

6-10-2021

Παλινδρόμηση

$X = (X_1, \dots, X_p)$ Διάφορα τυχαία μεταβλητών
inputs - ανεξ. μεταβλητές

$Y =$ τυχαία μεταβλητή (outcome - εξαρτημένη)

συνάρτηση πρόβλεψης του Y : $f(X)$

$$f(X) = E(Y|X)$$

Στατιστική : \cup υποθέτουμε $E(Y|X) = b_0 + b_1 X_1 + \dots + b_p X_p$

Επίσημα του b, σ^2

b αγνώστη παράμετροι

$$Y|X \sim \mathcal{N}(b_0 + b_1 X_1 + \dots + b_p X_p, \sigma^2)$$

Γενική Πρόσβαση (Αρχικά ελαφριά στατιστική υπόθεση)

Θεωρούμε του κείνου συναρτησίου πρόβλεψης

$$f(X) = b_0 + b_1 X_1 + \dots + b_p X_p \leftarrow$$

Θέσω $X_0 = 1$, $b = (b_0, b_1, \dots, b_p) \in \mathbb{R}^{p+1}$

$$\boxed{f(x) = \underline{x}^T b} \quad \left[\underline{x} = (X_0, X_1, \dots, X_p) \right]$$

$$X = \text{χρώμα} \in \{R, G, B\}$$

$$\left. \begin{aligned} X_R &= 1 (X=R) \\ X_G &= 1 (X=G) \\ X_B &= 1 (X=B) \end{aligned} \right\} \Rightarrow \tilde{X} = (X_R, X_G, X_B)$$

$$\begin{aligned} X=R &\Rightarrow \tilde{X} = \begin{pmatrix} 1 & 0 & 0 \end{pmatrix} \\ B &\Rightarrow \tilde{X} = \begin{pmatrix} 0 & 0 & 1 \end{pmatrix} \\ G &\Rightarrow \tilde{X} = \begin{pmatrix} 0 & 1 & 0 \end{pmatrix} \end{aligned}$$

← είναι ο αναφοράς

Interaction / Αλληλεπίδραση

$$Y = b_0 + b_1 X_1 + b_2 X_2 + \underbrace{b_3 X_1 X_2}_{\text{interaction term}}$$

$$\frac{\partial Y}{\partial X_1} = b_1 + b_3 X_2 = \text{η επίδραση του } X_1 \text{ οπου } Y \text{ εξαρτάται από το } X_2$$

$$\frac{\partial}{\partial X_2} \left(\frac{\partial Y}{\partial X_1} \right) = \underline{\underline{b_3}} \leftarrow \text{αλληλεπίδραση}$$

Επίπεδο Να βρεθεί \hat{b} τέτοιο
 ώστε η $f(x) = x^T \hat{b}$ να κάνει
 τον καλύτερο προσάρμοξη στα δεδομένα
 του training set:

Κριτήριο Αποδοσία ζεραγωνισμών καταλοίπων
 Residual sum of Squares (RSS)

$$RSS(b) = \sum_{i=1}^N [y_i - \underline{f(x_i)}]^2 \quad \underline{f(x_i)} = x_i^T b$$

$$\underline{e} = \begin{pmatrix} y_1 - x_1^T b \\ y_2 - x_2^T b \\ \vdots \\ y_N - x_N^T b \end{pmatrix}$$

$$RSS(b) = \underline{e}^T \underline{e}$$

$$X \quad b$$

$N \times (p+1) \quad (p+1) \times 1$

$$\underline{e} = \underline{y} - X \underline{b}$$

$$RSS(b) = (\underline{y} - X \underline{b})^T (\underline{y} - X \underline{b})$$

$$\begin{aligned}
 \min_b \text{RSS}(b) &= \min_b (y - Xb)^T (y - Xb) \\
 &= \min_b \left(y^T y - \underbrace{y^T X b}_{a^T b} - \underbrace{b^T X^T y}_{b^T a} + b^T X^T X b \right) \\
 &= \min_b \left(y^T y - 2 y^T X \cdot b + \underline{b^T X^T X b} \right)
 \end{aligned}$$

$\text{RSS}(b)$: kupri (b)

$$\begin{aligned}
 \nabla^2 \text{RSS}(b) &= 2 X^T X \\
 X^T X &\text{ detaká opoféivos} \\
 \Leftrightarrow X &\text{ ntipos baktori}
 \end{aligned}$$

Επιπέδων $RSS(b) \leftarrow \min_b$ για $\nabla_b RSS(b) = 0$.

$$RSS(b) = y^T y - 2 \overbrace{y^T X}^{\alpha^T} \cdot b + \underbrace{b^T X^T X}_A b.$$

$$\nabla_b RSS(b) = \begin{pmatrix} \frac{\partial RSS}{\partial b_0} \\ \vdots \\ \frac{\partial RSS}{\partial b_p} \end{pmatrix} = \frac{-2 X^T y + 2 (X^T X) \cdot b}{}$$

Παράδειγμα $g(\underline{b}) = \alpha^T \cdot b = \alpha_0 b_0 + \alpha_1 b_1 + \dots + \alpha_p b_p$

$$\frac{\partial g}{\partial b_i} = \alpha_i \quad \Rightarrow \quad \nabla g = \begin{pmatrix} \alpha_0 \\ \alpha_1 \\ \vdots \\ \alpha_p \end{pmatrix} = \alpha.$$

$$h = b^T A b = \sum_{ij} \alpha_{ij} b_i b_j, \quad A : \text{συμμετρικός}$$

$$\delta.o. \quad \nabla_b b^T A b = 2Ab$$

$$\nabla_b \text{RSS}(b) = 0 \Rightarrow -2X^T(y - Xb) = 0 \Leftarrow$$

$$\Rightarrow X^T y = X^T X \cdot b \Rightarrow$$

$$\hat{b} = (X^T X)^{-1} \cdot X^T \cdot y$$

$$\hat{y} = \begin{pmatrix} \hat{y}_1 \\ \vdots \\ \hat{y}_n \end{pmatrix} = \underbrace{X \cdot \hat{b}} = \underbrace{X (X^T X)^{-1} \cdot X^T}_{H} \cdot y = H \cdot y$$

$$\hat{y} = H \cdot y$$

H : hat matrix

$$\begin{pmatrix} H^T = H \\ H^2 = H \end{pmatrix}$$

New representation $\underline{x}_0^T = (x_{00}, \dots, x_{0p})$

$$\hat{y} = x_0^T \cdot \hat{b}$$

Στατιστικές Ιδιότητες του $\hat{\beta}$

① Υποθέτουμε y_1, \dots, y_N : αυστηρά ανεξάρτητες από (αλληλοσυσχετισμό)

ομοσκεδαστικότητα $\rightarrow \text{Var}(y_1) = \dots = \text{Var}(y_N) = \sigma^2$

X : όχι weights

$\hat{\beta}$ = best linear unbiased estimator $\in \mathbb{R}^{p+1}$

$$\hat{\beta} = (X^T X)^{-1} \cdot X^T \underline{y}$$

Παραρ. 1: $\rightarrow x_1^T = (x_{10}, \dots, x_{1p})$ $y_1 | X_1 = x_1 \rightarrow y_1$
 $\rightarrow x_2^T = (x_{20}, \dots, x_{2p})$ $y_2 | X_2 = x_2 \rightarrow y_2$

$$E(\hat{\beta}) = (X^T X)^{-1} \cdot X^T \cdot \underline{E(y)}$$

$$\text{Var}(\hat{\beta}) = \text{Var}(G \cdot \underline{y}) = G \text{Var}(\underline{y}) G^T \quad \left\{ G = (X^T X)^{-1} \cdot X^T \right.$$

$$\underline{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix} \Rightarrow \text{Var}(\underline{y}) = \sigma^2 \underline{I} = \begin{pmatrix} \sigma^2 & & 0 \\ & \ddots & \\ 0 & & \sigma^2 \end{pmatrix}$$

$$\underline{X} : \Sigma_x$$

$$Y = A \cdot X \Rightarrow \Sigma_y = A \Sigma_x A^T \quad (\text{nidarövert}).$$

$$\Rightarrow \text{Var}(\hat{b}) = G \cdot \sigma^2 I \quad G^T = \sigma^2 \cdot G G^T$$

$$\left. \begin{array}{l} G = (X^T X)^{-1} \cdot X^T \\ G^T = X (X^T X)^{-1} \end{array} \right\} \Rightarrow G G^T = \underbrace{(X^T X)^{-1}}_I \cdot \underbrace{X^T X}_I (X^T X)^{-1} = (X^T X)^{-1}$$

$$\Rightarrow \boxed{\text{Var}(\hat{b}) = (X^T X)^{-1} \cdot \sigma^2} \leftarrow$$

Ιδιότητες

(1) Αν εκτιμήσουμε το σ^2 : $\hat{\sigma}^2 = \frac{1}{N-p-1} \sum_{i=1}^N (y_i - \hat{y}_i)^2$

$E(\hat{\sigma}^2) = \sigma^2$ $\hat{\sigma}^2$: αμερόληπτη

(δείξτε το !!)

$\hat{\sigma}^2 = \frac{RSS(\hat{b})}{N-p-1}$

[συνολική διασπορά
μειν. MSB]

Στατιστική Συμπληρωματικότητα για τα \hat{b}

Επιπλέον υποθέσεις $E(y|X=x) = \boxed{x^T \cdot b}$ ⁽¹⁾ $= b_0 + b_1 x_1 + \dots + b_p x_p$

όπου b_0, b_1, \dots, b_p αγνώστους παράμετροι

$y|X=x = x^T b + \varepsilon$, $\varepsilon \sim \boxed{N(0, \sigma^2)}$ ⁽²⁾

$\varepsilon_1, \varepsilon_2, \dots, \varepsilon_N$ ανεξάρτητα

y_1, \dots, y_N ανεξάρτητα

$E \hat{b} = \underbrace{(X^T X)^{-1}}_G \cdot X^T \cdot E y =$

$\hat{b} = G \cdot y$

$= \underbrace{(X^T X)^{-1}} \cdot \underbrace{X^T \cdot X}_{b} = b \Rightarrow \boxed{E(\hat{b}) = b}$ αμερόληπτη

$\hat{y} = X \cdot \hat{b} \Rightarrow E(\hat{y}) = E(y)$:

και οι προβλέψεις
είναι αμερόληπτες !!

δεν έχουν συστηματικό
σφάλμα

Αν δώσουμε $E(y|x) = x^T \cdot b$ κ' εμείς εκτιμήσουμε \hat{b} , $\hat{y} = X \hat{b} \Rightarrow \boxed{E(\hat{y}) \neq E(y)}$ βία

