

# Στατιστική για Ηλεκτρολόγους Μηχανικούς ΣΥΣΧΕΤΙΣΗ ΚΑΙ ΠΑΛΙΝΔΡΟΜΗΣΗ

Δημήτρης Κουγιουμτζής

20 Μαΐου 2010

# Συσχέτιση

Δύο τ.μ.  $X$  και  $Y$  συσχετίζονται:

- Η μία επηρεάζει την άλλη
- Επηρεάζονται και οι δύο από κάποια άλλη

$\sigma_X^2, \sigma_Y^2$ : διασπορά

συνδιασπορά των  $X$  και  $Y$ :

$$\sigma_{XY} = \text{Cov}(X, Y) = E(XY) - E(X)E(Y),$$

**συντελεστής συσχέτισης  $\rho$**










$$\rho = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

## |διότητες του $\rho$

- $\rho \in [-1, 1]$
- $\rho = 1$ : *τέλεια θετική συσχέτιση*
- $\rho = -1$ : *τέλεια αρνητική συσχέτιση*
- $\rho$  'κοντά' στο  $-1$  ή  $1$  → *ισχυρή συσχέτιση*
- $\rho$  'κοντά' στο  $0$  → *οι τ.μ. είναι πρακτικά ασυσχέτιστες*
- $\rho$  δεν εξαρτάται από τη μονάδα μέτρησης των  $X$  και  $Y$
- $\rho$  είναι συμμετρικός ως προς τις  $X$  και  $Y$

# Διάγραμμα διασποράς

Δείγμα των  $X$  και  $Y$  κατά ζεύγη:  $(x_1, y_1), \dots, (x_n, y_n)$



# Σημειακή εκτίμηση του $\rho$

Εκτίμηση διασποράς

$$s_X^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right)$$

Εκτίμηση συνδιασποράς

$$s_{XY} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n-1} \left( \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \right)$$

Εκτίμηση του συντελεστή συσχέτισης

$$\rho = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} \rightarrow \hat{\rho} \equiv r = \frac{s_{XY}}{s_X s_Y}$$

$$r = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sqrt{(\sum_{i=1}^n x_i^2 - n\bar{x}^2)(\sum_{i=1}^n y_i^2 - n\bar{y}^2)}}$$

## Σημειακή εκτίμηση του $\rho$ (συνέχεια)

- Το  $r$  είναι η σημειακή εκτίμηση του  $\rho$  από το δείγμα και λέγεται **συντελεστής συσχέτισης Pearson**
- Μπορούν να υπολογιστούν παραμετρικά διαστήματα εμπιστοσύνης για το  $\rho$ .
- Μπορούν να γίνουν παραμετρικοί έλεγχοι υπόθεσης για κάποια τιμή του  $\rho$ .

Η πιο σημαντική υπόθεση είναι  $H_0: \rho = 0$ .

### Συντελεστής προσδιορισμού $r^2$ (ή σε ποσοστά $100r^2\%$ )


Δηλώνει το ποσοστό μεταβλητήτας που μπορούμε να ερμηνεύσουμε για τη μια τ.μ. όταν γνωρίζουμε την άλλη.

# Παράδειγμα

Θέλουμε να  
εκτιμήσουμε τη  
**συσχέτιση** της  
**αντίστασης** και του  
**χρόνου αποτυχίας**  
κάποιου  
υπερφορτωμένου  
αντιστάτη

Δείγμα 20 δοκιμών  
αντιστάσεων

A/A (i)	Αντίσταση $x_i$ (ohm)	Χρόνος αποτυχίας $y_i$ (min)
1	28	26
2	29	20
3	31	26
4	33	22
5	33	25
6	33	35
7	34	28
8	34	33
9	36	21
10	36	36
11	37	30
12	39	33
13	40	45
14	42	39
15	43	32
16	44	45
17	46	47
18	47	44
19	47	46
20	48	37



Τυπολογίζουμε

$$\bar{x} = 38 \quad \bar{y} = 33.5$$

$$\sum_{i=1}^{20} x_i^2 = 29634$$

$$\sum_{i=1}^{20} y_i^2 = 23910$$

$$\sum_{i=1}^{20} x_i y_i = 26305$$

$$r = \frac{26305 - 20 \cdot 38 \cdot 33.5}{\sqrt{(29634 - 20 \cdot 38^2) \cdot (23910 - 20 \cdot 33.5^2)}} = 0.804$$

Η αντίσταση και ο χρόνος αποτυχίας αντιστάτη έχουν γραμμική θετική συσχέτιση αλλά όχι ισχυρή.

Το ποσοστό μεταβλητότητας της αντίστασης που μπορούμε να εξηγήσουμε γνωρίζοντας τον χρόνο αποτυχίας αντιστάτη (και αντίστροφα) είναι 0.646.

# Απλή Γραμμική Παλινδρόμηση

**συσχέτιση:** γραμμική σχέση δύο τ.μ.  $X$  και  $Y$

**παλινδρόμηση:** εξάρτηση μιας τ.μ.  $Y$  από μια άλλη μεταβλητή  $X$

$Y$ : **εξαρτημένη μεταβλητή** (*τυχαία*)

$X$ : **ανεξαρτητή μεταβλητή** (*καθορισμένη*)

*Παράδειγμα:* διατμητική αντοχή αργίλου σε διάφορα βάθη  
 $X$  ?     $Y$  ? ;


Γενικά θέλουμε να βρούμε  $F_Y(y|X = x)$

Περιοριζόμαστε στη μέση τιμή  
και υποθέτουμε γραμμική εξάρτηση

$$E(Y|X = x) = \alpha + \beta x$$

**γραμμική παλινδρόμηση της  $Y$  στη  $X$**

Παρατηρήσεις  
 $(x_1, y_1), \dots, (x_n, y_n)$



$\alpha$ : σταθερός όρος

$\beta$ : συντελεστής του  $x$  (κλίση ευθείας)

Η τ.μ.  $y_i$  για κάποια τιμή  $x_i$  της  $X$  είναι

$$y_i = \alpha + \beta x_i + \epsilon_i$$

$\epsilon_i = y_i - E(Y|X=x_i)$  σφάλμα παλινδρόμησης

Πρόβλημα παλινδρόμησης:

Ποια είναι η 'καλύτερη' ευθεία;

Ποιες είναι οι 'καλύτερες' εκτιμήσεις των  $\alpha, \beta$ ;

# Συνθήκες απλής γραμμικής παλινδρόμησης

- Η  $X$  είναι **ελεγχόμενη** (καθορισμένη)
- Η εξάρτηση της  $Y$  από τη  $X$  είναι **γραμμική**
- $E(\epsilon_i) = 0$  και  $\text{Var}(\epsilon_i) = \sigma_\epsilon^2$  για κάθε  $x_i$

$$\begin{aligned}\text{Var}(y_i|X = x_i) &= \text{Var}(\alpha + \beta x_i + \epsilon_i) = \text{Var}(\epsilon_i) \\ &\Downarrow \\ \text{Var}(Y|X = x) &\equiv \sigma_{Y|X}^2 = \sigma_\epsilon^2 \equiv \sigma^2\end{aligned}$$

**ομοσκεδαστικότητα:** η διασπορά της  $Y$  δε μεταβάλλεται με τη  $X$

**ετεροσκεδαστικότητα:** η διασπορά της  $Y$  μεταβάλλεται με τη  $X$ .

Άγνωστοι (παράμετροι) παλινδρόμησης:  $\alpha, \beta, \sigma^2$

[Συνήθως υποθέτουμε  $Y|X = x \sim N(\alpha + \beta x, \sigma^2)$  ]

# Εκτίμηση των παραμέτρων της ευθείας παλινδρόμησης

**Μέθοδος ελαχίστων τετραγώνων:**

Το άθροισμα των τετραγώνων των κατακόρυφων αποστάσεων των σημείων από την ευθεία είναι το ελάχιστο

$$\min_{\alpha, \beta} \sum_{i=1}^n \epsilon_i^2 \quad \text{ή} \quad \min_{\alpha, \beta} \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$$

Λύση:

$$\left. \begin{array}{l} \frac{\partial \sum (y_i - \alpha - \beta x_i)^2}{\partial \alpha} = 0 \\ \frac{\partial \sum (y_i - \alpha - \beta x_i)^2}{\partial \beta} = 0 \end{array} \right\} \begin{array}{l} \sum_{i=1}^n y_i = n\alpha + \beta \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i y_i = \alpha \sum_{i=1}^n x_i + \beta \sum_{i=1}^n x_i^2 \end{array}$$

Εκτιμήσεις των  $\beta$  και  $\alpha$  είναι

$$b = \frac{s_{XY}}{s_X^2} \quad a = \bar{y} - b\bar{x}$$

**ευθεία ελαχίστων τετραγώνων:**  $\hat{y} = a + bx$


## Εκτίμηση της διασποράς των σφαλμάτων

Για κάθε  $x_i$ :  $\hat{y}_i = a + bx_i$

$e_i = y_i - \hat{y}_i$ : σφάλμα

ελαχίστων τετραγώνων ή  
υπόλοιπο

$e_i$ : εκτίμηση του σφαλματος  
παλινδρόμησης  $\epsilon_i$



Η εκτίμηση της διασποράς  $\sigma^2$  του σφαλματος

$$s^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

θέτοντας  $\hat{y}_i = a + bx_i$

$$s^2 = \frac{n-1}{n-2} \left( s_Y^2 - \frac{s_{XY}^2}{s_X^2} \right) = \frac{n-1}{n-2} (s_Y^2 - b^2 s_X^2)$$

# Παρατηρήσεις

- Η ευθεία ελαχίστων τετραγώνων περνάει από το σημείο  $(\bar{x}, \bar{y})$ :  $a + b\bar{x} = \bar{y} - b\bar{x} + b\bar{x} = \bar{y}$   
Άρα η ευθεία ελαχίστων τετραγώνων μπορεί επίσης να οριστεί ως  $y_i - \bar{y} = b(x_i - \bar{x})$
- Η εκτίμηση των  $\alpha$  και  $\beta$  με τη μέθοδο των ελαχίστων τετραγώνων **δεν** προϋποθέτει
  - (i) σταθερή διασπορά της  $Y$  για κάθε  $x$  και
  - (ii) κανονική κατανομή της  $Y$  για κάθε  $x$
- Για κάθε τιμή  $x_0$  της  $X$ , η πρόβλεψη της  $y_0$  από την ευθεία ελαχίστων τετραγώνων είναι

$$y_0 = a + bx_0$$


**Προσοχή:** Η τιμή  $x_0$  πρέπει να ανήκει στο εύρος των γνωστών τιμών της  $X$ .

# Παράδειγμα

Θέλουμε να μελετήσουμε σ' ένα ολοκληρωμένο κύκλωμα την **εξάρτηση** της **απολαβής ρεύματος κρυσταλλούχνιας** (τρανζίστορ) από την **αντίσταση του στρώματος της κρυσταλλούχνιας**.

A/A (i)	Αντίσταση στρώματος $x_i$ (ohm/cm)	Απολαβή ρεύματος $y_i$
1	66	5.3
2	66	6.5
3	69	7.4
4	78	7.2
5	87	7.8
6	93	10.8
7	105	9.1
8	111	8.1
9	123	12.6
10	141	9.8

Εξαρτάται η απολαβή  
ρεύματος τρανζίστορ από την  
αντίσταση του στρώματος  
κρυσταλλολυχνίας;  
Είναι η εξάρτηση γραμμική;



## Παράδειγμα (συνέχεια)

$$\text{Τιπολογίζουμε} \quad \bar{x} = 93.9 \quad \bar{y} = 8.46$$

$$\sum_{i=1}^{10} x_i^2 = 94131 \quad \sum_{i=1}^{10} y_i^2 = 757.64 \quad \sum_{i=1}^{10} x_i y_i = 8320.2$$

$$s_{XY} = 41.81 \quad s_X^2 = 662.1 \quad s_Y^2 = 4.66$$

Οι εκτιμήσεις  $b$  και  $a$

$$b = \frac{s_{XY}}{s_X^2} = \frac{41.81}{662.1} = 0.063$$

$$a = \bar{y} - b\bar{x} = 8.46 - 0.063 \cdot 93.9 = 2.53$$

Η εκτίμηση της διασποράς των σφαλμάτων παλινδρόμησης

$$s^2 = \frac{n-1}{n-2} (s_Y^2 - b^2 s_X^2) = \frac{9}{8} (4.66 - 0.063^2 \cdot 41.81) = 5.056$$

Ευθεία ελαχίστων τετραγώνων:  $y = 2.53 + 0.063x$   
με διασπορά σφαλμάτων  $s^2 = 5.056$

## Παράδειγμα: Ερμηνεία των αποτελεσμάτων


- $b$ : Αύξηση αντίστασης στρώματος κατά μία μονάδα μέτρησης ( $1 \text{ ohm/cm}$ )  
→ απολαβή του ρεύματος της κρυσταλλούχνιας αυξάνεται κατά 0.063.
- $a$ : Αντίσταση στρώματος 0  
→ απολαβή ρεύματος 2.53 [αδύνατον]
- $s^2$ : Τυπικό σφάλμα εκτίμησης της παλινδρόμησης είναι  $\sqrt{5.056} \rightarrow 2.249$  [σχετικά μεγάλο]

## Παράδειγμα: Πρόβλεψη

Με βάση το μοντέλο παλινδρόμησης μπορούμε να προβλέψουμε την απολαβή ρεύματος για κάθε αντίσταση στρώματος κρυσταλλούχνιας στο διάστημα [66, 141] ohm/cm:

$$x_0 = 120 : \quad y_0 = 2.53 + 0.063 \cdot 120 = 10.11$$

με ακρίβεια πρόβλεψης (προσεγγιστικά)  $10.11 \pm 2.249$



# Σχέση $r$ και $b$

Για το πρόβλημα της παλινδρόμησης, 'αγνοούμε' ότι η  $X$  δεν είναι τ.μ. και ορίζουμε το συντελεστή συσχέτισης  $\rho$ .

Σχέση μεταξύ του  $r$  και του  $b$  ( $r = \frac{s_{XY}}{s_X s_Y}$  και  $b = \frac{s_{XY}}{s_X^2}$ )

$$r = b \frac{s_X}{s_Y} \quad \text{ή} \quad b = r \frac{s_Y}{s_X}$$

- $r$  και  $b$  εκφράζουν ποιοτικά τη γραμμική συσχέτιση των  $X$  και  $Y$
- $b$  εξαρτάται από τη μονάδα μέτρησης των  $X$  και  $Y$
- $r$  παίρνει τιμές στο διάστημα  $[-1, 1]$
- $r > 0 \Rightarrow b > 0 \quad (r < 0 \Rightarrow b < 0)$
- $r = 0 \Rightarrow b = 0$

# Σχέση $r$ και $s^2$

Σχέση του  $r^2$  και της διασποράς του σφάλματος  $s^2$

$$s^2 = \frac{n-1}{n-2} s_Y^2 (1 - r^2) \quad \text{ή} \quad r^2 = 1 - \frac{n-2}{n-1} \frac{s^2}{s_Y^2}$$

Όσο μεγαλύτερο είναι το  $r^2$  τόσο μικρότερο είναι το  $s^2$  και καλύτερη η πρόβλεψη.

## Συνέχεια παραδείγματος:

Συντελεστής συσχέτισης:

$$r = \frac{s_{XY}}{s_X s_Y} = \frac{41.81}{\sqrt{662.1 \cdot 4.66}} = 0.753$$

$r = 0.753$ : ασθενής θετική συσχέτιση της απολαβής ρεύματος και αντίστασης στρώματος κρυσταλλούχνιας