

Jaroslav Hájek

O rozdělení některých statistik za přítomnosti vnitrotržní korelace

Časopis pro pěstování matematiky, Vol. 83 (1958), No. 3, 327–329

Persistent URL: <http://dml.cz/dmlcz/108296>

Terms of use:

© Institute of Mathematics AS CR, 1958

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



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

O ROZDĚLENÍ NĚKTERÝCH STATISTIK ZA PŘÍTOMNOSTI
VNITROTŘÍDNÍ KORELACE

JAROSLAV HÁJEK, Praha

(Došlo dne 6. září 1957)

DT: 519.271
519.272.2

Velmi jednoduchým způsobem je dokázáno, že přítomnost vnitro-
třídní korelace nemá vliv na rozdělení některých důležitých statistik.
Dosažený výsledek v sobě zahrnuje výsledek, ke kterému dospěl
M. HALPERIN v práci [1].

Věta. *Mějme normální náhodné veličiny y_1, y_2, \dots, y_n s libovolnými středními
hodnotami. Tvrdíme, že následující dvě hypotesy H_1 a H_2 o rozptylu a korelačních
koeficientech*

$$H_1: \quad \begin{aligned} Dy_i &= \sigma^2, & i, j &= 1, \dots, n; \\ \rho_{ij} &= \rho, & i \neq j, & -\frac{1}{n-1} < \rho < 1; \end{aligned} \quad (1)$$

$$H_2: \quad \begin{aligned} Dy_i &= (1 - \rho) \sigma^2, & i, j &= 1, \dots, n; \\ \rho_{ij} &= 0, & i \neq j, & \end{aligned} \quad (2)$$

vedou k témuž rozdělení u vektoru $(y_1 - \bar{y}, \dots, y_n - \bar{y})$, kde $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$, a tu-
díž i u všech statistik tvaru $s = s(y_1 - \bar{y}, \dots, y_n - \bar{y})$; kromě toho, při obou hypo-
tesách je výběrový průměr \bar{y} nezávislý na vektoru $(y_1 - \bar{y}, \dots, y_n - \bar{y})$.

Důkaz. Necht normální náhodné veličiny z_1, \dots, z_n se chovají podle hypotesy
 H_2 , tj. jsou nezávislé na rozptylu $(1 - \rho) \sigma^2$. Přímým výpočtem se snadno
dokáže, že potom náhodné veličiny

$$y_i = z_i - \frac{1}{n} \left(1 - \sqrt{\frac{1 + (n-1)\rho}{1-\rho}} \right) \sum_{i=1}^n (z_i - Mz_i) \quad (3)$$

se chovají podle hypotesy H_1 , tj. mají rozptyl σ^2 a korelační koeficienty $\rho_{ij} = \rho$;
kromě toho střední hodnoty jsou stejné, $My_i = Mz_i$. Z (3) plyne, že $y_i - \bar{y} =$
 $= z_i - \bar{z}$, takže $(y_1 - \bar{y}, \dots, y_n - \bar{y}) = (z_1 - \bar{z}, \dots, z_n - \bar{z})$, odkud plyne první
tvrzení věty. Dále z (3) a z $My_i = Mz_i$ vyplývá, že

$$\bar{y} - M\bar{y} = \sqrt{\frac{1 + (n-1)\rho}{1-\rho}} (\bar{z} - M\bar{z}), \quad (4)$$

takže nezávislost \bar{z} a $(z_1 - \bar{z}, \dots, z_n - \bar{z})$, jež je dobře známa, implikuje nezávislost \bar{y} a $(y_1 - \bar{y}, \dots, y_n - \bar{y})$. Tím je důkaz proveden.

Věta umožňuje převést výsledky vypracované pro obvyklou hypotézu H_2 , znamenající nezávislost, na poněkud obecnější případ popsany hypotézou H_1 , znamenající přítomnost vnitrotřídní korelace, tj. korelace konstantní pro všechny páry náhodných veličin.

Příklad 1. Příkladem statistik tvaru $s = s(y_1 - \bar{y}, \dots, y_n - \bar{y})$ jsou nejlepší lineární odhady b_j regresních koeficientů β_j ve vztahu

$$My_i = \mu + \sum_{j=1}^k \beta_j(x_j - \bar{x}), \quad (5)$$

dále residuální rozptyl $\sum_{i=1}^n (y_i - \bar{y} - \sum b_j(x_j - \bar{x}))^2$, dále vektor, jehož komponentami jsou právě jmenované statistiky apod. Přítomnost vnitrotřídní korelace má na tyto a jim podobné statistiky stejný účinek jako změna rozptylu z σ^2 na $(1 - \rho) \sigma^2$ při ponechání předpokladu nezávislosti.

Příklad 2. Při náhodném výběru n elementů z N elementů bez opakování je $\rho = -\frac{1}{N-1}$. Za předpokladu, že rozdělení pozorování je zhruba normální, z naší věty vyplývá, že Studentův poměr

$$t = \frac{\bar{y} - \bar{y}}{\sqrt{\left(\frac{1-n}{N}\right) \sum_{i=1}^n (y_i - \bar{y})^2}},$$

kde \bar{y} resp. \bar{y} je průměr hodnot na vybraných resp. na všech elementech, má zhruba Studentovo rozdělení s $n - 1$ stupni a nikoliv s $\frac{n-1}{1-\frac{n}{N}}$, jak je do-

poručováno v CRAMÉROVĚ knize [2] na str. 523. K témuž závěru dospějeme, předpokládáme-li, že hodnoty y_1, \dots, y_n tvoří náhodný výběr z normálního rozdělení a hodnoty y_1, \dots, y_n část tohoto výběru.

Poznámka. Representace (3), která je poněkud jednodušší než ta, kterou použil J. E. WALSH v [3], nám dovoluje ihned najít hustotu pozorování (y_1, \dots, y_n) při platnosti hypotézy H_1 . Skutečně hustota vektoru (z_1, \dots, z_n) je rovna

$$K_1 e^{-\frac{1}{2} \sum_{i=1}^n \frac{(z_i - Mz_i)^2}{(1-\rho)\sigma^2}} = K_1 e^{-\frac{1}{2} \left[\sum_{i=1}^n \frac{(z_i - Mz_i - \bar{z} + M\bar{z})^2}{(1-\rho)\sigma^2} + \frac{n(\bar{z} - M\bar{z})^2}{(1-\rho)\sigma^2} \right]}.$$

Lineární transformací (3), z které plyne $z_i - Mz_i - \bar{z} + M\bar{z} = y_i - My_i - \bar{y} + M\bar{y}$ a (4), dostáváme hustotu (y_1, \dots, y_n) ve tvaru

$$K_2 e^{-\frac{1}{2} \left[\sum_{i=1}^n \frac{(y_i - My_i - \bar{y} + M\bar{y})^2}{(1-\rho)\sigma^2} + \frac{n}{\sigma^2[1+(n-1)\rho]} (\bar{y} - M\bar{y})^2 \right]}. \quad (6)$$

Determinant kovariační matice při hypotese H_1 je roven

$$\sigma^{2n}[1 + (n - 1) \rho] (1 - \rho)^{n-1},$$

takže

$$K_2 = (2\pi)^{-\frac{n}{2}} \sigma^{-n} (1 - \rho)^{-\frac{n-1}{2}} [1 + (n - 1) \rho]^{-\frac{1}{2}}.$$

Z hustoty (6) vyplývá, že maximálně věrohodné odhady regresních koeficientů v (5) jsou tytéž při obou hypotésách H_1 i H_2 . Nemá tedy Halperin pravdu, když v [1] tvrdí, že nalezení maximálně věrohodných odhadů při hypotese H_1 je neúměrně složité. Ve skutečnosti odhady (3.3) uvedené v jeho práci [1] nejsou ničím jiným než maximálně věrohodnými odhady.

LITERATURA

- [1] *M. Halperin*: „Normal regression theory in the presence of intra-class correlation“, Ann. Math. Statist. 22 (1951), 573–580.
- [2] *H. Cramér*: „Mathematical methods of statistics“, Princeton University Press, 1946.
- [3] *J. E. Walsh*: „Concerning the effect of intraclass correlation on certain significance tests“, Ann. Math. Statist. 18 (1947), 88–96.

Резюме

О РАСПРЕДЕЛЕНИИ НЕКОТОРЫХ СТАТИСТИК ПРИ НАЛИЧИИ МЕЖДУКЛАССОВОЙ КОРРЕЛЯЦИИ

ЯРОСЛАВ ГАЕК (Jaroslav Hájek), Прага
(Поступило в редакцию 6/IX 1957 г.)

В статье доказывается, что n -мерному нормальному распределению с постоянной дисперсией σ^2 и с коэффициентом корреляции ρ соответствует плотность вероятности (6). Из вида последней следует, что максимально правдоподобные оценки коэффициентов регрессии β_j в соотношении $My_i = a + \sum \beta_j(x_{ji} - \bar{x}_j)$ не зависят от ρ . Одновременно выводятся некоторые результаты, содержащиеся в [1] и [3].

Summary

ON THE DISTRIBUTION OF SOME STATISTICS IN THE PRESENCE OF INTRACLAS CORRELATION

JAROSLAV HÁJEK, Praha
(Received September 6, 1957)

The n -dimensional normal distribution with constant variance σ^2 and correlation coefficient ρ is proved to possess the probability density (6). From its form it is easily seen that the maximal-likelihood estimates of the regression coefficients β_j in the relation $My_i = a + \sum \beta_j(x_{ji} - \bar{x}_j)$ are independent of ρ . Some results contained in [1] and [3] are derived in addition.