

# ΣΤΑΤΙΣΤΙΚΗ ΚΑΙ ΘΕΩΡΙΑ ΑΠΟΦΑΣΕΩΝ

ΔΙΑΛΕΞΗ: ΠΑΛΙΝΔΡΟΜΗΣΗ

Διδάσκουσα: Ε. Γάκη, Επίκ. Καθηγήτρια



# Περιεχόμενα Ενότητας

- Ανάλυση Παλινδρόμησης
- Εκτίμηση Ευθείας παλινδρόμησης
- Εκτίμηση των συντελεστών της ευθείας παλινδρόμησης
- Στατιστική Συμπερασματολογία στην ανάλυση παλινδρόμησης
  - Διαστήματα Εμπιστοσύνης
  - Έλεγχοι Υποθέσεων
  - Συντελεστής Προσδιορισμού
- Πολλαπλή Παλινδρόμηση
- Μη γραμμικά μοντέλα

# Περιεχόμενα Μαθήματος

- Ανάλυση Παλινδρόμησης
- Εκτίμηση Ευθείας παλινδρόμησης
- Εκτίμηση των συντελεστών της ευθείας παλινδρόμησης
- Στατιστική Συμπερασματολογία στην ανάλυση παλινδρόμησης
  - Διαστήματα Εμπιστοσύνης
  - Έλεγχοι Υποθέσεων

# Στοχαστικό ή Ντετερμινιστικό Μοντέλο?

Έστω

$$Y = \alpha + \beta X$$

αν  $X$  το εισόδημα &  
 $Y$  οι δαπάνες κατανάλωσης

Ντετερμινιστικό μοντέλο

Αυτό σημαίνει ότι όλοι όσοι έχουν το ίδιο εισόδημα καταναλώνουν το ίδιο ποσό.

**ΙΣΧΥΕΙ??**

**ΌΧΙ.**

Γι αυτό στην πράξη θα πρέπει να χρησιμοποιούνται μοντέλα που να περικλύουν το στοιχείο της **τυχειότητας**, πράγμα το οποίο επιτυγχάνεται με την προσθήκη μιας τυχαίας μεταβλητής  $\varepsilon$ .

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

Το μοντέλο αυτό ονομάζεται **στοχαστικό** ή **μοντέλο πιθανότητας** (stochastic model or probabilistic model).

# Ανάλυση Παλινδρόμησης

- Η ανάλυση παλινδρόμησης ( regression analysis) έχει ως αντικειμενικό σκοπό την πρόβλεψη.
- Στόχος είναι η επιλογή κατάλληλου στοχαστικού μοντέλου το οποίο θα χρησιμοποιηθεί για την πρόβλεψη των τιμών μιας εξαρτημένης μεταβλητής (dependent random variable)  $Y$  από τις τιμές μιας τουλάχιστον ανεξάρτητης τυχαίας μεταβλητής (Independent random variable)  $X$ .
- Αν η τυχαία μεταβλητή  $Y$  είναι γραμμική συνάρτηση των παραμέτρων του μοντέλου τότε μιλάμε για ένα γραμμικό μοντέλο (linear model).
- Αν η  $Y$  εξαρτάται από μία μόνο ανεξάρτητη τυχαία μεταβλητή  $X$  έχουμε το μοντέλο της απλής γραμμικής παλινδρόμησης (simple linear regression model):

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

- Αν η  $Y$  εξαρτάται από περισσότερες τυχαίες μεταβλητές  $X_1, X_2, \dots, X_K$  έχουμε το μοντέλο της πολλαπλής παλινδρόμησης (multiple regression model).

$$Y = \alpha + \beta_1 X_1 + \dots + \beta_K X_K + \varepsilon$$

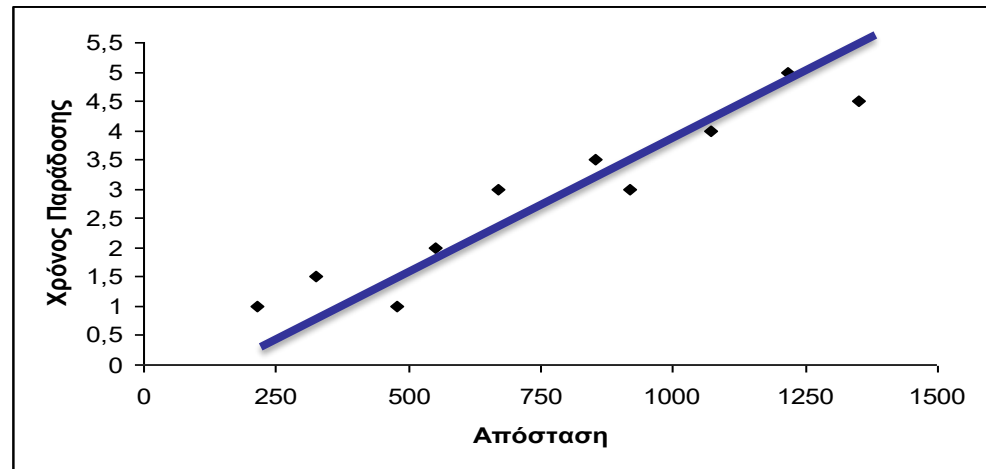
# Διάγραμμα Διασποράς

Σε μια μελέτη σχετική με τη γονιμότητα, επιλέγεται τυχαίο δείγμα 10 νιόπαντρων ζευγαριών και ρωτούνται για τον αριθμό των παιδιών που θα ήθελαν να αποκτήσουν (επιθυμητός αριθμός παιδιών  $X$ ). Είκοσι χρόνια αργότερα και τα 10 αυτά ζευγάρια ρωτήθηκαν για τον αριθμό των παιδιών που τελικά απέκτησαν (πραγματικός αριθμός παιδιών  $Y$ ). Τα αποτελέσματα της έρευνας συγκεντρώθηκαν στον παρακάτω πίνακα.

Επιθυμητός αριθμός παιδιών ( $X$ )	0	1	2	1	0	3	4	2	2	1
Πραγματικός Αριθμός παιδιών ( $Y$ )	0	2	1	3	1	3	4	2	1	2

Ο ερευνητής ενδιαφέρεται να εξετάσει αν ο αριθμός των παιδιών που κάθε ζευγάρι τελικά απέκτησε ( $Y$ ) μπορεί να ερμηνευτεί από τον αριθμό των παιδιών που τα ζευγάρια έλεγαν ότι θα επιθυμούσαν να αποκτήσουν κατά το χρόνο του γάμου τους ( $X$ ).

Το πρώτο βήμα στη μελέτη τέτοιων προβλημάτων είναι η κατασκευή του **διαγράμματος διασποράς** (scatter diagram). Απεικονίζουμε δηλαδή σε σύστημα καρτεσιανών συντεταγμένων το τυχαίο δείγμα των παρατηρήσεων  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ . Το διάγραμμα διασποράς που προκύπτει μας δίνει χρήσιμες πληροφορίες για τη μορφή του στοχαστικού μοντέλου το οποίο πρέπει να ελέγξουμε



# Εκτίμηση της ευθείας της Παλινδρόμησης

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



τυχαίο λάθος

Από τη σχέση προκύπτει ότι η τιμή  $y_i$  της  $Y$  που παρατηρούμε για μια συγκεκριμένη τιμή  $x_i$  της  $X$  είναι μια τυχαία τιμή από τον πληθυσμό των τιμών της τυχαίας μεταβλητής  $Y$  και αντιστοιχούν στο συγκεκριμένο  $x_i$ .

( $Y$  τυχαία μεταβλητή,  $x_i$ ,  $y_i$  τιμές CLEAR???)

Τι συμβαίνει με τα σφάλματα??

Για το τυχαίο σφάλμα  $\varepsilon_i$  υποθέτουμε ότι είναι τυχαία μεταβλητή με τη μέση τιμή μηδέν

$$E(\varepsilon_i) = 0$$

Κατά συνέπεια η τυχαία μεταβλητή  $Y$  ακολουθεί μία κατανομή για την οποία ισχύει:


**ΠΡΟΣΟΧΗ:** Η μέση τιμή της τυχαίας μεταβλητής  $Y$  συνδέεται γραμμικά με το  $x_i$  για κάθε συγκεκριμένο  $x_i$ .

$$E[Y_i / X_i] = E[\alpha + \beta x_i + \varepsilon_i] = \alpha + \beta E(x_i) + E(\varepsilon_i) = \alpha + \beta E(x_i)$$

# Εκτίμηση της ευθείας της Παλινδρόμησης

$$E[Y_i/X_i] = \alpha + \beta x_i$$

Η παραπάνω σχέση ονομάζεται **ευθεία παλινδρόμησης** (regression line) και οι **συντελεστές  $\alpha$  και  $\beta$**  ονομάζονται **συντελεστές γραμμικής παλινδρόμησης** (linear regression coefficients).



Από το διάγραμμα φαίνεται ότι

- ✓ το  $\alpha$  είναι το σημείο στο οποίο η ευθεία παλινδρόμησης τέμνει τον άξονα των  $y$ , είναι δηλαδή η τιμή της  $Y$  που αντιστοιχεί στο  $x = 0$
- ✓ το  $\beta$  είναι η κλίση της ευθείας παλινδρόμησης και εκφράζει την αύξηση (μείωση) της  $Y$  που αντιστοιχεί σε αύξηση της  $X$  κατά μία μονάδα.

*Σημείωση: οι συντελεστές του μοντέλου είναι οι συντελεστές παλινδρόμησης στον πληθυσμό. Συνήθως έχουμε δείγμα. **Τι κάνουμε???***



# Εκτίμηση των συντελεστών της Παλινδρόμησης

## Θυμάστε τις εκτιμήτριες?? (Lecture 6: Estimation)

1. Θα προσδιορίσουμε τις **εκτιμήτριες**  $\hat{\alpha}, \hat{\beta}$  για τους συντελεστές  $\alpha$  και  $\beta$
2. Σε κάθε συγκεκριμένο δείγμα θα χρησιμοποιήσουμε τις [παραπάνω εκτιμήτριες και θα υπολογίσουμε τις **σημειακές εκτιμήσεις** τις οποίες συμβολίζουμε με  $a$  και  $b$ .

ΕΤΣΙ αν συμβολίσουμε με

- $\hat{Y}$  την εκτιμήτρια της  $E(Y_i/x_i)$  και
- $\hat{y}_i$  μια εκτίμηση της

θα οδηγηθούμε σε μία σημειακή εκτίμηση της ευθείας παλινδρόμησης

η οποία είναι

$$\hat{Y} = \hat{\alpha} + \hat{\beta}x$$

$$\hat{y} = a + bx$$

και

$$E[Y_i/X_i] = \alpha + \beta x_i$$

Για να υπολογίσουμε τα  $a$  και  $b$  θα χρησιμοποιήσουμε τη Μέθοδο Ελαχίστων Τετραγώνων (Lecture 6)

# Εκτίμηση των συντελεστών της Παλινδρόμησης

Σύμφωνα με τη μέθοδο των ελαχίστων τετραγώνων διαλέγουμε τα  $\alpha$  και  $\beta$  έτσι ώστε να ελαχιστοποιείται η παράσταση

$$Q = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - (\alpha + \beta X_i))^2$$

Τα αποτελέσματα που προκύπτουν μας δίνουν

$$\hat{\alpha} = \frac{(\sum x_i^2)(\sum Y_i) - (\sum x_i)(\sum x_i Y_i)}{n(\sum x_i^2) - (\sum x_i)^2} \quad \text{και} \quad \hat{\beta} = \frac{n(\sum x_i Y_i) - (\sum x_i)(\sum Y_i)}{n(\sum x_i^2) - (\sum x_i)^2}$$

Χρησιμοποιώντας τους τελευταίους τύπους παίρνω τις εκτιμήσεις για  $a$  και  $b$

$$a = \frac{(\sum x_i^2)(\sum y_i) - (\sum x_i)(\sum x_i y_i)}{n(\sum x_i^2) - (\sum x_i)^2} \quad b = \frac{n(\sum x_i y_i) - (\sum x_i)(\sum y_i)}{n(\sum x_i^2) - (\sum x_i)^2}$$

# Πως προσδιορίζω τους συντελεστές στην πράξη?

Από τις τελευταίες 2 σχέσεις με μαθηματικούς μετασχηματισμούς προκύπτει

$$a = \bar{y} - b\bar{x} \quad \text{όπου} \quad b = \frac{\sum_i (X_i - \bar{x})(Y_i - \bar{y})}{\sum_i (X_i - \bar{x})^2}$$

και

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n Y_i \quad \text{και} \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n X_i$$

Στην πράξη χρησιμοποιώ τους εξής συμβολισμούς

$$S_{xx} = \sum_i (x_i - \bar{X})^2 = \sum_i x_i^2 - \frac{(\sum x_i)^2}{n}$$

ΟΠΟΤΕ έχουμε

$$a = \bar{Y} - \frac{S_{xy}}{S_{xx}} \bar{X}$$

$$S_{yy} = \sum_i (y_i - \bar{Y})^2 = \sum_i y_i^2 - \frac{(\sum y_i)^2}{n}$$

$$b = \frac{S_{xy}}{S_{xx}}$$

$$S_{xy} = \sum_i (x_i - \bar{X})(y_i - \bar{Y}) = \sum_i (x_i - \bar{X})y_i$$


# Γραφικά για να δούμε τι συμβαίνει.....

Είναι φανερό ότι οι υπολογιζόμενες  $\hat{y}_i$  τιμές δεν είναι όλες ίσες με τις πραγματικές τιμές  $y_i$

Η διαφορά μεταξύ των πραγματικών τιμών  $y_i$  και των υπολογιζόμενων  $\hat{y}_i$

$$e_i = y_i - \hat{y}_i$$

ονομάζεται **κατάλοιπο** (residual) και μπορεί να θεωρηθεί ως εκτίμηση της άγνωστης τιμής του διαταρακτικού όρου  $\varepsilon_i$



# Στατιστική Συμπερασματολογία στην Ανάλυση Παλινδρόμησης

# Ας ασχοληθούμε με τον διαταρακτικό όρο

Το μοντέλο της ευθείας παλινδρόμησης είναι  $Y_i = \alpha + \beta X_i + \varepsilon_i$

- ✓ όλα τα  $\varepsilon_i$  ακολουθούν **κανονική κατανομή** με μέση τιμή μηδέν και την ίδια διακύμανση έστω  $\sigma^2$ . Δηλαδή  $\varepsilon_i \sim N(0, \sigma^2)$  για όλα τα  $i=1, 2, \dots$
- ✓ Τα  $\varepsilon_i$  είναι **ανεξάρτητα** μεταξύ τους.
- ✓ Τα  $x_i$  είναι **προκαθορισμένα**

ΤΙ ΣΗΜΑΙΝΟΥΝ ΑΥΤΑ???

✓ ότι η διακύμανση της τυχαίας μεταβλητής  $\varepsilon_i$  **είναι σταθερή** για όλες τις τιμές του  $x$ . Στην περίπτωση που η διακύμανση παραμένει σταθερή, ο διαταρακτικός όρος είναι **ομοσκεδαστικός** (homoskedastic)

*Αν η διακύμανση δεν είναι σταθερή, ο διαταρακτικός όρος είναι **ετεροσκεδαστικός** (heteroskedastic)*

✓ ότι οι διαταρακτικοί όροι είναι **ασυσχέτιστοι** μεταξύ τους.

$$\text{Cov}(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i, \varepsilon_j) - E(\varepsilon_i)E(\varepsilon_j) = 0 \quad \text{για } i \neq j$$

Οι βασικές ιδιότητες του μοντέλου της απλής γραμμικής παλινδρόμησης είναι:

**κανονικότητα, ομοσκεδαστικότητα και ανεξαρτησία λαθών.**

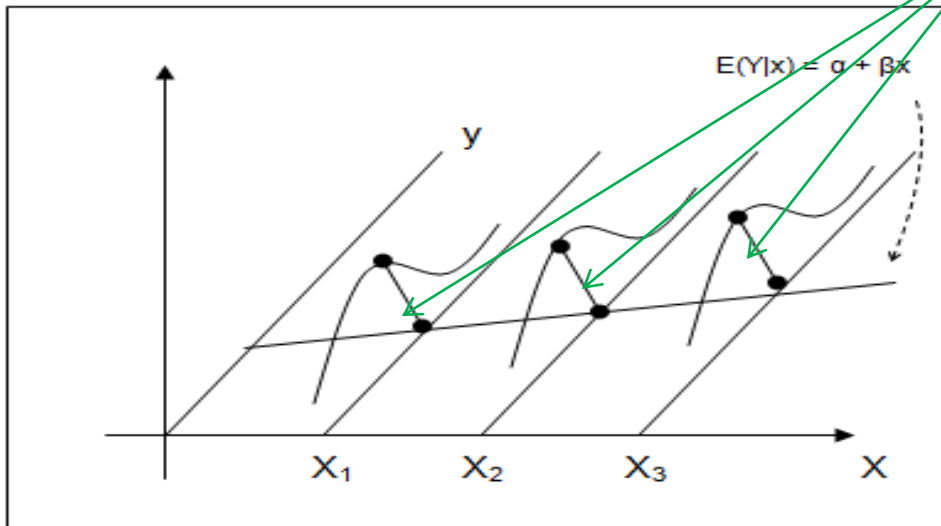
# Ομοσκεδαστικότητα, Κανονικότητα

Οπότε

i. Τα  $Y_i$  είναι  $N(a + \beta x_i, \sigma^2)$ ,  $i=1,2,\dots$

ii. Τα  $Y_i$  είναι ανεξάρτητα μεταξύ τους και επίσης

iii. Τα  $x_i$  είναι προκαθορισμένα.



Λόγω της υπόθεσης **της κανονικότητας**, οι τιμές της  $Y$  ακολουθούν την κανονική κατανομή για κάθε τιμή του  $x$

Λόγω της υπόθεσης της **ομοσκεδαστικότητας** η μεταβλητότητα γύρω από την ευθεία παλινδρόμησης είναι σταθερή για όλες τις τιμές του  $x$ .

Ο τρίτος άξονα αναφέρεται στην συνάρτηση πυκνότητας του διαταρακτικού όρου

# Εκτίμηση της Διακύμανσης των Τυχαίων Σφαλμάτων

- Με τη μέθοδο των ελαχίστων τετραγώνων οδηγούμεθα σε μία ευθεία η οποία προσαρμόζεται στα δεδομένα έτσι ώστε **το άθροισμα των τετραγώνων των καταλοίπων να ελαχιστοποιείται** και η οποία χρησιμεύει για να εκτιμήσουμε μια τιμή της  $Y$  για συγκεκριμένο  $x$ .
- Κατά συνέπεια χρειαζόμαστε ένα **μέτρο** για τη μεταβλητότητα που υπάρχει μεταξύ της παρατηρούμενης τιμής της  $Y$  και της αντίστοιχης υπολογιζόμενης τιμής μέσω του μοντέλου που έχουμε εκτιμήσει.
- Άρα χρειαζόμαστε την ποσότητα  $\sigma^2$  τη διακύμανση δηλαδή των τυχαίων σφαλμάτων.
- Η τιμή όμως της διακύμανσης  $\sigma^2$  σπανίως είναι γνωστή. Πρέπει λοιπόν να την εκτιμήσουμε, είναι δε λογικό η εκτίμηση αυτή, που θα συμβολίσουμε με  $s^2_{Y/x}$  να βασίζεται στα κατάλοιπα  $e_i = y_i -$

$$\hat{\sigma}^2 \equiv S^2_{Y/x} = \frac{\sum (Y_i - \hat{Y}_i)^2}{n-2}$$

$\hat{Y}_i$

$$s^2_{Y/x} = \frac{1}{n-2} \left( S_{YY} - \frac{S^2_{xY}}{S_{xx}} \right)$$

Η τετραγωνική ρίζα της εκτίμησης  $s^2_{Y/x}$  ονομάζεται **τυπικό σφάλμα της εκτίμησης της  $Y$**



Διαστήματα Εμπιστοσύνης  
για τις παραμέτρους του μοντέλου της απλής γραμμικής  
παλινδρόμησης

# Διάστημα Εμπιστοσύνης για το $\beta$

Διάστημα εμπιστοσύνης για το  $\beta$

$$\text{Ισχύει } \hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{S_{xx}}\right)$$

$$\text{Αποδεικνύεται } \frac{\hat{\beta} - \beta}{S_{Y/x} / \sqrt{S_{xx}}} \sim t_{n-2}$$

Ένα  $100(1-\alpha)\%$  διάστημα εμπιστοσύνης για την κλίση  $\beta$  της ευθείας παλινδρόμησης είναι το

$$\left( \hat{\beta} - t_{n-2, 1-\alpha/2} S_{\hat{\beta}}, \hat{\beta} + t_{n-2, 1-\alpha/2} S_{\hat{\beta}} \right)$$

Όπου  $S_{\hat{\beta}} = S_{Y/x} / \sqrt{S_{xx}}$  είναι το τυπικό σφάλμα εκτίμησης της .

# Διάστημα Εμπιστοσύνης για το $\alpha$

Ισχύει  $\hat{\alpha} \sim N\left(\alpha, \sigma^2 \left(\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}\right)\right)$

Αποδεικνύεται  $\frac{\hat{\alpha} - \alpha}{S_{Y/x} \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}}} \sim t_{n-2}$

Ένα  $100(1-\alpha)\%$  διάστημα εμπιστοσύνης για το  $\alpha$  είναι το

$$\left( \hat{\alpha} - t_{n-2, 1-\alpha/2} S_{\hat{\alpha}}, \hat{\alpha} + t_{n-2, 1-\alpha/2} S_{\hat{\alpha}} \right)$$

Όπου  $S_{\hat{\alpha}} = S_{Y/x} \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}}$  είναι το τυπικό σφάλμα εκτίμησης της  $\hat{\alpha}$

# Διάστημα Εμπιστοσύνης για την $E(Y/X_t)$

Ισχύει  $\hat{Y}_t \square N(E(Y/X_t), \sigma^2 \left( \frac{1}{n} + \frac{(X_t - \bar{X})^2}{S_{XX}} \right))$

Αποδεικνύεται  $\frac{\hat{Y} - E(Y/X_t)}{s^2_{Y/X} \sqrt{\left\{ \frac{1}{n} + \frac{(X_t - \bar{X})^2}{S_{XX}} \right\}}} \square t_{n-2}$

Ένα  $100(1-\alpha)\%$  διάστημα εμπιστοσύνης για την  $E(Y/X_t)$

$$\left( \hat{Y} - t_{n-2, 1-\alpha/2} S_{\hat{Y}_t/X_t}, \hat{Y} + t_{n-2, 1-\alpha/2} S_{\hat{Y}_t/X_t} \right)$$

Όπου  $S_{\hat{Y}_t/X_t} = s_{Y/X_t} \sqrt{\left\{ \frac{1}{n} + \frac{(X_t - \bar{X})^2}{S_{XX}} \right\}}$

# Διάστημα Πρόβλεψης

$$\hat{Y}_k \pm t_{n-2, 1-\alpha/2} S_{\hat{Y}_k/X_k}$$

$$S_{\hat{Y}_k/X_k} = S_{Y/X} \sqrt{\left\{ 1 + \frac{1}{n} + \frac{(X_k - \bar{X})^2}{S_{XX}} \right\}}.$$


# Έλεγχοι Στατιστικών Υποθέσεων

# Έλεγχος Υπόθεσης για το $\beta$

$$H_0 : \beta = \beta_0$$

Ως στατιστική συνάρτηση ελέγχου έχουμε  $T_0 = \frac{\hat{\beta} - \beta_0}{S_{Y/X} / \sqrt{S_{XX}}} \sim t_{n-2}$

$$H_0 : \beta = \beta_0$$
$$H_1 : \beta > \beta_0$$




Δηλαδή,

Απόρριψε την  $H_0$  αν

$$t_0 > t_{n-2, 1-a}$$

$$H_0 : \beta = \beta_0$$
$$H_1 : \beta \neq \beta_0$$




Απόρριψε την  $H_0$  αν

$$t_0 > t_{n-2, 1-a/2}$$

ή

$$t_0 < -t_{n-2, 1-a/2}$$

$$H_0 : \beta = \beta_0$$
$$H_1 : \beta < \beta_0$$




Απόρριψε την  $H_0$  αν

$$t_0 < -t_{n-2, 1-a}$$

# Έλεγχος Υπόθεσης για το $\alpha$

$$H_0 : \alpha = \alpha_0$$


Ως στατιστική συνάρτηση ελέγχου έχουμε  $T_o = \frac{\hat{\alpha} - \alpha_0}{S_{Y/X} \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{S_{XX}}}} \sim t_{n-2}$



Δηλαδή,

Απόρριψε την  $H_0$  αν

$$t_o > t_{n-2, 1-\alpha}$$




Απόρριψε την  $H_0$  αν

$$t_o > t_{n-2, 1-\alpha/2}$$

ή

$$t_o < -t_{n-2, 1-\alpha/2}$$



Απόρριψε την  $H_0$  αν

$$t_o < -t_{n-2, 1-\alpha}$$



# Παράδειγμα

Ο Πίνακας περιέχει την βαθμολογία πέντε φοιτητών στα μαθήματα των Μαθηματικών (X) και της Στατιστικής (Y).

α. Να εκτιμηθεί η ευθεία γραμμικής παλινδρόμησης της Y πάνω στη X και να ερμηνευτούν οι συντελεστές της.

β. Να εκτιμηθεί το τυπικό σφάλμα της Y και να ερμηνευτεί.

γ. Να εκτιμηθεί ο βαθμός ενός φοιτητή στο μάθημα Στατιστικής όταν ο βαθμός του στα Μαθηματικά είναι 4.

δ. Να υπολογιστεί το 95% διάστημα πρόβλεψης του βαθμού της Στατιστικής όταν ο βαθμός των Μαθηματικών είναι 7.

*Σημείωση:* Δίνεται ότι το επίπεδο σημαντικότητας είναι  $\alpha=0.05$ .

Μαθηματικά (X)	Στατιστική (Y)
2	1
3	2
5	5
6	6
8	7

# Παράδειγμα

Με βάση τα δεδομένα της άσκησης δημιουργείται ο παρακάτω Πίνακας.

(1)	(2)	(3)	(4)	(5)	(6)
$X_i$	$Y_i$	$X_i^2$	$Y_i^2$	$(X_i - \bar{X})$	$(X_i - \bar{X})Y_i$
2	1	4	1	-2.8	-2.8
3	2	9	4	-1.8	-3.6
5	5	25	25	0.2	1.0
6	6	36	36	1.2	7.2
8	7	64	49	3.2	22.4
<b>ΣΥΝΟΛΑ</b>	<b>24</b>	<b>21</b>	<b>138</b>	<b>115</b>	<b>24,2</b>

# Παράδειγμα

Υπολογισμός βοηθητικών στοιχείων

$$\bar{X} = \frac{24}{5} = 4.8, \quad \bar{Y} = \frac{21}{5} = 4.2$$

$$S_{XX} = \sum X_i - \frac{\left(\sum X_i\right)^2}{n} = 138 - \frac{24^2}{5} = 22.8$$

$$S_{YY} = \sum Y_i - \frac{\left(\sum Y_i\right)^2}{n} = 115 - \frac{21^2}{5} = 26.8$$

$$S_{YX} = \sum (X_i - \bar{X})Y_i = 24.2$$

# Παράδειγμα

## α) Ευθεία Παλινδρόμησης

$$a = \bar{Y} - \frac{S_{XY}}{S_{XX}} \bar{X} = 4.2 - \frac{24.2}{22.8} 4.8 \Rightarrow a = -0.89$$

$$b = \frac{S_{XY}}{S_{XX}} = \frac{24.2}{22.8} \Rightarrow b = 1.06$$

Άρα η ευθεία παλινδρόμησης είναι:  $\hat{Y} = -0.89 + 1.06X$

## β) Τυπικό Σφάλμα της Y

$$S_{y/x}^2 = \frac{1}{n-2} \left( S_{yy} - \frac{S_{xy}^2}{S_{xx}} \right) = \frac{1}{5-2} \left( 26.8 - \frac{(24.2)^2}{22.8} \right) \Rightarrow S_{y/x}^2 \cong 0.4$$

$$\text{Άρα } S_{y/x} = \sqrt{S_{y/x}^2} = 0.6$$

# Παράδειγμα

## Γ. Εκτίμηση της τιμής του $y$

Η ευθεία παλινδρόμησης είναι:

$$\hat{Y}_i = -0.89 + 1.06 * x$$

Για  $x = 4$  έχουμε  $\hat{Y}_i = -0.89 + 1.06 * 4 \Rightarrow \hat{Y}_i = 3.35$

# Παράδειγμα

## Δ. Διάστημα πρόβλεψης της τιμής του $y$

Ο γενικός τύπος του διαστήματος πρόβλεψης είναι:

$$\hat{Y}_k \pm t_{n-2, 1-\alpha/2} S_{\hat{Y}_k/X_k} \quad (1)$$

Στη συγκεκριμένη περίπτωση

$$x_k = 7 \rightarrow \hat{Y}_k = -0.89 + 1.06 * 7 = 6.53$$

$$n = 5, \alpha = 0.05$$

$$t_{n-2, 1-\alpha/2} = t_{3, 0.975} = 3.1824$$

$$S_{\hat{Y}_k/X_k} = S_{Y/X} \sqrt{\frac{n+1}{n} + \frac{(X_k - \bar{X})^2}{S_{xx}}} = 0.06 \sqrt{\frac{6}{5} + \frac{4.84}{22.8}} = 0.72$$

Κατά συνέπεια το διάστημα πρόβλεψης είναι:  $6.5 \pm 3.1824 * 0.72$  δηλαδή  $6.53 \pm 2.29$  ή  $(4.24, 8.82)$