

Jaroslav Janko

Koeficient korelace v homogradní statistice

Časopis pro pěstování matematiky a fysiky, Vol. 55 (1926), No. 2, 160--164

Persistent URL: <http://dml.cz/dmlcz/121529>

Terms of use:

© Union of Czech Mathematicians and Physicists, 1926

Institute of Mathematics of the Academy of Sciences of the Czech Republic provides access to digitized documents strictly for personal use. Each copy of any part of this document must contain these *Terms of use*.



This paper has been digitized, optimized for electronic delivery and stamped with digital signature within the project *DML-CZ: The Czech Digital Mathematics Library* <http://project.dml.cz>

Koeficient korelace v homogradní statistice.

Napsal Dr. Jaroslav Janko.

Uvažujme počet s jednotek, o němž předpokládáme, že je konstantní. Tyto jednotky nechť se třídí podle n alternujících znaků A, B, C, \dots , takže střední počet jejich jest respektive $s_1, s_2, s_3, \dots, s_n$.

Jest tedy

$$s_1 + s_2 + s_3 + \dots + s_n = s. \quad (1)$$

Klademe-li $p_1 = \frac{s_1}{s}, p_2 = \frac{s_2}{s}, \dots, p_n = \frac{s_n}{s},$

pak můžeme považovati p_1, p_2, \dots, p_n za pravděpodobnosti, že jednotka ze souboru náhodně vybraná patří skupině A, B, C, \dots . Podle rovnice (1) je zřejmé

$$p_1 + p_2 + \dots + p_n = 1 \quad (2)$$

Vyberme tedy ze souboru libovolně s jednotek; obdržíme-li m_1, m_2, \dots, m_n jednotek se znaky A, B, C, \dots pak jest

$$m_1 + m_2 + \dots + m_n = s.$$

Položíme nyní

$$m_i = s p_i + l_i \quad (i = 1, 2, 3, \dots, n)$$

při čemž podle (2)

$$l_1 + l_2 + l_3 + \dots + l_n = 0. \quad (3)$$

Ptejme se nyní na korelaci mezi k libovolnými l . Při mnohonásobné korelaci (předpokládáme normální) jest korelační funkce¹⁾

$$\varphi(l_1, l_2, \dots, l_v) = \frac{1}{(2\pi)^{\frac{v}{2}} \sigma_1 \sigma_2 \dots \sigma_v \sqrt{R}} e^{-\frac{1}{2} \chi^2} \quad (4)$$

kde σ jsou standardní deviace, χ^2 jsou elipsoidy četnosti v n -rozměrném prostoru

$$\chi^2 = \frac{1}{R} \left(\sum R_{pp} \frac{l_p^2}{\sigma_p^2} + 2 \sum R_{st} \frac{l_s l_t}{\sigma_s \sigma_t} \right),$$

¹⁾ A. Bowley: Elements of Statistics str. 406.

$$R = \begin{vmatrix} 1 & r_{12} & r_{13} & \dots & r_{1v} \\ r_{21} & 1 & r_{23} & \dots & r_{2v} \\ \dots & \dots & \dots & \dots & \dots \\ r_{v1} & r_{v2} & r_{v3} & \dots & 1 \end{vmatrix}$$

R_{pp} a R_{st} jsou příslušné minory k jednotlivým koeficientům korelace r_{pp} resp. r_{st} . Dále jest $r_{st} = r_{ts}$. Omezíme-li se na přibližné vyjádření $n!$ pomocí Stirlingovy formule, jest při zanedbání členů řádu $\frac{1}{\sqrt{s}}$ pravděpodobnost současných úchylek²⁾ l_1, l_2, \dots, l_n ,

$$P(m_1, m_2, m_3, \dots, m_n) = \frac{e^{-\frac{1}{2s}\Phi}}{(2\pi s)^{\frac{n-1}{2}} (p_1 p_2 \dots p_n)^{\frac{1}{2}}} \quad (5)$$

kde

$$\Phi = \frac{l_1^2}{p_1} + \frac{l_2^2}{p_2} + \dots + \frac{l_n^2}{p_n}$$

Hledejme tedy korelaci k -násobnou kterýchkoliv úchylek, na př. l_1, l_2, \dots, l_k ; na základě rovnice (3) můžeme vyloučiti třeba l_n , ostatní pak $l_{k+1}, l_{k+2}, \dots, l_{n-1}$ nabývají všech hodnot od $-\infty$ do $+\infty$. Je to ovšem metoda přibližná, neboť musíme uvážiti, že pokládáme l_1, l_2, \dots, l_n za veličiny malé vzhledem k sp_1, sp_2, \dots, sp_n . Dostáváme tedy

$$P(l_1, l_2, \dots, l_k) = \int_{-\infty}^{+\infty} dl_{k+1} \int_{-\infty}^{+\infty} dl_{k+2} \dots \int_{-\infty}^{+\infty} dl_{n-1} P(m_1, m_2, \dots, m_n) \quad (6)$$

Vyloučíme-li l_n pomocí rovnice (3) jest

$$\Phi_1 = \sum_{i=1}^{n-1} l_i^2 \left(\frac{1}{p_i} + \frac{1}{p_n} \right) + \frac{1}{p_n} \sum_{i=1}^{n-1} \sum_{j=1}^{n-1} l_i l_j \quad (7)$$

kdež jest $i \neq j$.

Determinant této kvadratické formy si označíme D , subdeterminant pak D_{ij} , subdeterminanty druhého řádu $D_{ij, rs}$ atd., prvky jeho d_{pq} .

Máme-li integrovati $P(m_1, m_2, \dots, m_n)$ na př. podle l_1 , rozložíme Φ_1 takto:

²⁾ Viz na příklad C. V. Charlier: Vorlesungen über die Grundzüge der mathematischen Statistik.

$$\begin{aligned} \Phi_1 &= d_{11} l_1^2 + 2l_1 \sum_{i=2}^{n-1} d_{1i} l_i + \sum_{i=2}^{n-1} \sum_{j=2}^{n-1} d_{ij} l_i l_j = \\ &= d_{11} \left(l_1 + \frac{d_{12}}{d_{11}} l_2 + \frac{d_{13}}{d_{11}} l_3 + \dots + \frac{d_{1n-1}}{d_{11}} l_{n-1} \right)^2 + \\ &+ \sum_{i=2}^{n-1} \sum_{j=2}^{n-1} \frac{d_{ij} d_{11} - d_{1i} d_{1j}}{d_{11}} l_i l_j. \end{aligned}$$

Po této transformaci lze provést integraci podle ξ

$$\xi = l_1 + \frac{d_{12}}{d_{11}} l_2 + \dots + \frac{d_{1n-1}}{d_{11}} l_{n-1}.$$

Před integrál vystoupí faktor $\frac{\sqrt{\pi}}{\sqrt{d_{11}}}$; proměnná l_1 je odstraněna a

Φ_1 se redukuje na

$$\sum_{i=2}^{n-1} \sum_{j=2}^{n-1} \frac{d_{ij} d_{11} - d_{1i} d_{1j}}{d_{11}} l_i l_j.$$

Použijeme-li známých vztahů odvozených Pearsonem⁵⁾

$$d_{ij} = \frac{1}{2} \frac{R_{ij}}{\sigma_i \sigma_j R}, \quad d_{1i} = \frac{1}{2} \frac{R_{1i}}{\sigma_i^2 R}$$

dostáváme

$$\frac{d_{ij} d_{11} - d_{1i} d_{1j}}{d_{11}} = \frac{1}{2 \sigma_i \sigma_j R_{11}} \cdot \frac{R_{ij} R_{11} - R_{1i} R_{1j}}{R} = \frac{R_{11, ij}}{2 \sigma_i \sigma_j R_{11}}.$$

Determinant v čitateli $R_{ij} R_{11} - R_{1i} R_{1j}$ se totiž podle známé věty rovná součinu z hlavního determinantu a subdeterminantu druhého řádu. Redukovaná forma Φ_1 se dá vyjádřit tedy pomocí determinantu R_{11} stejně jako původní pomocí determinantu R . Třeba jen ještě zdůraznit, že integrál má smysl, jen když forma Φ_1 je definitní. Tímto způsobem pak pokračujeme dále, takže v našem případě máme podle rovnice (4)

$$P(l_1, l_2, \dots, l_k) = \frac{e^{-\frac{1}{2} \chi_k^2}}{(2\pi)^{\frac{k}{2}} \sigma_1 \sigma_2 \dots \sigma_k \sqrt{R_{k+1, k+1; \dots, n-1, n-1}}} \quad (8)$$

⁵⁾ Phil. Trans. 187, který uvádí tam priority Edgeworthovu. Viz A. Bowley: Elements of statistics.

kdež

$$\chi_k^2 = \sum_{i=1}^k \sum_{j=1}^k \frac{R_{k+1, k+1; \dots n-1, n-1; i, j}}{\sigma_i \sigma_j R_{k+1, k+1; \dots n-1, n-1}} l_i l_j \quad (9)$$

Tak dostáváme konečně obecný vztah

$$\begin{aligned} & \frac{1}{\sigma_i \sigma_j} \frac{R_{k+1, k+1; \dots n-1, n-1; i, j}}{R_{k+1, k+1; \dots n-1, n-1}} = \\ & = \frac{D_{11, 11; \dots i-1, j-1; i+1, j+1; \dots k, k}}{D_{11, 11 \dots k, k}} \end{aligned} \quad (10)$$

Na základě této rovnice můžeme pak napsati všechny potřebné případy zvláštní. Uvedeme zde jen jeden příkladem.

Pro $n=5, k=2$ máme dle (10) a (7) píšeme-li $1-p_i = q^i$ tyto rovnice

$$\begin{aligned} \frac{1}{\sigma_1^2} \frac{R_{33, 44; 11}}{R_{33, 44}} &= \frac{1}{\sigma_1^2} \frac{1}{1-r_{12}^2} = \frac{q_2}{s p_1 (p_3 + p_4 + p_5)}, \\ \frac{1}{\sigma_1^2} \frac{R_{33, 44; 22}}{R_{33, 44}} &= \frac{1}{\sigma_2^2} \frac{1}{1-r_{12}^2} = \frac{q_1}{s p_1 (p_3 + p_4 + p_5)}, \\ \frac{1}{\sigma_1 \sigma_2} \frac{R_{33, 44; 12}}{R_{33, 44}} &= \frac{1}{\sigma_1 \sigma_2} \frac{r_{12}}{1-r_{12}^2} = \frac{1}{s (p_3 + p_4 + p_5)}; \end{aligned}$$

z nich pak vyplývá

$$\begin{aligned} r_{12} \frac{\sigma_1}{\sigma_2} &= -\frac{p_1}{q_2}, \\ r_{12} \frac{\sigma_2}{\sigma_1} &= -\frac{p_2}{q_1}, \\ r_{12}^2 &= \frac{p_1 p_2}{q_1 q_2}. \end{aligned}$$

Z prvních dvou rovnic je patrné, že r je negativní, tedy

$$r_{12} = -\sqrt{\frac{p_1 p_2}{q_1 q_2}}.$$

Tato rovnice byla po prvé uvedena Pearsonem⁴⁾ a vyplývá zde ihned jako zvláštní případ z našeho obecného odvození. Nemění se ovšem, jedná-li se o jiný případ n při $k=2$.

Konečně ještě dostáváme

$$\sigma_1 = \sqrt{s p_1 q_1}, \quad \sigma_2 = \sqrt{s p_2 q_2}.$$

⁴⁾ Math. Contrib. to the theory of evolution XIV.

Sur le coefficient de corrélation dans la statistique homogène.

(Extrait de l'article précédent.)

Nous résolvons la question d'une corrélation multiple d'ordre k entre les écarts quelconques l_i ($i=1, 2, \dots, n$) dans l'ensemble s des individus classés d'après n propriétés alternantes.

En employant l'expression approchée $P(m_1, m_2, \dots, m_n)$ pour la probabilité des écarts simultanés l_1, l_2, \dots, l_n , nous obtenons l'équation (6), qui peut être ramenée à l'équation (8) à l'aide de l'expression $d_{ij} = \frac{1}{2} \frac{R_{ij}}{\sigma_i \sigma_j R}$; il en suit immédiatement la relation (10) entre les coefficients partiels de corrélation et les probabilités fondamentales. Comme un cas spécial nous trouvons aisément

$$r_{1,2} = -\sqrt{\frac{p_1 p_2}{q_1 q_2}},$$

équation indiquée pour la première fois par Pearson.