

18-10-2021

Γραμμικές Μέθοδοι Ταξινόμησης

μεταβλητή $\underline{X} = (X_1, \dots, X_p)$: predictors/ανεξ. μεταβλητές
features

G : εξαρ. μεταβλητή (outcome)

$G \in \{1, 2, \dots, K\} \equiv \{g_1, \dots, g_K\}$
κατηγορίες (classes)

Παρατήρηση i στο training set: $(x_i^T) = (x_1, \dots, x_p)$
 $g_i \in \{1, \dots, K\}$, $i=1, \dots, N$

$\Rightarrow \dots \Rightarrow$ συνάρτηση πρόβλεψης

$\hat{G}(\underline{x})$ = πρόβλεψη για την
κατηγορία μιας νέας
Παρατήρησης με σημείο \underline{x}

Συνάρτηση απώλειας $L(G, \hat{G}) =$
 κόστος/απώβεια αν σε μια παρατήρηση
 κατηγορίας G προβλέψουμε \hat{G}

Επιλέγουμε $L(G, \hat{G}) = 1(\hat{G} \neq G)$

Μέσο σφάλμα πρόβλεψης $\left[\begin{array}{l} \text{θεωρώντας } (X, G) \\ \text{από κοινού κατανομή} \end{array} \right]$

$$\begin{aligned} EPE &= E_{(X, G)} [L(G, \hat{G})] = E[1(\hat{G} \neq G)] = \\ &= P(\hat{G} \neq G) \end{aligned}$$

Δεδομένου $X=x$

$$\begin{aligned} EPE(x) &= P(\hat{G}(x) \neq G | X=x) = \\ &= \sum_{k=1}^K P(G=k | X=x) \cdot P(\hat{G}(x) \neq k) \end{aligned}$$

\swarrow σφάλμα
 " 1 αν $k \neq \hat{G}(x)$
 0 αν $k = \hat{G}(x)$

$$= P(G \neq \hat{G}(x) | X=x) = \underline{1 - P(G = \hat{G}(x) | X=x)}$$

$\min_{\hat{G}} EPE(x)$

\Rightarrow


$$\max_{\hat{G}=1, \dots, K} P(G = \hat{G}(x) | X=x)$$

Ενοπίευσ αν $G|X=x$ είναι γνωστή κατανομή

\Rightarrow Bayes classifier: $\hat{G}(x) = \underset{k \in \mathcal{K}}{\operatorname{argmax}} P(G=k|X=x)$

$\left[\operatorname{argmax}_{x \in A} f(x) = \{x^* : f(x^*) \geq f(x) \forall x \in A\} \right]$
συνεπώς μπορούμε argmax οποιαδήποτε ζευγί να μην δουλεύει

Γιατί Bayes?



Γνωρίζω $\left[P(E_1), \dots, P(E_k) \right] \rightarrow$ prior
 $\left. \begin{matrix} P(A|E_1) \dots P(A|E_k) \end{matrix} \right\}$

Με ενδιαφέρει $P(E_1|A), \dots, P(E_k|A) \rightarrow$ posterior

$$P(E_j|A) = \frac{P(A|E_j) P(E_j)}{\sum_j P(A|E_j) P(E_j)} \sim P(E_j) P(A|E_j)$$

Εστω prior κατανομή των G :

$$(\pi_1, \dots, \pi_k) \quad \pi_j = P(G=j) \quad \left. \vphantom{(\pi_1, \dots, \pi_k)} \right\} \text{πriors'}$$

Εστω $f_k(x)$: σππ των $(X|G=k)$

και finally

$$P(G=k | X=x) = \frac{\pi_k f_k(x)}{\sum_{k=1}^K \pi_k f_k(x)} =$$
$$= \underline{C(x) \cdot \pi_k f_k(x)}$$

① Classification via Linear Regression

$$\forall k=1, \dots, K \quad Y_k = 1(G=k) = \begin{cases} 1 & G=k \\ 0 & G \neq k \end{cases}$$

$$\underline{G} \Leftrightarrow \underline{Y} = (Y_1, \dots, Y_K) = (0, \dots, \underset{\substack{\uparrow \\ k=G}}{1}, \dots, 0)$$

$$\textcircled{A} \quad \forall k \quad Y_k = b_{k0} + b_{k1}X_1 + \dots + b_{kp}X_p \Rightarrow \hat{b}_k = (\hat{b}_{k0}, \hat{b}_{k1}, \dots, \hat{b}_{kp})^T \text{ LSE}$$

$$k=1, \dots, K, \quad Y_k = (\underline{1}, X^T) b_k$$

② Πολλαπλάσια Παρενδρίση (Multivariate Regression) (Πηχτές εξαρτημένες μεταβλητές)

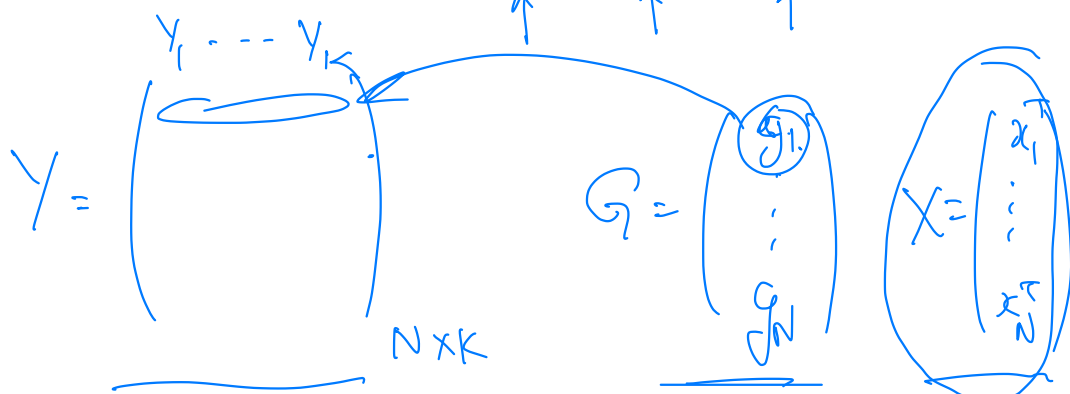
$$\underline{Y} = (Y_1, \dots, Y_K) =$$

$$= \left((\underline{1}, X^T) \underline{b}_1, \dots, (\underline{1}, X^T) \underline{b}_k \right)$$

$$= (\underline{1}, X^T) B, \quad B = \begin{pmatrix} \underline{b}_1 & \dots & \underline{b}_k \end{pmatrix}_{(p+1) \times K}$$

$$= \begin{pmatrix} b_{10} & b_{20} & \dots & b_{k0} \\ \vdots & \vdots & \dots & \vdots \\ b_{1p} & b_{2p} & \dots & b_{kp} \end{pmatrix} \in \mathcal{B}$$

Training set:



$$\forall i=1, \dots, N \Rightarrow \hat{y}_i \in \mathbb{R}^k$$

$$= \hat{y}_i = (\hat{y}_{i1}, \dots, \hat{y}_{ik}) = \underline{(1, x_i^T)} \hat{B}$$

Loss function $\sum_{i=1}^N \sum_{k=1}^K (\hat{y}_{ik} - y_{ik})^2 \leftarrow \min_{\hat{B}}$

$$= \sum_{k=1}^K \left[\sum_{i=1}^N (\hat{y}_{ik} - y_{ik})^2 \right] -$$

RSS(\underline{b}_k) (multiple regression zum Y_k)

(A), (B) immer

\hat{B} : \forall für $k=1, \dots, K$
 möglich $\hat{b}_k = \underbrace{(X^T X)^{-1}}_G X^T \underline{y}_k$ $\underline{y}_k = X(X^T X)^{-1} X^T y_k = H y_k$

$$\hat{B} = (\hat{b}_1, \dots, \hat{b}_k)$$

$$= (G \underline{y}_1, \dots, G \underline{y}_k) = G Y$$

$$\hat{B} = G Y$$

$$\hat{Y} = H Y$$

$$\hat{Y} = HY$$

$$Y, \hat{Y} \in \mathbb{R}^{N \times (p+1)}, \quad H \in \mathbb{R}^{(p+1) \times (p+1)}$$

\hat{y}_1 εικρίφουμ τωυ $y_1 = \begin{cases} 0 \\ 1 \end{cases}$

$$\forall x \Rightarrow \hat{y}_1(x), \hat{y}_2(x), \dots, \hat{y}_K(x)$$

$$\hat{g}(x) = k \quad \text{αν} \quad \hat{y}_k(x) = \max_j \hat{y}_j(x), \quad j=1, \dots, K$$

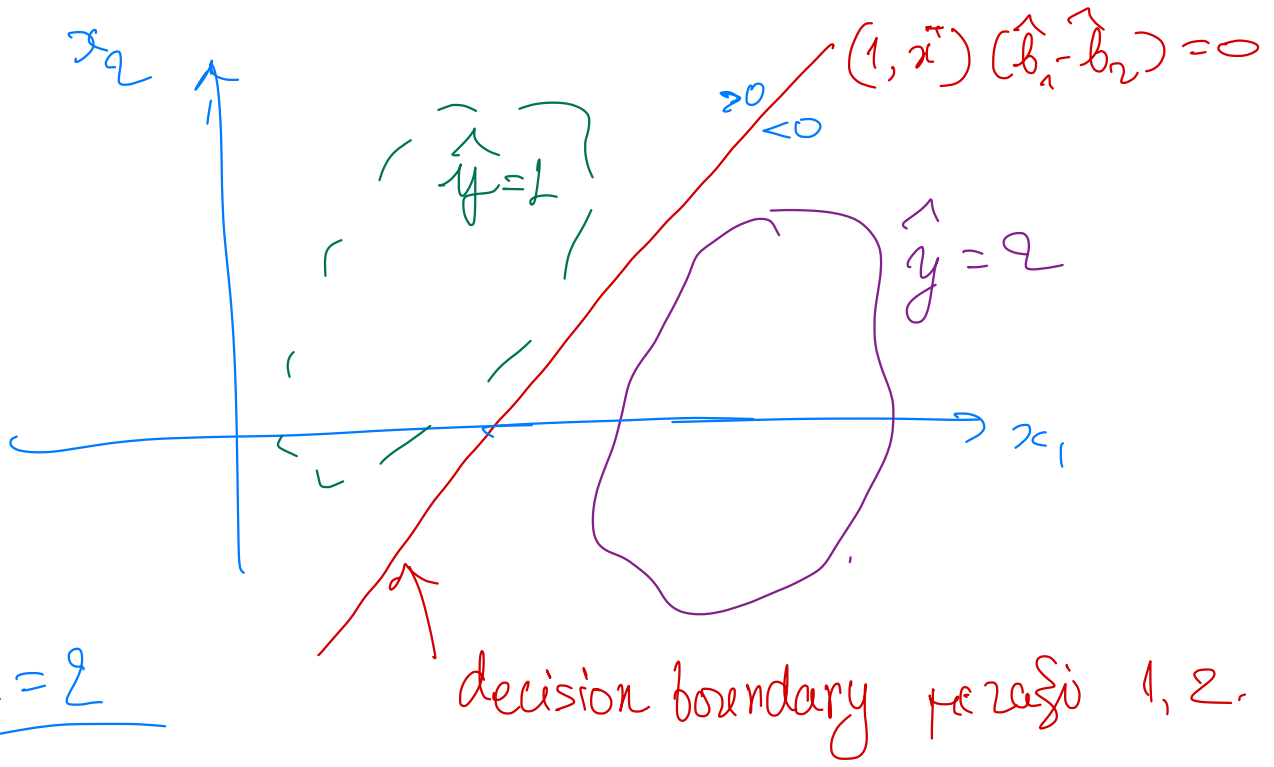
$$\text{Εωυ} \quad k, l \in \{1, \dots, K\}$$

Μεταξυ των k, l με παραρρημ α θα
ραξυνοφινδι ωυ k αν $\forall \hat{y}_k(x) \geq \hat{y}_l(x)$

$$\hat{b}_{k0} + \hat{b}_{k1}x_1 + \dots + \hat{b}_{kp}x_p = (1, x^T) \hat{b}_k \geq (1, x^T) \hat{b}_l$$


$$\Rightarrow \left[(1, x^T) (\hat{b}_k - \hat{b}_l) \geq 0 \right] \begin{matrix} > & k \\ = 0 & \text{αδίαφρ.} \\ < 0 & l. \end{matrix}$$

Καίονα για διακρηον μεταξυ k, l .




$K=2$

$K=3$



Παράδειγμα

$x \in \mathbb{R}$, $K=3$



y_1, y_2, y_3

