

# ΑΝΑΛΥΣΗ ΔΙΑΚΥΜΑΝΣΗΣ

Επικ. Καθ. Στέλιος Ζήμερας

Τμήμα Μαθηματικών  
Κατεύθυνση Στατιστικής και Αναλογιστικά –  
Χρηματοοικονομικά Μαθηματικά

2015

# Μοντελοποίηση

- Έστω για την σύγκριση  $k$  δειγμάτων συλλέγουμε  $n_i$  παρατηρήσεις  $Y_{ij}$   $j=1,2,\dots, n_i$  από το δείγμα  $i$  με  $i=1,2,\dots,k$

$$1^{\circ} \text{ δείγμα} \Rightarrow Y_{11}, Y_{12}, \dots, Y_{1n_1} \Rightarrow N(\mu_1, \sigma^2)$$

$$2^{\circ} \text{ δείγμα} \Rightarrow Y_{21}, Y_{22}, \dots, Y_{2n_2} \Rightarrow N(\mu_2, \sigma^2)$$

⋮  
⋮

$$k^{\text{τάξεως}} \text{ δείγμα} \Rightarrow Y_{k1}, Y_{k2}, \dots, Y_{kn_k} \Rightarrow N(\mu_k, \sigma^2)$$



Πειραματικό σχέδιο

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

# Μοντελοποίηση

Δηλ: οι μέσες τιμές των πληθυσμών από τους οποίους λαμβάνονται τα εν λόγω δείγματα είναι ίσες μεταξύ τους

Θεωρούμε ότι  $n = n_1 + n_2 + \dots + n_k$  όπου  $n$ : είναι το μέγεθος του δείγματος.

Θα έχουμε ότι για την παρατήρηση  $Y_{ij}$  που γράφεται ως

$$Y_{ij} = \mu_i + \varepsilon_{ij}, i = 1, 2, \dots, k; j = 1, 2, \dots, n_i$$

όπου οι τ.μ.  $\varepsilon_{ij}$  είναι ανεξάρτητες και  $\varepsilon_{ij} \sim N(0, \sigma^2)$  με  $\sigma^2 > 0$

# Μοντελοποίηση

Αν θέσουμε:

$$Y' = (Y_{11}, Y_{12}, \dots, Y_{1n_1}, Y_{21}, Y_{22}, \dots, Y_{2n_2}, \dots, Y_{k1}, Y_{k2}, \dots, Y_{kn_k})$$

$$\beta' = (\beta_1, \beta_2, \dots, \beta_k) \Rightarrow \mu' = (\mu_1, \mu_2, \dots, \mu_k)$$

$$\varepsilon' = (\varepsilon_{11}, \varepsilon_{12}, \dots, \varepsilon_{1n_1}, \varepsilon_{21}, \varepsilon_{22}, \dots, \varepsilon_{2n_2}, \dots, \varepsilon_{k1}, \varepsilon_{k2}, \dots, \varepsilon_{kn_k})$$

$$X = \begin{bmatrix} \left. \begin{array}{c} 1 \\ \vdots \\ 1 \end{array} \right\} n_1 & 0 & \dots & 0 \\ & \vdots & \dots & \vdots \\ & 0 & \dots & 0 \\ & \left. \begin{array}{c} 1 \\ \vdots \\ 1 \end{array} \right\} n_2 & \dots & \vdots \\ & 0 & \dots & 0 \\ & 0 & \dots & 1 \\ & \vdots & \dots & \vdots \\ & 0 & \dots & 1 \end{bmatrix} \left. \begin{array}{c} \\ \\ \\ \\ \\ \\ \\ \end{array} \right\} n_k$$

# Μοντελοποίηση

- Αν θέσουμε  $Y'$  για τα διανύσματα όλων των παρατηρήσεων

$$Y' = (Y_{11}, Y_{12}, \dots, Y_{1n_1}, Y_{21}, Y_{22}, \dots, Y_{2n_2}, \dots, Y_{k1}, Y_{k2}, \dots, Y_{kn_k})$$

Για κάθε  $i=1,2,\dots,k$  έστω  $\mu_i$  η κοινή μέση τιμή των  $Y_{ij}$   
 $j=1,2,\dots,n_i$  τα οποία είναι ισόνομα. Έτσι μπορούμε να γράψουμε το μοντέλο μας ως:

$$Y_{ij} = E(Y_{ij}) + \varepsilon_{ij} = \mu_i + \varepsilon_{ij}$$



$$\mathbf{Y} = E(\mathbf{Y}) + \boldsymbol{\varepsilon} = X_{n \times k} \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_k \end{pmatrix} + \boldsymbol{\varepsilon}$$


# Μοντελοποίηση

Η τάξη του πίνακα  $X$  είναι  $k - k$  ανεξάρτητοι γραμμικοί συνδυασμοί

$$E(\mathbf{Y}) = X_{n \times k} \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_k \end{pmatrix}$$

Επομένως μπορούμε να παρατηρήσουμε μέσω του  $E(\mathbf{Y})$  τα  $\mathbf{Y}$  ως:

$$\mathbf{Y} = \mathbf{X}\mathbf{b} + \boldsymbol{\varepsilon}$$



$$X = [1_n, X] \quad \mathbf{b} = (\mu, \alpha_1, \alpha_2, \dots, \alpha_k)'$$
$$Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}$$

# Μοντελοποίηση

Επειδή ο πίνακας  $X$  είναι ελλιπούς τάξης ( $k+1$  στήλες είναι γραμμικά εξαρτημένες), οι παράμετροι  $\mu, \alpha_i, i=1,2,\dots,k$  δεν καθορίζονται μονοσήμαντα από την σχέση  $E(Y)$

Για τον λόγο αυτό θα πρέπει να υπάρχουν περιορισμοί όπως

$$\sum_{i=1}^k a_{ij} = 0$$

Άρα ισχύει:

$$\mu = \bar{\mu}$$

$$\alpha_i = \mu_i - \bar{\mu}$$

$$\bar{\mu} = \frac{1}{k} \sum_{i=1}^k \mu_i$$



Το  $\mu$  έχει την ερμηνεία του συνολικού μέσου όρου, ενώ τα  $\alpha_i$  δείχνουν πόσο κάθε  $\mu_i$  διαφέρει από το συνολικό μέσο όρο.

Τα  $\alpha_i$  ονομάζονται επίδραση του δείγματος  $i$ .

# Μοντελοποίηση

Τότε το παραπάνω μοντέλο μπορεί να πάρει την μορφή

$$Y = X\beta + \varepsilon$$

$$\mu = X\beta = E(Y)$$

$$Y = \mu + \varepsilon$$

όπου η μήτρα  $X$  είναι τάξεως  $k$ , αφού καμία στήλη της; Δεν μπορεί να είναι γραμμικός συνδυασμός άλλων στηλών  $\tau(X)=k$

Για τα  $\varepsilon_{ij}$  παρατηρούμε ότι  $\varepsilon \sim N_n(0, \sigma^2 I_n)$   $\sigma^2 I = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix}$

Μήτρα διακυμάνσεων-συνδιακυμάνσεων


Από τα παραπάνω έχουμε το κανονικό κλασσικό γραμμικό υπόδειγμα με  $\tau(X)=k$  όπου

$$Y \sim N_n(X\beta, \sigma^2 I_n)$$



# Μοντελοποίηση

Η υπόθεση  $H_0$  μπορεί να γραφεί:



$$\mu_1 - \mu_k = 0, \mu_2 - \mu_k = 0, \dots, \mu_{k-1} - \mu_k = 0$$

# Μοντελοποίηση

Γραμμικοί συνδυασμοί:

$$\mu_1 - \mu_k = 1 * \mu_1 + 0 * \mu_2 + 0 * \mu_3 + \dots + 0 * \mu_{k-1} + (-1) * \mu_k = l'_1 \mu$$

$$\Rightarrow l'_1 = (100 \dots 0 - 1)$$

$$\mu_2 - \mu_k = 0 * \mu_1 + 1 * \mu_2 + 0 * \mu_3 + \dots + 0 * \mu_{k-1} + (-1) * \mu_k = l'_2 \mu$$

$$\Rightarrow l'_2 = (010 \dots 0 - 1)$$

---

$$\mu_{k-1} - \mu_k = 0 * \mu_1 + 0 * \mu_2 + 0 * \mu_3 + \dots + 1 * \mu_{k-1} + (-1) * \mu_k = l'_{k-1} \mu$$

$$\Rightarrow l'_{k-1} = (000 \dots 1 - 1)$$

# Μοντελοποίηση

Τα διανύσματα  $l'_1, l'_2, \dots, l'_{k-1}$  είναι ανεξάρτητα.

Άρα τα διανύσματα

$$l'_1\mu, l'_2\mu, \dots, l'_{k-1}\mu$$

είναι ανεξάρτητες εκτιμήσιμες συναρτήσεις.

## Γραμμικές εκτιμήσιμες συναρτήσεις

### Πρόταση:

Δίνεται το υπόδειγμα  $Y = X\beta + \varepsilon$ . Τότε οι παρακάτω προτάσεις είναι ισοδύναμες:

- Η γραμμική συνάρτηση  $l'\mu$  είναι εκτιμήσιμη
- Το διάνυσμα  $l_{k \times 1}$  είναι γραμμικός συνδυασμός των στηλών της  $X'$
- Ο γραμμικός συνδυασμός δίνεται από:  $l = X_{k \times n} \lambda_{n \times 1}$ ,  $\lambda \in R^n$

# Μοντελοποίηση

## Θεώρημα:

Δίνεται το σύστημα κανονικών εξισώσεων


$Y = X\beta + \varepsilon$  με συνάρτηση  $S(\beta) = (Y - X\beta)'(Y - X\beta)$ . Οι παρακάτω προτάσεις είναι ισοδύναμες

1. Το διάνυσμα  $\beta$  είναι λύση του συστήματος των κανονικών εξισώσεων
2. Το διάνυσμα  $\beta$  ελαχιστοποιεί την συνάρτηση  $S$

# Μοντελοποίηση


## Γραφική παρουσίαση του ΓΓΜ $Y=X\beta+\varepsilon$

Το  $X\beta$  είναι γραμμικός συνδυασμός των στηλών της μήτρας  $X$  άρα  $X\beta \in L(X)$  (πεδίο ορισμού της συνάρτησης). Αν συμβολίσουμε με  $\eta$  το διάνυσμα  $X\beta$  παρατηρούμε ότι  $\eta \in L(X)$  με  $Y=\eta+\varepsilon$



# Μοντελοποίηση

**Πρόταση:** Ας θεωρήσουμε ένα διάνυσμα  $Y \in \mathbb{R}^n$  και έστω  $V_r$  ένας υπόχωρος του  $\mathbb{R}^n$ . Σχηματίζουμε την συνάρτηση  $f$  με τύπο  $f(z) = (Y-z)'(Y-z)$  με  $z \in V_r$ . Τότε η  $f$  παρουσιάζει ελάχιστο για  $z=z^*$ , μόνο αν  $z^*$  είναι η ορθή προβολή του  $Y$  πάνω στο  $V_r$ .



Παρατηρούμε ότι

$$f(z) = (Y-z)'(Y-z) = \|Y-z\|^2$$

(μήκος του  $\overrightarrow{BA}$ )<sup>2</sup>

Το μήκος του  $\overrightarrow{BA}$  γίνεται ελάχιστο αν αυτό συμπέσει με το  $\overrightarrow{\Gamma A}$ , οπότε το  $z=z^*$

# Μοντελοποίηση

Αν θέσουμε

$$C_{(k-1) \times k} = \begin{bmatrix} l'_1 \\ l'_2 \\ \vdots \\ l'_{k-1} \end{bmatrix} = \begin{bmatrix} 1 * \mu_1 + 0 * \mu_2 + \dots + 0 * \mu_{k-1} + (-1) \mu_k \\ 0 * \mu_1 + 1 * \mu_2 + \dots + 0 * \mu_{k-1} + (-1) \mu_k \\ \vdots \\ 0 * \mu_1 + 0 * \mu_2 + \dots + 1 * \mu_{k-1} + (-1) \mu_k \end{bmatrix}$$



$$\begin{bmatrix} 1 & 0 & \dots & 0 & -1 \\ 0 & 1 & \dots & 0 & -1 \\ \vdots & \vdots & \dots & \vdots & \vdots \\ 0 & 0 & \dots & 1 & -1 \end{bmatrix} \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_k \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \Rightarrow \begin{bmatrix} l'_1 \\ l'_2 \\ \vdots \\ l'_{k-1} \end{bmatrix} \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_k \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \Rightarrow \mathbf{C}\boldsymbol{\mu} = \mathbf{0}$$

# Μοντελοποίηση

## Έλεγχος υποθέσεων $C\mu=0$

- ✓ Επιλέγουμε επίπεδο σημαντικότητας  $\alpha$
- ✓ Επιλύουμε ως προς  $x_0$  την εξίσωση

$$P\{F^* > x_0\} = \alpha$$

όπου  $F^* \sim F_{k-1, n-k}$

- ✓ Υπολογίζουμε την ποσότητα

$$F^* = \frac{MST_r}{MSE} \sim F_{(k-1), (n-k)}$$

$$F^* = \frac{\frac{(R_1^2 - R_0^2)}{k-1}}{\frac{R_0^2}{n-k}}$$

$$F^* = \frac{s_b^2}{s_w^2} = \frac{\text{μέσο άθροισμα των τετραγώνων των επεμβάσεων (MST_r)}}{\text{Μέσο άθροισμα τετραγώνων σφάλματος (MSE)}}$$



# Μοντελοποίηση

Η ποσότητα

$$F^* = \frac{\frac{(R_1^2 - R_0^2)}{k-1}}{\frac{R_0^2}{n-k}}$$




$$R_0^2 = \min(Y - X\beta)'(Y - X\beta)$$


$$R_1^2 = \min(Y - X\beta)'(Y - X\beta) |_{C\mu=0}$$

- ✓ Αν  $F^* > x_0$  τότε απορρίπτουμε την υπόθεση  $H_0$
- ✓ Αν  $F^* < x_0$  τότε δεν απορρίπτουμε την υπόθεση  $H_0$

όπου  $C\mu=0$  ερμηνεύεται ως  $\beta=0$  άρα οι παράμετροι  $\beta$  μέσα στο γραμμικό μοντέλο εξηγούνται από γραμμικούς συνδυασμούς των μέσων κάθε δείγματος.

# Μοντελοποίηση

$$F^* = \frac{MST_r}{MSE} = \frac{\frac{SST_r}{k-1}}{\frac{SSE}{n-k}} = \frac{\frac{\sum_j n_j (\bar{y}_j - \bar{y})^2}{k-1}}{\frac{\sum_{ij} (y_{ij} - \bar{y}_j)^2}{n-k}}$$


$$F^* = \frac{\frac{(R_1^2 - R_0^2)}{k-1}}{\frac{R_0^2}{n-k}}$$


$$R_1^2 - R_0^2 = \sum_j n_j (\bar{y}_j - \bar{y})^2$$

$$R_0^2 = \sum_{ij} (y_{ij} - \bar{y}_j)^2$$

# Μοντελοποίηση

Έχουμε την ποσότητα

$$R_0^2 = (Y - X\hat{\beta})'(Y - X\hat{\beta}) = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \hat{\beta}_i)^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \hat{\mu}_i)^2$$

όπου  $\hat{\beta}$  είναι η λύση του συστήματος των κανονικών εξισώσεων ( $\hat{\beta} = \hat{\mu}$ )

Αν θέσουμε

$$\begin{aligned} S(\beta) &= S(\beta_1, \beta_2, \dots, \beta_k) = (Y - X\hat{\beta})'(Y - X\hat{\beta}) = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \beta_i)^2 = \\ &= \sum_{j=1}^{n_1} (Y_{1j} - \beta_1)^2 + \sum_{j=1}^{n_2} (Y_{2j} - \beta_2)^2 + \dots + \sum_{j=1}^{n_k} (Y_{kj} - \beta_k)^2 \end{aligned}$$

# Μοντελοποίηση

Σύστημα κανονικών εξισώσεων:

$$\frac{\partial S}{\partial \beta_1} = -2 \sum_{j=1}^{n_1} (Y_{1j} - \beta_1) = 0 \Rightarrow n_1 \beta_1 = \sum_{j=1}^{n_1} Y_{1j}$$

$$\frac{\partial S}{\partial \beta_2} = -2 \sum_{j=1}^{n_2} (Y_{2j} - \beta_2) = 0 \Rightarrow n_2 \beta_2 = \sum_{j=1}^{n_2} Y_{2j}$$

⋮

$$\frac{\partial S}{\partial \beta_k} = -2 \sum_{j=1}^{n_k} (Y_{kj} - \beta_k) = 0 \Rightarrow n_k \beta_k = \sum_{j=1}^{n_k} Y_{kj}$$

# Μοντελοποίηση

Εκτιμήσεις

$$\hat{\beta}_1 = \frac{1}{n_1} \sum_{j=1}^{n_1} Y_{1j} = \bar{Y}_{1.} = \hat{\mu}_1$$

$$\hat{\beta}_2 = \frac{1}{n_2} \sum_{j=1}^{n_2} Y_{2j} = \bar{Y}_{2.} = \hat{\mu}_2$$

⋮

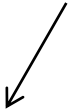
$$\hat{\beta}_k = \frac{1}{n_k} \sum_{j=1}^{n_k} Y_{kj} = \bar{Y}_{k.} = \hat{\mu}_k$$



$$\hat{\beta} = \begin{bmatrix} \bar{Y}_{1.} \\ \bar{Y}_{2.} \\ \vdots \\ \bar{Y}_{k.} \end{bmatrix}$$

# Μοντελοποίηση

Επομένως η  $R_0^2$  παίρνει την μορφή

$$R_0^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})^2$$


Άθροισμα τετραγώνων των αποκλίσεων



Άθροισμα τετραγώνων μέσα στα δείγματα

# Μοντελοποίηση

Ας θέσουμε  $\mu^*$  την κοινή τιμή των  $\mu_i$ ,  $i=1,2,\dots,k$  κάτω από την  $H_0$ , δηλ:  $\mu_1 = \mu_2 = \dots = \mu_k = \mu^*$  ή  $\beta_1 = \beta_2 = \dots = \beta_k = \beta^*$

Έχουμε την ποσότητα

$$R_1^2 = \min_{C\mu=0} (Y - X\hat{\beta}^*)' (Y - X\hat{\beta}^*)$$

όπου  $\hat{\beta}^*$  είναι η ελάχιστων τετραγώνων εκτιμήτρια της παραμέτρου  $\beta$  κάτω από τους περιορισμούς  $C\mu=0$  ( $C\beta=0$ )

Αν θέσουμε

$$\begin{aligned} S'(\beta^*) &= S'(\beta^*)_{C\beta=0} = (Y - X\hat{\beta}^*)' (Y - X\hat{\beta}^*) = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \beta^*)^2 = \\ &= \sum_{j=1}^{n_1} (Y_{1j} - \beta^*)^2 + \sum_{j=1}^{n_2} (Y_{2j} - \beta^*)^2 + \dots + \sum_{j=1}^{n_k} (Y_{kj} - \beta^*)^2 \end{aligned}$$

# Μοντελοποίηση

Σύστημα κανονικών εξισώσεων:

$$\frac{\partial S'}{\partial \beta^*} = -2 \sum_{j=1}^{n_1} (Y_{1j} - \beta^*) = 0 \Rightarrow n_1 \beta^* = \sum_{j=1}^{n_1} Y_{1j}$$

$$\frac{\partial S'}{\partial \beta^*} = -2 \sum_{j=1}^{n_2} (Y_{2j} - \beta^*) = 0 \Rightarrow n_2 \beta^* = \sum_{j=1}^{n_2} Y_{2j}$$

⋮

$$\frac{\partial S'}{\partial \beta^*} = -2 \sum_{j=1}^{n_k} (Y_{kj} - \beta^*) = 0 \Rightarrow n_k \beta^* = \sum_{j=1}^{n_k} Y_{kj}$$



$$(n_1 + n_2 + \dots + n_k) \beta^* = \sum_{j=1}^{n_1} Y_{1j} + \sum_{j=1}^{n_2} Y_{2j} + \dots + \sum_{j=1}^{n_k} Y_{kj} = \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}$$



# Μοντελοποίηση

Εκτιμήσεις


$$\hat{\beta}^* = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij} = \bar{Y}$$



$$\hat{\beta}^* = \begin{bmatrix} \bar{Y} \\ \bar{Y} \\ \vdots \\ \bar{Y} \end{bmatrix}$$



$$\hat{\beta}_1^* = \bar{Y}, \hat{\beta}_2^* = \bar{Y}, \dots, \hat{\beta}_k^* = \bar{Y}$$



**Εκτιμήτριες ελαχίστων τετραγώνων**

# Μοντελοποίηση

Επομένως η  $R_1^2$  παίρνει την μορφή

$$R_1^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2$$



Ολικό άθροισμα τετραγώνων

$$R_0^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})^2 \quad \longleftrightarrow \quad R_1^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2$$

$$R_1^2 - R_0^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 - \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})^2$$

Άθροισμα τετραγώνων εκτός δειγμάτων

# Μοντελοποίηση


Ως προς τις μορφές των μέσων έχουμε

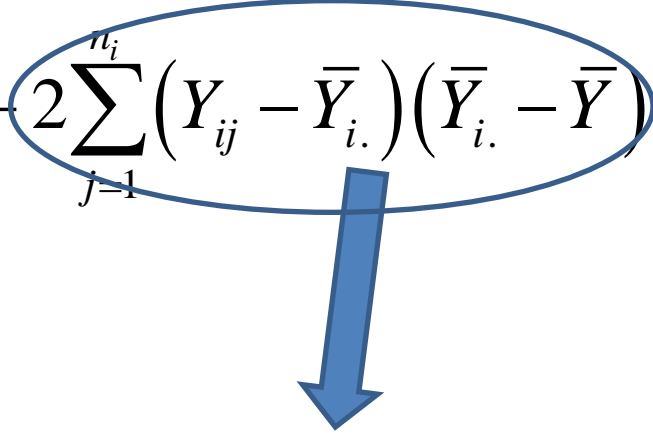
$$\bar{Y} = \frac{1}{n} \sum_i^k \sum_j^{n_i} Y_{ij} \longrightarrow \text{Μεγάλος μέσος}$$

$$\bar{Y}_i = \frac{1}{n_i} \sum_j^{n_i} Y_{ij} \longrightarrow \text{Μικρός μέσος}$$

# Μοντελοποίηση

Μπορούμε να γράψουμε:


$$Y_{ij} - \bar{Y} = (Y_{ij} - \bar{Y}_{i.}) + (\bar{Y}_{i.} - \bar{Y})$$

$$\sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 = \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})^2 + \sum_{j=1}^{n_i} (\bar{Y}_{i.} - \bar{Y})^2 + 2 \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})(\bar{Y}_{i.} - \bar{Y})$$


$$\sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.})(\bar{Y}_{i.} - \bar{Y}) = (\bar{Y}_{i.} - \bar{Y}) \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{i.}) = (\bar{Y}_{i.} - \bar{Y}) * 0 = 0$$

# Μοντελοποίηση

Μπορούμε να γράψουμε:

$$\sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 = \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2 + n_i (\bar{Y}_i - \bar{Y})^2 \Rightarrow$$

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2 + \sum_{i=1}^k n_i (\bar{Y}_i - \bar{Y})^2$$


$$R_1^2$$

$$R_0^2$$

$$R_1^2 = R_0^2 + \sum_{i=1}^k n_i (\bar{Y}_i - \bar{Y})^2 \Rightarrow R_1^2 - R_0^2 = \sum_{i=1}^k n_i (\bar{Y}_i - \bar{Y})^2$$

# Μοντελοποίηση

## Πίνακας Ανάλυσης Διακύμανσης

Πηγή μεταβλητότητας	Άθροισμα τετραγώνων	Βαθμοί ελευθερίας	Μέσο άθροισμα τετραγώνων	F
Απόκλιση από την $H_0$ (μεταξύ δειγμάτων)	$R_1^2 - R_0^2$	k-1	$\frac{R_1^2 - R_0^2}{k - 1}$	$F^* = \frac{\frac{R_1^2 - R_0^2}{k - 1}}{\frac{R_0^2}{n - k}}$
Κατάλοιπα (εντός δειγμάτων)	$R_0^2$	n-k	$\frac{R_0^2}{n - k}$	
Σύνολο	$R_1^2$	n-1		

# Μοντελοποίηση

Απλοποιήσεις

$$R_1^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}^2 - \frac{1}{n} \left( \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij} \right)^2$$

Απόδειξη

$$\begin{aligned} R_1^2 &= \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij}^2 - 2\bar{Y}Y_{ij} + \bar{Y}^2) = \sum_i \sum_j Y_{ij}^2 - 2\bar{Y} \left( \sum_i \sum_j Y_{ij} \right) + n\bar{Y}^2 = \\ &= \sum_i \sum_j Y_{ij}^2 - 2n\bar{Y}^2 + n\bar{Y}^2 = \sum_i \sum_j Y_{ij}^2 - \frac{1}{n} \left( \sum_i \sum_j Y_{ij} \right)^2 \end{aligned}$$

# Μοντελοποίηση

Απλοποιήσεις

$$R_0^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}^2 - \sum_{i=1}^k \frac{1}{n_i} \left( \sum_{j=1}^{n_i} Y_{ij} \right)^2$$

Απόδειξη

$$\begin{aligned} R_0^2 &= \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2 = \sum_j (Y_{1j} - \bar{Y}_1)^2 + \dots + \sum_j (Y_{kj} - \bar{Y}_k)^2 = \\ &= \sum_j Y_{1j}^2 - \frac{1}{n_1} \left( \sum_j Y_{1j} \right)^2 + \dots + \sum_j Y_{kj}^2 - \frac{1}{n_k} \left( \sum_j Y_{kj} \right)^2 = \\ &= \sum_i \sum_j Y_{ij}^2 - \left\{ \frac{1}{n_1} \left( \sum_j Y_{1j} \right)^2 + \dots + \frac{1}{n_k} \left( \sum_j Y_{kj} \right)^2 \right\} = \\ &= \sum_i \sum_j Y_{ij}^2 - \sum_i \frac{1}{n_i} \left( \sum_j Y_{ij} \right)^2 \end{aligned}$$



# Μοντελοποίηση

Απλοποιήσεις

$$R_1^2 - R_0^2 = \sum_{i=1}^k \frac{1}{n_i} \left( \sum_{j=1}^{n_i} Y_{ij} \right)^2 - \frac{1}{n} \left( \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij} \right)^2$$

# Μοντελοποίηση


## Πίνακας Υπολογισμού Διακύμανσης

# Δείγμα	Δείγμα	παρατηρήσεις	Άθροισμα παρατηρήσεων	Μέσο τετραγωνικό άθροισμα	Άθροισμα τετραγώνων	Μέση τιμή
1	$Y_{11}, Y_{12}, \dots, Y_{1n_1}$	$n_1$	$\sum_j Y_{1j}$	$\frac{1}{n_1} \left( \sum_j Y_{1j} \right)^2$	$\sum_j Y_{1j}^2$	$\bar{Y}_1.$
2	$Y_{21}, Y_{22}, \dots, Y_{2n_2}$	$n_2$	$\sum_j Y_{2j}$	$\frac{1}{n_2} \left( \sum_j Y_{2j} \right)^2$	$\sum_j Y_{2j}^2$	$\bar{Y}_2.$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
k	$Y_{k1}, Y_{k2}, \dots, Y_{kn_k}$	$n_k$	$\sum_j Y_{kj}$	$\frac{1}{n_k} \left( \sum_j Y_{kj} \right)^2$	$\sum_j Y_{kj}^2$	$\bar{Y}_k.$
Σύνολο		n	$\sum_i \sum_j Y_{ij}$	$\sum_i \frac{1}{n_i} \left( \sum_j Y_{ij} \right)^2$	$\sum_i \sum_j Y_{ij}^2$	$\bar{Y}$

# Γεωμετρική ερμηνεία του F-test

## Γραφική παρουσίαση του ΓΓΜ $Y=X\beta+\varepsilon$

Το  $X\beta$  είναι γραμμικός συνδυασμός των στηλών της μήτρας  $X$  άρα  $X\beta \in L(X)$  (πεδίο ορισμού της συνάρτησης). Αν συμβολίσουμε με  $\eta$  το διάνυσμα  $X\beta$  παρατηρούμε ότι  $\eta \in L(X)$  με  $Y=\eta+\varepsilon$




# Γεωμετρική ερμηνεία του F-test

Αν  $\hat{\eta}$  είναι η ορθή προβολή του  $Y$  πάνω στο χώρο  $L(X)$  τότε θα έχουμε

$$Y = \hat{\eta} + e$$

όπου  $e = Y - \hat{\eta} = Y - X\hat{\beta}$  είναι το διάνυσμα των καταλοίπων (residuals), και  $\hat{\beta}$  είναι μια εκτιμήτρια ελαχίστων τετραγώνων της παραμέτρου  $\beta$ .



Τότε  $\hat{\eta} \perp e$  και


$$R_0^2 = e'e = (\text{μήκος του } \overline{\Gamma\Delta})^2 = \|\overline{\Gamma\Delta}\|^2$$

# Γεωμετρική ερμηνεία του F-test

Κάτω από την υπόθεση  $C\mu = \omega_0$  το  $Y$  προβάλλεται σε ένα υπόχωρο του  $L(X)$   $r-q$  διαστάσεων  $V_{r-q}$

Αν  $\hat{\eta}_1$  η ορθή προβολή του  $Y$  στον υπόχωρο  $V_{r-q}$  τότε τα αντίστοιχα κατάλοιπα (residuals) θα είναι


$$\tilde{e}_1 = Y - X\tilde{\beta}$$



όπου  $\tilde{\beta}$  θέση όπου ελαχιστοποιείται η  $(Y - X\tilde{\beta})'(Y - X\tilde{\beta})$

$$R_1^2 = \tilde{e}_1' \tilde{e}_1 = (\text{μῆκος του } \overline{K\Lambda})^2 = \|\overline{K\Lambda}\|^2$$

# Γεωμετρική ερμηνεία του F-test



$$R_1^2 = \tilde{e}_1' \tilde{e}_1$$

$$R_0^2 = e'e$$

$$\overline{O\Delta} = Y$$

$$\overline{O\Gamma} = \hat{\eta}$$

$$\overline{OA} = \hat{\eta}_1$$


$$\overline{A\Delta} = \tilde{e}_1 = Y - \hat{\eta}_1$$

$$\overline{\Gamma\Delta} = \tilde{e} = Y - \hat{\eta}$$

$$\overline{A\Gamma} = \hat{\eta} - \hat{\eta}_1$$

$$R_1^2 - R_0^2 = \|\hat{\eta} - \hat{\eta}_1\|^2$$

# Γεωμετρική ερμηνεία του F-test




Παρατηρούμε ότι  
 $e \perp \hat{\eta} - \hat{\eta}_1 \in L(X)$   
 και το  $e$  ανήκει στο  
 ορθογώνιο σύμπλεγμα του  
 $L(X)$ .

Επίσης έχουμε

$$\tilde{e}_1 = (\hat{\eta} - \hat{\eta}_1) - e$$

# Γεωμετρική ερμηνεία του F-test



$$\begin{aligned}
 R_1^2 - R_0^2 &= \tilde{e}'_1 \tilde{e}_1 - e'e = [e + (\hat{\eta} - \hat{\eta}_1)]' [e + (\hat{\eta} - \hat{\eta}_1)] = \\
 &= e'e + e'(\hat{\eta} - \hat{\eta}_1) + (\hat{\eta} - \hat{\eta}_1)' e + (\hat{\eta} - \hat{\eta}_1)' (\hat{\eta} - \hat{\eta}_1) = \\
 &= e'e + (\hat{\eta} - \hat{\eta}_1)' (\hat{\eta} - \hat{\eta}_1) = R_0^2 + \|\hat{\eta} - \hat{\eta}_1\|^2
 \end{aligned}$$



# Παραδείγματα

Διαθέτουμε 3 είδη χοιριδίων. Μελετάμε αν το είδος της τροφής επιδρά στην αύξηση του βάρους.

Ένα σύνολο 12 χοιριδίων χωριστήκαν τυχαία σε 3 ισοπληθείς ομάδες και σε κάθε μια ομάδα δόθηκε ένα είδος τροφής για ένα χρονικό διάστημα στο τέλος του οποίου μετρήθηκε η αύξηση του βάρους καθενός από τα 12 χοιρίδια.

# Παραδείγματα

Ομάδα χοιριδίων	Αύξηση βάρους			
1	1.42	1.28	1.37	1.37
2	1.4	1.33	1.41	1.42
3	1.17	1.39	1.4	1.37

Υποθέτουμε ότι οι παρατηρήσεις είναι κανονικές, ανεξάρτητες και προέρχονται από κανονικό πληθυσμό.

Θέλουμε να ελέγξουμε την υπόθεση της ισότητας των μέσων έναντι της εναλλακτικής

# Παραδείγματα

Ομάδα χοιριδί ων					$n_i$	$\sum_j Y_{ij}$	$\frac{1}{n_i} \left( \sum_j Y_{ij} \right)^2$	$\sum_j Y_{ij}^2$	$\bar{Y}_i$
1	1.42	1.28	1.37	1.37	4	5.44	7.398	7.408	1.36
2	1.4	1.33	1.41	1.42	4	5.66	7.728	7.733	1.39
3	1.17	1.39	1.4	1.37	4	5.33	7.102	7.137	1.33
Σύνολο					12	16.33	22.229	22.779	1.36

# Παραδείγματα

$$R_1^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}^2 - \frac{1}{n} \left( \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij} \right)^2 = 22.279 - \frac{1}{12} (16.33)^2 = 0.0574$$

$$R_0^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}^2 - \sum_{i=1}^k \frac{1}{n_i} \left( \sum_{j=1}^{n_i} Y_{ij} \right)^2 = 22.279 - 22.229 = 0.0509$$

$$R_1^2 - R_0^2 = 0.0574 - 0.0509 = 0.000659$$

# Παραδείγματα

## Πίνακας Ανάλυσης Διακύμανσης

Πηγή μεταβλητότητας	Άθροισμα τετραγώνων	Βαθμοί ελευθερίας	Μέσο άθροισμα τετραγώνων	F
Απόκλιση από την $H_0$ (μεταξύ δειγμάτων)	0.00659	2	0.00329	0.583
Κατάλοιπα (εντός δειγμάτων)	0.0509	9	0.00565	
Σύνολο	0.0574	11		

Με επίπεδο σημαντικότητας  $\alpha=0.05$ , παρατηρούμε ότι η τιμή της συνάρτησης  $F_{2,9,0.05}=4.26$   
 $4.26 > 0.583$  άρα αποδέχομαι την αρχική υπόθεση  $H_0$

# Παραδείγματα

The screenshot displays the PASW Statistics Data Editor interface. The main data grid contains the following information:

	ΒΑΡΟΣ	ΟΜΑΔΕΣ	var	var	var	var	var	var	var	var	var	var	var	var	var	var	var	var	var
1	1,42	1,00																	
2	1,28	1,00																	
3	1,37	1,00																	
4	1,37	1,00																	
5	1,40	2,00																	
6	1,33	2,00																	
7	1,41	2,00																	
8	1,42	2,00																	
9	1,17	3,00																	
10	1,39	3,00																	
11	1,40	3,00																	
12	1,37	3,00																	
13																			
14																			
15																			
16																			
17																			
18																			
19																			
20																			
21																			
22																			
23																			
24																			
25																			
26																			
27																			
28																			
29																			
30																			

ομάδες

Μεταβλητή Βάρος χοιριδίων

PASW Statistics Processor is ready

1:33 πμ  
16/3/2015

# Παραδείγματα

The screenshot shows the PASW Statistics Data Editor interface. The main window displays a data table with the following columns: 'BAΡΟΣ' and 'ΟΜΑΔΕΣ'. The data is as follows:

	BAΡΟΣ	ΟΜΑΔΕΣ
1	1,42	1,1
2	1,28	1,1
3	1,37	1,1
4	1,37	1,1
5	1,40	2,1
6	1,33	2,1
7	1,41	2,1
8	1,42	2,1
9	1,17	3,1
10	1,39	3,1
11	1,40	3,1
12	1,37	3,1
13		
14		
15		
16		
17		
18		
19		
20		
21		
22		
23		
24		
25		
26		
27		
28		
29		
30		

The 'Analyze' menu is open, showing the following options:

- Reports
- Descriptive Statistics
- Tables
- Compare Means
- General Linear Model
- Generalized Linear Models
- Mixed Models
- Correlate
- Regression
- Loglinear
- Neural Networks
- Classify
- Dimension Reduction
- Scale
- Nonparametric Tests**
  - One Sample...
  - Independent Samples...
  - Related Samples...
  - Legacy Dialogs**
    - Chi-square...
    - Binomial...
    - Runs...
    - 1-Sample K-S...**
    - 2 Independent Samples...
    - K Independent Samples...
    - 2 Related Samples...
    - K Related Samples...
- Forecasting
- Survival
- Multiple Response
- Missing Value Analysis...
- Multiple Imputation
- Complex Samples
- Quality Control
- ROC Curve...

The bottom status bar shows '1-Sample K-S...' and 'PASW Statistics Processor is ready'. The system tray at the bottom right displays the time '1:37 πμ' and the date '16/3/2015'.

# Παραδείγματα

The screenshot shows the SPSS Data Editor interface. The main window displays a data table with two columns: 'BAPOΣ' and 'ΟΜΑΔΕΣ'. The 'BAPOΣ' column contains values ranging from 1,28 to 1,42, and the 'ΟΜΑΔΕΣ' column contains values ranging from 1,00 to 3,00. A dialog box titled 'One-Sample Kolmogorov-Smirnov Test' is open, showing the 'Test Variable List' with 'BAPOΣ' selected. The 'Test Distribution' section has 'Normal' selected. The 'Exact' and 'Options' buttons are visible.

	BAPOΣ	ΟΜΑΔΕΣ
1	1,42	1,00
2	1,28	1,00
3	1,37	1,00
4	1,37	1,00
5	1,40	2,00
6	1,33	2,00
7	1,41	2,00
8	1,42	2,00
9	1,17	3,00
10	1,39	3,00
11	1,40	3,00
12	1,37	3,00

## One-Sample Kolmogorov-Smirnov Test

		BAPOΣ
N		12
Normal Parameters <sup>a,b</sup>	Mean	1,3608
	Std. Deviation	,07229
Most Extreme Differences	Absolute	,300
	Positive	,207
	Negative	-,300
Kolmogorov-Smirnov Z		1,041
Asymp. Sig. (2-tailed)		,229

a. Test distribution is Normal.

b. Calculated from data.

$p > 0.05$ , άρα δεν υπάρχει στατιστικά σημαντική διαφορά  
Αποδέχομαι την  $H_0$  κανονική κατανομή



# Παραδείγματα

The screenshot displays the PASW Statistics Data Editor interface. The main window shows a dataset with two columns: 'BAPOΣ' and 'ΟΜΑΔΕΣ'. The data is as follows:

	BAPOΣ	ΟΜΑΔΕΣ
1	1,42	1,
2	1,28	1,
3	1,37	1,
4	1,37	1,
5	1,40	2,
6	1,33	2,
7	1,41	2,
8	1,42	2,
9	1,17	3,
10	1,39	3,
11	1,40	3,
12	1,37	3,
13		
14		
15		
16		
17		
18		
19		
20		
21		
22		
23		
24		
25		
26		
27		
28		
29		
30		

The 'Analyze' menu is open, and 'One-Way ANOVA...' is selected. The status bar at the bottom indicates 'One-Way ANOVA...' and 'PASW Statistics Processor is ready'. The system tray shows the time as 1:45 πμ and the date as 16/3/2015.



# Παραδείγματα

## Descriptives

ΒΑΡΟΣ

	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean	
					Lower Bound	Upper Bound
1,00	4	1,3600	,05831	,02915	1,2672	1,4528
2,00	4	1,3900	,04082	,02041	1,3250	1,4550
3,00	4	1,3325	,10905	,05452	1,1590	1,5060
Total	12	1,3608	,07229	,02087	1,3149	1,4068

$Y_{i.}$   $\Rightarrow$  έλεγχος υποθέσεων  $H_0$

## ANOVA

ΒΑΡΟΣ

	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	,007	2	,003	,585	,577
Within Groups	,051	9	,006		
Total	,057	11			

$p=0.577 > 0.05$

Αποδέχομαι την  $H_0$

Δεν διαφέρουν σημαντικά οι μέσοι