

# Envägs variansanalys (ANOVA) för test av olika väntevärde i flera grupper

Tobias Abenius <Tobias.Abenius@Chalmers.se>

February 21, 2012

## Envägs variansanalys (ANOVA)

I envägs variansanalys utnyttjas att täljaren i  $s^2$  kan separeras

$$N = \sum_{i=1}^k n_i \tag{1}$$

$$(N - 1)s^2 = \sum_{i=1}^k \underbrace{\sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{..})^2}_{S_{\text{Total}}} = \tag{2}$$

$$= \underbrace{\sum_{i=1}^k n_i (\bar{y}_{i\cdot} - \bar{y}_{..})^2}_{S_B \text{ mellan grupper}} + \underbrace{\sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot})^2}_{S_W \text{ inom grupper}}. \tag{3}$$

Från detta kan man sen testa hur förhållandet mellan spridningen i data mellan grupper och spridningen inom grupper ser ut.

Storheterna  $S_B$  och  $S_W$  har olika namn i olika litteratur. Det kortare  $S$  skrivs också  $SS$  och står för *sum of squares* vilket är lätt att komma ihåg. Bokstäverna  $B$  och  $W$  står för *between* respektive *within*. Det som skiljer mellan olika grupper kallas också för behandlingar eller *treatments* –  $SS_T$ , medan inom grupper kallas för oförklara fel eller *error* –  $SS_E$ . Om man sedan delar med antalet frihetsgrader så kallas det ett medelkvadratsumma, *mean square*, *mean sum of squares* –  $MS$  eller motsvarande.

## Antaganden

1. Respons är normalfördelad (eller approximativt normalfördelad)
2. Observationerna är oberoende
3. Populationernas varians är lika
4. Respons för en given grupp är oberoende och likafördelade normalfördelade stokastiska variabler

## Hypoteser

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_K$$

$$H_A : \text{alla ej lika, dvs: } \exists i, j : \mu_i \neq \mu_j, i \neq j$$

För  $K$  st grupper.

## Test

Om man kan förkasta hypotes  $H_0$  eller ej på nivå  $\alpha$  kan testas med ett *F-test*. Ett F-test testar om sannolikheten att ett värde inte tillhör en F-fördelning är mindre än  $\alpha$  eller ej. Om vi bildar kvoten mellan två  $\chi^2$ -fördelade storheter är den F-fördelad. Vi bildar kvoten

$$F = \frac{\text{Spridning mellan grupper}}{\text{Spridning inom grupper}}$$

Spridning mellan grupper är då

$$MS_B = \sum_i \frac{n_i(\bar{y}_{i\cdot} - \bar{y})^2}{df_b},$$

$$df_b = K - 1$$

där  $n_i$  är antalet observationer i den  $i$ :te gruppen och punkten i  $\bar{y}_{i\cdot}$  betyder att man tar genomsnittet över den  $i$ :te gruppen, och man summerar över alla de  $K$  st grupperna. Frihetsgraderna är här antalet grupper  $K - 1$  (för det skattade medelvärdet för alla observationer i alla grupper).

Detta är alltså avståndet mellan varje gruppmedelvärde och medelvärdet för alla  $K$  gruppars alla observationer.

Spridning inom grupper är

$$MS_W = \sum_{i,j} \frac{(y_{ij} - \bar{y}_{i\cdot})^2}{df_w},$$

$$df_w = N - K,$$

dvs avståndet mellan varje enstaka observation och denna observations gruppmedelvärde summerat över alla observationer i alla grupper. Frihetsgraderna är här antalet observationer minus ett skattat medelvärde för varje grupp.

$N$  är här det totala antalet observationer och  $y_{ij}$  är den  $j$ :te observationen i den  $i$ :te gruppen.

Om kvoten  $F$  når ut i svansen på F-fördelningen kan man förkasta  $H_0$  med sannolikheten

$$p = 1 - F_{df_b, df_w}(F),$$

dvs 1 – fördelningsfunktionen för F-fördelningen med  $df_b$  respektive  $df_w$  frihetsgrader, alltså svansens yta. Se exempel nedan.

## Exempel

Vi har observerat en storhet som tros vara normalfördelad med samma varians i tre olika grupper, A, B och C. Värdena på storheten i fråga för de olika grupperna mättes till

$$\begin{aligned} A &: 2.3, 2.2, 2.1, 2.3, 2.0, 2.5, 2.3, 2.4, 2.2, 2.4 \\ B &: 2.1, 2.3, 2.0, 2.2, 2.0, 2.1, 2, 2.2, 2.3, 2.2, 2.2, 2.1, 2.2, 2.2, 2.3 \\ C &: 2.2, 2.4, 2.2, 2.3, 2.2, 2.3, 2.2 \end{aligned}$$

Vi numrerar grupperna så att A är 1, B är 2 och C är grupp 3. Antalet observationer och medelvärdet för grupperna är då

$$\begin{aligned} n_1 &= 10 \quad \bar{y}_{1\cdot} = 2.27 \\ n_2 &= 15 \quad \bar{y}_{2\cdot} = 2.16 \\ n_3 &= 7 \quad \bar{y}_{3\cdot} = 2.257143 \end{aligned}$$

Medelvärdet över alla observationer kan man då få genom att se att

$$\begin{aligned} \bar{y}_{..} &= \frac{\sum_{i,j} y_{ij}}{N} = \frac{\sum_{i,j} y_{ij}}{n_1 + n_2 + n_3} = \\ &= \frac{\sum_i n_i \bar{y}_{i\cdot}}{n_1 + n_2 + n_3} = \\ &= \frac{10 \cdot 2.27 + 15 \cdot 2.16 + 7 \cdot 2.257143}{10 + 15 + 7} = \\ &= 2.215625 \end{aligned}$$

Vi räknar också ut

$$s^2 = 0.01555444 = \frac{SS_{\text{Total}}}{N - 1}$$




Figure 1: F-fördelningen för detta exempel

Kvadratsumman  $S_B$  får vi genom att

$$\begin{aligned}
 S_B &= \sum_i n_i (\bar{y}_{i\cdot} - \bar{y})^2 = \\
 &= 10 \cdot (2.27 - 2.215625)^2 + 15 \cdot (2.16 - 2.215625)^2 + \\
 &\quad + 7 \cdot (2.257143 - 2.215625)^2 = \\
 &= 0.08804473
 \end{aligned}$$

Vi delar med antalet frihetsgrader  $df_b = K - 1$  och får medelkvadratsumman

$$MS_B = S_B / (K - 1) = 0.08804473 / (3 - 1) = 0.04402232$$

som mäter variationen mellan grupperna. Nu ska vi hitta variationen inom grupperna enligt, vilket är omständigt att göra för hand,

$$\begin{aligned}
 S_W &= \sum_{i,j} (y_{ij} - \bar{y}_{i\cdot})^2 = \\
 &= \underbrace{0.201}_A + \underbrace{0.156}_B + \underbrace{0.03714286}_C = 0.3941429.
 \end{aligned}$$

Istället utnyttjar vi att

$$\begin{aligned}(N - 1)s^2 &= S_{\text{Total}} = S_W + S_B \\ S_W &= S_{\text{Total}} - S_B = \underbrace{(10 + 15 + 7 - 1)}_{N-1} \underbrace{0.01555444}_{s^2} - \underbrace{0.08804473}_{SS_B} = \\ &= 0.3941429\end{aligned}$$

Vi delar med antalet frihetsgrader  $df_w = N - K$  och får medelkvadratsumman

$$MS_W = S_W / (N - K) = 0.3941429 / (32 - 3) = 0.01359113$$

som mäter variationen inom grupperna. Vi bildar kvoten F som är vår teststatistika

$$F = \frac{MS_B}{MS_W} = 3.239047.$$

Detta kan vi jämföra med det kritiska värdet,

$$F < F_{\text{crit}} = 3.327654,$$

dvs detta är ej ett signifikant resultat. Vi kan ej förkasta  $H_0$  om lika väntevärde i alla grupper. Om det finns en skillnad mellan grupperna kan vi inte se den. Kanske måste vi ha fler mätningar för att se den eller så finns den inte alls.