

12:00-14:30

Μέθοδος γραμμικών αντιθέσεων ή μέθοδος Scheffe

ΟΡΙΣΜΟΣ: Κάθε γραμμικός συνδυασμός των κύριων επιδράσεων $\alpha_i, i=1, \dots, I$ των επιπέδων του παράγοντα στην εξαρτημένη μεταβλητή, της μορφής:

$$L = \sum_{i=1}^I c_i \alpha_i \text{ με } \sum_{i=1}^I c_i = 0 \text{ λέγεται γραμμική αντίθεση.}$$

Η γραμμική αντίθεση επιτρέπει τη διατύπωση συχυρίσεων περισσότερων των δύο $\alpha_i, i=1, \dots, I$

π.χ. Έστω ενδιαφέρει $\alpha_i = \alpha_{i'}$ (ΕΣΔ)

$$\left. \begin{array}{l} \text{Αν } c_k = 0, k \neq i, i' \\ \text{Αν } c_i = 1, c_{i'} = -1 \end{array} \right\} \Rightarrow L = \sum_{i=1}^I c_i \alpha_i = 0 \Leftrightarrow \alpha_i = \alpha_{i'} \Leftrightarrow \alpha_i - \alpha_{i'} = 0$$

Άρα $H_0: \alpha_i = \alpha_{i'} \Leftrightarrow L = 0$

$$\text{β) } c_k = 0, \forall k \neq i, m, \ell$$

$$c_i = 1, c_m = \frac{1}{2} = c_\ell$$

← Είναι η επίδραση του k -επιπέδου ισοδύναμη με το μέσο όρο των επιδράσεων των ℓ και m επιπέδων.

$$L = \sum_{i=1}^I c_i \alpha_i = \alpha_i - \frac{1}{2} \alpha_m - \frac{1}{2} \alpha_\ell$$

$$L = 0 \Leftrightarrow \alpha_i = \frac{1}{2} \alpha_m + \frac{1}{2} \alpha_\ell$$

↑ Η επίδραση του i -επιπέδου είναι ίση με το ημίαθροισμα των επιδράσεων των επιπέδων m, ℓ .

◆ Έχει ενδιαφέρον η **μασσιμική** στατιστική τεστ για έλεγχο $H_0: L = 0$ έναντι $H_a: L \neq 0$.

Θεωρώ ότι οι υποθέσεις για τα σφάλματα ικανοποιούνται: δηλ. $\epsilon_{ij} \sim N(0, \sigma^2)$

$$i=1, \dots, I, j=1, \dots, J_i$$

και έστω ανεξάρτητα λόγω των υποθέσεων για τα σφάλματα $Y_{ij} \sim N(\mu + \alpha_i, \sigma^2)$, άρα

$\bar{Y}_i \sim N(\mu + \alpha_i, \frac{\sigma^2}{J_i})$, $i=1, \dots, I$ ανεξάρτητα, λόγω της ανεξαρτησίας των Y_{ij}

λόγω ασυσχέτιστου και ανεξαρτησίας των σφαλμάτων.

Με την κατά Wald προσέγγιση ένα τεστ για έλεγχο $H_0: L=0$.

θα στηρίξεται σε ένα ευπημής της L .
Θεωρώ τον εξής ευπημής της $L: \hat{L} = \sum_{i=1}^I a_i \hat{a}_i$, $\hat{a}_i = \bar{Y}_i - \bar{Y}_..$, $i=1, \dots, I$.

$$\hat{L} = \sum_{i=1}^I a_i \hat{a}_i = \sum_{i=1}^I a_i (\bar{Y}_i - \bar{Y}_..) = \sum_{i=1}^I a_i \bar{Y}_i - \bar{Y}_.. \sum_{i=1}^I a_i \Rightarrow \hat{L} = \sum_{i=1}^I a_i \bar{Y}_i$$

Το \hat{L} είναι ένας γραμμικός συνδυασμός των ανεξάρτητων $\bar{Y}_i \sim N(\mu + a_i, \frac{\sigma^2}{J_i})_{i=1, \dots, I}$.
Άρα $\hat{L} \sim \text{Normal}$.

$$\bullet E(\hat{L}) = E\left(\sum_{i=1}^I a_i \bar{Y}_i\right) = \sum_{i=1}^I a_i E(\bar{Y}_i) = \sum_{i=1}^I a_i (\mu + a_i) = \mu \sum_{i=1}^I a_i + \sum_{i=1}^I a_i^2 \Rightarrow$$

$$E(\hat{L}) = \sum_{i=1}^I a_i^2 = L$$

$$\bullet \text{Var}(\hat{L}) = \text{Var}\left(\sum_{i=1}^I a_i \bar{Y}_i\right) \xrightarrow[\text{(συνδιασμημένες=0)}]{\substack{\bar{Y}_i \text{ ανεξ.} \\ \text{λόγω ισοκύκλισης}}}$$

$$\text{Var}(\hat{L}) = \sigma^2 \sum_{i=1}^I \left(\frac{a_i^2}{J_i}\right), \quad i=1, \dots, I$$

$$\text{Άρα, } \hat{L} \sim N\left(L, \sigma^2 \sum_{i=1}^I \frac{a_i^2}{J_i}\right) \Rightarrow \frac{\hat{L} - L}{\sqrt{\sum_{i=1}^I \frac{a_i^2 \sigma^2}{J_i}}} \sim N(0, 1)$$

$$\text{Υπό την } H_0: L=0, \text{ το } \hat{L} \sim N\left(0, \sigma^2 \sum_{i=1}^I \frac{a_i^2}{J_i}\right) \Rightarrow \frac{\hat{L}}{\sqrt{\sum_{i=1}^I \frac{\sigma^2 a_i^2}{J_i}}} \sim N(0, 1)$$

$$\text{Υπό την } H_0: L=0, \text{ το } \frac{\hat{L}}{\sigma \cdot \left(\sum_{i=1}^I \frac{a_i^2}{J_i}\right)^{1/2}} \sim N(0, 1) \Rightarrow \text{θα του να το διώξω γιατί δεν το θυρίτω.}$$

$$\frac{\hat{L}^2}{\sigma^2 \sum_{i=1}^I \frac{a_i^2}{J_i}} \sim \chi_1^2 \text{ υπό την } H_0: L=0.$$

Θυμόμαστε $\frac{SS_{res}}{\sigma^2} \sim \chi_{N-I}^2$ (MS_L : μέσο τετράγωνο που οφείδεται στη γραμμική αντίθεση L)

$$\text{Συμβολίζω } MS_L = \frac{\hat{L}^2}{\sum_{i=1}^I \frac{a_i^2}{J_i}} \text{ και θεωρώ το } F_L \stackrel{op.}{=} \frac{MS_L}{MS_{res}} = \frac{\frac{\hat{L}^2}{\sum_{i=1}^I \frac{a_i^2}{J_i}}}{SS_{res}/(N-I)}$$

$$= \frac{\frac{\hat{L}^2}{\sigma^2 \sum_{i=1}^I c_i^2 / J_i}}{SS_{res} / \sigma^2 (N-I)} \sim \frac{\chi_1^2}{\chi_{N-I}^2 / (N-I)} \frac{\hat{L}, SS_{res} \text{ ανεξ.}}{\text{ανεξ. } MS_{res}} F_{1, N-I} \text{ υπό } H_0: L=0.$$

Μορφή της κρίσιμης περιοχής: Μεγάλες τιμές του F_L οδηγούν σε μεγάλες τιμές του \hat{L} και επειδή \hat{L} εμπνέει τον L , μεγάλες τιμές του F_L οδηγούν σε απόρριψη της $H_0: L=0$.

κ.π. $F_L \geq C$.

Προσδιορισμός C : $\alpha = P(\text{απορ. } H_0 | H_0 \text{ αληθ.}) = P(F_L \geq C | F_L \sim F_{1, N-I}) \Rightarrow$
 $\Rightarrow \alpha = P(F_{1, N-I} \geq C) \Rightarrow$
 $\Rightarrow C = F_{1, N-I, \alpha}$.

Συμμετρικά: Για τον έλεγχο της $H_0: L=0$, χρησιμοποιείται η στατιστική συνάρτηση $F_L = \frac{MS_L}{MS_{res}}$, $MS_L = \frac{\hat{L}^2}{\sum_{i=1}^I \frac{c_i^2}{J_i}}$ με κατανομή την $F_{1, N-I}$ υπό

$H_0: L=0$ και κ.π. μετέδουσα την $F_L \geq F_{1, N-I, \alpha}$.

Ανάλυση υπολοίπων

Υπόλοιπα: $e_{ij} = Y_{ij} - \hat{Y}_{ij} = Y_{ij} - (\hat{\mu} + \hat{\alpha}_i) = Y_{ij} - (\bar{Y}_{..} + \bar{Y}_i - \bar{Y}_{..}) \Rightarrow$
 $e_{ij} = Y_{ij} - \bar{Y}_i, i=1, \dots, I, j=1, \dots, J_i$.

Τα e_{ij} χρησιμοποιούνται όπως και στα μοντέλα παλινδρόμησης για τον έλεγχο ικανοποίησης των υποθέσεων για τα σφάλματα.

Η ανάλυση διακύμανσης κατά ένα παράγοντα ως ειδική περίπτωση του γενικού γραμμικού μοντέλου $Y = X\beta + \varepsilon$


Μοντέλο ανάλυσης διακύμανσης κατά ένα παράγοντα.

$Y_{ij} = \mu_i + e_{ij} \Leftrightarrow Y_{ij} = \underbrace{\mu + \alpha_i}_{\beta_i} + e_{ij}, i=1, \dots, I, j=1, \dots, J_i$

Μοντέλο ανάλυσης Διακύμανσης κατά δυο Παραγοντές

Η ανάλυση διακύμανσης κατά δυο παραγοντές διερευνά τη σχέση ανάμεσα σε μια ποσοτική μεταβλητή Y και σε δυο παραγοντές (ποιοτικές μεταβλητές) A και B , που ο A εμφανίζεται σε I επίπεδα και ο B εμφανίζεται σε J επίπεδα.

Ενδιαφέρον εστιάζεται στην ανίχνευση των επιπέδων των δύο παραγόντων που ασκούν σημαντικότερη επίδραση στην εξαρτημένη μεταβλητή Y .



Y : εξαρτημένη ποσοτική

A, B : παραγοντές (ποιοτική ανεξάρτητη μεταβλητή)

$1, 2, \dots, I, 1, 2, \dots, J$ επίπεδα

Μορφή δεδομένων

παραγοντας A	παραγοντας B				Σύνολα
	1	2	...	J	
1	Y_{11}	Y_{12}	...	Y_{1J}	$Y_{1.}$ $\bar{Y}_{1.}$
2	Y_{21}	Y_{22}	...	Y_{2J}	$Y_{2.}$ $\bar{Y}_{2.}$
...					
I	Y_{I1}	Y_{I2}	...	Y_{IJ}	$Y_{I.}$ $\bar{Y}_{I.}$
Σύνολα	$\frac{Y_{.1}}{I}$	$\frac{Y_{.2}}{I}$...	$\frac{Y_{.J}}{I}$	

→ παριστα παρατηρηση της Y υπο το επιπεδο i του A και το επιπεδο j του B , $i=1, \dots, I, j=1, \dots, J$

Θεωρω μια παρατηρηση ανα κληρονομο, μια παρατηρηση ανα δοκιμασια.

Περισσότερες παρατηρήσεις ανα δοκιμασία → μοντέλα με αλληλεπίδραση

$$Y_{i.} = \sum_{j=1}^J Y_{ij}, \quad \bar{Y}_{i.} = \frac{1}{J} \sum_{j=1}^J Y_{ij}$$


$$Y_{.j} = \sum_{i=1}^I Y_{ij}, \quad \bar{Y}_{.j} = \frac{1}{I} \sum_{i=1}^I Y_{ij}$$

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

$$\bar{Y}_{..} = \frac{1}{IJ} \sum_{i=1}^I \sum_{j=1}^J Y_{ij} = \frac{1}{I} \sum_{i=1}^I \bar{Y}_{i.} = \frac{1}{J} \sum_{j=1}^J \bar{Y}_{.j} = \frac{1}{IJ} Y_{..} \quad \text{γενικός δείγματικός μέσος}$$

Μοντέλο

$$Y_{ij} = \mu + \alpha_i + \beta_j + \varepsilon_{ij} \quad i=1, \dots, I, \quad j=1, \dots, J$$



Εκτιμητές Ελαχίστων Τετραγώνων του μοντέλου

Ελαχιστοποίηση $S = \sum_{i=1}^I \sum_{j=1}^J \varepsilon_{ij}^2 = \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \mu - \alpha_i - \beta_j)^2$

$\frac{\partial S}{\partial \mu} = 0$	$\frac{\partial S}{\partial \alpha_i} = 0, i=1, \dots, I$	$\frac{\partial S}{\partial \beta_j} = 0, j=1, \dots, J$
---------------------------------------	---	--

κανονικές εξισώσεις

$$\left\{ \begin{array}{l} IJ\mu + J \sum_{i=1}^I \alpha_i + I \sum_{j=1}^J \beta_j = Y_{..} \\ J\mu + \sum_{j=1}^J \beta_j = \bar{Y}_{i.}, i=1, \dots, I \\ I\mu + \sum_{i=1}^I \alpha_i = \bar{Y}_{.j}, j=1, \dots, J \end{array} \right.$$

(γιατί η 1η εξίσωση μπορεί να παραχθεί από τις υπόλοιπες)

∄ μοναδική λύση. Περίχω μοναδική λύση καταφέρνω στην υιοθέτηση πλευρικών συνθηκών. Διασθητικά ένας επιμητής του μ πρέπει να είναι $\bar{Y}_{..}$. Πρέπει $\sum_{i=1}^I \alpha_i = \sum_{j=1}^J \beta_j = 0$. (για να μπορούμε να εκτιμήσουμε το μ)

Αν υιοθετήσω ως πλευρικές συνθήκες τις $\sum_{i=1}^I \alpha_i = \sum_{j=1}^J \beta_j = 0$, τότε οι μοναδικές λύσεις

του συστήματος των κανονικών εξισώσεων είναι:

$$\hat{\mu} = \bar{Y}_{..}$$

$$\hat{\alpha}_i = \bar{Y}_{i.} - \bar{Y}_{..}, i=1, \dots, I$$

$$\hat{\beta}_j = \bar{Y}_{.j} - \bar{Y}_{..}, j=1, \dots, J$$

ΠΑΡΑΔΕΙΓΜΑ: $Y = \mu + \alpha_i + \epsilon_{ij}$




Ανάλυση διακύμανσης κατά δύο παράγοντες και γενικό γραμμικό μοντέλο

$$\underset{\sim}{Y} = \begin{bmatrix} Y_{11} \\ Y_{12} \\ \vdots \\ Y_{1I} \\ Y_{21} \\ Y_{22} \\ \vdots \\ Y_{2J} \\ \vdots \\ Y_{I1} \\ Y_{I2} \\ \vdots \\ Y_{IJ} \end{bmatrix}, \quad \underset{\sim}{X} = \begin{bmatrix} \begin{matrix} \uparrow \\ \downarrow \end{matrix} & \begin{matrix} \leftarrow I \rightarrow & \leftarrow J \rightarrow \end{matrix} \\ 1 & 1 & 0 & 0 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 1 & 0 & 0 & 0 & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \begin{matrix} \uparrow \\ \downarrow \end{matrix} & 1 & 0 & 0 & 1 & 1 & 0 & 0 \\ \begin{matrix} \uparrow \\ \downarrow \end{matrix} & 1 & 0 & 0 & 1 & 0 & 1 & 0 \\ \vdots & \vdots \\ \begin{matrix} \uparrow \\ \downarrow \end{matrix} & 1 & 0 & 0 & 1 & 0 & 0 & 1 \end{bmatrix}, \quad \underset{\sim}{\beta} = \begin{bmatrix} \mu \\ \alpha_1 \\ \vdots \\ \alpha_I \\ \beta_1 \\ \vdots \\ \beta_J \\ \epsilon \end{bmatrix}$$

(I+J+1) × 1

$$\hat{\beta} = (X'X)^{-1} X'Y \quad \text{IJ} \times (\text{I} + \text{J} + 1)$$

Ανάλυση διακύμανσης κατά δύο παράγοντες



$$Y_{ij} = \mu + a_i + \beta_j + \varepsilon_{ij}, \quad \begin{matrix} i=1, 2, \dots, I \\ j=1, 2, \dots, J \end{matrix}$$

$$\text{ΕΕΤ: } \left. \begin{matrix} \hat{\mu} = \bar{Y}_{...} \\ \hat{a}_i = \bar{Y}_{i.} - \bar{Y}_{..}, \quad i=1, \dots, I \\ \hat{\beta}_j = \bar{Y}_{.j} - \bar{Y}_{..}, \quad j=1, \dots, J \end{matrix} \right\} \begin{matrix} \sum_{i=1}^I a_i = 0 \\ \sum_{j=1}^J \beta_j = 0 \end{matrix}$$

Υποθέσεις σφαλμάτων

$$\left. \begin{matrix} 1) E(\varepsilon_{ij}) = 0 \\ 2) \text{Var}(\varepsilon_{ij}) = \sigma^2 \\ 3) \text{Cov}(\varepsilon_{ij}, \varepsilon_{kl}) = 0 \\ 4) \varepsilon_{ij} \sim N(0, \sigma^2) \end{matrix} \right\} \begin{matrix} \varepsilon_{ij} \sim N(0, \sigma^2) \\ \text{αυτοχέπιστα} \\ \text{(ανεξάρτητα)} \end{matrix} \left. \begin{matrix} 1) E(Y_{ij}) = \mu + a_i + \beta_j \\ 2) \text{Var}(Y_{ij}) = \sigma^2 \\ 3) \text{Cov}(Y_{ij}, Y_{kl}) = 0 \\ 4) Y_{ij} \sim N(\mu + a_i + \beta_j, \sigma^2) \end{matrix} \right\} \begin{matrix} Y_{ij} \sim N(\mu + a_i + \beta_j, \sigma^2) \\ \text{αυτοχέπιστα} \\ \text{(ανεξάρτητα)} \end{matrix}$$

ΙΔΙΟΤΗΤΕΣ των ΕΕΤ

1) Οι ΕΕΤ επιπλέον αμερόληπτα τις αντίστοιχες παραμέτρους
 $E(\hat{\mu}) = \mu, \quad E(\hat{a}_i) = a_i, \quad E(\hat{\beta}_j) = \beta_j, \quad i=1, \dots, I, \quad j=1, \dots, J$

ΑΠΟΔΕΙΞΗ:

$$\begin{aligned} E(\hat{a}_i) &= E(\bar{Y}_{i.} - \bar{Y}_{..}) = E(\bar{Y}_{i.}) - E(\bar{Y}_{..}) = E\left(\frac{1}{J} \sum_{j=1}^J Y_{ij}\right) - E\left(\frac{1}{IJ} \sum_{i=1}^I \sum_{j=1}^J Y_{ij}\right) = \\ &= E\left(\frac{1}{J} \sum_{j=1}^J (\mu + a_i + \beta_j + \varepsilon_{ij})\right) - E\left(\frac{1}{IJ} \sum_{i=1}^I \sum_{j=1}^J (\mu + a_i + \beta_j + \varepsilon_{ij})\right) = \\ &= \frac{1}{J} \sum_{j=1}^J (\mu + a_i + \beta_j + E(\varepsilon_{ij})) - \frac{1}{IJ} \sum_{i=1}^I \sum_{j=1}^J (\mu + a_i + \beta_j + E(\varepsilon_{ij})) = \\ &= \frac{1}{J} (J\mu + Ja_i + \sum_{j=1}^J \beta_j) - \frac{1}{IJ} (IJ\mu + I \sum_{i=1}^I a_i + I \sum_{j=1}^J \beta_j) = \mu + a_i - \mu = a_i \end{aligned}$$

2) Υπό τις υποθέσεις για τα σφάλματα οι ΕΕΤ(μ, α_i, β_j) = ΕΜΠ(μ, α_i, β_j)

ΑΠΟΔΕΙΞΗ:

$$L = \prod_{i=1}^I \prod_{j=1}^J f_{Y_{ij}}(y_{ij}) = \prod_{i=1}^I \prod_{j=1}^J \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2\sigma^2}(Y_{ij} - \mu - \alpha_i - \beta_j)^2} = \frac{1}{(\sigma)^{IJ} (2\pi)^{IJ/2}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \mu - \alpha_i - \beta_j)^2}$$

log L = ... συνεχιζόμαστε στα άλλα μοντέλα

3) Ολική μεταβλητότητα στο μοντέλο Ανάλυσης Διακύμανσης κατά 2 παράγοντες —
Πίνακας ΑΝΑΔΙΑ ανάλυσης διακύμανσης κατά 2 παράγοντες

Ολική μεταβλητότητα \equiv Δειγματική διακύμανση ειτός του όρου που σχετίζεται με μέγεθος δείγματος.



$$SS_{tot} = \sum_{i=1}^I \sum_{j=1}^J (\bar{Y}_{ij} - \bar{Y}_{..})^2 \Rightarrow SS_{tot} = J \sum_{i=1}^I (\bar{Y}_{i.} - \bar{Y}_{..})^2 + I \sum_{j=1}^J (\bar{Y}_{.j} - \bar{Y}_{..})^2 + \sum_{i=1}^I \sum_{j=1}^J (Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..})^2$$

$$SS_{tot} = SS_A + SS_B + SS_{res}$$

Υπόλοιπα μοντέλο ανάλυσης διακύμανσης κατά δύο παράγοντες

$$e_{ij} = Y_{ij} - \hat{Y}_{ij} = Y_{ij} - (\mu - \hat{\alpha}_i - \hat{\beta}_j) = Y_{ij} - (\bar{Y}_{..} + \bar{Y}_{i.} - \bar{Y}_{.j} - \bar{Y}_{..}) \Rightarrow$$

$$e_{ij} = Y_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}_{..}$$