

# Testiranje neodvisnosti

## Matematična formulacija

### Problem in parametrični prostor

Verjetnostni prostor  $\Omega$  razbijemo na disjunktne unije:

$$\bullet \Omega = A_1 \sqcup A_2 \sqcup \dots \sqcup A_r \text{ in } \bullet \Omega = B_1 \sqcup B_2 \sqcup \dots \sqcup B_s.$$

Privzamemo, da za vsa števila  $i$  in  $j$  velja  $p_{ij} = P(A_i \cap B_j) > 0$ .

(Sledi tudi  $p_i = P(A_i) > 0$  in  $q_j = P(B_j) > 0$ .) Velja torej

$$\Theta = \left\{ [p_{ij}]_{1 \leq i \leq r, 1 \leq j \leq s} \mid p_{ij} > 0, \sum_{i,j} p_{ij} = 1 \right\}, \text{ kar je simpleks}$$

razsežnosti  $rs - 1$ , ki naravno leži v prostoru matrik  $\mathbb{R}^{r \times s}$ .

### Ničelna hipoteza neodvisnosti

Neodvisnost:  $\forall i, j : p_{ij} = P(A_i \cap B_j) = P(A_i) \cdot P(B_j) = p_i \cdot q_j$ .

To pomeni, da za vsake št.  $i$  in  $j$  velja  $p_{ij} = \left( \sum_k p_{ik} \right) \cdot \left( \sum_l p_{lj} \right)$ .

Ker je ničelna hipoteza očitno parametrizirana s kartezičnim produktom  $\Delta^{r-1} \times \Delta^{s-1}$ , je  $\dim H_0 = r + s - 2$ . Velja

$$\dim \Theta - \dim H_0 = rs - 1 - (r + s) + 2 = rs - r - s + 1 = (r-1) \cdot (s-1).$$

# Testiranje neodvisnosti

## Eksperiment

### Opis eksperimenta oziroma vzorčenja

Neodvisno in slučajno izberemo  $n$  elementov iz množice  $\Omega$  in s  $T_{ij}$  označimo število elementov, ki pripadajo preseku  $A_i \cap B_j$ .

Rezultate predstavimo v **kontingenčni tabeli**:

	1	2	...	$s-1$	$s$	
1	$T_{11}$	$T_{12}$	...	$T_{1,s-1}$	$T_{1s}$	$U_1$
2	$T_{21}$	$T_{22}$	...	$T_{2,s-1}$	$T_{2s}$	$U_2$
$\vdots$	$\vdots$	$\vdots$		$\vdots$	$\vdots$	$\vdots$
$r$	$T_{r1}$	$T_{r2}$	...	$T_{r,s-1}$	$T_{rs}$	$U_r$
	$V_1$	$V_2$	...	$V_{s-1}$	$V_s$	$n$

Gre seveda za diskretno slučajno spremenljivko  $X$  s končno zalogo vrednosti  $\{(i, j) \mid 1 \leq i \leq r, 1 \leq j \leq s\}$ , kjer je  $X(\omega) = (i, j)$ , če  $\omega \in A_i \cap B_j$ .

# Testiranje neodvisnosti: razmerje verjetij

Funkcija verjetja za vzorec velikosti  $n$  in cenilka največjega verjetja

Kot prej:  $L(x_1, \dots, x_n; \mathbf{p}) = \prod_{i,j} p_{ij}^{T_{ij}}$ ,

kjer je  $T_{ij}$  število parov  $(i, j)$  med vrednostmi  $x_1, \dots, x_n$ .

CNV je  $\hat{p}_{ij} = \frac{T_{ij}}{n}$ , zato:  $\sup_{\mathbf{p} \in \Theta} L(\mathbf{x}; \mathbf{p}) = \prod_{ij} \left(\frac{T_{ij}}{n}\right)^{T_{ij}}$ .

Cenilka največjega verjetja na  $H_0$

Upoštevamo, da velja  $p_{ij} = p_i q_j$  in računamo:

$$\begin{aligned} L(\mathbf{x}; [p_i q_j]_{ij}) &= \prod_{ij} (p_i q_j)^{T_{ij}} = \prod_{ij} p_i^{T_{ij}} q_j^{T_{ij}} = \left(\prod_{ij} p_i^{T_{ij}}\right) \cdot \left(\prod_{ij} q_j^{T_{ij}}\right) \\ &= \left(\prod_i p_i^{\sum_j T_{ij}}\right) \cdot \left(\prod_j q_j^{\sum_i T_{ij}}\right) = \left(\prod_i p_i^{U_i}\right) \cdot \left(\prod_j q_j^{V_j}\right). \end{aligned}$$

Upoštevamo  $\sum_i p_i = 1$  in  $\sum_j q_j = 1$  in dobimo  $\hat{p}_i = \frac{U_i}{n}$ ,  $\hat{q}_j = \frac{V_j}{n}$ .

Torej:  $\sup_{\mathbf{p} \in H_0} L(\mathbf{x}; \mathbf{p}) = \left(\prod_i \left(\frac{U_i}{n}\right)^{U_i}\right) \cdot \left(\prod_j \left(\frac{V_j}{n}\right)^{V_j}\right) = \dots = \prod_{ij} \left(\frac{U_i V_j}{n^2}\right)^{T_{ij}}$ .

# Testiranje neodvisnosti

Testiranje na podlagi razmerja verjetij

## Testna statistika

- $\lambda_n(\mathbf{x}) = \prod_{ij} \left( \frac{U_i V_j}{n T_{ij}} \right)^{T_{ij}},$
- $-2 \log \lambda_n(\mathbf{x}) = -2 \sum_{ij} T_{ij} \log \left( \frac{U_i V_j}{n T_{ij}} \right).$

## Test 1

Zavrnamo hipotezo neodvisnosti  $H_0 : p_{ij} = p_i \cdot q_j$ , če

$-2 \log \lambda_n(\mathbf{x}) > C$ . Pri tem

- konstanto  $C$  določimo eksaktno z multinomsko porazdelitvijo za majhne vzorce ali
- vzamemo  $C = \chi_{(r-1)(s-1); \alpha}^2$  za velike vzorce, kjer upoštevamo  $-2 \log \lambda_n \xrightarrow[n \rightarrow \infty]{d} \chi_{(r-1)(s-1)}^2.$

# Testiranje neodvisnosti

Zamenjava z asimptotično ekvivalentnim testom

## Standardna $\chi^2$ -testa

Kot prej se izkaže, da z uporabo Taylorjevega polinoma 2. stopnje za logaritem dobimo dve statistiki, ki ravno tako v porazdelitvi konvergirata k porazdelitvi  $\chi^2_{(r-1)(s-1)}$ . To sta

- $\sum_{i,j} \frac{(T_{ij} - U_i V_j / n)^2}{T_{ij}}$  in
- $\sum_{i,j} \frac{(T_{ij} - U_i V_j / n)^2}{U_i V_j / n}$ .

## Običajni zapis

Pišimo  $\hat{T}_{ij} = U_i V_j / n$ . Števila  $\hat{T}_{ij}$  imenujemo (glede na  $H_0$ ) pričakovane frekvence, števila  $T_{ij}$  pa opažene frekvence.

$$H_0 \text{ zavrnamo, če } \sum_{1 \leq i \leq r, 1 \leq j \leq s} \frac{(T_{ij} - \hat{T}_{ij})^2}{\hat{T}_{ij}} > \chi^2_{(r-1)(s-1); \alpha}.$$