

13/3/2025

Παρασκευή 14/3 : Αέθουσα Γ εργαστήριο

Classification Problems

$$Y \in \{g_1, g_2, \dots, g_K\}$$

$X = (X_1, \dots, X_p)$ ανεξάρτητες μεταβλητές

(X, Y) από κοινού (άγνωστη) κατανομή

$$P(Y = g_k | X = x) \quad k = 1, 2, \dots, K$$



$$F(X | Y = g_k) = P(X \leq x | Y = g_k) \quad \left(\begin{array}{l} \text{για } p=1, \text{ έχουμε} \\ f(x | g_k) = \text{δυσμενής} \\ \text{ή η στήλη} \end{array} \right)$$

π.χ. $X = (X_1, \dots, X_p)$ (μετρήσιμες αξίες/αποδοχές)


$$Y = \begin{cases} 1, & \text{έχει ασθένεια} \\ 0, & \text{υγιής} \end{cases}$$

$$P(Y = 1 | X = x) \leftarrow \begin{array}{l} \text{δίνω των ηθαιώμενων νόσων} \\ \text{διδόμειον των μετρήσεων} \\ \text{(θέλω να το εξεπείσωμε} \\ \Rightarrow \text{"πρόβλεψη"}) \end{array}$$

$$\left. \begin{array}{l} F(X | Y = 0) : \text{κατανομή } X \text{ για υγιείς} \\ F(X | Y = 1) \quad \quad \quad " \quad \quad \quad X \quad \quad \quad \text{ασθενείς} \end{array} \right\} \Rightarrow \begin{array}{l} \text{κλινικές} \\ \text{δοκιμές} \\ \text{(case-control)} \end{array}$$



$$X = (X_1, X_2)$$



$$\text{Eow } \left. \begin{array}{l} P(Y=1) = p \\ P(Y=0) = 1-p \end{array} \right\} \text{ nepiθwria } (Y)$$

Bayes

$$P(Y=1|X=x) = \frac{p \cdot f(x|y=1)}{p \cdot f(x|y=1) + (1-p) \cdot f(x|y=0)}$$

Κριτήριο / Συνάρτηση Αιωλέας

Γενικό μοντέλο $Y \in \{g_1, \dots, g_K\}$ (μεθοδολογία)

Training set $(x_1, y_1), \dots, (x_n, y_n) \Rightarrow \dots \Rightarrow$

$\hat{G}(x)$: προβλεπτική συνάρτηση
 $\hat{G}(x) \in \{g_1, \dots, g_K\}$ } πόσο καλή είναι η $\hat{G}(x)$?

Test Set $\{(x_0, y_0), \dots\}$

$$\hat{y}_i = \hat{G}_i(x_i) \quad i \in \text{TestSet}.$$

$$\text{Κριτήριο (Συνάρτηση αιωλέας)} = L(y, \hat{G})$$

$$\text{Ενώ } L(y_i, \hat{y}_i) = \begin{cases} 1 & , y_i \neq \hat{y}_i \\ 0 & , y_i = \hat{y}_i \end{cases} = 1 - \frac{I(y_i = \hat{y}_i)}{\delta_{y_i, \hat{y}_i}}$$

(ie Test)

$$L(y, \hat{G}) = \frac{\sum_{i \in \text{Test}} L(y_i, \hat{G}(x_i))}{|\text{Test set}|} = \frac{\% \text{ λάθος ταξινομήσεων}}{(\text{misclassification rate})}$$

$$\text{MPE} = E_{(x,y)} (L(y, \hat{G}(x))) \leftarrow$$

$$\text{Για } L = 1 - I(y_i = \hat{y}_i)$$

min
 $\hat{G}$
 $\in \text{class}$

$$E[L(Y, \hat{G}(x))] = E_x \left[E_{Y|X} (L(Y, \hat{G}(x)) | X) \right]$$

$$= E_x \left[\sum_{k=1}^K P(Y = g_k | X) \cdot L(g_k, \hat{G}(x)) \right]$$

Bayes risk

Σημιακή βελτιστοποίηση

$$\forall x : \min_{\hat{G}(x)} \sum_{k=1}^K P(Y = g_k | X=x) \cdot L(g_k, \hat{G}(x))$$

$\hat{G} \in \{g_1, \dots, g_K\}$

Αν $L(y, \hat{y}) = 1 - I(y = \hat{y})$

Τότε $\sum_{k=1}^K P(Y = g_k | X=x) L(g_k, \hat{G}(x)) =$

$$= \sum_{g_k \neq \hat{G}(x)} P(Y = g_k | X=x) \cdot 1 = \boxed{1 - P(Y = \hat{G}(x) | X=x)}$$

Βέλτιστη Πρόβλεψη $| X=x$


$$\min_{\hat{G}} \{1 - P(Y = \hat{G} | X=x)\} \Leftrightarrow \boxed{\max_{\hat{G}} P(Y = \hat{G} | X=x)}$$

$$\Rightarrow \hat{G}(x) = \operatorname{argmax}_{g \in \{g_1, \dots, g_K\}} P(Y = g | X=x)$$

Bayes classifier

Τία $X = (X_1, X_2)$, $Y \in \{0, 1\}$

$$\hat{G}(x) = \begin{cases} 0, & P(Y=1|X=x) < 1/2 \\ 1, & P(Y=1|X=x) > 1/2 \end{cases}$$



Παραμετρικά μοντέλα

1) Logistic Regression ($Y \in \{0, 1\}$)
 $\rightarrow P(Y=1|x) = p(x)$

$$\log \frac{p(x)}{1-p(x)} = b_0 + b_1^T \cdot x$$

μοντέλο

2) Generative Models (Discriminant Analysis)

$$F(x|0) \sim \dots \dots \dots \text{αριστερά} \quad \text{στην}$$

$$F(x|1) \sim \dots \dots \dots \text{"} \quad \text{στην.}$$

$$\text{Training set} \Rightarrow \left. \begin{matrix} \hat{F}(x|0) \\ \hat{F}(x|1) \end{matrix} \right\} \Rightarrow \text{Bayes} \cdot \hat{P}(Y=1|x=x)$$

n.x. av $X = X_1$

$$X|Y=0 \quad X \sim \mathcal{N}(\mu_0, \sigma^2)$$

$$X|Y=1 \quad X \sim \mathcal{N}(\mu_1, \sigma^2)$$

x.b.g. $(\mu_1 > \mu_0)$

$$f(x|y=0) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu_0)^2}{2\sigma^2}}$$

$$f(x|y=1) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu_1)^2}{2\sigma^2}}$$

$$P(Y=1|X=x) = \frac{p f(x|1)}{p f(x|1) + (1-p) f(x|0)}$$

$$P(Y=0|X=x) = \frac{(1-p) f(x|0)}{p f(x|1) + (1-p) f(x|0)}$$

Kanones Bayes classifier

$$\hat{G}=1 \quad \text{av} \quad p f(x|1) > (1-p) f(x|0) \Rightarrow$$

$$\Leftrightarrow \frac{f(x|1)}{f(x|0)} > \frac{1-p}{p} \Leftrightarrow$$

$$\log \frac{f(x|1)}{f(x|0)} > \log \frac{1-p}{p} = A$$


$$\log f(x|1) - \log f(x|0) > A \Leftrightarrow$$

$$\Leftrightarrow \frac{(x-\mu_0)^2}{2\sigma^2} - \frac{(x-\mu_1)^2}{2\sigma^2} > A \Leftrightarrow$$

$$\overbrace{(\mu_1 - \mu_0)}^{>0} (2x - (\mu_1 + \mu_0)) > 2A\sigma^2 \Rightarrow$$

$$\Rightarrow 2x - (\mu_1 + \mu_0) > \frac{2A\sigma^2}{\mu_1 - \mu_0} = C \Rightarrow$$


$$\Rightarrow x > \frac{\mu_1 + \mu_0}{2} + \frac{C}{2}$$



Av $X = (X_1, X_2)$


$$\left. \begin{array}{l} X|Y=0 \sim \mathcal{N}(\mu_0, \Sigma) \\ X|Y=1 \sim \mathcal{N}(\mu_1, \Sigma) \end{array} \right\} \Rightarrow \dots$$

$$P(Y=1|X=x) > P(Y=0|X=x) \Leftrightarrow \boxed{a^T x > C}$$




Σύνορο Bayes

Υγιεινά



Μέθοδος knn (k nearest neighbor)

Εκτίμηση $P(Y=j | X=x_0)$ με παραμετροί



Εστω k=4

$N_0(x_0) = \{ 4 \text{ κοντινότερα σημεία του training set} \\ \text{στο } x_0 \text{ (ως προς } x) \}$


κοντινότερα : $\|x - x_0\|$

$|N_0(x_0)| = k \quad \& \quad \|x_i - x_0\| < \|x_j - x_0\| \quad \forall i \in N_0, j \notin N_0$

$\hat{G}(x_0) = g_i$ or
 ↓
 Estimation
 on training set

$$\frac{1}{K} \sum_{j=1}^K I(y_j = g_i) \leftarrow \max_i$$

% napar. on y_0
 not equal $y = g_i$



$K=1$ $n!$ $K \rightarrow n$ ($n = |\text{Training set}|$)

ευεξής

←
+ —


1. Για $K \rightarrow n$ (μεγάλο)

$\forall x_0$: % ($Y=1$) = αναλογία = % ($Y=1$) στο = q_1
 training set.

or $q_1 > 1/2 \Rightarrow \hat{G}(x_0) = 1 \quad \forall x_0$
 $q_1 < 1/2 \Rightarrow \hat{G}(x_0) = 0$



} ελάχιστη
ευεξής

2 Ovar $k \rightarrow 1$



KNN: K=1

KNN: K=100



Dawid's
diavolo
Bayes

Παράδειγμα

$$Y \in \{0, 1\}$$

$$X = (X_1, X_2)$$

$$(X_1, X_2)_{iid} \sim \mathcal{U}(0, 1)$$

$$P(Y=1 | X=(x_1, x_2)) = p(x_1, x_2)$$

$$Y | (X_1=x_1, X_2=x_2) \sim \text{Ber}(p(x_1, x_2))$$

Προσφοίωση

Υποθέτω συνάρτηση συνόρου :

$$p(x_1, x_2) = \begin{cases} \frac{1}{2} \left(\frac{x_2}{b(x_1)} \right)^\alpha, & x_2 < b(x_1) \\ \frac{1}{2} \left(\frac{1-x_2}{1-b(x_1)} \right)^\alpha, & x_2 > b(x_1) \end{cases}$$

$$\text{όπου } b(x_1) = 0.7 + 0.1 x_1 - 0.8 x_1^2 + 4 x_1^3 - 2.8 x_1^4$$

$$\text{Bayes boundary : } \{(x_1, x_2) : p(x_1, x_2) = \frac{1}{2}\}$$

Αλγόριθμος Προσφοίωσης

Έστω $n = 1000$ (μέγεθος training set)

$$\alpha = 2$$

$$K = 10 \quad (\text{κνη})$$

- 1) Δημιουργώ N -training sets μέσω προσφοίωσης από την παραπάνω κατανομή. $(N \rightarrow \infty)$

2) Δημιουργία 1 test set μεγέθους
 $n_{\text{test}} = 100$ από την ίδια κατανομή.

3) Για κάθε training set $r=1,2,\dots,N$

Ⓐ Εφαρμογή του knn ($k=10$) σε r

Ⓑ βρίσκω προβλέψεις $\hat{y}_j$ $j \in \text{Test set}$

Ⓓ υπολογίζω % misclassification

% λάθος test set όπου $\hat{y} \neq y$

MPE_r

$$4) \hat{MPE} = \frac{1}{N} \sum_{r=1}^N MPE_r$$

$MPE_r, r=1,2,\dots$ iid

$$\hat{MPE} \xrightarrow{N \rightarrow \infty} MPE \quad (\mu.n.1)$$

(Monte Carlo Simulation)

