

ΑΝΑΛΥΣΗ ΔΙΑΚΥΜΑΝΣΗΣ - ΑΠΛΗ ΠΑΛΙΝΔΡΟΜΗΣΗ

Πόσο καλά είναι η ερώδια ελαχίστων τετραγώνων ως εκτίμηση της ερώδειας

$$\hat{Y} = \hat{\theta}_0 + \hat{\theta}_1 X$$

$$E(Y|X) = \theta_0 + \theta_1 X$$

Από την προφανή σχέση

$$Y_i - \bar{Y} = Y_i - \hat{Y}_i + \hat{Y}_i - \bar{Y}$$

απόκλιση των Y_i από το \bar{Y}

μπορούμε να δείξουμε ότι

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$$

Ούτως ισχύει ότι:

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

$$\text{Οπως } \sum_{i=1}^n (Y_i - \hat{Y}_i) = \sum_{i=1}^n e_i = 0 \quad (\text{βλέπε ιδιότητες})$$

$$\text{Επίσης } \sum_{i=1}^n (Y_i - \hat{Y}_i)(\hat{\theta}_0 + \hat{\theta}_1 X_i) = \hat{\theta}_0 \sum_{i=1}^n (Y_i - \hat{Y}_i) + \hat{\theta}_1 \sum_{i=1}^n X_i (Y_i - \hat{Y}_i) =$$

$$= 0 \quad \text{λόγω κανονικών εξισώσεων.}$$

Επομένως το $\sum_{i=1}^n (Y_i - \bar{Y})^2$ που είναι το άθροισμα τετραγώνων των παρατηρήσεων Y_i από τη μέση τιμή και λέγεται

ΟΛΙΚΟ ΑΘΡΟΙΣΜΑ ΤΕΤΡΑΓΩΝΩΝ SS_{tot}

ισούται με το άθροισμα

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$$

Υπερθέσεων:

$$\sum Y_i = \sum \hat{Y}_i$$

↓
 άθροισμα τετραγώνων υπολοίπων

↓
 άθροισμα τετραγώνων προβλεπόμενων τιμών από τη μέση τιμή τους

Άρα $SS_{tot} = SS_{res} + SS_{reg}$

\downarrow \downarrow \downarrow
 ΟΛΙΚΗ ΥΠΟΛΟΙΠΑ ΠΑΛ/ΣΗ
 ΜΕΤΑ

Όσο μεγαλύτερο το SS_{reg} τόσο μεγαλύτερη η σχέση εξάρτησης.

Ένας τρόπος αξιολόγησης της παλινδρόμησης αποτελεί ο συντελεστής προσδιορισμού

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

(Προφανώς $0 \leq R^2 \leq 1$)

Δίνει το ποσοστό της μεταβλητότητας της Y που εξηγείται από την παλινδρόμηση. Ισχύει ότι

$$r_{xy}^2 = R^2 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2}$$

Θυμηθείτε ότι

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}}$$

Επομένως

$$r^2 = \frac{\left(\sum (x_i - \bar{x})(y_i - \bar{y}) \right)^2}{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}$$

Είναι $\sum (y_i - \bar{y})^2 = SS_{tot}$

$$\hat{\beta}_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \implies \sum (x_i - \bar{x})(y_i - \bar{y}) = \hat{\beta}_1 \sum (x_i - \bar{x})^2$$

Άρα $r^2 = \frac{\hat{\beta}_1^2 \sum (x_i - \bar{x})^2}{SS_{tot}} = \frac{SS_{reg}}{SS_{tot}}$

Όπως $SS_{reg} = \sum_{i=1}^n (\hat{\beta}_0 + \hat{\beta}_1 x_i - \bar{y})^2 \stackrel{\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}}{=} \sum_{i=1}^n (\bar{y} - \hat{\beta}_1 \bar{x} + \hat{\beta}_1 x_i - \bar{y})^2$

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

Σε κάθε άθροιση τετραγώνων αντίστοιχών ορισμένοι βαθμοί ελευθερίας που ισοδυναμούν με το πλήθος των ανεξάρτητων μεταβλητών των Y_i που απαιτούνται για τον υπολογισμό του εν λόγω άθροισματος.

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

ΕΔΩ ΑΠΑΙΤΟΥΝΤΑΙ $n-1$ το πλήθος γιατί ισχύει ότι $\sum (Y_i - \bar{Y}) = 0$

Άρα ο όρος $Y_n - \bar{Y} = -\sum_{i=1}^{n-1} (Y_i - \bar{Y})$ άρα στο SS_{tot} χρειάζονται

$n-1$ μεταβλητές Y_i .

$$SS_{reg} = \sum (\hat{Y}_i - \bar{Y})^2 = \hat{\beta}_1^2 \sum (x_i - \bar{x})^2$$

άρα έχει 1 β.ε αφού μπορεί να υπολογιστεί από μια μεταβλητή των Y_i , των $\hat{\beta}_1$

SS_{reg} προφανώς έχει $n-2$ β.ε καθώς

$$SS_{reg} = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

και πληροί τις κανονικές εξισώσεις

$$\sum (Y_i - \hat{Y}_i) = 0$$

$$\sum x_i (Y_i - \hat{Y}_i) = 0$$

Τα παραπάνω ακολουθούν στον ακόλουθο πίνακα ANADIA

Πρόταση ΜΕΤ/ΤΑΣ	Άθροιση τετρ.	β.ε.	Μέσα τετράγωνα
ΠΑΜΙΝΔΡΟΝΗΣΗ	SS_{reg}	1	$MS_{reg} = SS_{reg} / 1$
ΥΠΟΝΟΙΤΑ	SS_{rer}	$n-2$	$MS_{rer} = SS_{rer} / n-2$
ΟΝΧΗ	SS_{tot}	$n-1$	

Αποδεικνύεται (Μαθημα Τῶν εἰσακρίσεων) SS_{reg} και SS_{rer} ανεξάρτητες
ὅταν $H_0: \beta_1 = 0$ αληθινῶς
τότε $SS_{reg} | \sigma^2 \sim \chi^2_1$, $SS_{rer} | \sigma^2 \sim \chi^2_{n-2}$

Σηλασθῆν $F = \frac{MS_{reg}}{MS_{rer}} \stackrel{H_0}{\sim} F_{1, n-2}$

Ἄρα εἰδείχω τὴν $H_0: \beta_1 = 0$ με περίσῃ ἀπόρριψῆς
 $F \geq F_{\alpha, 1, n-2}$

Αποδεικνύεται ὅτι $E(MS_{rer}) = \sigma^2$
 $E(MS_{reg}) = \sigma^2 + \beta_1^2 \sum_{i=1}^n (x_i - \bar{x})^2$

- ΣΧΟΛΙΑΣΜΟΣ ΓΙΑ ΚΑΤΑΛΛΗΛΟΤΗΤΑ ΜΟΝΤΕΛΟΥ
- ΑΝΑΛΥΣΗ ΥΠΟΛΟΙΠΩΝ
- ΜΕΤΑΣΧΗΜΑΤΙΣΜΟΙ "ΓΡΑΜΜΙΚΟΠΟΙΗΣΗΣ"
- ΜΕΤΑΣΧΗΜΑΤΙΣΜΟΙ ΚΑΝΟΝΙΚΟΤΗΤΑΣ
- ΠΟΙΟΤΙΚΕΣ ΜΕΤΑΒΛΗΤΕΣ
- ΠΟΛΥΜΕΤΡΗ ΓΡ. ΠΑΛΙΝΔΡΟΜΗΣΗ