

ANALÝZA ZÁVISLOSTÍ – 1. ČÁST

- zkoumání závislosti dvou event. více proměnných, měření síly této závislosti, atd.
- cílem je hlubší vniknutí do podstaty sledovaných jevů a procesů, přiblížení k tzv. příčinným souvislostem.

Dvourozměrná tabulka rozdělení četností

- je elementární metodou popisu závislosti
- rozlišujeme různé typy tabulek.

Korelační tabulka: obě proměnné jsou numerické.

Kontingenční tabulka: alespoň jedna proměnná je slovní.

Asociační tabulka: obě proměnné jsou alternativní.

Čtyřpolní tabulka: obě proměnné nabývají pouze dvou obměn.

Dvourozměrná tabulka rozdělení četností

x_i	y_j				Součty četností $n_{i\bullet}$
	y_1	y_2	\dots	y_s	
x_1	n_{11}	n_{12}	\dots	n_{1s}	$n_{1\bullet}$
x_2	n_{21}	n_{22}	\dots	n_{2s}	$n_{2\bullet}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
x_k	n_{r1}	n_{r2}	\dots	n_{rs}	$n_{r\bullet}$
Součty četností $n_{\bullet j}$	$n_{\bullet 1}$	$n_{\bullet 2}$	\dots	$n_{\bullet s}$	n

Symbolika:

n_{ij} ... sdružené (simultánní) absolutní četnosti

$n_{i\bullet}, n_{\bullet j}$... okrajové (marginální) absolutní četnosti

p_{ij} ... sdružené relativní četnosti

$p_{i\bullet}, p_{\bullet j}$... marginální relativní četnosti.

$$n_{i\bullet} = \sum_{j=1}^s n_{ij}; \quad n_{\bullet j} = \sum_{i=1}^r n_{ij}; \quad p_{i\bullet} = \frac{n_{i\bullet}}{n}; \quad p_{\bullet j} = \frac{n_{\bullet j}}{n}; \quad p_{ij} = \frac{n_{ij}}{n}$$

$$\sum_{i=1}^r n_{i\bullet} = \sum_{j=1}^s n_{\bullet j} = \sum_{i=1}^r \sum_{j=1}^s n_{ij} = n$$

Podmíněné rozdělení četností:

Rozdělení četností jedné proměnné, které odpovídá určité obměně druhé proměnné (tj. za podmínky, že druhá proměnná nabyla určité obměny).

Podmíněné relativní četnosti: $p_{j|i} = \frac{n_{ij}}{n_{i\bullet}} ; p_{i|j} = \frac{n_{ij}}{n_{\bullet j}}$

Podmíněný průměr: $\bar{y}_i = \frac{\sum_{j=1}^s y_j n_{ij}}{n_{i\bullet}} = \frac{\sum_{j=1}^s y_{ij}}{n_{i\bullet}}$

Podmíněný rozptyl: $s_{yi}^2 = \frac{\sum_{j=1}^s (y_j - \bar{y}_i)^2 n_{ij}}{n_{i\bullet}} = \frac{\sum_{j=1}^s (y_{ij} - \bar{y}_i)^2}{n_{i\bullet}}$

Pro výpočty je často používána také jiná forma tabulky, která umožňuje třídění hodnot proměnné y podle proměnné x do k skupin.

Tabulka třídění proměnné y podle proměnné x

$i = 1, 2, \dots, k$ x_i	$j = 1, 2, \dots, n_i$ y_{ij}	n_i	\bar{y}_i	s_{yi}^2
x_1	y_{11}, y_{12}, y_{13}	n_1	\bar{y}_1	s_{y1}^2
x_2	$y_{21}, y_{22}, y_{23}, y_{24}, y_{25}$	n_2	\bar{y}_2	s_{y2}^2
\cdot	\cdot	\cdot	\cdot	\cdot
\cdot	\cdot	\cdot	\cdot	\cdot
\cdot	\cdot	\cdot	\cdot	\cdot
x_k	$y_{k1}, y_{k2}, y_{k3}, y_{k4}$	n_k	\bar{y}_k	s_{yk}^2
Celkem		n	\bar{y}	s_y^2

Podmíněný průměr: $\bar{y}_i = \frac{\sum_{j=1}^{n_i} y_{ij}}{n_i}$

Podmíněný rozptyl: $s_{yi}^2 = \frac{\sum_{j=1}^{n_i} (y_{ij} - \bar{y}_i)^2}{n_i}$

Grafické znázornění dvourozměrného rozdělení četností

- je další formou popisu závislosti
- lze použít různé typy grafů.

❖ *čára podmíněných průměrů*

❖ *čára podmíněných rozptylů*

❖ *bodový graf (diagram).*

Rozklad rozptylu

Princip: celkový rozptyl proměnné y (s_y^2) lze vyjádřit jako součet rozptylu podmíněných průměrů ($s_{y.m}^2$) a průměru podmíněných rozptylů ($s_{y.v}^2$).

Vzorec pro rozklad rozptylu:

$$s_y^2 = s_{y.m}^2 + s_{y.v}^2$$

Celkový rozptyl (s_y^2)

$$s_y^2 = \frac{\sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2}{n} = \frac{S_y}{n}; \quad \bar{y} = \frac{\sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij}}{n}$$

y_{ij} ... jednotlivé hodnoty sledované proměnné

\bar{y} ... celkový průměr

n ... rozsah výběru

S_y ... celkový součet čtverců.

1. Rozptyl podmíněných průměrů ($s_{y.m}^2$)

- meziskupinový rozptyl
- odráží variabilitu mezi skupinami
- kolísání podmíněných průměrů je důsledkem závislosti y na x
- meziskupinová variabilita je vysvětlitelná faktorem x .

$$s_{y.m}^2 = \frac{\sum_{i=1}^k (\bar{y}_i - \bar{y})^2 n_i}{n} = \frac{S_{y.m}}{n}$$

\bar{y}_i ... podmíněný průměr

$S_{y.m}$... meziskupinový součet čtverců.

2. Průměr podmíněných rozptylů ($s_{y.v}^2$)

- vnitroskupinový rozptyl
- odráží variabilitu uvnitř skupin
- kolísání je důsledkem závislosti y na jiných faktorech než na x .

$$s_{y.v}^2 = \frac{\sum_{i=1}^k s_i^2 n_i}{n} = \frac{S_{y.v}}{n}$$

s_i^2 ... podmíněný rozptyl

$S_{y.v}$... vnitroskupinový (reziduální) součet čtverců.

Poznámka: jestliže platí $s_y^2 = s_{y.m}^2 + s_{y.v}^2$, pak také platí $S_y = S_{y.m} + S_{y.v}$. Za účelem zjednodušení vzorců lze tudíž používat pouze čitatele vzorců, tzv. součty čtverců.

Analýza rozptylu

- jednofaktorová analýza, faktorem je proměnná x (číselná nebo slovní)
- je to test, který zkoumá, zda změny hodnot numerické proměnné y lze vysvětlit změnami faktoru x
- slouží k ověření významnosti rozdílu výběrových průměrů více náhodných výběrů.

Předpoklady testu:

- ze základního souboru s normálním rozdělením $N(\mu; \sigma^2)$ je pořízeno k nezávislých náhodných výběrů
- každý z výběrů má normální rozdělení s neznámou střední hodnotou $\mu_1, \mu_2, \dots, \mu_k$ a s neznámým rozptylem $\sigma_1^2, \sigma_2^2, \dots, \sigma_k^2$
- rozptyly všech skupin jsou stejné, tj. $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2$ (tzv. homoskedasticita)
- shodu rozptylů je třeba ověřit vhodným testem, např. Bartlettovým
- počet pozorování musí být větší než počet skupin, tj. $n > k$.

Testovací postup:

1) $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$ (tj. y nezávisí na x ; rozdělení proměnné y mají na různých úrovních faktoru x stejné střední hodnoty)

$H_1 : \text{non } H_0$

2) Testové kritérium:

$$F = \frac{\frac{S_{y.m}}{k-1}}{\frac{S_{y.v}}{n-k}}; \quad \text{Statistika } F \text{ má při platnosti } H_0 \text{ rozdělení } F(k-1; n-k)$$

3) Kritický obor:

$$W \equiv \{F; F \geq F_{1-\alpha}(k-1; n-k)\}$$

4) Závěr testu:

Pokud leží hodnota testového kritéria v kritickém oboru, zamítáme H_0 a přijímáme H_1 , tedy prokázali jsme hypotézu H_1 o závislosti proměnné y na faktoru x .

Měření síly (intenzity, těsnosti) závislosti proměnné y na faktoru x :

$$\text{Poměr determinace: } P^2 = \frac{S_{y.m}}{S_y}; \quad P^2 \in \langle 0; 1 \rangle$$

$$\text{Poměr korelace: } P = \sqrt{P^2}; \quad P \in \langle 0; 1 \rangle$$