

2023-12-08

Αξιολόγηση Μοντέλου - Συμπερασματική

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

$$\varepsilon \sim N(0, \sigma^2)$$

ωχαιά ανόθεση

Δείγμα

x	y
x_1	y_1
\vdots	\vdots
x_n	y_n

ωχαιά βήθηα

$$\begin{aligned} SSE &= \sum_{j=1}^n (y_j - b_0 - b_1 x_j)^2 \\ &= \sum_{j=1}^n (y_j - \hat{y}_j)^2 \end{aligned}$$

$$\min SSE(b_0, b_1) \Rightarrow \text{Εκτιμήτες επί } x, z \in \mathbb{R},$$

$\hat{\beta}_0, \hat{\beta}_1$

Ιδιότητες

$$E(\hat{b}_1) = b_1$$

$$E(\hat{b}_0) = b_0$$

αμερολήπτες εκτιμήτριες
(unbiased)

$$\forall b_0 \neq b_1$$

ανόθεση

Εκτίμηση μιας θ

Δείγμα $(y_1, \dots, y_n) \Rightarrow$

ανάπτυξη-εξαρτησία
 $\theta(y_1, \dots, y_n)$

↓
τιμή του θ για (y_1, \dots, y_n)
"
Εξέλιξη

π.χ. $\bar{X}_n = \frac{X_1 + \dots + X_n}{n}$ εξαρτησία

για ανεξαρ. δείγματα $\bar{X}_n = \text{S.F.} \leftarrow$ εξέλιξη του θ .

Διαφορετικά δείγματα $\Rightarrow (y'_1, \dots, y'_n) \rightarrow \hat{\theta}_2 = \dots$
 $= \hat{\theta}(y'_1, \dots, y'_n)$

$\hat{\theta}$: ωραία μεταβλητή

$E(\hat{\theta})$: Επανάλαμβάνουμε τα δείγματα $N \rightarrow \infty$ φορές με τις ίδιες συνθήκες
εξαρτησίας $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_N$

$$E(\hat{\theta}) \approx \frac{\hat{\theta}_1 + \dots + \hat{\theta}_N}{N}$$

Οτι $E(\hat{\theta}) \neq \theta \leftarrow$ μεροληψία [συστηματικό σφάλμα]

π.χ. αν β_0, β_1 : $\min_{b_0, b_1} \sum_{i=1}^n |y_i - b_0 - b_1 x_i|$

Τυχαίο δείγμα στο γραμμικό μοντέλο

Από δείγμα

Δείγμα	x_1	y_1	y'_1
	x_2	y_2	y'_2
	\vdots	\vdots	\vdots
	x_n	y_n	y'_n

τα x ίδια !!


Τα x_1, \dots, x_n θεωρούνται σταθερά

Η μόνη τυχαίωση προκύπτει από $\varepsilon_1, \dots, \varepsilon_n$
 $\delta_{\text{anf.}}$ y_1, \dots, y_n


- ① $E(\hat{\beta}_0) = \beta_0$
 $E(\hat{\beta}_1) = \beta_1$
- ② Κατανομή των $\hat{\beta}_0, \hat{\beta}_1$?
- ③ Διασπορά / Διασπορά ?

αν $\hat{\beta}_1$ μεγάλη διασπορά

$$\sigma^2(\hat{b}_1)$$




$$\sigma^2(\hat{b}_1) \approx 0$$



Bias/Variance

Biased, $\sigma^2(\hat{b}_1) \approx 0$




$$\hat{b}_0 \sim \mathcal{N}(b_0, \sigma^2(\hat{b}_0))$$

$$\hat{b}_1 \sim \mathcal{N}(b_1, \sigma^2(\hat{b}_1))$$

$$S^2(\hat{b}_0) = \sigma^2(\hat{b}_0)$$

$$S^2(\hat{b}_1) = \sigma^2(\hat{b}_1)$$

$$\Delta E \quad b_1 \quad \hat{b}_1 \quad \underbrace{t_{\alpha/2, n-2}}_{\leq} \leq b_1 \leq \hat{b}_1 - t_{\alpha/2, n-2} S(\hat{b}_1)$$

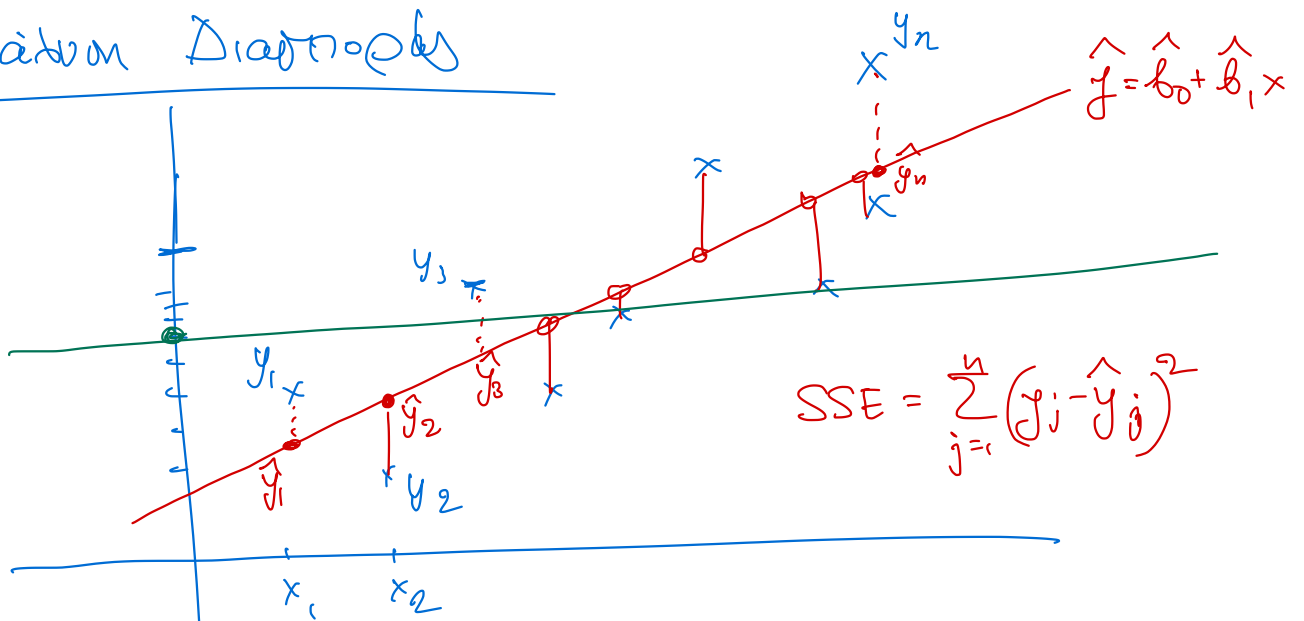


$$H_0 : b_1 = 0 \quad H_a : b_1 \neq 0$$

Αν απορρ. $H_0 \Rightarrow$ υπάρχει ένδεξη συσχέτιση μεταξύ x κ' y

Έλεγχος στατιστικής σημαντικότητας των b_1 κ' b_2 επίδραση των μεταβλητών

Ανάσων Διασποράς



"Μυθιστο Μοντέλο"

$$y = \mu + \varepsilon \quad \left(\begin{array}{c} \text{φανέρω} \\ x \end{array} \right)$$

$$\hat{y} = \hat{\mu} = \bar{y}_n$$

$$SSR = SS_{\text{model}} = \sum_{j=1}^n (\hat{y}_j - \bar{y})^2$$

↓
Sum Squares regression (model)

$$SST = \sum_{j=1}^n (y_j - \bar{y})^2$$

Sum of squares total

ονομαζεί μεταβλητότητα του Y
(ανεξάρτητο από το μωτέφο)

Θεώρημα (ANOVA)

Όταν τα \hat{b}_0, \hat{b}_1 από LSE

τότε

$$SST = SSR + SSE$$

↓
μεταβλητότητα
εξηγείται
από
το μωτέφο

↓
να παραμείνει
ανεξήγητη

↓ R^2

$$R^2 = \frac{SSR}{SST}$$

= % μεταβλ. του Y
αν εξηγείται από
το μωτέφο

