

Problem

V populaciji ljudi Ω (trenutnih in bodočih) starih nad 18 let, ki imajo previsok nivo holesterola LDL v krvi, želimo primerjati dve terapiji oziroma zdravili, recimo jima A in B , zaradi kontrole pa želimo hkrati primerjati še psihosomatske učinke terapije s placeboom, recimo ji C . Tedaj bi nas zanimalo razlike nivojev holesterola pred in po terapijah A , B , C . Te razlike bi bile slučajne spremenljivke X_1 , X_2 , X_3 .

Osnovni privzetek („model“)

Verjamemo, da gre za normalno porazdeljene slučajne spremenljivke, kjer je odklon σ neodvisen od zdravljenja in enak za vse tri slučajne spremenljivke, sicer pa neznan. Torej $X_1 \sim N(\mu_1, \sigma)$, $X_2 \sim N(\mu_2, \sigma)$, $X_3 \sim N(\mu_3, \sigma)$.

Popolnoma randomizirani model

Temeljno vprašanje



Temeljno vprašanje

Temeljno vprašanje je, ali lahko statistično ugotovimo, da je med vsem tremi terapijami (ozziroma med obema terapijama ter placebo) sploh kakšna statistično zaznavna razlika.



Če želimo dokazati, da gre za razliko,

želimo zavrniti ničelno hipotezo $\mu_1 = \mu_2 = \mu_3$.



Popolnoma randomizirani model

Eksperiment

Privzemimo, da imamo m terapij.

- Izberemo naključnega bolnika ω .
- Izberemo terapijo $j \in \{1, 2, 3, \dots, m\}$ (naključno).
- Beležimo rezultat eksperimenta $X_j(\omega)$.

Ureditev in predstavitev podatkov

- Naj bo n_1 število tistih bolnikov, ki so prejeli terapijo 1.
- Naj bo n_2 število tistih bolnikov, ki so prejeli terapijo 2.
- ...
- Naj bo n_m število tistih bolnikov, ki so prejeli terapijo m .

Velja

$$n_1 + n_2 + \cdots + n_m = n.$$

Popolnoma randomizirani model

Ureditev

Rezultate predstavimo v tabeli:

$i \setminus j$	1	2	3	...	m
1	X_{11}	X_{12}	X_{13}	...	X_{1m}
2	X_{21}	X_{22}	X_{23}	...	X_{2m}
3	X_{31}	X_{32}	X_{33}	...	X_{3m}
:					
n_2	...	$X_{n_2,2}$
n_1	$X_{n_1,1}$	
n_m			$X_{n_m,m}$
n_3			$X_{n_3,3}$		

V j -tem stolpcu navedemo rezultate terapije št. j .

Popolnoma randomizirani model

Testna statistika

Oznaki

- $\bar{X}_{\bullet j}$ = povprečje j -tega stolpca = $\frac{1}{n_j} \sum_{i=1}^{n_j} X_{ij}$,
- $\bar{X}_{\bullet\bullet}$ = povprečje celotnega vzorca
 $= \frac{1}{n} \sum_{j=1}^m \sum_{i=1}^{n_j} X_{ij} = \frac{1}{n} \sum_{j=1}^m n_j \bar{X}_{\bullet j}$

Naivna testna statistika

variacija skupine j glede na celotno povprečje

$$\frac{\sum_{j=1}^m n_j \overbrace{(\bar{X}_{\bullet j} - \bar{X}_{\bullet\bullet})^2}^{\text{VMS}}}{\sum_{j=1}^m \underbrace{\sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2}_{(n_j-1) \cdot S_j^2}} = \frac{\text{VMS}}{\text{VZS}}.$$

$(n_j-1) \cdot S_j^2$: variacija znotraj skupine j

Popolnoma randomizirani model

Testna statistika

Dejanska testna statistika

$$F = \frac{\text{VMS}/(m-1)}{\text{VZS}/(n-m)} = \frac{\sum_{j=1}^m n_j (\bar{X}_{\bullet j} - \bar{X}_{\bullet\bullet})^2 / (m-1)}{\sum_{j=1}^m \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2 / (n-m)}.$$

Porazdelitev testne statistike

Če velja ničelna hipoteza $H_0: \mu_1 = \mu_2 = \dots = \mu_m$ (pravimo ji tudi hipoteza **homogenosti**), ima F Fisherjevo porazdelitev z $m-1$ ter $n-m$ prostostnimi stopnjami.

Test

$$\begin{cases} H_0 \text{ zavrnemo,} & \text{če } F > C \\ H_0 \text{ ne zavrnemo,} & \text{če } F \leqslant C, \end{cases}$$

kjer $C = F_{m-1, n-m; \alpha}$, zgornji α -percentil F -porazdelitve z $m-1$ in n prostostnimi stopnjami. Test ima eksaktno značilnost α .

Popolnoma randomizirani model

Pojasnila glede testne statistike

Oglejmo si $\sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2$

$i \setminus j$	1	2	3	...	j	...	m
1	X_{11}	X_{12}	X_{13}	...	X_{1j}	...	X_{1m}
2	X_{21}	X_{22}	X_{23}	...	X_{2j}	...	X_{2m}
3	X_{31}	X_{32}	X_{33}	...	X_{3j}	...	X_{3m}
:							
n_2	...	$X_{n_2,2}$
n_1	$X_{n_1,1}$		$X_{n_1,j}$
n_m		$X_{n_m,m}$
n_3			$X_{n_3,3}$				

- j -ti stolpec lahko gledamo kot n_j neodvisnih replikacij eksperimenta $N(\mu_j, \sigma)$.
- Torej je $\frac{1}{\sigma^2} \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2$ porazdeljena kot $\chi_{n_j-1}^2$.

Popolnoma randomizirani model

Pojasnila glede testne statistike



Oglejmo si $\sum_{j=1}^m \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2$

- Od prej: $\frac{1}{\sigma^2} \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2$ je porazdeljena kot $\chi^2_{n_j - 1}$.
- Pripomnimo, da se $C_j = \frac{1}{\sigma^2} \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2$ tiče samo j -tega stolpca. Torej so C_1, \dots, C_m paroma neodvisne.
- Torej je $\frac{1}{\sigma^2} \sum_{j=1}^m \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2$ porazdeljena po zakonu χ^2 z $\sum_{j=1}^m (n_j - 1) = n - m$ prostostnimi stopnjami.



Popolnoma randomizirani model

Pojasnila glede testne statistike

Naj velja H_0 , t.j. $\mu_1 = \mu_2 = \dots = \mu_m =: \mu$

Velja dekompozicija

$$\frac{1}{\sigma^2} \sum_{j=1}^m \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet\bullet})^2 = \frac{1}{\sigma^2} \sum_{j=1}^m \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2 + \frac{1}{\sigma^2} \sum_{j=1}^m n_j (\bar{X}_{\bullet j} - \bar{X}_{\bullet\bullet})^2.$$

- Leva stran je porazdeljena po zakonu χ^2_{n-1} (ker velja H_0).
- Po zgornjem neodvisno od H_0 vedno velja
$$\frac{1}{\sigma^2} \sum_{j=1}^m \sum_{i=1}^{n_j} (X_{ij} - \bar{X}_{\bullet j})^2 \sim \chi^2_{n-m}.$$
- Izkaže se, da sta sumanda na desni neodvisna.
- Sledi
$$\frac{1}{\sigma^2} \sum_{j=1}^m n_j (\bar{X}_{\bullet j} - \bar{X}_{\bullet\bullet})^2 \sim \chi^2_{m-1}.$$