

ΑΝΑΛΥΣΗ ΔΙΑΚΥΜΑΝΣΗΣ ΣΤΟ ΜΟΝΤΕΛΟ ΤΗΣ Α.Γ.Π.

Ανάλυση της ολικής μεταβλητότητας στο μοντέλο της α.γ.π.

Ολική μεταβλητότητα  $\approx$  Δειγματική διακύμανση των  $Y_1, \dots, Y_n$ .


Δειγματική διακύμανση των  $Y_1, \dots, Y_n \rightarrow S^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2$

Ολική μεταβλητότητα στα  $Y_1, \dots, Y_n \approx \sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$

προσθαφισίω  $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$  (ΑΣΚΗΣΗ)   
 ↓ ολική μεταβλητότητα   
 ↓ μεταβλητότητα που οφείλεται στο μοντέλο της α.γ.π.   
 ↓ μεταβλητότητα που οφείλεται στα υποδοίνα

$$SS_{tot} = SS_{reg} + SS_{res}$$

( $MS_{reg} \gg MS_{res}$ ) το ίδιο



- ▶ Αν  $SS_{reg} \gg SS_{res}$  τότε το μοντέλο της α.γ.π. φαίνεται να είναι υποσχόμενο (καλό)
- ▶ Αν  $SS_{reg} \ll SS_{res}$  τότε το μοντέλο δεν φαίνεται να είναι υποσχόμενο

• Άλλη μορφή για το άθροισμα τετραχ. που οφείλεται στην παλινδρόμηση  $SS_{reg}$

$$SS_{reg} = \sum (\hat{Y}_i - \bar{Y})^2 = \sum (\hat{\beta}_0 + \hat{\beta}_1 X_i - \bar{Y})^2 = \sum (\bar{Y} - \hat{\beta}_1 \bar{X} + \hat{\beta}_1 X_i - \bar{Y})^2 = \hat{\beta}_1^2 \sum (X_i - \bar{X})^2$$

Άρα λοιπόν προσπαθούμε να αναδείξουμε αυτή τη σχέση κατασκευάζοντας έναν πίνακα:

Πίνακας ανάλυσης διακύμανσης του μοντέλου της α.δ.π.

## ΠΙΝΑΚΑΣ ΑΝΑΛΥΣΗΣ

πηγή μεταβλητότητας	Αθρ. τετρ. SS	β.ε	MS μέσω τετραχ.	F κρίσιμο
μοντέλο α.δ.π.	$SS_{reg}$	1	$MS_{reg} = SS_{reg}/1$	$F = \frac{MS_{reg}}{MS_{res}}$
υπόλοιπο	$SS_{res}$	$n-2$	$MS_{res} = SS_{res}/(n-2)$	
ολική μεταβλητότητα	$SS_{tot}$	$n-1$		

Για να αξιοποιήσω αυτό τον πίνακα χρησιμοποιώ το  $F$  κριτήριο που προαναφέρθηκε.

**ΟΡΙΣΜΟΣ:** Βαθμιάς ελευθερίας ενός αθροίσματος τετραγώνων είναι το πλήθος των ανεξάρτητων πληροφοριών στο  $Y_1, \dots, Y_n$  τις οποίες πρέπει να διαθέτουμε ώστε να μπορούμε να υπολογίσουμε το αντίστοιχο άθροισμα.

Ας πούμε για το  $SS_{tot}$  ξέρω  $SS_{tot} = \sum (Y_i - \bar{Y})^2$  δηλαδή αρκεί να έχω  $n$ -πληροφορίες για να το υπολογίσω:

$Y_1 - \bar{Y}$   
 $Y_2 - \bar{Y}$   
 $Y_n - \bar{Y}$

ομως!!  $\bar{Y} = \frac{1}{n} \sum Y_i$  δηλ. μπορώ να εκφράσω το  $Y_n$  συναρτήσει των άλλων άρα έχω  $n-1$  β.ε

ΑΠΟΔΕΙΞΗ ότι β.ε. του  $SS_{tot}$  είναι  $n-1$

$$SS_{tot} = \sum (Y_i - \bar{Y})^2$$

$$\text{όπου } \bar{Y} = \frac{1}{n} \sum Y_i \Rightarrow \sum Y_i = n\bar{Y} \Rightarrow Y_n + \sum_{i=1}^{n-1} Y_i = n\bar{Y} \Rightarrow Y_n = n\bar{Y} - \sum_{i=1}^{n-1} Y_i$$

$$Y_n - \bar{Y} = n\bar{Y} - \sum_{i=1}^{n-1} Y_i - \bar{Y} = (n-1)\bar{Y} - \sum_{i=1}^{n-1} Y_i \Rightarrow Y_n - \bar{Y} = - \sum_{i=1}^{n-1} (Y_i - \bar{Y}) \Rightarrow$$

$$\Rightarrow (Y_n - \bar{Y})^2 = \left[ \sum_{i=1}^{n-1} (Y_i - \bar{Y}) \right]^2$$



$$\begin{aligned} \text{δηλαδή } SS_{\text{tot}} &= \sum (Y_i - \bar{Y})^2 = \sum_{i=1}^{n-1} (Y_i - \bar{Y})^2 + (Y_n - \bar{Y})^2 = \\ &= \sum_{i=1}^{n-1} (Y_i - \bar{Y})^2 + \left[ \sum_{i=1}^n (Y_i - \bar{Y}) \right]^2 \end{aligned}$$

Άρα, χρειάζεται να ξέρω  $Y_1 - \bar{Y}, \dots, Y_n - \bar{Y}$  για να υπολογίσω το  $SS_{\text{tot}}$ .  
Άρα, οι β.ε. είναι  $n-1$ .

Εμπειρικός κανόνας για β.ε.

Το  $SS_{\text{tot}}$  έχει β.ε.: πλήθος παρατηρήσεων - 1  
(μέγεθος δείγματος) - 1

Το  $SS_{\text{reg}}$  έχει β.ε.: όσο πλήθος ανεξαρτητών μεταβλητών (για την περίπτωση μας μόνο η  $X$ ).

Το  $SS_{\text{res}}$  έχει β.ε. την διαφορά

Συντελεστής Προσδιορισμού ή προσαρμοστικότητα

$$R^2 \stackrel{\text{def}}{=} \frac{SS_{\text{reg}}}{SS_{\text{tot}}} = 1 - \frac{SS_{\text{res}}}{SS_{\text{tot}}} \quad \text{από τη σχέση } SS_{\text{reg}} + SS_{\text{res}} = SS_{\text{tot}}.$$

και οι 2 ιδιότητες είναι οι εξής:

- 1) ο  $R^2$  είναι καθαρός αριθμός
  - 2)  $0 \leq R^2 \leq 1$  και άρα εκφράζεται ως ποσοστό!
- Ενδιαφέρουν παρουσιάζουν οι τιμές 0 και 1.

- ▶ Τιμή του  $R^2$  κοντά στο 1: δηλαδή θα πρέπει  $SS_{\text{reg}} \approx SS_{\text{tot}}$  δηλ.  $SS_{\text{reg}} \gg SS_{\text{res}}$   
υποσχόμενο μοντέλο
- ▶ Τιμή του  $R^2$  κοντά στο 0: δηλαδή θα πρέπει  $SS_{\text{reg}} \ll SS_{\text{res}}$  μη υποσχόμενο  
(κακό) μοντέλο

Μια ερμηνεία για το  $R^2$ : εκφράζει το ποσοστό της ολικής μεταβλητότητας των  $Y_1, \dots, Y_n$  που ερμηνεύονται από το μοντέλο μας.

## Επανάληψη

α.χ.π.  $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$   $i=1, \dots, n$   
↑ παράμετροι

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}, \quad \hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$$

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i, \quad i=1, \dots, n, \quad \varepsilon_i = Y_i - \hat{Y}_i$$

ΑΝΑΛΙΑ:  $SS_{tot} = SS_{reg} + SS_{res}$

Αν  $SS_{res} \ll SS_{reg} \rightarrow$  καταλληλότητα μοντέλου.

$$R^2 = \frac{SS_{reg}}{SS_{tot}} = 1 - \frac{SS_{res}}{SS_{tot}}$$

$$0 \leq R^2 \leq 1$$

↓ φτωχό μοντέλο      ↓ κατάλληλο μοντέλο

ΥΠΟΘΕΣΕΙΣ ΣΤΑ ΣΦΑΛΜΑΤΑ ΤΟΥ ΜΟΝΤΕΛΟΥ Α.Γ.Π.

Υποθέσεις σφάλματα: (Μοντέλο α.χ.π.  $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, i=1, \dots, n$ )

1)  $E(\varepsilon_i) = 0, i=1, \dots, n$

2)  $Var(\varepsilon_i) = \sigma^2, i=1, \dots, n$ , τα σφάλματα έχουν κοινή διακύμανση

3) Τα  $\varepsilon_i$  ασυσχέτητα ανά δύο:  $Cov(\varepsilon_i, \varepsilon_j) = 0 \quad \forall i, j=1, \dots, n, i \neq j$

4)  $\varepsilon_i \sim N(0, \sigma^2), i=1, \dots, n$

Συνέπειες στα  $Y_i$  ( $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$ ):

1)  $E(Y_i) = \beta_0 + \beta_1 X_i, i=1, \dots, n$

2)  $Var(Y_i) = \sigma^2, i=1, \dots, n$

3)  $Cov(Y_i, Y_j) = 0, i, j=1, \dots, n, i \neq j$  (γραμμικές συναρτήσεις ασυσχέτων είναι ασυσχέτες)

4)  $Y_i \sim N(\beta_0 + \beta_1 X_i, \sigma^2), i=1, \dots, n$



**ΘΕΩΡΗΜΑ:** Αν οι υποθέσεις για τα σφάλματα ικανοποιούνται τότε ισχύουν τα εξής:

$$\alpha) \hat{\beta}_1 \sim N\left(\beta_1, \frac{\sigma^2}{\sum (x_i - \bar{x})^2}\right) \quad \text{Var}(\hat{\beta}_1)$$

$$\beta) \hat{\beta}_0 \sim N\left(\beta_0, \frac{\sum x_i^2}{n \sum (x_i - \bar{x})^2} \sigma^2 = \sigma^2 \left\{ \frac{1}{n} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2} \right\}\right) \quad \text{Var}(\hat{\beta}_0)$$

**ΠΑΡΑΤΗΡΗΣΗ:**  $\hat{\beta}_0, \hat{\beta}_1$  είναι αμερόληπτοι των  $\beta_0, \beta_1$ , δηλ. των παραμέτρων που επιτιμούν.

**ΑΠΟΔΕΙΞΗ:**

$$\alpha) \hat{\beta}_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} = \sum_{i=1}^n \frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} y_i$$

Το  $\hat{\beta}_1$  είναι γραμμικός συνδυασμός των ανεξάρτητων  $y_i$

$y_i$  ασυσχέπτα  $y_i \sim N$

Ισχύει: Αν  $w_1, w_2, \dots, w_m$  είναι κανονικές τ.μ. τότε  $\sum_{i=1}^m a_i w_i \sim N\left(\sum_{i=1}^m a_i E(w_i), \dots\right)$

$$\text{Var}(\sum a_i w_i) = \sum a_i^2 \text{Var}(w_i) + \sum_{i=1}^m \sum_{j=1, j \neq i}^m a_i a_j \text{Cov}(w_i, w_j)$$

Άρα,  $\hat{\beta}_1 \sim \text{Normal}$

$$E(\hat{\beta}_1) = E\left[\sum_{i=1}^n \frac{(x_i - \bar{x}) y_i}{\sum_{i=1}^n (x_i - \bar{x})^2}\right] = \sum_{i=1}^n \frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} E(y_i) =$$

$$= \sum_{i=1}^n \frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} E(\beta_0 + \beta_1 x_i + \epsilon_i) = \sum_{i=1}^n \frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} (\beta_0 + \beta_1 x_i + E(\epsilon_i)) =$$

$$= \beta_0 \sum_{i=1}^n \frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} + \beta_1 \sum_{i=1}^n \frac{(x_i - \bar{x}) x_i}{\sum (x_i - \bar{x})^2} =$$

$$= \beta_1 \frac{\sum (x_i^2 - \bar{x} x_i)}{\sum (x_i^2 - 2\bar{x} x_i + \bar{x}^2)} = \beta_1 \frac{\sum x_i^2 - \bar{x} \sum x_i}{\sum x_i^2 - 2\bar{x} \sum x_i + n\bar{x}^2} = \beta_1 \frac{\sum x_i^2 - n\bar{x}^2}{\sum x_i^2 - 2n\bar{x}^2 + n\bar{x}^2} =$$

$$= \beta_1 \frac{\sum x_i^2 - n\bar{x}^2}{\sum x_i^2 - n\bar{x}^2} = \beta_1.$$

**ΠΟΡΙΣΜΑ:** Αν  $w_i$  ασυσχέπτες ( $\text{Cov}(w_i, w_j) = 0, i \neq j$ ) τότε:

$$\sum_{i=1}^m a_i w_i \sim N\left(\sum_{i=1}^m a_i E(w_i), \text{Var}\left(\sum_{i=1}^m a_i w_i\right) = \sum_{i=1}^m a_i^2 \text{Var}(w_i)\right)$$

$$\text{Var}(\hat{\beta}_1) = \text{Var} \left[ \sum_{i=1}^n \frac{X_i - \bar{X}}{\sum (X_i - \bar{X})^2} Y_i \right]$$

Αν  $W_1, \dots, W_n$  τ.μ. τότε:  $\text{Var}(\sum_{i=1}^n a_i W_i) = \sum_{i=1}^n a_i^2 \text{Var}(W_i) + \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n a_i a_j \text{Cov}(W_i, W_j)$

Αν  $W_1, \dots, W_n$  ασυσχετίστες τότε:  $\text{Var}(\sum_{i=1}^n a_i W_i) = \sum_{i=1}^n a_i^2 \text{Var} W_i$

Επομένως: 
$$\begin{aligned} \text{Var}(\hat{\beta}_1) &= \sum_{i=1}^n \left( \frac{X_i - \bar{X}}{\sum (X_i - \bar{X})^2} \right)^2 \text{Var}(Y_i) = \sigma^2 \cdot \sum_{i=1}^n \frac{(X_i - \bar{X})^2}{[\sum (X_i - \bar{X})^2]^2} = \\ &= \sigma^2 \frac{\sum (X_i - \bar{X})^2}{[\sum (X_i - \bar{X})^2]^2} = \frac{\sigma^2}{\sum (X_i - \bar{X})^2} \end{aligned}$$

**ΠΑΡΑΤΗΡΗΣΗ:** Το  $\sigma^2$  άγνωστο. Άρα, για να αξιοποιηθούν οι κατανομές αυτές το  $\sigma^2$  πρέπει να επιμηθεί.

**ΘΕΩΡΗΜΑ:** Από τις υποθέσεις για τα σφάλματα  $E(MS_{res}) = \sigma^2$ , δηλ. ο ανερόληπτος επιμητής της  $\sigma^2$  είναι το  $MS_{res}$ . (χωρίς απόδειξη)

**ΠΑΡΑΤΗΡΗΣΗ:** Το  $\hat{\sigma}^2 = MS_{res}$  είναι ανερόληπτος επιμητής της  $\sigma^2$

**ΘΕΩΡΗΜΑ:** Υπό τις υποθέσεις για τα σφάλματα,  $\frac{SS_{res}}{\sigma^2} \sim \chi_{n-2}^2$ .

**ΑΠΟΔΕΙΞΗ:**

Αν  $W_1, \dots, W_n \sim N(\mu, \sigma^2)$  τότε:  $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$ ,  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (W_i - \bar{W})^2$

Τα  $Y_i \sim N(\beta_0 + \beta_1 X_i, \sigma^2)$ ,  $i=1, \dots, n$

$\Rightarrow Y_i - (\beta_0 + \beta_1 X_i) \sim N(0, \sigma^2)$

$\Rightarrow \frac{Y_i - (\beta_0 + \beta_1 X_i)}{\sigma} \sim \chi_1^2$  (Τι κανονικές και ασυσχετίστες οι  $\chi_1^2$  ανεξάρτητες)

$\Rightarrow \sum_{i=1}^n \left[ \frac{Y_i - (\beta_0 + \beta_1 X_i)}{\sigma} \right]^2 \sim \sum_{i=1}^n \chi_1^2 \equiv \chi_{\sum_{i=1}^n 1}^2$

Άρα,  $\frac{\sum (Y_i - (\beta_0 + \beta_1 X_i))^2}{\sigma^2} \sim \chi_n^2$  (A)



$$S^2 S_{res} = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i))^2 \quad (B)$$

Από τις (A), (B)  $\Rightarrow \sum_{i=1}^n \frac{[Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i)]^2}{\sigma^2} \sim \chi_{n-2}^2$  (?)  
αντικαθιστώντας τα  $\beta_0, \beta_1$  με  $\hat{\beta}_0$  και  $\hat{\beta}_1$   
 $\Rightarrow \frac{S^2 S_{res}}{\sigma^2} \sim \chi_{n-2}^2$  είναι σαν να βάλω 2 δεσμούς άρα από  
n πάνω σε n-2

**ΘΕΩΡΗΜΑ:** Οι  $\hat{\beta}_0$  και  $\hat{\beta}_1$  είναι ανεξάρτητοι του  $M^2 S_{res}$  και άρα ανεξάρτητοι του  $S^2 S_{res}$ .  
(χωρίς απόδειξη) EET