

Παλινδρόμηση και Ανάλυση Διακύμανσης

Ανάλυση Διακύμανσης κατά 1 παράγοντα  $i=1, \dots, I$   
 $Y_{ij} = \mu + \alpha_i + \epsilon_{ij}$   $j=1, \dots, J_i$

EET:  $\hat{\mu} = \bar{Y}_{..}$ ,  $\hat{\alpha}_i = \bar{Y}_{i.} - \bar{Y}_{..}$

Εκτιμώμενο μοντέλο:  $\hat{Y}_{ij} = \hat{\mu} + \hat{\alpha}_i = \bar{Y}_{i.}$

Πίνακας ANADIA:  $SS_{tot} = SS_{tr} + SS_{res}$

Υποθέσεις για τα σφάλματα:

- ↳ (i)  $E(\epsilon_{ij}) = 0 \rightarrow E(Y_{ij}) = \mu + \alpha_i$
- ↳ (ii)  $Var(\epsilon_{ij}) = \sigma^2 \rightarrow Var(Y_{ij}) = \sigma^2$
- ↳ (iii)  $Cov(\epsilon_{ij}, \epsilon_{kl}) = 0 \rightarrow Cov(Y_{ij}, Y_{kl}) = 0$
- ↳ (iv)  $\epsilon_{ij} \sim N(0, \sigma^2) \rightarrow Y_{ij} \sim N(\mu + \alpha_i, \sigma^2)$

**Ιδιότητες** (Αν οι υποθ για τα σφάλματα ισχύουν)

(1) Οι EET  $\hat{\mu}$  και  $\hat{\alpha}_i$ ,  $i=1, \dots, I$  είναι αμερόληπτοι εκτιμητές των  $\mu$  και  $\alpha_i$ . Δηλ  $E(\hat{\mu}) = \mu$ ,  $E(\hat{\alpha}_i) = \alpha_i$   $i=1, \dots, I$  (Ασκηση)

(2) Οι EET των  $\mu$  και  $\alpha_i$  συμπίπτουν με τους ΕΜΠ. (Ασκηση)

(3) **ΘΕΩΡΗΜΑ:** Αν οι υποθ. για τα σφάλματα ικανοποιούνται, τότε υπό την πλευρική συνθήκη  $\sum_{i=1}^I J_i \alpha_i = 0$ , ισχύουν: α)  $E(MS_{res}) = \sigma^2$   
 β)  $E(MS_{tr}) = \sigma^2 + \frac{1}{I-1} \sum_{i=1}^I J_i \alpha_i^2$

Από α) (Ισχύει αν  $W_1, \dots, W_n$  τδ από πληθυσμό με διακύμανση  $\sigma^2$  τότε  $E(S_w^2) = \sigma^2$  όπου  $S_w^2 = \frac{1}{n-1} \sum_{i=1}^n (W_i - \bar{W})^2$ )

Άρα αφού  $Y_{i1}, Y_{i2}, \dots, Y_{ij}$  είναι τυχ. δείγματα από πληθυσμό με διακύμανση  $\sigma^2$ .

$$E\left(\frac{1}{J_i-1} \sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i\cdot})^2\right) = \sigma^2 \quad (*)$$

$$MS_{res} = \frac{SS_{res}}{N-I} = \frac{1}{N-I} \sum_{i=1}^I \sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i\cdot})^2$$

$$E(MS_{res}) = \frac{1}{N-I} \sum_{i=1}^I \left[ E\left(\sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i\cdot})^2\right) \right]$$

$$\stackrel{(*)}{=} \frac{1}{N-I} \sum_{i=1}^I \left[ (J_i-1) \sigma^2 \right]$$

$$= \frac{\sigma^2}{N-I} \sum_{i=1}^I (J_i-1)$$

$$= \frac{\sigma^2}{N-I} \left( \sum_{i=1}^I J_i - I \right)$$

$$= \frac{\sigma^2}{N-I} (N-I)$$

$$= \sigma^2.$$

Από

β) Από το μοντέλο  $Y_{ij} = \mu + \alpha_i + \epsilon_{ij}$  και την πλευρική συνθήκη  $\sum_{i=1}^I J_i \alpha_i = 0$

$$Y_{i\cdot} = J_i \mu + J_i \alpha_i + \epsilon_{i\cdot} \quad \text{και} \quad Y_{\cdot\cdot} = N\mu + \epsilon_{\cdot\cdot}$$

$$E(Y_{i\cdot}) = J_i(\mu + \alpha_i), \quad \text{Var}(Y_{i\cdot}) = J_i \sigma^2$$

$$E(Y_{\cdot\cdot}) = N\mu, \quad \text{Var}(Y_{\cdot\cdot}) = N\sigma^2.$$

$$E(SS_{tr}) = E\left(\sum_{i=1}^I J_i (\bar{Y}_{i\cdot} - \bar{Y}_{\cdot\cdot})^2\right) = E\left(\sum_{i=1}^I J_i \left(\frac{Y_{i\cdot}}{J_i} - \frac{Y_{\cdot\cdot}}{N}\right)^2\right)$$

$$= E\left(\sum_{i=1}^I \frac{Y_{i.}^2}{J_i} - \frac{Y_{..}^2}{N}\right) = \sum_{i=1}^I \frac{1}{J_i} E(Y_{i.}^2) - \frac{1}{N} E(Y_{..}^2)$$

$$= \sum_{i=1}^I \frac{1}{J_i} (\text{Var}(Y_{i.}) + (EY_{i.})^2) - \frac{1}{N} (\text{Var}(Y_{..}) + (EY_{..})^2)$$

$$= \sum_{i=1}^I \frac{1}{J_i} (J_i \sigma^2 + J_i^2 (\mu + \alpha_i)^2) - \frac{1}{N} (N \sigma^2 + N^2 \mu^2)$$

πράξεις

$$(I-1)\sigma^2 + \sum_{i=1}^I J_i \alpha_i^2$$

Άρα  $E(MS_{tr}) = E\left(\frac{1}{I-1} SS_{tr}\right)$

$$= \frac{1}{I-1} E(SS_{tr})$$

$$= \frac{1}{I-1} \left[ (I-1)\sigma^2 + \sum_{i=1}^I J_i \alpha_i^2 \right]$$

$$= \sigma^2 + \frac{1}{I-1} \sum_{i=1}^I J_i \alpha_i^2$$

Έλεγχος της  $H_0: \alpha_1 = \alpha_2 = \dots = \alpha_I$

**Πρακτικά** σημαίνει ότι όλα τα επίπεδα του παράγοντα ισοεπιδρούν στην εξαρτημένη μεταβλητή  $Y$ .

Για την κατασκευή τεστ για έλεγχο της  $H_0$  βολεύει να θεωρήσω την ισοδύναμη (όπου  $H_0: \alpha_i = \alpha, i=1, \dots, I \rightarrow Y_{ij} = \mu + \alpha + \epsilon_{ij} = \mu^* + \epsilon_{ij}$ )

$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_I = 0$  (όπου  $H_0: \alpha_i = 0, i=1, \dots, I \rightarrow Y_{ij} = \mu + \epsilon_{ij}$ )

⇓

στηρίζομαστε στο γεγονός ότι  $E(MS_{res}) = \sigma^2$  ή  $E(MS_{tr}) = \sigma^2 + \frac{1}{I-1} \sum_{i=1}^I J_i \alpha_i^2$

Προφανώς αν  $H_0$  αληθής τότε  $E(MS_{res}) = E(MS_{tr})$

ή αν  $H_0$  αληθής τότε  $MS_{res} \approx MS_{tr}$

Μαθηματική Λογική: Αν  $A \Rightarrow B$  τότε  $\sim B \Rightarrow \sim A$ .

$\left\{ \begin{array}{l} \text{Αν } MS_{res} \text{ πολύ διαφορετικό } MS_{tr} \text{ τότε η } H_0 \text{ δεν είναι αληθής} \\ \text{Αρα, Αν } MS_{res} \approx MS_{tr} \text{ τότε } H_0 \text{ αληθής.} \end{array} \right.$

Αρα ένα τεστ θα βασιστεί στη σύγκριση των  $MS_{res}$  ή  $MS_{tr}$ .

**ΘΕΩΡΗΜΑ:** (Διερευνά τις κατανομές  $SS_{res}$ ,  $SS_{tr}$ )

Αν οι υποθέσεις για τα σφάλματα ικανοποιούνται τότε υπό την  $H_0$   $\alpha_1 = \alpha_2 = \dots = \alpha_I = 0$  έχουμε:

$$a) \frac{SS_{res}}{\sigma^2} \sim \chi^2_{N-I} \quad b) \frac{SS_{tr}}{\sigma^2} \sim \chi^2_{I-1}$$

ΑπόΔ

Ισχύει ότι  $Y_{ij} \sim N(\mu + \alpha_i, \sigma^2) \quad i=1, \dots, I$

Επιπλέον υπό  $H_0$  :  $\alpha_1 = \dots = \alpha_I = 0$  τότε  $j=1, \dots, J_i$

το  $Y_{ij} \sim N(\mu, \sigma^2)$ .

$$SS_{res} = \sum_{i=1}^I \sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i.})^2$$

$$SS_{tr} = \sum_{i=1}^I J_i (\bar{Y}_{i.} - \bar{Y}_{..})^2$$

a)

$$\left( \begin{array}{l} \text{Γνωρίζω Αν } W_1, \dots, W_n \text{ τ.δ από } N(\mu, \sigma^2) \\ \text{τότε } \frac{(n-1)S^2}{\sigma^2} \sim \chi^2_{n-1}, \quad S^2 = \frac{1}{n-1} \sum (W_i - \bar{W})^2 \end{array} \right)$$

Επειδή  $Y_{i1}, \dots, Y_{ij_i}$  είναι τ.δ από  $N(\mu, \sigma^2) \quad \forall i$

$$\frac{\sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i.})^2}{\sigma^2} \sim \chi^2_{J_i-1} \quad \forall i=1, \dots, I$$

$$\Rightarrow \sum_{i=1}^I \frac{\sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i.})^2}{\sigma^2} \sim \chi^2_{\sum_{i=1}^I (J_i-1)}$$

ανεξαρτ.

$$\Rightarrow \frac{\sum_{i=1}^I \sum_{j=1}^{J_i} (Y_{ij} - \bar{Y}_{i.})^2}{\sigma^2} \sim \chi^2_{\sum_{i=1}^I J_i - I} = \chi^2_{N-I}$$

Αν  $W_1, \dots, W_n$  τ.δ από  $N(\mu, \sigma^2)$   
 β) το  $\bar{W} \sim N(\mu, \sigma^2/n)$

Επειδή  $Y_{i1}, Y_{i2}, \dots, Y_{iJ_i}$  είναι τ.δ από  $N(\mu, \sigma^2)$   
 οπότε  $\bar{Y}_i \sim N(\mu, \frac{\sigma^2}{J_i}) \quad \forall i=1, \dots, I$

$$\Rightarrow \frac{\bar{Y}_i - \mu}{\sqrt{\frac{\sigma^2}{J_i}}} \sim N(0,1) \quad \forall i=1, \dots, I$$

$$\frac{(\bar{Y}_i - \mu) \sqrt{J_i}}{\sigma} \sim N(0,1) \xrightarrow[\text{τετραγωνισμός}]{\text{υψώνω στο } \sigma^2} \frac{(\bar{Y}_i - \mu)^2 J_i}{\sigma^2} \sim N(0,1)^2 \equiv X_1^2$$

$$\frac{Y_{ij}}{\sigma^2} \sum_{i=1}^I \frac{J_i (\bar{Y}_i - \mu)^2}{\sigma^2} \sim \sum_{i=1}^I X_{2i}^2$$

$$\sum_{i=1}^I \frac{J_i (\bar{Y}_i - \mu)^2}{\sigma^2} \sim X_1^2$$

$$\sum_{i=1}^I \frac{J_i (\bar{Y}_i - \bar{Y}_{..})^2}{\sigma^2} \sim X_{I-1}^2$$

$$\frac{SS_{tr}}{\sigma^2} \sim X_{I-1}^2$$

Για τον έλεγχο της  $H_0: \alpha_1 = \dots = \alpha_I = 0$   
 θεωρούμε το

$$F = \frac{MS_{tr}}{MS_{res}}$$

$SS_{tr}$  ανεξ  $SS_{res}$

$$= \frac{SS_{tr}/(I-1)}{SS_{res}/(N-I)} = \frac{SS_{tr}/\sigma^2(I-1)}{SS_{res}/\sigma^2(N-I)} \sim \frac{X_{I-1}^2/(I-1)}{X_{N-I}^2/(N-I)}$$

$$\equiv F_{I-1, N-I}$$

υπό την  $H_0$ .

και κρίσιμη περιοχή μεγάλες τιμές του  $F$  δηλ  $F \geq c$ .

Υπολογισμός του κρίσιμου σημείου  $c$ .

$$\begin{aligned}\alpha &= P(\text{απορ } H_0 / H_0 \text{ αληθ}) = P(F \geq c / F \sim F_{I-1, N-I}) \\ &= P(F_{I-1, N-I} \geq c) \\ &\Rightarrow c = F_{I-1, N-I}\end{aligned}$$

Συγκεντρωτικά : Για τον έλεγχο της  $H_0$   $\alpha_1 = \alpha_2 = \dots = \alpha_I = 0$   
( $\Leftrightarrow H_0: \alpha_1 = \dots = \alpha_I$ )

Χρησιμοποιείται η ΣΣΤ  $F = \frac{MS_{\text{tr}}}{MS_{\text{res}}}$  με κατανομή  $F_{I-1, N-I}$

υπό  $H_0$  και κ.π  $F \geq F_{I-1, N-I, \alpha}$ .

Στην πράξη αναμένουμε η  $H_0$  να απορρ.


Αυτό σημαίνει ότι τα επίπεδα του παράγοντα δεν ασκούν όλα την ίδια επίδραση στην  $Y$ .

Αυτό σημαίνει ότι υπάρχουν επίπεδα που ασκούν σημαντικότερη επίδραση στην  $Y$ .

Αρα το ενδιαφέρον επικεντρώνεται στον εντοπισμό των επιπέδων που ασκούν τη σημαντικότερη επίδραση στην  $Y$  ή αλλιώς και στην κατάσταση των επιπέδων από το σημαντικότερο προς το λιγότερο σημαντικό, για την  $Y$ .

Αυτό επιτυγχάνεται με την τεχνική των πολλαπλών συγκρίσεων.

## ΠΟΜΑΠΛΕΣ ΣΥΓΚΡΙΣΕΙΣ



### Ελαχιστής Σημαντικής Διαφορής (ΕΣΔ)

Πολλαπλά τεστ που ελέγχουν ανά δύο την ισότητα ή τη διαφορετικότητα των  $\alpha_i$   $i=1, \dots, I$ .

Δηλ προχωρούμε σε ελέγχους

$H_0: \alpha_i = \alpha_{i'}$  έναντι  $H_a: \alpha_i \neq \alpha_{i'}$  για  $i, i' = 1, \dots, I$   
 $i \neq i'$

Για τον έλεγχο αυτό και σύμφωνα με την τεχνική Wald στηρίζομαστε σε εκτιμητές των παραμέτρων που εμφανίζονται στην  $H_0$  και ειδικά στους  $\hat{\alpha}_i = \bar{Y}_i - \bar{Y}_\cdot$  και  $\hat{\alpha}_{i'} = \bar{Y}_{i'} - \bar{Y}_\cdot$  και στη διαφορά τους

$$\hat{\alpha}_i - \hat{\alpha}_{i'} = \bar{Y}_i - \bar{Y}_{i'}$$

Προφανώς αν η  $\hat{\alpha}_i - \hat{\alpha}_{i'}$  είναι μεγάλη το  $\alpha_i$  διαφέρει από το  $\alpha_{i'}$  και η  $H_0: \alpha_i = \alpha_{i'}$  πρέπει να απορριφθεί.

Επομένως το τεστ θα στηριχτεί στην  $\hat{\alpha}_i - \hat{\alpha}_{i'} = \bar{Y}_i - \bar{Y}_{i'}$   $i, i' = 1, \dots, I$   $i \neq i'$

Επειδή  $Y_{i1}, \dots, Y_{iJ_i} \stackrel{i.i.d.}{\sim} N(\mu + \alpha_i, \sigma^2)$

το  $\bar{Y}_i \sim N(\mu + \alpha_i, \sigma^2/J_i)$  } Επειδή  $\bar{Y}_i$  ανεξ  $\bar{Y}_{i'}$   
 Όμοια  $\bar{Y}_{i'} \sim N(\mu + \alpha_{i'}, \sigma^2/J_{i'})$  }

$$\eta \quad \bar{Y}_i - \bar{Y}_{i'} \sim N(\alpha_i - \alpha_{i'}, \sigma^2 \left( \frac{1}{J_i} + \frac{1}{J_{i'}} \right))$$

$$\bar{Y}_i - \bar{Y}_{i'} \sim N(0, \sigma^2 \left( \frac{1}{J_i} + \frac{1}{J_{i'}} \right)) \text{ υπό } H_0: \alpha_i = \alpha_{i'}$$

Λόγω του ότι  $\frac{\bar{Y}_i - \bar{Y}_{i'}}{\sigma \sqrt{\frac{1}{J_i} + \frac{1}{J_{i'}}}} \sim N(0,1)$  και  $\frac{SS_{res}}{\sigma^2} \sim \chi^2_{N-1}$ .

$$\frac{\bar{Y}_i - \bar{Y}_{i'}}{\sqrt{MS_{res} \left( \frac{1}{J_i} + \frac{1}{J_{i'}} \right)}} \sim t_{N-1} \text{ υπό την } H_0: \alpha_i = \alpha_{i'}$$

Επομένως για τον έλεγχο της  $H_0: \alpha_i = \alpha_{i'}$   
χρησιμοποιείται η

$$\frac{\bar{Y}_i - \bar{Y}_{i'}}{\sqrt{MS_{res} \left( \frac{1}{J_i} + \frac{1}{J_{i'}} \right)}} \sim t_{N-1} \text{ υπό } H_0$$

και κ.π.  $\left| \frac{\bar{Y}_i - \bar{Y}_{i'}}{\sqrt{MS_{res} \left( \frac{1}{J_i} + \frac{1}{J_{i'}} \right)}} \right| > t_{N-1, \alpha/2}$

$$\eta \quad |\bar{Y}_i - \bar{Y}_{i'}| \geq \sqrt{MS_{res} \left( \frac{1}{J_i} + \frac{1}{J_{i'}} \right)} t_{N-1, \alpha/2}$$

ΣΥΝΟΨΗ της μεθόδου ΕΣΔ.

$$ΕΣΔ = t_{N-1, \alpha/2} \sqrt{MS_{res} \left( \frac{1}{J_i} + \frac{1}{J_{i'}} \right)}$$

Αν  $|\bar{Y}_i - \bar{Y}_{i'}| \geq ΕΣΔ$  τότε η  $H_0: \alpha_i = \alpha_{i'}$  απορρ.

Αν απορρίψω την  $H_0: \alpha_i = \alpha_{i'}$  κάποιο από τα δύο  
ασκεί σημαντικότερη επίδραση στην  $Y$ .

Ποιο?

Αν  $\bar{Y}_i > \bar{Y}_{i'}$  τότε το  $i$ -επίπεδο ασκει σημαντικότερη επίδραση  
στην  $Y$  από το  $i'$ .



Αν  $\overline{Y_i} < \overline{Y_{i'}}.$  τότε το  $i$ -επίπεδο έχει σημαντικότερη επίδραση στην  $Y$  από το  $i'.$