

Άσκηση (ΕΒΟ) (505)

Η ελληνική Βιομηχανία Όντων (ΕΒΟ) ανασχολεί μέρος του εργατικού δυναμικού της κατασκευαστικής κίνησης ενός τύπου όντων. Η ανασχολήση σε ώρες εργασίας ανά μήνα διαφέρει από μήνα σε μήνα ανάλογα με το μέγεθος της παραγγελίας που πρέπει να εκτελεσθούν. Στον παρακάτω πίνακα δίνονται οι παραγγελίες προς την ΕΒΟ των 10 τελευταίων μηνών μαζί με τις αντίστοιχες ώρες εργασίας που απαιτήθηκαν για την εκτέλεσή τους.

Μήνας Παραγγελίας (x_i)	Μέγεθος Παραγγελίας (x_i)	Ώρες Εργασίας (y_i)
1	30	73
2	20	50
3	60	128
4	80	170
5	40	87
6	50	108
7	60	135
8	30	69
9	70	148
10	60	132

i) Να κατασκευαστεί το διαγραμμά διασποράς και να σχεδιαστεί "με το χέρι" μια ευθεία που να δείχνει τη στατιστική σχέση μεταξύ μεγέθους παραγγελίας και ωρών εργασίας

ii) Να υπολογιστεί τας ευκλιμένες $\hat{\beta}_0$ και $\hat{\beta}_1$ των ελαχίστων τετραγώνων των παραμέτρων και των ευτιμώμενων σφαιρικών παλινδρομίων


iii) α. Χρησιμοποιώντας των ευτιμώμενων σφαιρικών παλινδρομίων ($\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$) να υπολογιστεί για κάθε μια από τις τιμές της ανεξάρτητης μεταβλητής, των ευτιμώμενων τιμών της εξαρτημένης μεταβλητής (\hat{y}_i)

β. Να υπολογιστούν τα υπόλοιπα (ή τις καταμέτρους αναλύσεις των παρατηρήσεων y_i από την ευθεία της

Επισημάνετε σφάλματα παλινδρόμησης). Τι παρατηρείτε για τα υπόλοιπα που υπολογίζατε;

- iv) α. Να ελεγχθεί η υπόθεση ότι $\beta_1 = 0$ με επίπεδο σημαντικότητας $\alpha = 0,05$.
 β. Να βρεθεί ένα 95% Διαστήμα εμπιστοσύνης για το β_1 .
 Υπάρχει κάποια σχέση μεταξύ των X και Y ;
 v) Να βρεθεί ένα 90% Διαστήμα εμπιστοσύνης για τη μέση τιμή του Y_0 όταν $X_0 = 55$
 vi) Να ελεγχθεί η υπόθεση $H_0: \rho = 0$ σε επίπεδο σημαντικότητας $\alpha = 0,01$, όπου ρ : ο συντελεστής συσχέτισης

ΛΥΣΗ



ii) Είχατε αποδείξει για τη συνάρτηση

$$Q(\beta_0, \beta_1) = \sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_i)^2$$

μέσω μερικών παραγώγων ότι

$$\frac{\partial Q}{\partial \beta_0} = -2 \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_i) \text{ και}$$

$$\frac{\partial Q}{\partial \beta_1} = -2 \sum_{i=1}^n X_i (Y_i - \beta_0 - \beta_1 X_i)$$

Διλαδή,
$$\begin{cases} \sum_{i=1}^n Y_i = n \hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i Y_i = \hat{\beta}_0 \sum_{i=1}^n X_i + \hat{\beta}_1 \sum_{i=1}^n X_i^2 \end{cases}$$

και επιπλέον το σύστημα βρισκόμαστε ότι:

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X} \text{ και } \hat{\beta}_1 = \frac{\sum (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sum (x_i - \bar{x})^2} = \frac{\sum x_i y_i - \frac{\sum x_i \sum y_i}{n}}{\sum x_i^2 - \frac{(\sum x_i)^2}{n}}$$

όπου $\hat{\beta}_0$ και $\hat{\beta}_1$ οι ζητούμενοι

επιπλέον ελάχιστων τετραγώνων (Οι τύποι μπορούν να χρησιμοποιηθούν δίχως την παραπάνω απόδειξη)

Με τη χρήση του ακόλουθου πίνακα και του δοσμένου πίνακα εξαρτημένων και ανεξαρτητών τυχαίων μεταβλητών έχουμε τους παρακάτω υπολογισμούς:

$Y_i \cdot X_i$	X_i^2
2180	300
1000	400
7680	3600
13600	6400
3480	1600
5400	2500
8100	3600
2070	900
10360	4900
7920	3600
ΣΥΝΟΛΟ 61800	28400

Συνεπώς, έχουμε:

$$\hat{\beta}_1 = \frac{61800 - \frac{500 \cdot 1100}{10}}{28400 - \frac{500^2}{10}} = 2.0$$

και

$$\hat{\beta}_0 = \frac{1100}{10} - 2.0 \frac{500}{10} = 10.0$$

Άρα, η επισημασμένη συνάρτηση παλινδρόμησης

είναι η εξής: $\hat{Y} = 2.0 \cdot X + 10.0$

(Παρατήρηση: $\hat{\beta}_1 = 2.0 > 0$ δηλ. ο συντελεστής

διευθύνσης της ευθείας είναι θετικός και άρα η ευθεία που σχετίζει τα X με τα Y θα έχει θετική κλίση όπως φαίνεται και στο ερώτημα (i))

(ii) α. Είναι: $\hat{Y} = 2.0 X_i + 10.0$

για καθένα από τα X_i του πίνακα (για $i=1, 2, \dots, 10$) παίρνουμε με αντικατάσταση των ευθείας τις αντίστοιχες τιμές των \hat{Y}_i

\hat{Y}_i	70	50	130	170	90	110	130	70	150	130	ΣΥΝΟΛΟ	1100
-------------	----	----	-----	-----	----	-----	-----	----	-----	-----	--------	-------------

β. Εξ ορισμού των υπολοίπων ορίζονται από τον τύπο

$$e_i = Y_i - \hat{Y}_i, \quad i=1, 2, \dots, 10$$

Έτσι, αντίστοιχα, $i=1, 2, \dots, 10$ παίρνουμε τα εξής:

e_i	3	0	-2	0	-3	-2	5	-1	-2	2
-------	---	---	----	---	----	----	---	----	----	---

Από που παρατηρούμε είναι ότι τα υπολοίπων (ή αποκλίσεις)

αν τα αθροίσουμε θα μας δώσουν αποτέλεσμα 0.

Δηλαδή $\sum_{i=1}^{n=10} e_i = 0$

iv) α. Από τη θεωρία γνωρίζουμε ότι

$$\hat{\beta}_1 \sim N\left(\beta_1, \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}\right)$$

Άρα,

$$B_1 = \frac{\hat{\beta}_1 - \beta_1}{S / \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} \underset{\text{Ανω.}}{\overset{H_0}{\sim}} t_{n-2} \quad (1)$$

Επίσης,

$$(\hat{\sigma}^2 =) S^2 = \frac{1}{10-2} \sum_{i=1}^{10} (y_i - 10.0 - 2.0x_i)^2 = \frac{60}{8} = 7.5 \Rightarrow S = \sqrt{7.5}$$

Ενώ,

$$\sum_{i=1}^n (x_i - \bar{x})^2 = 3400$$

Επομένως,

$$B_1 = \frac{2.0 - 0}{\sqrt{7.5} / \sqrt{3400}} = \frac{2.0}{0.0497} = 42.6$$

Επειτα,

$$t_{0.025, 8} = 2,306 \quad \leftarrow \text{(Από πίνακα Student)}$$

και λόγω ότι έχουμε αμειψίλευση κρίσιμης περιοχής

(δυνά $H_0: \beta_1 = 0$ v $H_1: \beta_1 \neq 0$) όπου $C_{\text{κρίση}} = (-\infty, -t_{\alpha/2, n-2}) \cup$
 $\cup (+t_{\alpha/2, n-2}, +\infty)$

Καθώς, $B_1 = 42,6 > t_{0,025, 8} = 2,306$.

(δυνά $B_1 \in C_{\text{κρίση}}$) σωστά H_0 απορρίπτεται

Άρα, σε επίπεδο σημαντικότητας $\alpha = 0,05$ το $\beta_1 \neq 0$

Παρατηρούμε: Υπάρχει θετική εφαρμογή του Y από το X

β. Με βάση τα παραπάνω ένα 95% Δ.Ε είναι το

$$\hat{\beta}_1 \pm t_{\alpha/2, n-2} \cdot \frac{S}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} \Rightarrow 2.0 \pm 2,306 \cdot \frac{\sqrt{7.5}}{\sqrt{3400}} \Rightarrow$$

$$\Rightarrow \text{Δ.Ε. } [1.89, 2.11]$$

v) Για συγκεκριμένες τιμές τυρά ($n \times X_0 = 55$) η διαδικασία που εφευρέσαμε είναι παρόμοια με την διαδικασία του βρωμίματος (Y_i).

Γνωστό από θεωρία:

$$E(\hat{Y}_0) = E(\hat{\beta}_0 + \hat{\beta}_1 X_0) = \hat{\beta}_0 + \hat{\beta}_1 X_0$$

και

$$\text{Var}(\hat{Y}_0) = \hat{\sigma}^2 \left(\frac{1}{n} + \frac{(X_0 - \bar{X})^2}{\sum (X_i - \bar{X})^2} \right)$$

Ενώ, ως προς:

$$\frac{\hat{Y}_0 - E(\hat{Y}_0)}{\sqrt{\widehat{\text{Var}}(\hat{Y}_0)}} \sim t_{n-2} \quad \text{και} \quad \Delta.Ε \quad \hat{Y}_0 \pm t_{\alpha/2, n-2} \sqrt{\widehat{\text{Var}}(\hat{Y}_0)}$$

Συνεπώς, συγκεκριμένα στην άσκηση μας έχουμε:

$$\hat{Y}_0 = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_0 = 10.0 + 2.0 \cdot 55 = 120$$

$$\text{και} \quad t_{\alpha/2, n-2} = t_{0.05, 8} = 1.860$$

Ενώ,

$$\widehat{\text{Var}}(\hat{Y}_0) = 7.5 \left(\frac{1}{10} + \frac{(55-50)^2}{3400} \right) = 0.80515$$

και άρα, ένα 90% Δ.Ε είναι το ακόλουθο

$$120 \pm 1.860 \cdot \sqrt{0.80515} \Rightarrow \Delta.Ε \quad \text{το} \quad [118.3, 121.7]$$

vi) Από τη θεωρία μας έχουμε:

$$r(x, y) = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} = \frac{6800}{\sqrt{3400 \cdot 13660}} = 0.9978$$

$$t = \frac{r \sqrt{n-2}}{\sqrt{1-r^2}} \stackrel{\#0}{\sim} t_{n-2} \quad (\text{με } H_0: \rho=0 \vee H_a: \rho \neq 0)$$

$$t = \frac{0.9978 \sqrt{8}}{\sqrt{1-0.9956}} = 42.6, \quad \text{Άρα} \quad t=42.6 > t_{0.005, 8} = 3.355$$

η $H_0: \rho=0$ απορρίπτεται για $\alpha=0.01$

β' τρόπος για το ερώτημα (iv) α.

Μέσω του πίνακα ANOVA (ANOVA).

Προβλεπόμενη μεταβλητότητα	B.E	SS	MS
Παλινδρόμηση	1	13600	13600
Υπολοίποι (ή απόκλιση)	8	60	7.5
ολική μεταβλητότητα	9	13660	

Στατιστική σωρότητα:

$$F = \frac{MS_{reg}}{MS_{res}} = \frac{SS_{reg}/1}{SS_{res}/n-2} = \frac{13600}{7.5} = 1813,3 \quad \left. \vphantom{F} \right\} F > F_{0,05,1,8} \Rightarrow$$

σε επίπεδο σφάλματος $\alpha = 0,05$

το $F_{0,05,1,8} = 5,32$

$\Rightarrow H_0: \beta_1 = 0$ απορρίπτεται όπως δείξαμε και μέσω του t -test

(Επίσης $R^2 = \frac{13600}{13660} = 0,9956$ ← Συντελεστής προσδιορισμού

Δηλ. το 99,56% (ποσοστό) της μεταβλητότητας του Y οφείλεται στην παλινδρόμηση).