

FORMULE ZA 8. VAJO PRI PREDMETU NAKLJUČNI POJAVI

Enakost povprečij  $r \geq 2$  normalno porazdeljenih populacij s podobno varianco lahko preverimo s testom, ki se imenuje analiza variance. Pri tem testu ničelna hipoteza trdi, da so vsa povprečja enaka, alternativna pa, da se vsaj eno povprečje razlikuje od drugih:

$$\begin{aligned} H_0 : m_1 = m_2 = \dots = m_r, \\ H_1 : m_i \neq m_j, \quad \text{za vsaj en par } (i, j). \end{aligned} \quad (1)$$

Za preverjanje enakosti potrebujemo po en vzorec s po  $n_i$  elementi iz vsake populacije, skupaj torej  $r$  vzorcev z  $N = \sum_i n_i$  elementi:

vzorec 1	$x_{11}$	$x_{12}$	$\dots$	$x_{1n_1}$
vzorec 2	$x_{21}$	$x_{22}$	$\dots$	$x_{2n_2}$
$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$
vzorec $r$	$x_{r1}$	$x_{r2}$	$\dots$	$x_{rn_r}$

Test temelji na primerjavi povprečnega odstopanja izmerjene spremenljivke med vzorci s povprečnim odstopanjem spremenljivke znotraj vzorcev. V kolikor so odstopanja med vzorci značilno večja kot odstopanja znotraj vzorcev,  $H_0$  zavrnemo. Uporabimo  $F$ -porazdeljeno testno statistiko:

$$F = \frac{S_1^2}{S_2^2}, \quad (2)$$

ki ima  $(r - 1, N - r)$  prostostnih stopenj.  $S_1^2$  predstavlja povprečno kvadratično odstopanje med posameznimi vzorci, medtem ko  $S_2^2$  predstavlja povprečno kvadratično odstopanje znotraj vzorcev. Veličine, potrebne za izračun testne statistike, vpišujemo v tabelo:

Odstopanje	Vsota kvadratičnih odstopanj	Število prostostnih stopenj	Povprečje kvadratičnih odstopanj	Statistika
Med skupinami	$Q_1$	$r - 1$	$S_1^2 = \frac{Q_1}{r - 1}$	$F = \frac{S_1^2}{S_2^2}$
Znotraj skupin	$Q_2$	$N - r$	$S_2^2 = \frac{Q_2}{N - r}$	
Celotno	$Q$	$N - 1$		

Pri izračunu si lahko pomagamo z naslednjimi formulami:

$$Q = \sum_{i=1}^r \sum_{j=1}^{n_i} x_{ij}^2 - \frac{x_{\bullet\bullet}^2}{N} \quad x_{\bullet\bullet} = \sum_{i=1}^r \sum_{j=1}^{n_i} x_{ij} \quad (3)$$

$$Q_1 = \sum_{i=1}^r \frac{x_{i\bullet}^2}{n_i} - \frac{x_{\bullet\bullet}^2}{N} \quad x_{i\bullet} = \sum_{j=1}^{n_i} x_{ij} \quad (4)$$

$$Q_2 = Q - Q_1 \quad N = \sum_{i=1}^r n_i \quad (5)$$

Linearnost odvisnosti med dvema spremenljivkama  $X$  in  $Y$  lahko s korelacijskim koeficientom:

$$r_{XY} = \frac{\text{Cov}[X, Y]}{\sqrt{\text{Var}[X] \text{Var}[Y]}} = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{\left( n \sum_{i=1}^n x_i^2 - \left( \sum_{i=1}^n x_i \right)^2 \right) \left( n \sum_{i=1}^n y_i^2 - \left( \sum_{i=1}^n y_i \right)^2 \right)}}, \quad (6)$$

katerega zaloga vrednosti je  $[-1, 1]$ . Vrednosti  $|r_{XY}| \approx 1$  kažejo na izrazito linearno odvisnost med  $X$  in  $Y$ , medtem ko vrednosti  $|r_{XY}| < 0.5$  kažejo, da spremenljivki nista linearno odvisni. V slednjem primeru sta spremenljivki lahko neodvisni ali pa je njuna odvisnost nelinearna.

Matematični model linearne odvisnosti je:

$$Y = aX + b, \quad (7)$$

graf te enačbe pa je premica. Koeficienta  $a$  in  $b$  izračunamo:

$$a = \frac{\text{Cov}[X, Y]}{\text{Var}[X]} = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left( \sum_{i=1}^n x_i \right)^2}, \quad (8)$$

$$b = E[Y] - aE[X] = \frac{1}{n} \sum_{i=1}^n y_i - \frac{a}{n} \sum_{i=1}^n x_i.$$

S tema koeficientoma določena premica se najboljše prilega izmerjenim točkam  $(x_i, y_i)$ , saj je povprečno kvadratično odstopanje izmerjenih točk od premice minimalno.

Linearni model lahko uporabimo tudi, kadar zveza med spremenljivkama ni linearna. V takih primerih si lahko pomagamo z logaritmiranjem zveze, v kolikor jo s tem lineariziramo, ali pa uvedemo nove spremenljivke, kot npr.:

$$Y = aX^2 + b = aZ + b, \quad \text{kjer je } X^2 = Z. \quad (9)$$