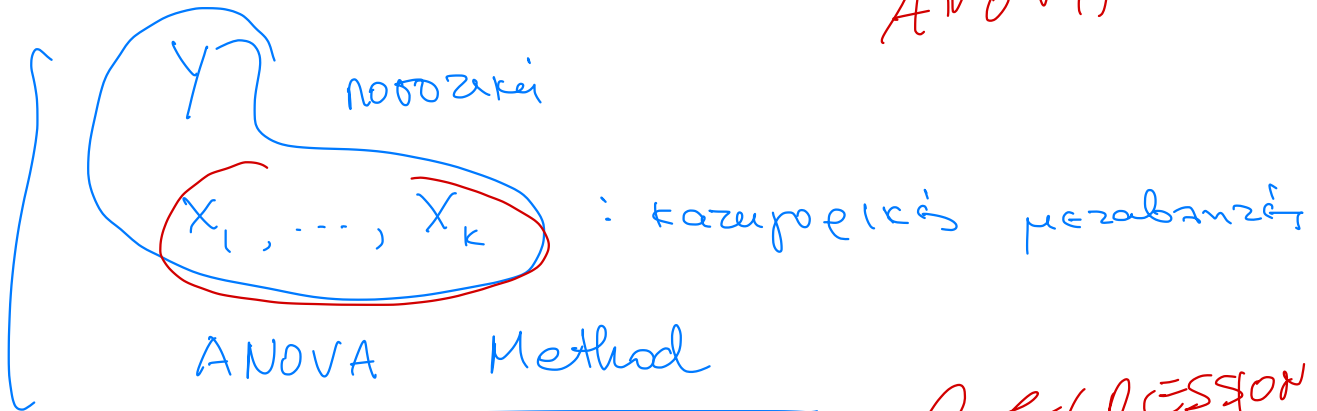


14-3-2023

# Μοντέλα Πλινδρόμησης με Κατηγορικές Ανεξάρτητες Μεταβλητές.

ANOVA



REGRESSION

Πλινδρόμηση  $\left\{ \begin{array}{l} Y \text{ ποσοτική} \\ X_1, \dots, X_k \text{ ποσοτικές} \end{array} \right.$

Y ποσοτική

ANACOVA

$X_1, \dots, X_k$   
ποσοτικές

$X_{k+1}, \dots, X_p$   
κατηγορικές

Ενιαίο Μοντέλο

$$Y = b_0 + b_1 X_1 + \dots$$

# Μεταβλητές

1) Κατηγορικές (Nominal) Επίπεδα  
π.χ. X = χρώμα { ασπρο  
καίρο  
γκρι  
καφέ

2) Ordinal (Διατεταγμένες)  
π.χ. Likert scale { λιγ  
πολύ  
πέρα πολύ

3) Ποσοτικές / κλίμακας (Scale) } Λογισμικά  
εχουν μονάδα μέτρησης

## Παράδειγμα

Y = Τιμή πώλησης διαμερισμάτων

Πόλη: { Bos  
Chi  
NY

Cats	Price
Chi	150
Bos	200
Chi	120
NY	300
Chi	.
NY	.
⋮	.
⋮	.

Εσω

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

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

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

$$H_0: \mu_{NY} = \mu_{CHI} \quad H_1: \mu_{NY} \neq \mu_{CHI}$$

$$H_0: \mu_{NY} = \mu_{BOS} \quad H_1: \mu_{NY} \neq \mu_{BOS}$$

$$H_0: CHI - BOS$$

αλληλοί  
εξαρτά

$$1^{\text{ος}} \quad P(\text{"σωστός"}) : 0.95$$

$$2^{\text{ος}} \quad P \text{ " } : 0.95$$

$$\underline{P(\dots) : 0.95}$$

$$P(\text{ολα σωστά}) = 0.95 \times 0.95 \times 0.95 < 0.95.$$

Θα διαφέρει έναν έλεγχο

$$H_0: \mu_{NY} = \mu_{Bos} = \mu_{Chi} \quad : \quad H_1: \text{τολάχιστον δύο διαφορετικές μετρήσιμες τιμές}$$

Κωδικοποιών μια κατηγορική μεταβλητή.

①

city	X
NY	1
Chi	2
Bos	3

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

dataset

X	Y
1	150
2	300
3	200
1	⋮
3	⋮
2	⋮

$$E(Y|NY) =$$

$$E(Y|X=1) = b_0 + b_1$$

$$E(Y|NY) = E(Y|X=1) = b_0 + b_1 = \mu_{NY}$$

$$E(Y|Chi) = E(Y|X=2) = b_0 + 2b_1 = \mu_{Chi}$$

$$E(Y|Bos) = E(Y|X=3) = b_0 + 3b_1 = \mu_{Bos}$$

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

$$\mu_{Bos} - \mu_{Chi} = b_1$$

$$\mu_{Bos} - \mu_{NY} = 2b_1$$

$$\Rightarrow \mu_{Chi} - \mu_{NY} = \mu_{Bos} - \mu_{Chi} = \frac{1}{2}(\mu_{Bos} - \mu_{NY})$$

②

Bos	1
NY	2
Chi	3

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

⇒ - - -

$$\mu_{NY} = \mu_{Bos} = \mu_{CHI} = \mu_{NY} = \frac{1}{2} (\mu_{CHI} - \mu_{Bos})$$

③

Bos	-5
NY	4
Chi	7

⇒ - - - -

"Σωστό" Κωδικοποίηση (Δίκετες (binary) μεταβλητές)

City | 3 εντάδα } 3 νέες μεταβλητές  
 Bos  
 Chi  
 NY

$$X_{NY} = \begin{cases} 1 & \text{αν City} = NY \\ 0 & \text{αν City} \neq NY \end{cases}$$

$$X_{BOS} = \begin{cases} 1 & \text{City} = BOS \\ 0 & \text{City} \neq BOS \end{cases}$$

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

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

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

4 παράμετροι  
 > 3 !!

Y	City	$X_{NY}$	$X_{CHI}$	$X_{BOS}$
	Chi	0	1	0
	Chi	0	1	0
	Bos	0	0	1
	Ny	1	0	0
	NY	1	0	0
	Bos	0	0	1
			⋮	

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

~~ΒΟΣ~~  
 ΕΠΙΛΕΞΟ  
 αναφοράς

$$Y = b_0 + b_1 X_{NY} + b_2 X_{CHI}$$

← 3 παραμ

Κωδικό νοήμον

Γενικά

Για κάθε επιπέδο ενός των επιπέδων αναφοράς ορίζουμε μια διακριτή μεταβλητή

Εσω 20 ~~μπαζέτο~~

$$Y = b_0 + b_1 X_{NY} + b_2 X_{CHI}$$

Ερμηνείες των β.

Για κάθε επίπεδο υπολογίζουμε το  $E(Y)$  με βάση το ~~μπαζέτο~~

City: Bos

$$X_{NY} = 0$$

$$X_{CHI} = 0$$

$$Y = b_0 \Rightarrow E(Y|Bos) = \boxed{b_0 = \mu_{Bos}}$$

City	Y	
Bos	$\mu_{Bos} = \beta_0$	} $\beta_0 = \mu_{Bos}$ $\beta_1 = \mu_{NY} - \beta_0 = \underline{\mu_{NY} - \mu_{Bos}}$ $\beta_2 = \mu_{CHI} - \mu_{Bos}$
NY	$\mu_{NY} = \beta_0 + \beta_1$	
Chi	$\mu_{CHI} = \beta_0 + \beta_2$	

$Y = \beta_0 + \beta_1 NY + \beta_2 CHI$

Τεχνικά

$$\beta_0 = E(Y|X: \text{ενιαίο αναφερόμενο } \hat{\alpha}_1)$$

$$\beta_1 = E(Y|X = \text{ενιαίο δότ}) - E(Y|αναφ.)$$

$$\beta_2 = E(Y|X = \text{ενιαίο δότ}) - E(Y|αναφ.)$$

⋮  
⋮  
⋮

F-test για συσσωρευτικό μοντέλο

$$H_0: \beta_1 = \beta_2 = 0$$

$$H_1: \beta_1 \neq 0 \text{ ή } \beta_2 \neq 0 \text{ ή κ' τα δύο}$$

$$H_0: \left. \begin{array}{l} \beta_1 = 0 \Rightarrow \mu_{NY} = \mu_{Bos} \\ \beta_2 = 0 \Rightarrow \mu_{CHI} = \mu_{Bos} \end{array} \right\} \Rightarrow \boxed{\mu_{NY} = \mu_{CHI} = \mu_{Bos}}$$

$$\Leftrightarrow H_0: \mu_{NY} = \mu_{CHI} = \mu_{BOS}$$

$$Y = \beta_0 + b_1 X_{NY} + b_2 X_{CHI}$$

$$\beta_0 = 201.636$$

$$\beta_1 = 56.864$$

$$b_2 = -10.636$$

$$\mu_{BOS} = 201.636$$

$$\mu_{NY} = 201.636 + 56.864 = 258.5$$

$$\mu_{CHI} = 201.636 - 10.636 = 191$$

$$F\text{-test}: p = 7 \cdot 10^{-8}$$

υπόκειται οντως να ανήκει  
σε αυτήν κ' επι διακριτότητα

↓  
συμπερασμα  
με τις παραπάνω  
τις  $\mu_{NY}, \mu_{BOS}, \mu_{CHI}$ .

$$\text{Model 2: } Y = b_0 + b_1 X_{BOS} + b_2 X_{CHI} \quad (NY: \text{επιρ. αναγ.})$$

$$\hat{b}_0 = \hat{\mu}_{NY} = 258.5$$

$$\hat{b}_1 = -56.87 \Rightarrow \hat{\mu}_{BOS} = 258.5 - 56.87 = 201.63$$

$$\hat{b}_2 = -67.5 \Rightarrow \hat{\mu}_{CHI} = 258.5 - 67.5 = 191$$

$$H_0: b_1 = b_2 = 0$$

$$H_1: \dots$$

$$F = 30.54$$

$$p = 7 \cdot 10^{-8}$$




Μοντέλο με  $\geq 2$  κατηγορικές μεταβλητές

$X_1$   $k_1$  ενότητες  
 $X_2$   $k_2$  "  
 $\vdots$   
 $X_p$   $k_p$  ενότητες

Παράδειγμα

phys.Rdata

sex	smoking	Y (score)
M	Y	167
F	N	150
F	N	.
F	Y	.
M	N	.



Sex (2 levels) Row F: reference level

$$X_M = \begin{cases} 1 & \text{if sex} = M \\ 0 & \text{if sex} \neq M \end{cases}$$

Smoking (2 levels) N: reference level

$$X_Y = \begin{cases} 1 & \text{if smoking} = \text{Yes} \\ 0 & \text{if smoking} \neq \text{Yes} \end{cases}$$

$$Y = b_0 + b_1 X_M + b_2 X_Y \quad [3 \text{ παραμ.}]$$


Sex	Smoking	$X_M$	$X_Y$	$Y$
Female	No	0	0	$\mu_{FN} = b_0$
Female	Yes	0	1	$\mu_{FY} = b_0 + b_2$
Male	No	1	0	$\mu_{MN} = b_0 + b_1$
Male	Yes	1	1	$\mu_{MY} = b_0 + b_1 + b_2$

$$\hat{b}_0 = \mu_{FN}$$

$$\hat{b}_1 = \mu_{MN} - \mu_{FN} = \mu_{MY} - \mu_{FY}$$

$$\hat{b}_2 = \mu_{FY} - \mu_{FN} = \mu_{MY} - \mu_{MN}$$

1000 Divides



Effect φύλου για N

$$\mu_{FN} - \mu_{FN}$$

" " για Y

$$\mu_{MY} - \mu_{FY}$$

Το ποτέ υποτίθεται

ίσα

Αντιοίκα για το effect του καπνίσματος

$\hat{b}_1$  : effect sex (ίσο για smoking Y or N)

$\hat{b}_2$  : effect smoking (ίσο για sex M, F)

main effects

κύριες επιδράσεις

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

∴ main effects model.