

Analiza variance (ANOVA)

Analiza variance je ena najpomembnejših kemometrijskih metod. Pri ANOVI gre za analizo oziroma za primerjavo povprečij večjega števila vzorcev (k). Ničelna hipoteza ANOVE je vedno statistična enakost vseh povprečij. Testiramo predpostavko, da so vsi vzorci vzeti iz iste populacije. ANOVA je uporabna predvsem pri vrednotenju laboratorijev za delo z neko predpisano metodo, za primerjanje rezultatov iste metode, ki jih dajejo različni laboratoriji ali en laboratorij pod različnimi pogoji (posledično je torej uporabna za odkrivanje slabosti v laboratorijih), za testiranje ustreznosti kalibracije analitskih instrumentov (glej poglavje o kalibracijske premici), za testiranje modelov dobljenih z MLR (ali drugimi modelnimi metodami) s katerimi napovedujemo lastnosti kompleksnih vzorcev in podobno.

ANOVA je osnovana na dveh predpostavkah:
 a) vse meritve x_{ij} so normalno porazdeljene in
 b) variance v vzorcih so homogene (Bartlettov test)

K sreči je ANOVA zelo robustna metoda, kar pomeni, da daje uporabne rezultate tudi, če podatki malo odstopajo od obeh gornjih predpostavk.

Pri ANOVI vedno najprej sestavimo več skupini vzorcev, ki smo jih dobili z meritvami pri obdelavi ali ovrednotenju nekega analitskega procesa. Ničelna hipoteza H_0 pri ANOVA testu je, da so povprečja v skupinah vzorcev statistično enaka. Z drugimi besedami, da se ob upoštevanem tveganju α , ne razlikujejo med seboj. Ničelna hipoteza pri ANOVI preverjamo z F -testom, to je s primerjavo variance povprečij med skupinami vzorcev, ki smo jih izbrali, in variance povprečij znotraj vzorcev.

$$F = \frac{\sigma_{\text{med skupinami}}^2}{\sigma_{\text{znotraj skupin}}^2} < F_{\alpha, p_{11}, p_{22}}^{\text{tabele}} \rightarrow H_0 \text{ sprejeta}$$

Obe oznaki p_{11} in p_{22} v zgornji enačbi pomenita število prostostnih stopenj v števcu (p_{11}) in v imenovalcu (p_{22})

1

Večkratni t-test

Če želimo primerjati več povprečnih vrednosti bi lahko za to uporabili večkratni t-test. Vendar pri taki primerjavi uporabimo isto povprečno vrednost večkrat, zato posamezni t-testi niso več med seboj neodvisni. Kot posledica se verjetnost da bo vsaj en test spodletel pri primerjavi povprečnih vrednosti iz iste populacije poveča. En način da se znebimo tega problema je da prilagodimo tveganje (Bonferronijeva prilagoditev) posameznega testa (α') tako, da bo skupno tveganje (α) take določitve doseglo predpisano vrednost.

$$\alpha' = 1 - (1 - \alpha)^{\frac{1}{k}}$$

Primer:

Primerjamo 5 povprečij. Za tako primerjavo moramo narediti 10 t-testov. Če želimo, da bo skupno tveganje napovedi $\alpha=0.05$, potem mora biti izbrano tveganje posameznega testa α' :

$$\alpha' = 1 - (1 - \alpha)^{\frac{1}{k}} = 1 - (1 - 0.05)^{\frac{1}{10}} = 0.005$$

Eno-faktorska ANOVA (one-way ANOVA), medlaboratorijski test

Najenostavnejši primer ANOVE je primerjava povprečij k vzorcev. Vsak j -ti vzorec ima n_j meritev. Testiramo ali so vsa povprečja iz iste populacije. Če gre pri tem za medlaboratorijsko primerjavo k laboratorijev pri kateri je bilo v vsakem laboratoriju narejenih n_j meritev, preverjamo ali dobijo vsi laboratoriji statistično enake rezultate (seveda ob naprej predpisani stopnji tveganja α).

Oznaka x_{ij} pomeni i -to meritev v j -tem laboratoriju, \bar{x}_j je povprečje meritev j -tega laboratorija. Skupno število meritev v vseh laboratorijih ($n_1 + n_2 + \dots + n_j + \dots + n_k$) je enako N . \bar{x} pa označimo celotno povprečje vseh N meritev.

Izvor variance	Vsota kvadratov napak (SS)	SS (pr. s t)	F-test
Med k laboratoriji	$SS_{\text{med}} = \sum_{j=1}^k n_j (\bar{x}_j - \bar{x})^2 = \sum_{j=1}^k n_j \bar{x}_j^2 - N\bar{x}^2$	$SS_{\text{med}} / (k-1)$	
Znotraj laboratorija	$SS_{\text{znotraj}} = \sum_{j=1}^k \sum_{i=1}^{n_j} (x_{ij} - \bar{x}_j)^2 = \sum_{j=1}^k \sum_{i=1}^{n_j} x_{ij}^2 - \sum_{j=1}^k n_j \bar{x}_j^2$	$SS_{\text{znotraj}} / (N-k)$	$F = \frac{SS_{\text{med}} / (k-1)}{SS_{\text{znotraj}} / (N-k)} \rightarrow F_{\alpha, k-1, N-k}$
Skupna varianca	$SS_{\text{tot}} = \sum_{j=1}^k \sum_{i=1}^{n_j} x_{ij}^2 - N\bar{x}^2 = \sum_{j=1}^k \sum_{i=1}^{n_j} x_{ij}^2 - N\bar{x}^2$	$SS_{\text{tot}} / (N-1)$	

Ker je $SS_{\text{tot}} = SS_{\text{med lab.}} + SS_{\text{znotraj lab.}}$, ni treba računati vseh treh vrednosti, ampak moramo le dve. Najlažje je izračunati SS_{tot} in $SS_{\text{med lab.}}$, zato navadno izračunamo $SS_{\text{znotraj lab.}}$ posredno, iz razlike med prvima dvema:

$$SS_{\text{znotraj lab.}} = SS_{\text{tot}} - SS_{\text{med lab.}}$$

V večini primerov je $SS_{\text{znotraj lab.}}$ ki mu pravimo tudi ostanek ("residual", SS_{res}), manjši kot $SS_{\text{med lab.}}$. Zato bo koeficient F večji od ena (medlaboratorijske razlike so večje kot znotraj laboratorijske). Če temu ni tako, potem razlike med laboratoriji z gotovostjo niso signifikantne. Take postanejo bele, ko iz podatkov izračunani F preseže $F_{\text{tabelirana}}$.

3

