

7-3-2023

$$Y = b_0 + b_1 X + \varepsilon, \quad \varepsilon \sim \mathcal{N}(0, \sigma^2)$$

$$H_0: b_1 = 0 \quad H_1: b_1 \neq 0.$$

ελεγχος
στατιστικής σημαντικότητας

της b_1

(όλου του μιστέλου)

t-test
 $n-2$ β.ε.β.

Εκτίμηση/Πρόβλεψη για νέες τιμές του X .

Για $X = x_0$ $Y = ?$

$$Y = b_0 + b_1 x_0 + \varepsilon$$

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

① $\Rightarrow E(Y) = b_0 + b_1 x_0 \Rightarrow E(Y) = ?$ για $X = x_0$?
Εκτίμηση

② Αν έχω ένα μετασχηματισμένο αλγόριθμο με $X = x_0$

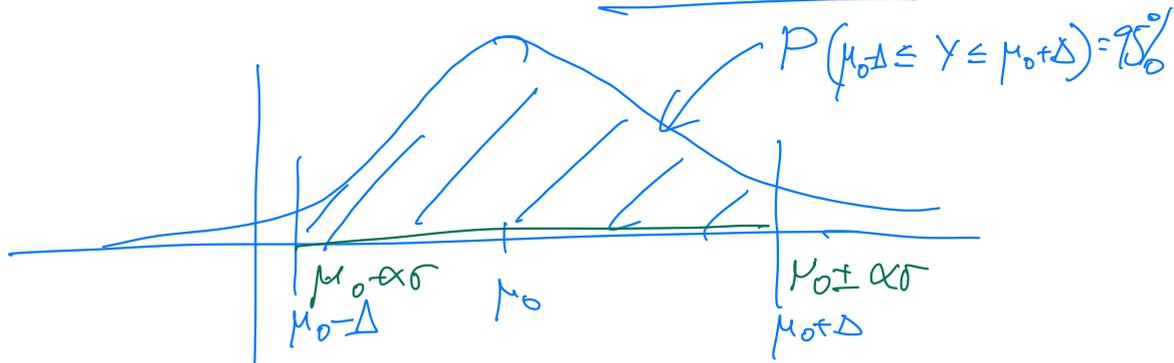
$? \leq Y \leq ?$

διαστημα προβλεψης

forecast interval

prediction interval

Αν ξέρουμε ότι για $X = x_0$ $E(Y) = \mu_0$



① Εκτίμηση των $E(Y)$ όταν $X=x_0$.

$$\hat{Y} = \hat{b}_0 + \hat{b}_1 X_0$$

σημιακή εκτίμηση των $E(Y|X=x_0)$

ΔE για $E(Y|X=x_0)$ ← διασπορά
επινοουμένων

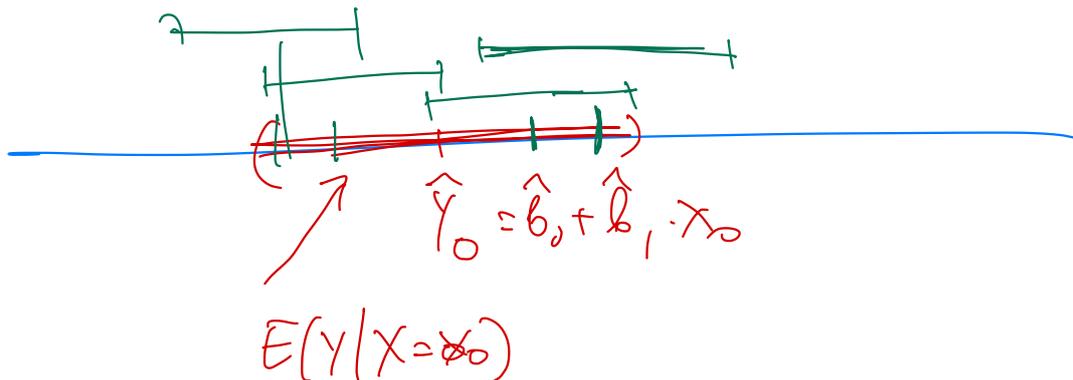
για $X=x_0$.

$$\hat{Y} = \hat{b}_0 + \hat{b}_1 x_0$$

: std. error

$$\Delta E = \hat{Y} \pm t_{\alpha/2, df} s_{\hat{Y}}$$

② Πρόβλεψη { Δ να γνωρίζουμε να $E(Y|X=x_0)$
 $= b_0 + b_1 x_0$
Μεμονωμένο άγνωστο με
δίκτυ των διακυβάντων



Διπίπτης $(1-\alpha) \cdot 100\%$

$$\hat{Y} \pm t_{\alpha/2, df_{er}} \cdot \underbrace{\sigma_{f, \hat{Y}_0}}_{\substack{\text{ων. σφ.} \\ \text{πρόβλεψης}}}$$

Δ Εφαρ. τ' Πρόβλεψης έχουν
ρόημα για τιές του $X = x_0$
που είναι μέσα στην περιοχή του
 X στο δείγμα.

Στο R:

`lm (score~age, data=exercise)`

`lm (score~age, data=ex2)`

x	y
x_1	y_1
\vdots	\vdots
x_n	y_n

$$l_1 = \text{lm}(y \sim x, \text{data} = \text{sample1})$$

$$\hat{b}_0, \hat{b}_1, \text{MSE}, R^2, \dots$$

dataset = sample1

Scipy

$$\text{predict}(l_1, \text{data} = \text{sample2}, \text{interval} = \text{"confidence"})$$

x	y
x'_1	?
x'_2	?
\vdots	?
x'_k	?

$$\text{predict}(l_1, \text{data} = \text{sample2}, \text{interval} = \text{"prediction"})$$

Μοντέλο Πολλαπλής Παλινδρόμησης

$$Y = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k + \varepsilon$$

Υποθέσεις

$$E(\varepsilon) = 0$$

$$\text{Var}(\varepsilon) = \sigma^2$$

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

b_0, b_1, \dots, b_k : άγνωστα

σ^2 : άγνωστο

$\varepsilon_i, \varepsilon_j$ ανεξάρτητα για διαφορετικές παρατηρήσεις i, j

Δείγμα

j	x_1	x_2	...	x_k	y
1	x_{11}	x_{21}		x_{k1}	y_1
2	x_{12}	x_{22}		x_{k2}	\vdots
\vdots	\vdots	\vdots		\vdots	\vdots
\vdots	\vdots	\vdots		\vdots	\vdots
n	x_{1n}	x_{2n}		x_{kn}	y_n

Μέθοδος

Ελαχ. τετραγώνων

$$SSE(b_0, b_1, \dots, b_k) = \sum_{j=1}^n \left(y_j - b_0 - b_1 x_{1j} - b_2 x_{2j} - \dots - b_k x_{kj} \right)^2$$

\uparrow
 $\min_{b_0, b_1, \dots, b_k} SSE$

\Rightarrow Εκτίμησης ελαχ. τετραγ.
 $\hat{b}_0, \hat{b}_1, \dots, \hat{b}_k$

(είναι και εφ' όσον ούτως μεγ. πιθανοφάνεια)

Εξ. Παλινδρόμησης

$$\hat{y} = \hat{b}_0 + \hat{b}_1 x_1 + \dots + \hat{b}_k x_k \quad \left. \vphantom{\hat{y}} \right\} \begin{array}{l} \text{response} \\ \text{surface} \end{array}$$

Ανασυν Διασποράς

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

$$SSR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

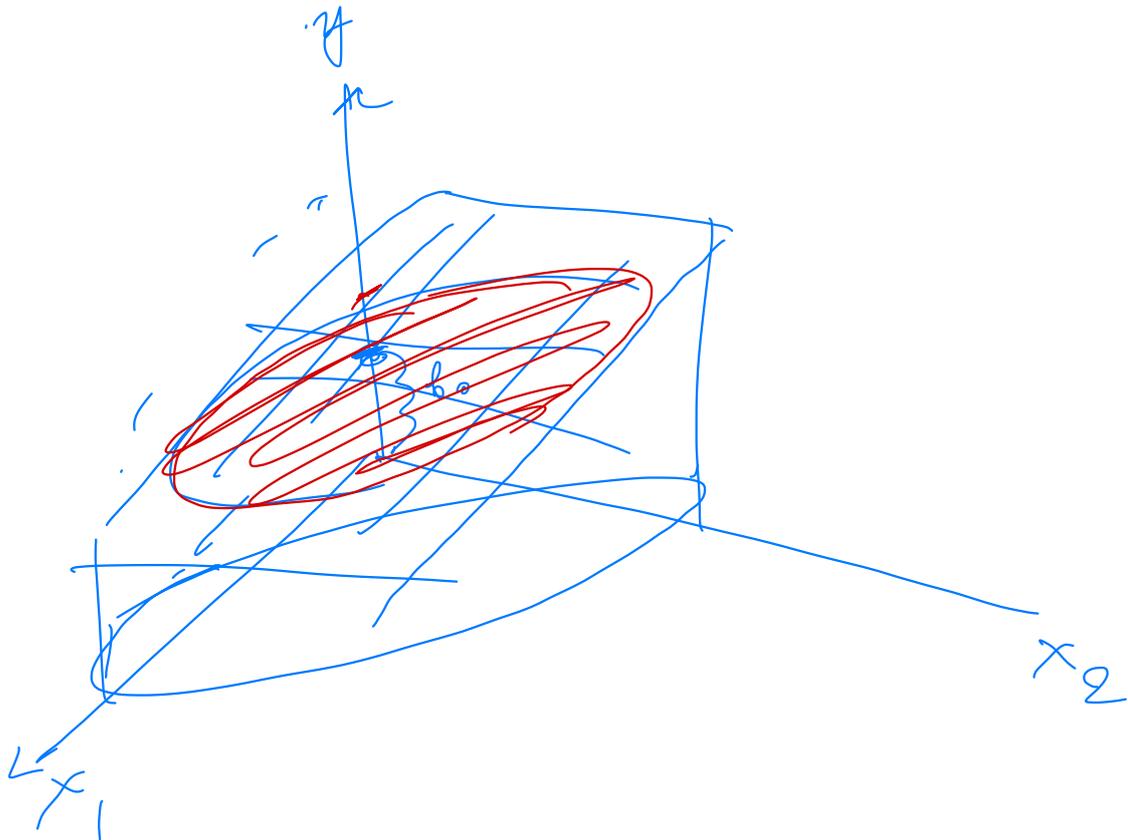
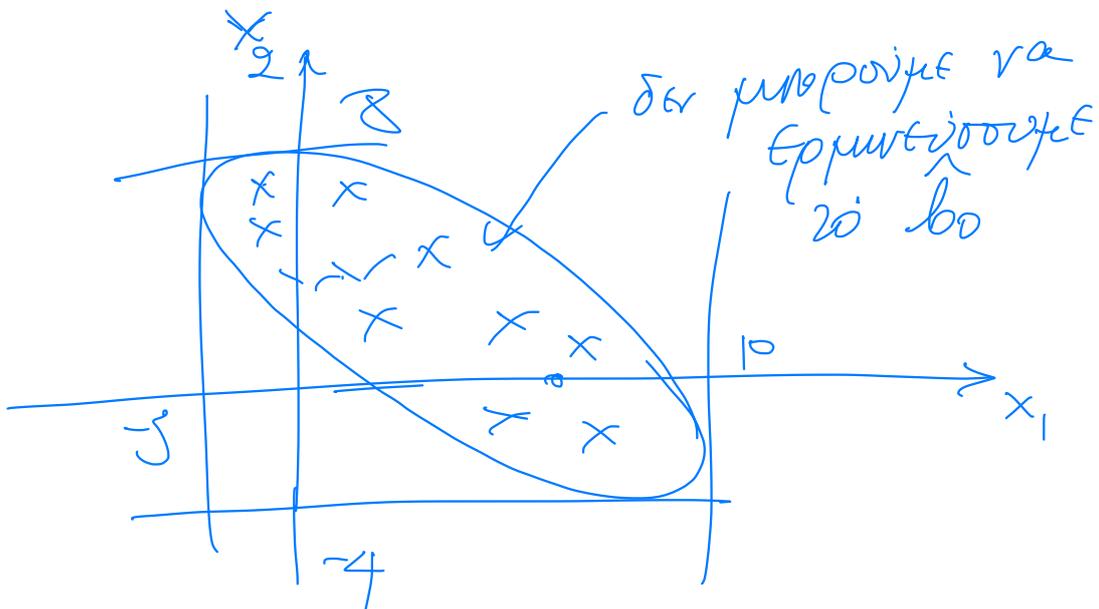
$$SST = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$SST = SSR + SSE$$

$$R^2 = \frac{SSR}{SST} = \begin{array}{l} \% \text{ μεταβλ. του } Y \\ \text{ που εξηγείται από} \\ (x_1, \dots, x_k) \end{array}$$

① Ερμηνείες

$$\hat{b}_0 = \hat{y} \quad (\text{για } x_1=0, x_2=0, \dots, x_k=0)$$



$$EY = b_0 + b_1 x_1 + \dots + b_k x_k$$

$$\hat{y} = \hat{b}_0 + \hat{b}_1 x_1 + \dots + \hat{b}_k x_k$$

\hat{b}_1 = μέση μεταβολή του Y όταν η x_1 αυξηθεί κατά 1 & όλες οι άλλες μείνουν σταθερές

$\hat{b}_2, \dots, \hat{b}_k$: αντιστοιχούν (μεμονωμένες επιδόσεις)

$$\hat{b}_1 = \frac{\partial y}{\partial x_1}$$

Παραίτημα

x_1, \dots, x_k δεν είναι απαραίτητο να διευκρινιστούν σε διαφορετικά χρονικά μετρήματα

π.χ. μπορεί $x_2 = x_1^2, x_3 = x_1^3, \dots, x_k = x_1^k$

μοντέλο πολλαπλής παλινδρόμησης

η $x_1 = \text{age}$ $Y = b_0 + b_1 x_1 + b_2 x_2 + b_3 x_1 x_2$
 $x_2 = \text{baire}$

Ερω π.χ.

$$\hat{Y} = \hat{b}_0 + \hat{b}_1 x + \hat{b}_2 x^2$$

$$= \hat{b}_0 + \hat{b}_1 x_1 + \hat{b}_2 x_2$$

όπου

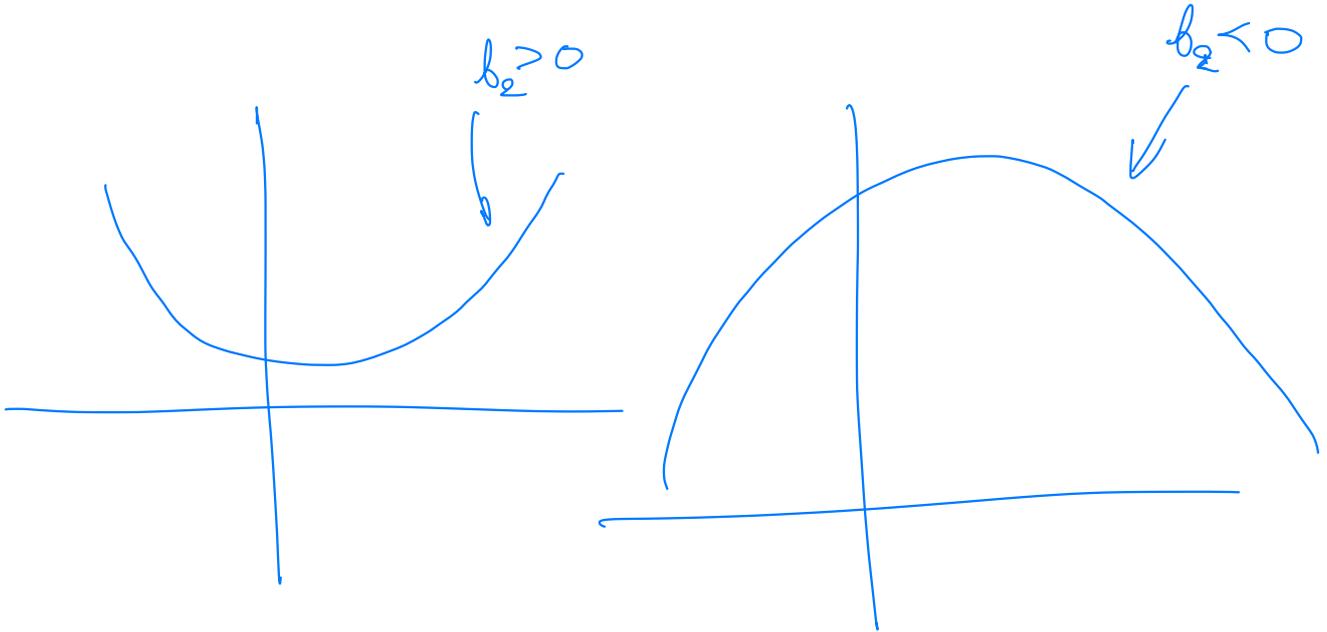
$$x_1 = x$$

$$x_2 = x^2$$

$$\hat{b}_1 = ?$$

Δε μπορούμε να αυξήσουμε
 σε x_1 κ' να κρατήσουμε
 σταθερή σε x_2

$$\frac{\partial \hat{Y}}{\partial x} = b_1 + 2b_2 x$$



$$Y = b_0 + b_1 \log x = b_0 + b_1 x_1 \quad \text{όπου } x_1 = \log x$$

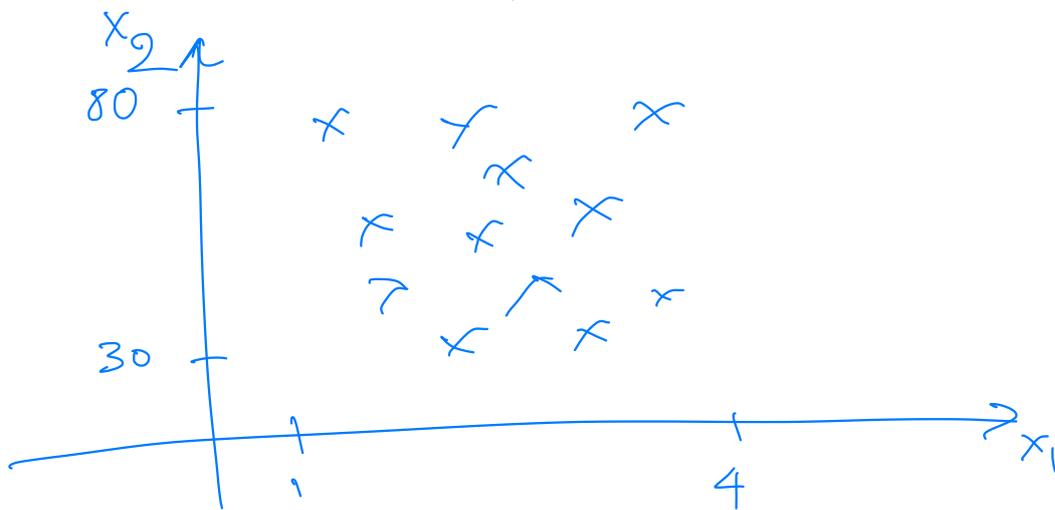
Παράδειγμα 2

Ερω $X_1 = \text{age}$ ($1 \leq X \leq 4$ σε έτη)

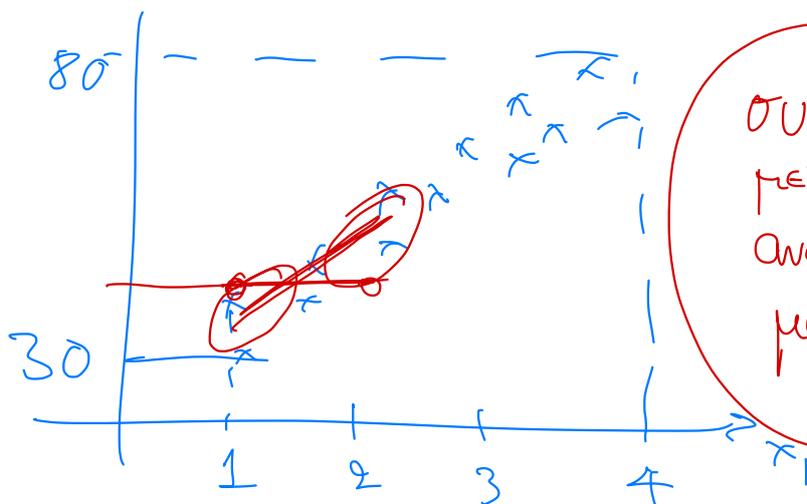
$X_2 = \text{height}$ (σε cm)

$Y = \text{response}$

$$y = b_0 + b_1 x_1 + b_2 x_2$$

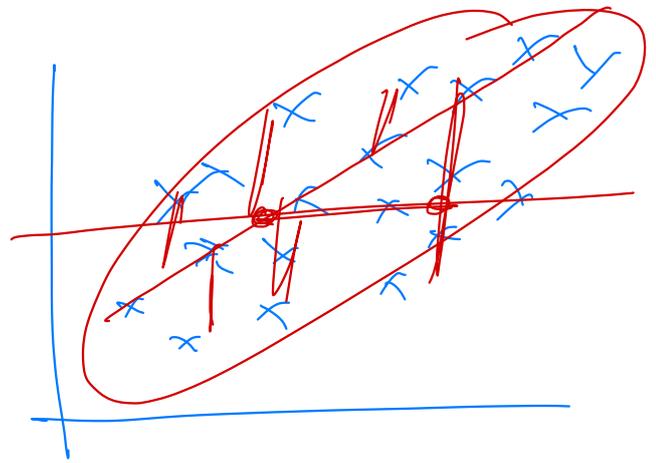
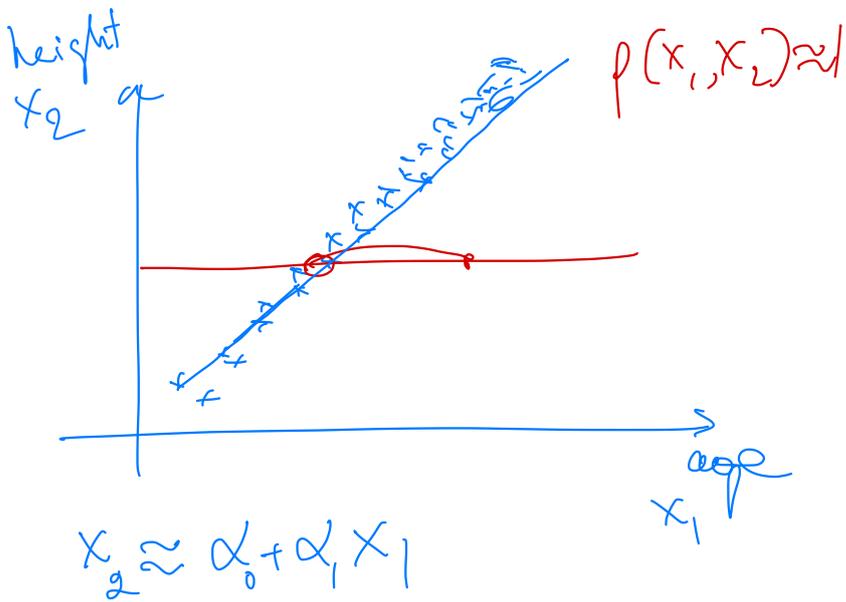


Από αυτό
είχαμε



ΣΥΣΧΕΤΙΣΗ
ΜΕΤΑΞΥ
ΑΝΕΞΑΡΤΗΤΩΝ
ΜΕΤΑΒΗΤΩΝ

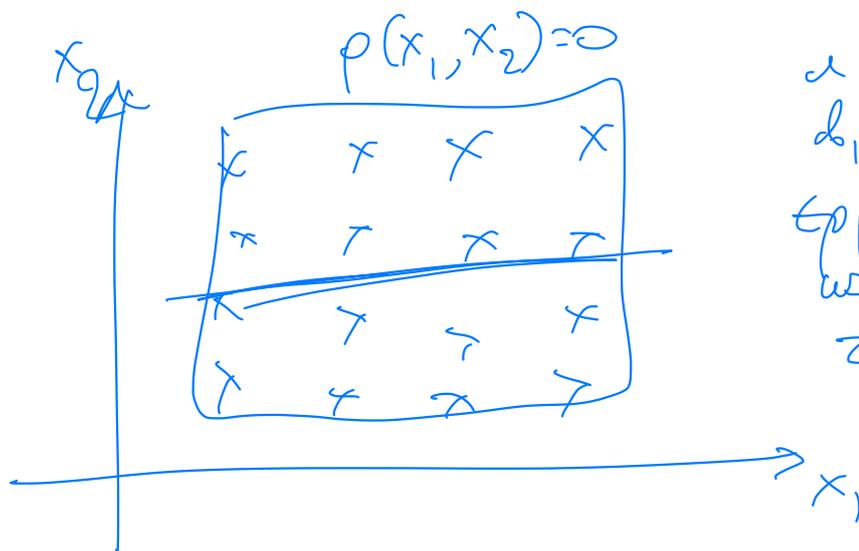
Ερμηνείες του



$$y = b_0 + b_1 x_1 + b_2 x_2$$

$$= b_0 + b_1 x_1 + b_2 (\alpha_0 + \alpha_1 x_1)$$

$$= (b_0 + b_2 \alpha_0) + (b_1 + b_2 \alpha_1) x_1$$



$\alpha \sim$
 b_1, b_2 έχουν
 επίρροια
 ως effects
 zw x_1, x_2

Єow $x_1 = \text{age}$
 $x_2 = \text{height}$
 $y = \text{bafos}$

① Єow μoręo 1 $Y = b_0 + b_1 x_1$ $x_1 = \text{age}$
Єow $R^2 = 0.70$

② Єow μoręo 2 $Y = b_0 + b_1 x_2$ $x_2 = \text{height}$
 $R^2 = 0.75$

③ Єow μoręo 3 κ' $\mu\text{ręifortę}$ $\rho(x_1, x_2) = 0.99$
 $Y = b_0 + b_1 x_1 + b_2 x_2$
 $R^2 \approx 0.75$

$$\text{Mod 1} : Y = b_0 + b_1 \text{ age}$$

$$R^2 = 0.87$$

$$\left. \begin{array}{l} \text{SSR} = 10255910 \\ \text{SSE} = 1485592 \end{array} \right\} \text{SST} = 11741502$$

$$\text{Mod 2} \quad Y = b_0 + b_1 \cdot \text{extime} \quad R^2 = 0.911$$

$$\text{SSR} = 10701573$$

$$\text{SSE} = 1039929$$

$$\text{Mod 3} : Y = b_0 + b_1 \text{ age} + b_2 \text{ extime} \quad R^2 = 0.92$$

$$\text{SSR} = 10255910 +$$

$$552338$$

$$\text{SSE} = 933254$$

$H_0: b_{age} = 0$ $H_1: b_{age} \neq 0$ $p = 0.0001$

Mod 1 (age)

$$SSR = 10255910$$

$$SSE = 1485592$$

$$SST = 11741502$$

$p = 0.30$ $H_0: b_{age} = 0$ $H_1: b_{age} \neq 0$

Mod 2 (extime)

$$SSR = 10701573$$

$$SSE = 1039929$$

$$SST = 11741502$$

Mod 3 (age+extime)

$$SSR = 10808248$$

$$SSE = 933254$$

$$SST = 11741502$$

$$SS(\text{age}) = 10255910$$

$$SS(\text{extime}) = 10701573$$

$$SS(\text{age+extime}) = 10808248$$

$$SS(\text{age|extime})$$

$$= SS(\text{age+extime}) - SS(\text{extime}) =$$

$$= 106675$$

$$SS(\text{age}) = 10255910$$

$$SS(\text{extime+age}) = 10808248$$

$$SS(\text{extime|age}) = SS(\text{extime+age}) - SS(\text{age})$$

$$= 552338$$

$$Y = b_0 + b_1 \cdot \text{Runtime}$$

$$R^2(\text{RT}) = 0.90$$

$$P_{\text{RT}} = 0.003$$

$$Y = b_0 + b_1 \text{age} + b_2 \text{Runtime}$$

$$R^2(\text{RT}|\text{age}) = 0.05$$

$$P_{\text{RT}|\text{age}}$$

$$= 0.45$$

An example

$$P_{\text{RT}|\text{age}} = 0.03 \leftarrow$$