

### Preverjanje neparametričnih hipotez

**Prilagoditveni test:** hipotezi se nanašata na *tip porazdelitvene funkcije*. Ničelna hipoteza trdi, da je obravnavana naključna spremenljivka  $X$  porazdeljena z verjetnostno porazdelitvijo  $f_0(x)$ , alternativna pa, da to ne drži:

$$\begin{aligned} H_0 : f(x) &= f_0(x), \\ H_1 : f(x) &\neq f_0(x). \end{aligned} \tag{1}$$

$H_0$  preverimo tako, da razpon naključne spremenljivke  $X$  razdelimo na  $r$  intervalov oziroma razredov s širinami  $\Delta x_i$ . Za vzorec z  $n$  elementi določimo število meritev (frekvenco)  $n_i$ , ki pripada posameznem razredu. Za vsak razred lahko ocenimo verjetnost  $p_i = n_i/n$ , da  $X$  zavzame vrednost, ki pripada temu razredu. Ocenjene frekvence  $n_i$  nato primerjamo s frekvencami  $n_{i_0} = p_{i_0}n$ , ki jih za razrede izračunamo na podlagi v  $H_0$  predpostavljene porazdelitve. Primerjavo izvedemo s testno statistiko, ki je utežena vsota kvadrata relativne razlike frekvenc:

$$\chi^2 = \sum_{i=1}^r \frac{(n_i - n_{i_0})^2}{n_{i_0}^2} n_{i_0} = \sum_{i=1}^r \frac{(n_i - n_{i_0})^2}{n_{i_0}} = n \sum_{i=1}^r \frac{(p_i - p_{i_0})^2}{p_{i_0}} = \left( \sum_{i=1}^r \frac{n_i^2}{n_{i_0}} \right) - n. \tag{2}$$

Porazdelitev testne statistike  $\chi^2$  se asimptotično bliža porazdelitvi  $\chi_{r-l-1}^2$ , kjer je  $l$  število parametrov predpostavljene porazdelitve, ki smo jih morali oceniti iz vzorca, da smo lahko izračunali frekvence  $n_{i_0}$ . Pri normalni porazdelitvi je  $l = 2$ , pri eksponentni in Poissonovi  $l = 1$  in pri enakomerni  $l = 0$ . Če je  $n$  velik in če je  $n_i \geq 5$  za vsak razred, je porazdelitev statistike  $\chi^2$  zelo podobna porazdelitvi  $\chi_{r-l-1}^2$ . Če vrednost testne statistike presega kritično vrednost  $\chi_{r-l-1;\alpha}^2$ ,  $H_0$  zavrnemo. Za večjo preglednost računa navadno naredimo tabelo s stolpci  $x_i$ ,  $n_i$ ,  $n_i^2$ ,  $n_{i_0} = p_{i_0}n$  in  $n_i^2/n_{i_0}$ . Vrednost testne statistike je enaka vsoti zadnjega stolpca.

**Test neodvisnosti:** hipotezi se nanašata na *(ne)odvisnost dveh naključnih spremenljivk* oziroma vplivov  $X$  in  $Y$ , katerih vrednosti lahko razdelimo na  $r$  oziroma  $c$  razredov. Na vzorcu  $n$  vrednosti za vsak par razredov  $(x_i, y_j)$  določimo frekvence  $n_{ij}$  in jih vpišemo v kontingenčno tabelo:

|               |          | Y             |               |          |               | $n_{i\star}$         |
|---------------|----------|---------------|---------------|----------|---------------|----------------------|
|               |          | $y_1$         | $y_2$         | $\cdots$ | $y_c$         |                      |
| X             | $x_1$    | $n_{11}$      | $n_{12}$      | $\cdots$ | $n_{1c}$      | $n_{1\star}$         |
|               | $x_2$    | $n_{21}$      | $n_{22}$      | $\cdots$ | $n_{2c}$      | $n_{2\star}$         |
|               | $\vdots$ | $\vdots$      | $\vdots$      | $\vdots$ | $\vdots$      | $\vdots$             |
|               | $x_r$    | $n_{r1}$      | $n_{r2}$      | $\cdots$ | $n_{rc}$      | $n_{r\star}$         |
| $n_{\star j}$ |          | $n_{\star 1}$ | $n_{\star 2}$ | $\cdots$ | $n_{\star c}$ | $n_{\star\star} = n$ |

V tabeli znak  $\star$  na mestu indeksa pomeni vsoto po tem indeksu:

$$n_{i\star} = \sum_{j=1}^c n_{ij} \quad \text{oziorama} \quad n_{\star j} = \sum_{i=1}^r n_{ij}. \tag{3}$$

Ničelna hipoteza pri tem testu trdi, da sta  $X$  in  $Y$  neodvisni, alternativna hipoteza pa, da nista:

$$\begin{aligned} H_0 : p_{ij} &= p_i \cdot p_j, & \text{za vsak par } (i, j) \\ H_1 : p_{ij} &\neq p_i \cdot p_j, & \text{za vsaj en par } (i, j). \end{aligned} \tag{4}$$

Pričakovano povezano verjetnost  $p_{ij_0}$  na podlagi  $H_0$  izračunamo s produktom robnih relativnih frekvenc:  $p_{ij_0} = p_{i_0}p_{j_0} = n_{i_*}n_{*j}/n^2$ . Ničelno hipotezo preverimo s testno statistiko:

$$\chi^2 = n \sum_{i=1}^r \sum_{j=1}^c \frac{(p_{ij} - p_{ij_0})^2}{p_{ij_0}} = n \sum_{i=1}^r \sum_{j=1}^c \frac{(n_{ij} - n_{i_*}n_{*j}/n)^2}{n_{i_*}n_{*j}} = n \left( \sum_{i=1}^r \sum_{j=1}^c \frac{n_{ij}^2}{n_{i_*}n_{*j}} - 1 \right), \quad (5)$$

Testna statistika  $\chi^2$  je  $\chi_{(r-1)(c-1)}^2$  porazdeljena. V kolikor je vrednost testne statistike večja od kritične  $\chi_{(r-1)(c-1); \alpha}^2$ ,  $H_0$  zavrnemo.

**Test homogenosti:** hipotezi se nanašata na *(ne)homogenost v skupin glede na predpisani kriterij*, ki ima  $r$  možnih vrednosti. Za vsako skupino imamo vzorec z  $n_i$  vrednostmi, ki so glede na kriterij razdeljene v  $r$  razredov. Tako določimo frekvence  $n_{ij}$ , ki jih vpišemo v kontingenčno tabelo:

|         |          | Kriterij |          |          |          | $n_{i_*} = n_i$ |
|---------|----------|----------|----------|----------|----------|-----------------|
|         |          | $y_1$    | $y_2$    | $\cdots$ | $y_r$    |                 |
| Skupine | $x_1$    | $n_{11}$ | $n_{12}$ | $\cdots$ | $n_{1r}$ | $n_{1_*} = n_1$ |
|         | $x_2$    | $n_{21}$ | $n_{22}$ | $\cdots$ | $n_{2r}$ | $n_{2_*} = n_2$ |
|         | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$ | $\vdots$        |
|         | $x_v$    | $n_{v1}$ | $n_{v2}$ | $\cdots$ | $n_{vr}$ | $n_{r_*} = n_v$ |
|         | $n_{*j}$ | $n_{*1}$ | $n_{*2}$ | $\cdots$ | $n_{*r}$ | $n_{*_*} = n$   |

Tabela je podobna kot pri testu neodvisnosti, le da so v tem primeru frekvence  $n_{ij}$  določene že pred testom z velikostjo vzorca posamezne skupine in niso odvisne od razvrščanja. Ničelna hipoteza pri tem testu trdi, da so skupine homogene glede na kriterij, alternativna hipoteza pa, da niso:

$$\begin{aligned} H_0 : p_{1j} = p_{2j} = \cdots = p_{vj} = p_{*j}, & \quad \text{za vsak } j \\ H_1 : p_{ij} \neq p_{kj}, & \quad \text{za vsaj eno trojico } (i, j, k). \end{aligned} \quad (6)$$

Pričakovano verjetnost za vsak razred kriterija ocenimo s  $p_{*j_0} = n_{*j}/n$ . Pričakovane vrednosti  $p_{ij_0}$  so torej  $p_{ij_0} = n_i p_{*j_0}/n = n_{i_*}n_{*j}/n^2$ . Cenilka za  $p_{ij_0}$  je enaka kot pri testu homogenosti, zato je tudi testna statistika enaka:

$$\chi^2 = n \sum_{i=1}^v \sum_{j=1}^r \frac{(p_{ij} - p_{ij_0})^2}{p_{ij_0}} = \sum_{i=1}^v \sum_{j=1}^r \frac{(n_{ij} - n_{i_*} \cdot n_{*j}/n)^2}{n_{i_*} \cdot n_{*j}/n} = n \left( \sum_{i=1}^v \sum_{j=1}^r \frac{n_{ij}^2}{n_{i_*}n_{*j}} - 1 \right), \quad (7)$$

ki je  $\chi_{(v-1)(r-1)}^2$  porazdeljena. V kolikor je vrednost testne statistike večja od kritične  $\chi_{(v-1)(r-1); \alpha}^2$ ,  $H_0$  zavrnemo.