

ANALYSIS OF VARIANCE

In its simplest form we assume that we have I different populations. Each population has a population mean μ_i and a population variance σ_i^2 . Suppose you have a sample of size n_i from each of the I populations. Assume the sample values $Y_{i1}, Y_{i2}, \dots, Y_{in_i}$ from the i th populations are i.i.d. normal with $E(Y_{ij}) = \mu_i$ and $\text{var}(Y_{ij}) = \sigma_i^2$. We wish to test

$$H_0: \mu_1 = \mu_2 = \dots = \mu_I \quad \text{versus} \quad H_1: \text{not all } \mu_i \text{ are equal.}$$

We will assume that $\sigma_1^2 = \dots = \sigma_I^2$.

- a. The figure below shows two possibilities for histograms of the samples.




Figure 1 Two possible histograms for $I = 4$.

In which case would you judge that the population means are different. Why? Explain.

- b. In analysis of variance we compare the dispersion of sample means (variance between groups) with the dispersion within groups (variance within). For simplicity assume $n_1 = n_2 = \dots = n_I = J$. Denote

$$Y_{i\cdot} = \frac{1}{J} \sum_{i=1}^J Y_{ij} .$$

If H_0 holds the variance of sample means is σ/\sqrt{J} . If the sample means are “too” dispersed compared to σ/\sqrt{J} we reject H_0 . But some theoretical work is needed.

- (i) Naj bodo Y_1, \dots, Y_J med sabo neodvisne normalne slučajne spremenljivke z enako porazdelitvijo. Označimo z μ skupno matematično upanje in z σ^2 skupno varianco. Pokažite, da je povprečje \bar{Y} neodvisno od vektorja $(Y_1 - \bar{Y}, \dots, Y_J - \bar{Y})$. Ker je $(\bar{Y}, Y_1 - \bar{Y}, \dots, Y_J - \bar{Y})$ večrazsežen normalen vektor, je dovolj pokazati, da sta \bar{Y} in $(Y_1 - \bar{Y}, \dots, Y_J - \bar{Y})$ nekorelirana. Upoštevajte še, da je

$$(Y_1 - \bar{Y}, \dots, Y_J - \bar{Y})^T = \mathbf{H}\mathbf{Y},$$

kjer je \mathbf{H} centrirna matrika

$$\mathbf{H} = \mathbf{I} - \frac{1}{J} \mathbf{1}\mathbf{1}^T$$

in $\mathbf{Y} = (Y_1, \dots, Y_J)^T$.

- (ii) Neznano varianco σ^2 lahko ocenimo z

$$s_p^2 = \hat{\sigma}^2 = \frac{1}{I(J-1)} \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - Y_{i.})^2.$$

Pokažite, da ta ocena nepristranska.

- (iii) Pokažite, da je

$$\frac{I(J-1)}{\sigma^2} s_p^2 \sim \chi^2(I(J-1)).$$

Pri tem uporabite Cochranov izrek, pri čemer upoštevajte, da je centrirna matrika \mathbf{H} simetrična, idempotentna z rangom $J-1$. Prepričajte se, da trditev drži ne glede na to, ali H_0 velja ali ne, le predpostavka, da so populacijske variance enake v vseh skupinah, mora veljati.

- (iv) Označite povprečje vseh Y_{ij} z

$$Y_{..} = \frac{1}{IJ} \sum_{i=1}^I \sum_{j=1}^J Y_{ij}.$$

Pokažite, da je izraz

$$s_b^2 = \frac{J}{I-1} \sum_{i=1}^I (Y_{i\cdot} - Y_{..})^2$$

nepristranska cenilka σ^2 , če H_0 drži. Dokažite še, da je

$$\frac{(I-1)}{\sigma^2} s_b^2 \sim \chi^2(I-1).$$

Poleg tega utemeljite, da sta s_p^2 in s_b^2 neodvisni slučajni spremenljivki. Pri tem uporabite spet centrirno matriko \mathbf{H} in točko (i).

- (v) Idejo iz a., da primerjamo raztros vzorčnih povprečij z raztrosom znotraj skupin, lahko zdaj statistično “udejanimo”. Pokažite, da je po definiciji

$$F = \frac{\frac{s_b^2}{\sigma^2}}{\frac{s_p^2}{\sigma^2}} \sim F_{I-1, I(J-1)}$$

c. Preberite razdelek 12.2.3 v učbeniku. Simulirajte porazdelitev testne statistike F in testne statistike K v dveh primerih za $I = 4$ in $J = 25$:

- (i) V primeru, ko H_0 drži. Narišite graf empirične porazdelitve testnih statistik v obeh primerih.
- (ii) V primeru, ko H_0 ne drži. V tem primeru primerjajte tudi moč F in K testa. Kruskal-Wallisov test ne potrebuje predpostavk o normalnosti. Na osnovi primerjave moči testov v primeru, ko porazdelitve Y_{ij} so normalne z enakimi variancami, komentirajte, kateri test bi bilo v praksi bolje uporabljati.