

2023-12-22

$$Y = b_0 + b_1 X_1 + b_2 X_2 + \varepsilon$$

$$X_2 = X_1^2$$

① Η στατιστική σημαντικότητα των συσχετισμών (μέσω t-test) υπολογίζεται κ' δίνεται υποδείξεις ότι η μεταβλητή αυτή μπορεί εξεταστεί στο μοντέλο που ήδη περιέχει όλες τις υπόλοιπες

② Η σημαντικότητα μιας μεταβλητής εξαρτάται από τις άλλες μεταβλητές που ήδη βρίσκονται στο μοντέλο.

③  $df_{\text{error}} = n - \underbrace{(k+1)}_{\text{απ. παρ. } \theta}$  στο μοντέλο

$$Y = b_0 + b_1 X_1 + \dots + b_k X_k + \varepsilon$$

Εμπειρικός κανόνας  $\left\{ \begin{array}{l} df_{\text{er}} > 30 \\ \text{no avoumpis } df_{\text{er}} > 10k \end{array} \right.$

# Ελέγχοι F στο μοντέλο πολλαπλής παλινδρόμησης

Ελέγχος F γενικά ρόλος  $\frac{MS_1}{MS_2}$

$$MS = \frac{SS}{df} \quad \left( \begin{array}{l} MSR = \frac{SSR}{df_r} \\ MSE = \frac{SSE}{df_{er}} \end{array} \right)$$

$$df_{er} = n - (k+1) = n - \#b$$

$$df_{reg} = df_{mod} = k = \#b - 1 = \# \text{ ανεξ. μεταβλητών.}$$

$$MSR = \frac{SSR}{df_r} = \frac{\text{Εξηγημένη μεταβλητικότητα των } Y}{k}$$

① Ελέγχος F για ολόλο μοντέλο

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0 \quad H_1: \text{τουλάχιστον ένα } \neq 0$$

$$F = \frac{MSR}{MSE} = \frac{\frac{SSR}{df_r=k}}{\frac{SSE}{df_{er}}} \quad \begin{array}{l} \nearrow F \gg \rightarrow H_1 \\ \searrow F \ll \rightarrow H_0 \end{array}$$

κατά  $\alpha$   $H_0: F \sim F_{df_r, df_{er}}$

$$\begin{array}{l} \text{accept } H_0: F \leq F_\alpha \\ \text{reject } H_0: F > F_\alpha \end{array} \quad \left( \begin{array}{l} (p \geq \alpha) \\ (p < \alpha) \end{array} \right)$$





3

# Ελέγχοι F type I (i sequential F-tests)

Στο μοντέλο

$$Y = b_0 + b_1 X_1 + b_2 X_2 + b_3 X_3 + \varepsilon$$

κ' ότι

$$Y = b_0 + b_1 X_3 + b_2 X_1 + b_3 X_2 + \varepsilon$$

το t-test της  $X_2$

θα είναι στο μοντέλο 1:  $H_0: b_1 = 0$   $H_1: b_1 \neq 0$

" Μοντέλο 2:  $H_0: b_2 = 0$ ,  $H_1: b_2 \neq 0$

Θα έχουν απ. β. ως το ίδιο αποτέλεσμα

Όπως κάποιες φορές ενδιαφέρει να βρούμε τις ομαλ. σημαντικότητας μιας μεταβ. ανάλογα με τη σειρά με την οποία έχει μπει

M1 :  $Y_0 : b_0 + b_1 X_1 + b_2 X_2 + b_3 X_3$

sequential F-tests

- $H_0: b_1 = 0$  :  $H_1: b_1 \neq 0$  <sup>μονομεταβ. (x1)</sup>  $(X_1)$
- $H_0: b_2 = 0$  :  $H_1: b_2 \neq 0$  <sup>x1, x2</sup>  $(X_2 | X_1)$
- $H_0: b_3 = 0$  :  $H_1: b_3 \neq 0$  <sup>x1, x2, x3</sup>  $(X_3 | X_1, X_2)$

!!  
μνήμη της 'μικρομεταβ. ποσότητας'

!!  
μνήμη της x1

$$M9: \quad Y_0 = b_0 + b_1 X_2 + b_2 X_3 + b_3 X_1$$

$$H_0: b_1 = 0 \quad H_1: b_1 \neq 0 \quad (X_2)$$

$$b_2 \quad (X_3 | X_2)$$

$$b_3 \quad (X_1 | X_2, X_3)$$

1. X.

$$X_1 = \text{age}$$

$$X_2 = \text{BP}$$

$$X_3 = \text{ap. zony/ntipa}$$

$$Y \text{ e.gap.}$$

$$Y = b_0 + b_1 X_1 + b_2 X_2 + b_3 X_3$$

seq. F-test.

1) Age : stat significant

2) BP/Age : " "

3) smoking/Age, BP " " "

#### ④ Partial F-tests : (Type III)

(~ t-test)

$$Y_0: b_0 + b_1 X_1 + b_2 X_2 + b_3 X_3$$

$$H_0: b_1 = 0, \quad H_1: b_1 \neq 0 \quad : \quad X_1 | X_2, X_3$$

$$H_0 \quad b_2 \quad \dots \quad : \quad X_2 | X_1, X_3$$

$$b_3 \quad : \quad X_3 | X_1, X_2$$


# Πολυωνομική Παφινδρόμηση

$$Y = b_0 + b_1 X_1 + b_2 X_2$$


$$X_2 = X_1^2$$

$$Y = b_0 + b_1 X_1 + b_2 X_1^2$$


← Πολυωνομική Παφινδρόμηση βαθμού 2




$$b_0 + b_1 X$$



$$b_0 + b_1 X + b_2 X^2$$



$$b_0 + b_1 X + b_2 X^2 + b_3 X^3$$



# ΚΑΤΗΓΟΡΙΚΕΣ ΜΕΤΑΒΛΗΤΕΣ (ΑΝΕΞΑΡΤΗΤΕΣ)

Στο μοντέλο παλινδρόμησης  $Y = b_0 + b_1 X_1 + b_2 X_2 + \varepsilon$   
υποθέτουμε ότι οι  $X_1, X_2$  είναι ποσοτικές

Όμως σε εξαρτητές κάποιες ανεξ. μετ. είναι κατηγορικές

Παράδειγμα: Τιμές διακριτοτήτων σε 3 πόλεις

$X$ : πόση : categorical

## Τύποι Μεταβλητών

1)  $X$ : κατηγορική (nominal) (categorical) : οι δυνατές τιμές τους είναι διακριτές & μη συγκρίσιμες (π.χ. χρώμα)

2)  $X$ : διατάξιμη (ordinal) : οι τιμές τους μπορούν να μετρηθούν σε αύξουσα ή φθίνουσα σειρά αλλά όχι αναφορικά

(κλίμακα Likert σε ερωτηματολόγια  
1: κακό  
2: λίγο  
3: πολύ  
4: εξαιρετικό)

3)  $X$ : κλίμακα (scale ποσοτικές)

: οι τιμές μετρούνται με βάση μονάδα μέτρησης

π.χ. ύψος (σε cm)  $X_1 = 200$   
 $X_2 = 100$   
 $X_1 = 2X_2$

Μεθοδολογία SE

# Παράδειγμα: (τιμές διασποράς)

$Y =$  τιμή λώλπου

δείγμα  $n=32$

$$\bar{y} = 219,97$$

$$\bar{y}_{NY} = 258,5$$

$$\bar{y}_{CHI} = 191$$

$$\bar{y}_{BOS} = 201$$

φαίνεται ότι η κοινή εστία έχει  
τις τρεις μεταβλητότητας  
τις τρεις

ίδια διασπορά

Εστω  $Y_{NY}$  : τιμή στη NY  $\sim N(\mu_{NY}, \sigma^2)$

$Y_{BOS}$  " " BOS  $\sim N(\mu_{BOS}, \sigma^2)$

$Y_{CHI}$  : " CHI  $\sim N(\mu_{CHI}, \sigma^2)$

Θα θέλαμε να κάνουμε τον έλεγχο:

3 άγνωστες  
παραμέτρους  
( $\mu_{NY}, \mu_{BOS}, \mu_{CHI}$ )

$$H_0 : \mu_{NY} = \mu_{BOS} = \mu_{CHI} \quad H_1 : \text{τουλάχιστον δύο διαφορετικές}$$

Στη βιοστατιστική έχουμε δει t-test για σύγκριση  
μέσω δύο πληθυσμών

$$H_0 : \mu_1 = \mu_2 \quad H_1 : \mu_1 \neq \mu_2$$



① Μέθοδος ANOVA (Analysis of Variance)  
 (διαφορετική ένοια από πίνακα ANOVA)  
 (Δεν χρησιμοποιείται)

② Παινδρόμηση μέσω καταλληλότητας κωδικοποίησης  
 ως  $X = \text{πόλη} \rightarrow \text{ποσοτική}$

City =  $\begin{cases} \text{Chi} \\ \text{Bos} \\ \text{NY} \end{cases} \rightarrow \text{ποσοτική}$

City :  $\begin{cases} \text{κατηγορική} \\ \text{σε 3 επίπεδα (levels)} \\ \{\text{Chi, Bos, NY}\} \end{cases} \rightarrow \begin{cases} \text{Chi} = 1 \\ \text{Bos} = 2 \\ \text{NY} = 3 \end{cases} = X$

$$Y = b_0 + b_1 X + \varepsilon$$

$$\text{Av City} = \text{Chi} \Rightarrow X=1 \Rightarrow EY = b_0 + b_1 = \mu_{\text{Chi}} -$$

$$\text{" Bos} \Rightarrow X=2 \Rightarrow EY = b_0 + 2b_1 = \mu_{\text{Bos}} -$$

$$\text{NY} \Rightarrow X=3 \Rightarrow EY = b_0 + 3b_1 = \mu_{\text{NY}} -$$

$$\underbrace{\mu_{\text{Bos}} - \mu_{\text{Chi}}}_{10} = \underbrace{\mu_{\text{NY}} - \mu_{\text{Bos}}}_{\sim 60} = b_1 \quad X ??$$

Κωδικοποίηση μέσω δυαδικών (0-1) μεταβλητών  
(binary, dummy variables)

Levels	$X_{CHI}$	$X_{BOS}$	$X_{NY}$	← όλες μεταβλητές
Chi	1	0	0	
Bos	0	1	0	
NY	0	0	1	

$$X_{CHI} = \begin{cases} 1 & \text{or City} = \text{Chi} \\ 0 & \text{or city} \neq \text{Chi} \end{cases}$$

$$X_{BOS} = \begin{cases} 1, & \text{City} = \text{Bos} \\ 0, & \text{διαφ.} \end{cases}$$

$$X_{NY} = \begin{cases} 1, & \text{city} = \text{NY} \\ 0, & \text{διαφ.} \end{cases}$$

Δαίτη

Price	City	$X_{CHI}$	$X_{BOS}$	$X_{NY}$
	Bos	0	1	0
	NY	0	0	1
	Chi	1	0	0
	NY	0	0	1
	...			
	...			

$$X_{CHI} + X_{BOS} + X_{NY} = 1$$

⇒ City = ?

$$Y = b_0 + b_1 X_{CH} + b_2 X_{BOS} + b_3 X_{NY}$$

4 μεταβλητές

στο αρχικό μόντελ 3:  $\mu_{CH}$ ,  $\mu_{BOS}$ ,  $\mu_{NY}$  ]

$X_{CH}$	$X_{BOS}$	
+	+	$\rightarrow$ City
0	0	NY
0	1	
1	0	
0	0	
1	1	

Παραλείπεται η NY

↓

NY : ενδεσo αναφοράς

$$Y = \beta_0 + \beta_1 X_{CH} + \beta_2 X_{BOS}$$

(3 παράμετροι)  
 $b_0, b_1, b_2$

Αν σε αυτό το μόντελο εκτιμούσαμε  $\hat{b}_0, \hat{b}_1, \hat{b}_2$

τις είναι οι εκτιμήσεις  $\hat{\mu}_{CH}, \hat{\mu}_{BOS}, \hat{\mu}_{NY}?$

$E Y = b_0 + b_1 X_{CH} + b_2 X_{BOS}$

Av City = NY

$$X_{CHI} = 0, X_{BOS} = 0 \Rightarrow EY = b_0 + b_1 \cdot 0 + b_2 \cdot 0 = \mu_{NY}$$

$$\Rightarrow \boxed{\mu_{NY} = b_0}$$

City = Chi.

$$X_{CHI} = 1, X_{BOS} = 0 \Rightarrow EY = b_0 + b_1 \cdot 1 + b_2 \cdot 0 = \mu_{CHI}$$

$$\Rightarrow \boxed{\mu_{CHI} = b_0 + b_1}$$

City = Bos

$$X_{BOS} = 1, X_{CHI} = 0 \Rightarrow EY = b_0 + b_1 \cdot 0 + b_2 \cdot 1 = \mu_{BOS}$$

$$\Rightarrow \boxed{\mu_{BOS} = b_0 + b_2}$$

$$\hat{b}_0 = 258.5$$

$$\hat{b}_1 = -67.5$$

$$\hat{b}_2 = -56.9$$

$$\hat{\mu}_{NY} = 258.5$$

$$\hat{\mu}_{CHI} = \hat{b}_0 + \hat{b}_1 = 258.5 - 67.5 = \underline{191}$$

$$\hat{\mu}_{BOS} = \hat{b}_0 + \hat{b}_2 = 258.5 - 56.9 \approx 202$$

## Equations

$$\mu_{NY} = b_0$$

$$\mu_{CHI} = b_0 + b_1$$

$$\mu_{BOS} = b_0 + b_2$$

$$b_0 = \mu_{NY}$$

$$b_1 = \mu_{CHI} - \mu_{NY}$$

$$b_2 = \mu_{BOS} - \mu_{NY}$$

Γενικά :  $b_0 = E(Y | \text{ενιαίο αναφοράς})$

$$b_1 = E(Y | \text{ενιαίο 1}) - E(Y | \text{αναφ})$$

$$b_2 = E(Y | \text{ενιαίο 2}) - E(Y | \text{αναφ})$$

0 αρχικός έλεγχος

$$H_0: \mu_{NY} = \mu_{CH1} = \mu_{BOS} \quad \text{vs} \quad H_1: \text{το max. 2 διαφέρουν}$$



$$\mu_{NY} = \mu_{CH1} \Rightarrow \beta_0 = \beta_0 + \beta_1 \Rightarrow \beta_1 = 0$$

$$\mu_{NY} = \mu_{BOS} \Rightarrow \beta_0 = \beta_0 + \beta_2 \Rightarrow \beta_2 = 0$$

ισοδυναμικός έλεγχος :  $H_0: b_1 = b_2 = 0$ ,  $H_1: \text{τολάχιστον ένα} \neq 0$

Έλεγχος F για τρεις μντζες

$$p = 3 \cdot 10^{-8} \approx 0$$

$\Rightarrow$  απορριπτεται ο σχεδός για κάθε  $\alpha$