všech ekonomicky zaměřených studentů 1. ročníku českých vysokých škol. Množina G_1 je tvořena těmi studenty, kteří uspěli v prvním zkušebním termínu z matematiky a množina G_2 obsahuje ty studenty, kteří uspěli v prvním zkušebním termínu z angličtiny. Ze základního souboru bylo náhodně vybráno 20 studentů, kteří tvoří výběrový soubor $\{\varepsilon_1, \dots, \varepsilon_{20}\}$. Z těchto 20 studentů 12 uspělo v matematice, 15 v angličtině a 11 v obou předmětech. Zapište absolutní a relativní četnosti úspěšných matematiků, angličtinářů a oboustranně úspěšných studentů.

Řešení:

$$N(G_1) = 12, N(G_2) = 15, N(G_1 \cap G_2) = 11, n = 20, p(G_1) = \frac{12}{20} = 0,6, p(G_2) = \frac{15}{20} = 0,75,$$

$$p(G_1 \cap G_2) = \frac{11}{20} = 0,55$$

Vidíme, že úspěšných matematiků je 60%, angličtinářů 75% a oboustranně úspěšných studentů jen 55%.

Vlastnosti relativní četnosti: Relativní četnost má následujících 12 vlastností, které jsou obdobné vlastnostem procent.

- $p(\emptyset) = 0$
- $p(G) \geq 0$ (nezápornost)
- $p(G) \leq 1$
- $p(G_1 \cup G_2) + p(G_1 \cap G_2) = p(G_1) + p(G_2)$
- $1 + p(G_1 \cap G_2) \geq p(G_1) + p(G_2)$
- $p(G_1 \cup G_2) + 0 \leq p(G_1) + p(G_2)$ (subaditivita)
- $G_1 \cap G_2 = \emptyset \Rightarrow p(G_1 \cup G_2) = p(G_1) + p(G_2)$ (aditivita)
- $p(G_2 \setminus G_1) = p(G_2) - p(G_1 \cap G_2)$
- $G_1 \subseteq G_2 \Rightarrow p(G_2 \setminus G_1) = p(G_2) - p(G_1)$ (subtraktivita)
- $G_1 \subseteq G_2 \Rightarrow p(G_1) \leq p(G_2)$ (monotonie)
- $p(E) = 1$ (normovanost)
- $p(G) + p(\bar{G}) = 1$ (komplementarita)

Pojem podmíněné relativní četnosti: Pokud se v daném základním souboru zajímáme o dvě podmnožiny, můžeme zavést pojem podmíněné relativní četnosti jedné podmnožiny v daném výběrovém souboru za předpokladu, že objekt pochází z druhé podmnožiny.

Nechť E je základní soubor, G_1, G_2 jeho podmnožiny, $\{\varepsilon_1, \dots, \varepsilon_n\}$ výběrový soubor. Definujeme

podmíněnou relativní četnost množiny G_1 ve výběrovém souboru za předpokladu G_2 :

$$p(G_1/G_2) = \frac{N(G_1 \cap G_2)}{N(G_2)} = \frac{p(G_1 \cap G_2)}{p(G_2)} \text{ a}$$

podmíněnou relativní četnost G_2 ve výběrovém souboru za předpokladu G_1 :

$$p(G_2/G_1) = \frac{N(G_1 \cap G_2)}{N(G_1)} = \frac{p(G_1 \cap G_2)}{p(G_1)}.$$

Příklad: Pro údaje z příkladu o studentech vypočtete podmíněnou relativní četnost úspěšných matematiků mezi úspěšnými angličtináři a podmíněnou relativní četnost úspěšných angličtinářů mezi úspěšnými matematiky.

(Připomínáme, že z 20 studentů 12 uspělo v matematice, 15 v angličtině a 11 v obou předmětech.)

Řešení:

$$N(G_1) = 12, N(G_2) = 15, N(G_1 \cap G_2) = 11, n = 20,$$

$$p(G_1/G_2) = \frac{N(G_1 \cap G_2)}{N(G_2)} = \frac{11}{15} = 0,73 \text{ (tzn., že 73\% těch studentů, kteří by-}$$

li úspěšní v angličtině, uspělo i v matematice)

$$p(G_2/G_1) = \frac{N(G_1 \cap G_2)}{N(G_1)} = \frac{11}{12} = 0,92 \text{ (tzn., že 92\% těch studentů, kteří byli}$$

úspěšní v matematice, uspělo i v angličtině)

Pojem četnostní nezávislosti dvou množin: O četnostní nezávislosti dvou množin v daném výběrovém souboru hovoříme tehdy, když informace o původu objektu z jedné množiny nijak nemění šance, s nimiž soudíme na jeho původ i z druhé množiny.

V příkladě se studenty by množiny úspěšných matematiků a úspěšných angličtinářů byly četnostně nezávislé, pokud podíl úspěšných matematiků mezi úspěšnými angličtináři by byl stejný jako podíl úspěšných matematiků mezi všemi zkoušenými studenty a stejně tak podíl úspěšných angličtinářů mezi úspěšnými matematiky by byl stejný jako podíl úspěšných angličtinářů mezi všemi zkoušenými studenty, tj.

$$\frac{n(G_1 \cap i_2)}{n(G_2)} = \frac{n(G_1)}{n} \wedge \frac{n(G_1 \cap i_2)}{n(G_1)} = \frac{n(G_2)}{n}$$

Po snadné úpravě dostaneme multiplikativní vztah

$$\frac{n(G_1 \cap i_2)}{n} = \frac{n(G_1)}{n} \cdot \frac{n(G_2)}{n}, \text{ tj. } p(G_1 \cap i_2) = p(G_1) \cdot p(G_2)$$

Řekneme tedy, že množiny G_1, G_2 jsou **četnostně nezávislé** v daném výběrovém souboru, jestliže $p(G_1 \cap i_2) = p(G_1) \cdot p(G_2)$.

(V praxi jen zřídka dojde k tomu, že uvedený vztah platí přesně.

Většinou je jen naznačena určitá tendence četnostní nezávislosti.)

Příklad: Pro údaje z příkladu o studentech zjistěte, zda úspěchy v matematice a angličtině jsou v daném výběrovém souboru čítnostně nezávislé.

(Připomínáme, že oboustranně úspěšných studentů bylo 55%, úspěšných matematiků 60% a úspěšných angličtinářů 75%.)

Řešení:

$p(G_1 \cap G_2) = 0,55$, $p(G_1)p(G_2) = 0,6 \times 0,75 = 0,45$, tedy skutečná relativní četnost oboustranně úspěšných studentů je větší než by odpovídalo četnostní nezávislosti množin G_1 , G_2 v daném výběrovém souboru. Znamená to, že úspěch v matematice se zpravidla sdružuje s úspěchem v angličtině a naopak.

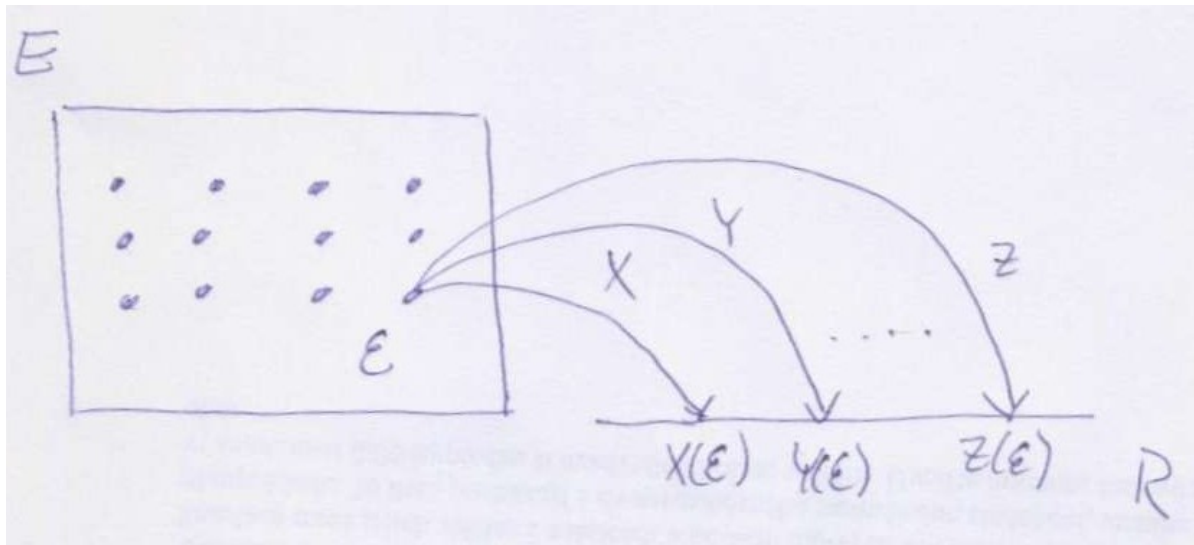
Pojem skalárního a vektorového znaku: Vlastnosti objektů vyjadřujeme číselně pomocí znaků.

Nechť E je základní soubor. Funkce

$X: E \rightarrow \mathbb{R}$, $Y: E \rightarrow \mathbb{R}$, ..., $Z: E \rightarrow \mathbb{R}$,

kteřé každému objektu přiřazují číslo, se nazývají **(skalární) znaky**.

Uspořádaná p -tice (X, Y, \dots, Z) se nazývá **vektorový znak**.



Označení: Nechť je dán výběrový soubor $\{\epsilon_1, \dots, \epsilon_n\} \subseteq E$. Hodnoty znaků X, Y, \dots, Z pro i -tý objekt označíme $x_i = X(\epsilon_i)$, $y_i = Y(\epsilon_i)$, ..., $z_i = Z(\epsilon_i)$, $i = 1, \dots, n$.

Pojem datového souboru:

Matice $\begin{pmatrix} x_1 & y_1 & \cdots & z_1 \\ x_2 & y_2 & \cdots & z_2 \\ \cdots & \cdots & \cdots & \cdots \\ x_m & y_n & \cdots & z_n \end{pmatrix}$ typu $n \times p$ se nazývá **datový soubor**. Její řádky

odpovídají jednotlivým objektům, sloupce znakům.

Libovolný sloupec této matice nazýváme **jednorozměrným datovým souborem**. Jestliže uspořádáme hodnoty některého znaku (např. znaku X) v jednorozměrném datovém souboru vzestupně podle velikosti,

dostaneme **uspořádaný datový soubor** $\begin{pmatrix} x_{(1)} \\ \vdots \\ x_{(n)} \end{pmatrix}$, kde $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$.

Vektor $\begin{pmatrix} x_{[1]} \\ \vdots \\ x_{[r]} \end{pmatrix}$, kde $x_{[1]} < \dots < x_{[r]}$ jsou navzájem různé hodnoty znaku

X , se nazývá **vektor variant**.

Příklad: Pro studenty z výběrového souboru uvedeného výše byly zjišťovány hodnoty znaků X – známka z matematiky v prvním zkušebním termínu, Y – známka z angličtiny v prvním zkušebním termínu, Z – pohlaví studenta (0 ... žena, 1 ... muž). Byl získán datový soubor

$$\begin{pmatrix} 2 & 2 & 0 \\ 1 & 3 & 1 \\ 4 & 3 & 1 \\ 1 & 1 & 0 \\ 1 & 2 & 1 \\ 4 & 4 & 1 \\ 3 & 3 & 1 \\ 3 & 4 & 0 \\ 1 & 1 & 0 \\ 1 & 1 & 0 \\ 4 & 2 & 1 \\ 4 & 4 & 0 \\ 2 & 2 & 0 \\ 4 & 3 & 1 \\ 2 & 3 & 1 \\ 4 & 4 & 0 \\ 1 & 1 & 0 \\ 4 & 3 & 1 \\ 4 & 4 & 1 \\ 1 & 3 & 0 \end{pmatrix}$$

Utvořte jednorozměrný uspořádaný i neuspořádaný datový soubor pro známky z matematiky a vektory variant pro známky z matematiky.

Řešení:

$$\begin{pmatrix} 2 \\ 1 \\ 4 \\ 1 \\ 1 \\ 4 \\ 3 \\ 3 \\ 1 \\ 1 \\ 4 \\ 4 \\ 2 \\ 4 \\ 4 \\ 2 \\ 4 \\ 1 \\ 4 \\ 4 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 2 \\ 2 \\ 2 \\ 3 \\ 4 \\ 4 \\ 4 \\ 4 \\ 4 \\ 4 \\ 4 \\ 4 \\ 4 \end{pmatrix}, \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \end{pmatrix}$$

Pojem jevu: Necht' $\{\varepsilon_1, \dots, \varepsilon_n\}$ je výběrový soubor, X, Y, \dots, Z jsou znaky, B, B_1, B_p jsou číselné množiny.

Zápis $\{X \in B\}$ znamená jev „znak X nabyl hodnoty z množiny B “.

Zápis $\{X \in B_1 \wedge Y \in B_2 \wedge \dots \wedge Z \in B_p\}$ znamená jev „znak X nabyl hodnoty z množiny B_1 a současně znak Y nabyl hodnoty z množiny B_2 atd. až znak Z nabyl hodnoty z množiny B_p “.

Symbol $N(X \in B)$ značí **absolutní četnost** jevu $\{X \in B\}$ ve výběrovém souboru, tj. počet těch objektů ve výběrovém souboru, pro něž $x_i \in B$.

Symbol $p(X \in B)$ znamená **relativní četnost** jevu $\{X \in B\}$ ve výběrovém souboru, tj. $p(X \in B) = \frac{N(X \in B)}{n}$.

Analogicky $N(X \in B_1 \wedge Y \in B_2 \wedge \dots \wedge Z \in B_p)$ resp.

$p(X \in B_1 \wedge Y \in B_2 \wedge \dots \wedge Z \in B_p)$ znamená absolutní resp. relativní četnost jevu $\{X \in B_1 \wedge Y \in B_2 \wedge \dots \wedge Z \in B_p\}$ ve výběrovém souboru.

Příklad: Pro datový soubor s údaji o známkách najděte relativní četnost

- a) matematických jedničkářů
- b) úspěšných matematiků
- c) oboustranně neúspěšných studentů.

Datový soubor má tvar:

```
( 2  2  0 )  
| 1  3  1 |  
| 4  3  1 |  
| 1  1  0 |  
| 1  2  1 |  
| 4  4  1 |  
| 3  3  1 |  
| 3  4  0 |  
| 1  1  0 |  
| 1  1  0 |  
| 4  2  1 |  
| 4  4  0 |  
| 2  2  0 |  
| 4  3  1 |  
| 2  3  1 |  
| 4  4  0 |  
| 1  1  0 |  
| 4  3  1 |  
| 4  4  1 |  
| 1  3  0 )
```

Řešení:

ad a) $p(X = 1) = \frac{7}{20} = 0,35;$

ad b) $p(X \leq 3) = \frac{12}{20} = 0,60;$

ad c) $p(X = 4 \wedge Y = 4) = \frac{4}{20} = 0,20.$

Zjistili jsme, že jedničku z matematiky mělo 35% studentů, zkoušku z matematiky úspěšně složilo 60% studentů a oboustranně neúspěšných bylo 20% studentů.

Jednorozměrné bodové rozložení četností

Jestliže počet variant znaku X v jednorozměrném datovém souboru není příliš velký, pak přiřazujeme četnosti jednotlivým variantám a hovoříme o **bodovém rozložení četností**.

Nechť je dán jednorozměrný datový soubor $\begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$, v němž znak X na-

bývá r variant.

Pro $j = 1, \dots, r$ definujeme:

$n_j = N(X = x_{[j]})$ – **absolutní četnost varianty $x_{[j]}$ ve výběrovém souboru**

$p_j = \frac{n_j}{n}$ – **relativní četnost varianty $x_{[j]}$ ve výběrovém souboru**

$N_j = N(X \leq x_{[j]}) = n_1 + \dots + n_j$ – **absolutní kumulativní četnost prvních j variant ve výběrovém souboru**

$F_j = \frac{N_j}{n} = p_1 + \dots + p_j$ – **relativní kumulativní četnost prvních j variant ve výběrovém souboru**

Tabulka typu

$x_{[j]}$	n_j	p_j	N_j	F_j
$x_{[1]}$	n_1	p_1	N_1	F_1
\vdots	\vdots	\vdots	\vdots	\vdots
$x_{[r]}$	n_r	p_r	N_r	F_r

se nazývá **variační řada** (nebo též **tabulka rozložení četností**).

Příklad: Máme jednorozměrný datový soubor, který obsahuje údaje o známkách z matematiky (znak X) u 20 studentů.

(2)
1
4
1
1
4
3
3
1
1
4
4
2
4
2
4
1
4
4
1)

Sestavte tabulku rozložení četností.

Řešení:

$x_{[j]}$	n_j	p_j	N_j	F_j
1	7	$7/20=0,35$	7	$7/20=0,35$
2	3	$3/20=0,15$	10	$10/20=0,50$
3	2	$2/20=0,10$	12	$12/20=0,60$
4	8	$8/20=0,40$	20	$20/20=1,00$
Σ	20	1,00	-	-

Pojem četnostní funkce a empirické distribuční funkce

Pomocí relativních četností zavedeme **četnostní funkci**.

Funkce $p(x) = \begin{cases} p_j & \text{pro } x = x_{[j]}, j=1, \dots, r \\ 0 & \text{jinak} \end{cases}$ se nazývá četnostní funkce.

Četnostní funkce je

nezáporná ($\forall x \in \mathbb{R}: p(x) \geq 0$)

a normovaná ($\sum_{x=-\infty}^{\infty} p(x) = 1$).

Pomocí kumulativních relativních četností zavedeme **empirickou distribuční funkci**.

Funkce $F(x) = \begin{cases} 0 & \text{pro } x < x_{[1]} \\ F_j & \text{pro } x_{[j]} \leq x < x_{[j+1]}, j=1, \dots, r-1 \\ 1 & \text{pro } x \geq x_{[r]} \end{cases}$ se nazývá empirická

distribuční funkce.

Empirická distribuční funkce je

neklesající ($\forall x_1, x_2 \in \mathbb{R}, x_1 < x_2: F(x_1) \leq F(x_2)$),

zprava spojitá ($\forall x_0 \in \mathbb{R}$ libovolné, ale pevně dané: $\lim_{x \rightarrow x_0+} F(x) = F(x_0)$)

a normovaná ($\lim_{x \rightarrow -\infty} F(x) = 0, \lim_{x \rightarrow \infty} F(x) = 1$).

Platí $\forall x \in \mathbb{R}: F(x) = \sum_{t \leq x} p(t)$.

Příklad: Pro známky z matematiky nakreslete graf četnostní funkce a empirické distribuční funkce.

Řešení:

Variační řada



$x_{[j]}$	n_j	p_j	N_j	F_j
1	7	$7/20=0,35$	7	$7/20=0,35$
2	3	$3/20=0,15$	10	$10/20=0,50$
3	2	$2/20=0,10$	12	$12/20=0,60$
4	8	$8/20=0,40$	20	$20/20=1,00$
Σ	20	1,00	-	-

Vzorce

$$p_j = \begin{cases} p_j & \text{pro } x = x_{[j]}, j=1, \dots, r \\ 0 & \text{jinak} \end{cases}$$


$$F(x) = \begin{cases} 0 & \text{pro } x < x_{[1]} \\ F_j & \text{pro } x_{[j]} \leq x < x_{[j+1]}, j=1, \dots, r-1 \\ 1 & \text{pro } x \geq x_{[r]} \end{cases}$$

Grafy




Vztah mezi četnostní funkcí a empirickou distribuční funkcí

$$\forall x \in \mathbb{R} : F(x) = \sum_{t \leq x} p(t)$$




Grafické znázornění jednorozměrného bodového rozložení četnosti

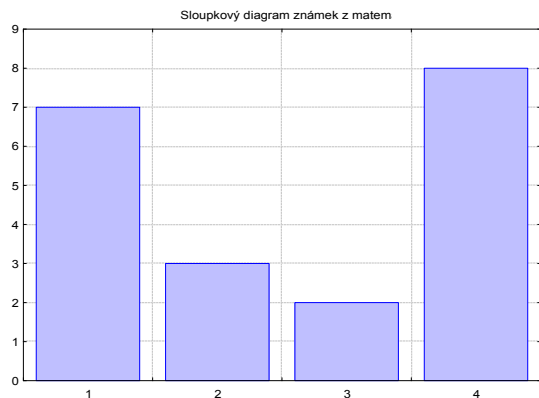
Tečkový diagram: na číselné ose vyznačíme jednotlivé varianty znaku X a nad každou variantu nakreslíme tolik teček, jaká je její absolutní četnost.



Polygon četnosti: je lomená čára spojující body, jejichž x-ová souřadnice je varianta znaku X a y-ová souřadnice je absolutní či relativní četnost této varianty.




Sloupkový diagram: je soustava na sebe nenavazujících obdélníků, kde střed základny je varianta znaku X a výška je absolutní či relativní četnost této varianty.



Výsečový graf: je kruh rozdělený na výseče, jejichž vnější obvod odpovídá absolutním četnostem variant znaku X.

Výsečový diagram známek z matematik



Dvourozměrné bodové rozložení četností

Nechť je dán dvourozměrný datový soubor $\begin{pmatrix} x_1 & y_1 \\ \dots & \dots \\ x_n & y_n \end{pmatrix}$, kde znak X má r variant a

znak Y má s variant. Pak definujeme:

$n_{jk} = N(X = x_{[j]} \wedge Y = y_{[k]})$ – **simultánní absolutní četnost dvojice $(x_{[j]}, y_{[k]})$** ve výběrovém souboru

$p_{jk} = \frac{n_{jk}}{n}$ – **simultánní relativní četnost dvojice $(x_{[j]}, y_{[k]})$** ve výběrovém souboru

$n_{j\cdot} = N(X = x_{[j]}) = n_{j1} + \dots + n_{js}$ – **marginální absolutní četnost varianty $x_{[j]}$**

$p_{j\cdot} = \frac{n_{j\cdot}}{n} = p_{j1} + \dots + p_{js}$ – **marginální relativní četnost varianty $x_{[j]}$**

$n_{\cdot k} = N(Y = y_{[k]}) = n_{1k} + \dots + n_{rk}$ – **marginální absolutní četnost varianty $y_{[k]}$**

$p_{\cdot k} = \frac{n_{\cdot k}}{n} = p_{1k} + \dots + p_{rk}$ – **marginální relativní četnost varianty $y_{[k]}$**

Simultánní četností zapisujeme do kontingenční tabulky.

Kontingenční tabulka simultánních absolutních četností má tvar:

	y	$y_{[1]}$...	$y_{[s]}$	$n_{j\cdot}$
x	n_{jk}				
$x_{[1]}$		n_{11}	...	n_{1s}	$n_{1\cdot}$
\vdots	
$x_{[r]}$		n_{r1}	...	n_{rs}	$n_{r\cdot}$
$n_{\cdot k}$		$n_{\cdot 1}$...	$n_{\cdot s}$	n

Příklad: Máme datový soubor, který obsahuje údaje o známkách z matematiky (znak X), z angličtiny (znak Y) a pohlaví studenta (znak Z, 0 – žena, 1 – muž) u 20 studentů:

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
X	2	1	4	1	1	4	3	3	1	1	4	4	2	4	2	4	1	4	4	1
Y	2	3	3	1	2	4	3	4	1	1	2	4	2	3	3	4	1	3	4	3
Z	0	1	1	0	1	1	1	0	0	0	1	0	0	1	1	0	0	1	1	0

Vytvořte kontingenční tabulku simultánních absolutních a relativních četností pro známky z matematiky a angličtiny.

Řešení:

Kontingenční tabulka simultánních absolutních četností

	y	1	2	3	4	$n_{j\cdot}$
x	n_{jk}					
1		4	1	2	0	7
2		0	2	1	0	3
3		0	0	1	1	2
4		0	1	3	4	8
$n_{\cdot k}$		4	4	7	5	$n = 20$

Kontingenční tabulka simultánních relativních četností

	y	1	2	3	4	$p_{j\cdot}$
x	p_{jk}					
1		0,20	0,05	0,10	0,00	0,35
2		0,00	0,10	0,05	0,00	0,15
3		0,00	0,00	0,05	0,05	0,10
4		0,00	0,05	0,15	0,20	0,40
$p_{\cdot k}$		0,20	0,20	0,35	0,25	1,00

Pojem simultánní a marginální četnostní funkce

Pomocí simultánních relativních četností zavedeme **simultánní četnostní funkci**:

Funkce

$$p_{\mathbf{x}, \mathbf{y}} = \begin{cases} p_{jk} & \text{pro } x = x_{[j]}, y = y_{[k]}, j=1, \dots, r, k=1, \dots, s \\ 0 & \text{jinak} \end{cases}$$

se nazývá simultánní četnostní funkce.

Pomocí marginálních relativních četností zavedeme **marginální četnostní funkce pro znaky X a Y**. Odlišíme je indexem takto:

$$p_1 = \begin{cases} p_j & \text{pro } x = x_{[j]}, j=1, \dots, r \\ 0 & \text{jinak} \end{cases},$$

$$p_2 = \begin{cases} p_k & \text{pro } y = y_{[k]}, k=1, \dots, s \\ 0 & \text{jinak} \end{cases}.$$


Mezi simultánní četnostní funkcí a marginálními četnostními funkcemi platí vztahy:

$$p_1 = \sum_{y=-\infty}^{\infty} p(x, y), \quad p_2 = \sum_{x=-\infty}^{\infty} p(x, y).$$

Příklad: Sestrojte graf simultánní četnostní funkce pro známky z matematiky a angličtiny.

Řešení: Vyjdeme z kontingenční tabulky simultánních relativních četností.

	y	1	2	3	4	$p_{j\cdot}$
x	p_{jk}					
1		0,20	0,05	0,10	0,00	0,35
2		0,00	0,10	0,05	0,00	0,15
3		0,00	0,00	0,05	0,05	0,10
4		0,00	0,05	0,15	0,20	0,40
$p_{\cdot k}$		0,20	0,20	0,35	0,25	1,00



Pojem četnostní nezávislosti znaků v daném výběrovém souboru

Řekneme, že znaky X, Y jsou v daném výběrovém souboru **četnostně nezávislé**, právě když pro všechna $j = 1, \dots, r$ a všechna $k = 1, \dots, s$ platí multiplikativní vztah:

$$p_{jk} = p_{j.} p_{.k} \text{ neboli pro } \forall (x, y) \in R^2: p(x, y) = p_1(x) p_2(y).$$

Příklad: Ověřte, zda v našem datovém souboru jsou známky z matematiky a angličtiny četnostně nezávislé.

Řešení: Vyjdeme z kontingenční tabulky relativních četností.

	y	1	2	3	4	$p_{j.}$
x	p_{jk}					
1		0,20	0,05	0,10	0,00	0,35
2		0,00	0,10	0,05	0,00	0,15
3		0,00	0,00	0,05	0,05	0,10
4		0,00	0,05	0,15	0,20	0,40
$p_{.k}$		0,20	0,20	0,35	0,25	1,00

Známky z matematiky a angličtiny nejsou četnostně nezávislé, protože už pro $j = 1, k = 1$ je multiplikativní vztah porušen:

$$p_{11} = 0,20, p_{1.} = 0,35, p_{.1} = 0,20, \text{ tudíž } 0,20 \neq 0,35 \cdot 0,20$$

Pojem řádkově a sloupcově podmíněných relativních četností

Sloupcově podmíněná relativní četnost varianty $x_{[j]}$ za předpokladu $y_{[k]}$:

$$p_{j(k)} = \frac{n_{jk}}{n_{.k}}$$

Řádkově podmíněná relativní četnost varianty $y_{[k]}$ za předpokladu $x_{[j]}$:

$$p_{(j)k} = \frac{n_{jk}}{n_{j.}}$$

Příklad: Pro datový soubor známek z matematiky a angličtiny sestavte kontingenční tabulku sloupcově a poté řádkově podmíněných relativních četností.

Řešení:

Nejprve se budeme zabývat sloupcově podmíněnými relativními četnostmi. Použijeme vzorec $p_{j(k)} = \frac{n_{jk}}{n_{.k}}$.

Vyjdeme z kontingenční tabulky simultánních absolutních četností.

	<i>y</i>	1	2	3	4	<i>n_{j.}</i>
<i>x</i>	<i>n_{jk}</i>					
1		4	1	2	0	7
2		0	2	1	0	3
3		0	0	1	1	2
4		0	1	3	4	8
<i>n_{.k}</i>		4	4	7	5	<i>n</i> = 20

	<i>y</i>	1	2	3	4
<i>x</i>	<i>p_{j(k)}</i>				
1		1,00	0,25	0,29	0,00
2		0,00	0,50	0,14	0,00
3		0,00	0,00	0,14	0,20
4		0,00	0,25	0,43	0,80
Σ		1,00	1,00	1,00	1,00

Interpretujeme např. třetí sloupec: z těch studentů, kteří měli trojku z angličtiny, mělo $2/7 = 29\%$ jedničku z matematiky, $1/7 = 14\%$ dvojku z matematiky, $1/7 = 14\%$ trojku z matematiky a $3/7 = 43\%$ čtyřku z matematiky.

Dále se budeme zabývat řádkově podmíněnými relativními četnostmi.

Použijeme vzorec $p_{j\cdot k} = \frac{n_{jk}}{n_{j\cdot}}$.

Opět nám poslouží kontingenční tabulka absolutních četností.


	y	1	2	3	4	$n_{j\cdot}$
x	n_{jk}					
1		4	1	2	0	7
2		0	2	1	0	3
3		0	0	1	1	2
4		0	1	3	4	8
$n_{\cdot k}$		4	4	7	5	$n = 20$

	y	1	2	3	4	Σ
x	$p_{(j)k}$					
1		0,57	0,14	0,29	0,00	1,00
2		0,00	0,67	0,33	0,00	1,00
3		0,00	0,00	0,50	0,50	1,00
4		0,00	0,12	0,38	0,50	1,00

Interpretujeme např. první řádek: z těch studentů, kteří měli jedničku z matematiky, mělo $4/7 = 57\%$ jedničku z angličtiny, $1/7 = 14\%$ dvojku z angličtiny a $2/7 = 29\%$ trojku z angličtiny.

Dvourozměrný tečkový diagram

Dvourozměrné rozložení četností lze znázornit pomocí **dvourozměrného tečkového diagramu**. Na vodorovnou osu vyneseme varianty znaku X, na svislou varianty znaku Y a do příslušných průsečíků nakreslíme tolik teček, jaká je absolutní četnost dané dvojice. V našem příkladě se studenty dostaneme tento diagram:



Dvourozměrný tečkový diagram svědčí o nepříliš výrazné tendenci k podobné klasifikaci v obou předmětech.

Zcela odlišný vzhled má diagram pro muže a pro ženy:

