

Θεωρία Αποφάσεων

Παρακάτω παρουσιάζονται συνοπτικά τα παραδείγματα τα οποία παρουσιάστηκαν κατά τη διάρκεια των διαλέξεων του μαθήματος και δεν συμπεριλαμβάνονται στο βιβλίο του μαθήματος.

ΚΕΦΑΛΑΙΟ 2^ο

Υπο Συνθήκη Πιθανότητες

$P(A | B)$ = Υποσύνολο του δειγματικού χώρου στο οποίο το B είναι αληθές και στο οποίο επίσης και το A είναι αληθές

Παράδειγμα

H = "Have a headache"

F = "Coming down with Flu"

$$P(H) = 1/10$$

$$P(F) = 1/40$$

$$P(H | F) = 1/2$$

"Headaches are rare and flu is rarer, but if you're coming down with 'flu there's a 50-50 chance you'll have a headache."

$P(H | F)$ = Fraction of flu-inflicted worlds in which you have a headache

$$= \frac{\text{\#worlds with flu and headache}}{\text{\#worlds with flu}}$$

$$= \frac{\text{Area of "H and F" region}}{\text{Area of "F" region}}$$

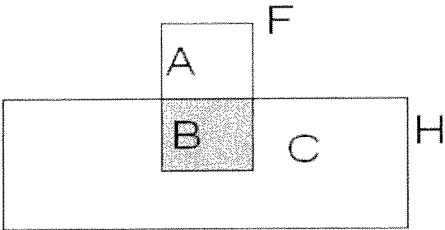
$$= \frac{P(H \wedge F)}{P(F)}$$

Πιθανοτικό Inference

One day you wake up with a headache. You think: "Drat! 50% of flus are associated with headaches so I must have a 50-50 chance of coming down with flu"

Is this reasoning good?

Another way to understand the intuition



Let's say we have $P(F)$, $P(H)$, and $P(H|F)$, like in the example in class.

Areawise, $P(F) = A + B$, $P(H) = B + C$,

Also, $P(H|F) = \frac{B}{A + B}$

Thus, to get the opposite conditional probability, i.e. $P(F|H)$, we need to figure out $\frac{B}{B + C}$

Since we know $B / (A+B)$, we can get $B / (B+C)$ by multiplying by $(A+B)$ and dividing by $(B+C)$. But since we already calculated, $A+B = P(F)$, and $B+C = P(H)$, so we are actually multiplying by $P(F)$ and dividing by $P(H)$. Which is Bayes Rule:

$$P(F|H) = P(H|F) * \frac{P(F)}{P(H)}$$

Ελαχιστοποίηση της πιθανότητας λάθους (Bayes Decision Rule)

Παράδειγμα

Classify cars on UNR campus whether they are more or less than \$50K:

- C1: price > \$50K
- C2: price < \$50K
- Feature x: height of car

From Bayes' rule, we know how to compute the posterior probabilities:

$$P(C_i / x) = \frac{p(x / C_i) P(C_i)}{p(x)}$$


Need to compute $p(x/C_1)$, $p(x/C_2)$, $P(C_1)$, $P(C_2)$

Determine prior probabilities

- Collect data: ask drivers how much their car was and measure height.
- e.g., 1209 samples: #C₁=221 #C₂=988


$$P(C_1) = \frac{221}{1209} = 0.183$$

$$P(C_2) = \frac{988}{1209} = 0.817$$




Determine class conditional probabilities (*likelihood*).

- Discretize car height into bins and use normalized histogram.



Calculate the posterior probability for each bin:


$$\begin{aligned}
 P(C_1 / x = 1.0) &= \frac{p(x = 1.0 / C_1) P(C_1)}{p(x = 1.0 / C_1) P(C_1) + p(x = 1.0 / C_2) P(C_2)} = \\
 &= \frac{0.2081 * 0.183}{0.2081 * 0.183 + 0.0597 * 0.817} = 0.438
 \end{aligned}$$



- Consider a classification problem with two classes defined by the following likelihood functions

$$P(x|\omega_1) = \frac{1}{\sqrt{2\pi}\sqrt{3}} e^{-\frac{1}{2} \frac{x^2}{3}}$$

$$P(x|\omega_2) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2}$$



- What is the decision rule that minimizes P[error]?


- Assume $P[\omega_1]=P[\omega_2]=0.5$, $C_{11}=C_{22}=0$, $C_{12}=1$ and $C_{21}=3^{1/2}$

$$\Lambda(x) = \frac{\frac{1}{\sqrt{2\pi}\sqrt{3}} e^{-\frac{1}{2} \frac{x^2}{3}} \omega_1}{\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2} \omega_2} > \frac{1}{\sqrt{3}} \Rightarrow$$

$$\frac{e^{-\frac{1}{2} \frac{x^2}{3}} \omega_1}{e^{-\frac{1}{2}(x-2)^2} \omega_2} > 1 \Rightarrow$$

$$-\frac{1}{2} \frac{x^2}{3} + \frac{1}{2}(x-2)^2 > 0 \Rightarrow$$

$$2x^2 - 12x + 12 > 0 \Rightarrow x = 4.73, 1.27$$



Επιλογή της κλάσης που έχει την μεγαλύτερη εκ των υστέρων πιθανότητα (Bayes Decision Rule)

Παράδειγμα

Ταξινόμηση αυτοκινήτων στο UNR campus σύμφωνα με το αν αξίζουν περισσότερα ή λιγότερα από \$50K:

- C1: τιμή > \$50K
- C2: τιμή < \$50K
- Χαρακτηριστικό x: ύψος του αυτοκινήτου


Από τον νόμο του Bayes, ξέρουμε να υπολογίζουμε τις εκ των υστέρων πιθανότητες.

$$P(C_i / x) = \frac{p(x / C_i)P(C_i)}{p(x)}$$

Πρέπει να υπολογίσουμε τις $p(x/C1)$, $p(x/C2)$, $P(C1)$, $P(C2)$

Καθόρισε τις εκ των προτέρων πιθανότητες

- Συλλογή δεδομένων: Ρώτησε οδηγούς πόσο αγόρασαν το αυτοκίνητο τους και μέτρησε το ύψος.
- π.χ., 1209 δείγματα: #C1=221 #C2=988




$$P(C_1) = \frac{221}{1209} = 0.183$$

$$P(C_2) = \frac{988}{1209} = 0.817$$

Καθόρισε τις υπο συνθήκη συναρτήσεις π.π. (πιθανοφάνεια)

- Διακριτοποίησε το ύψος των αυτοκινήτων σε bins και χρησιμοποίησε κανονικοποιημένο ιστόγραμμα




$p(x | C_i)$

Υπολόγισε την εκ των υστέρων πιθανότητα για κάθε bin:

$$P(C_1 / x = 1.0) = \frac{p(x = 1.0 / C_1) P(C_1)}{p(x = 1.0 / C_1) P(C_1) + p(x = 1.0 / C_2) P(C_2)} =$$

$$= \frac{0.2081 * 0.183}{0.2081 * 0.183 + 0.0597 * 0.817} = 0.438$$




Κανόνες Απόφασης

Παράδειγμα

Για ένα πρόβλημα ταξινόμησης δίνονται οι παρακάτω δεσμευμένες συναρτήσεις π.π

$$P(x | \omega_1) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-4)^2}$$

$$P(x | \omega_2) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-10)^2}$$



Θεωρώντας συνάρτηση κόστους μηδέν-ένα και ίσες εκ των προτέρων πιθανότητες βρείτε έναν κανόνα απόφασης

Λύση:

Αντικαταστήνοντας της τιμές των πιθανοφαινιών και των εκ των προτέρων πιθανοτήτων στο τύπο (3):

$$\Lambda(x) = \frac{\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-4)^2} \omega_1}{\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-10)^2} \omega_2} > 1$$


Απλοποιώντας, αλλάζοντας πρόσημο και λογαριθμίζοντας :

$$(x-4)^2 - (x-10)^2 < 0$$

Οπότε:

$$\begin{array}{c} \omega_1 \\ x < 7 \\ \omega_2 \end{array}$$

Το αποτέλεσμα το αναμένουμε και διαισθητικά μια που οι πιθανοφάνειες διαφέρουν μόνο ως προς τον μέσο όρο τους




Παράδειγμα

Για ένα πρόβλημα ταξινόμησης δίνονται οι παρακάτω δεσμευμένες συναρτήσεις π.π

$$P(x|\omega_1) = \frac{1}{\sqrt{2\pi}\sqrt{3}} e^{-\frac{1}{2} \frac{x^2}{3}}$$

$$P(x|\omega_2) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2}$$




Θεωρώντας $P(\omega_1) = P(\omega_2)$, $\lambda_{11} = \lambda_{22} = 0$, $\lambda_{12} = 1$ και $\lambda_{21} = 31/2$ ποιός είναι ο κανόνας, ο οποίος μειώνει την πιθανότητα λάθους?

$$\Lambda(x) = \frac{\frac{1}{\sqrt{2\pi}\sqrt{3}} e^{-\frac{1}{2} \frac{x^2}{3}}}{\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2}} > \frac{1}{\sqrt{3}} \Rightarrow$$

$$\frac{e^{-\frac{1}{2} \frac{x^2}{3}}}{e^{-\frac{1}{2}(x-2)^2}} > 1 \Rightarrow$$

$$-\frac{1}{2} \frac{x^2}{3} + \frac{1}{2}(x-2)^2 > 0 \Rightarrow$$

$$2x^2 - 12x + 12 > 0 \Rightarrow x = 4.73, 1.27$$



Ταξινόμηση Ελάχιστου Ρυθμού Λάθους και συνάρτησεις κανονικής κατανομής

Αριθμητικό Παράδειγμα

Έστω ότι :

$$\mu_1 = [0 \ 0 \ 0]^T; \mu_2 = [1 \ 1 \ 1]^T; \Sigma_1 = \Sigma_2 = \begin{bmatrix} 1/4 & 0 & 0 \\ 0 & 1/4 & 0 \\ 0 & 0 & 1/4 \end{bmatrix}; p(\omega_2) = 2p(\omega_1)$$

$$g_i(x) = -\frac{1}{2\sigma^2}(x - \mu_i)^T(x - \mu_i) + \log P(\omega_i) = -\frac{1}{2} \begin{bmatrix} x - \mu_x \\ y - \mu_y \\ z - \mu_z \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x - \mu_x \\ y - \mu_y \\ z - \mu_z \end{bmatrix} + \log P(\omega_i)$$

$$g_1(x) = -\frac{1}{2} \begin{bmatrix} x-0 \\ y-0 \\ z-0 \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x-0 \\ y-0 \\ z-0 \end{bmatrix} + \log \frac{1}{3}; \quad g_2(x) = -\frac{1}{2} \begin{bmatrix} x-1 \\ y-1 \\ z-1 \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x-1 \\ y-1 \\ z-1 \end{bmatrix} + \log \frac{2}{3}$$

$$g_1(x) \underset{\xi_1}{\vee} \underset{\xi_2}{\wedge} g_2(x) \Rightarrow -2(x^2 + y^2 + z^2) + \log \frac{1}{3} \underset{\omega_1}{\vee} \underset{\omega_2}{\wedge} -2((x-1)^2 + (y-1)^2 + (z-1)^2) + \log \frac{2}{3}$$

$$\underset{\xi_1}{\vee} \underset{\xi_2}{\wedge} x + y + z \underset{\omega_1}{\vee} \underset{\omega_2}{\wedge} \frac{6 - \log 2}{4} = 1.32$$

$$x_u = [0.1 \ 0.7 \ 0.8]^T$$

$$0.1 + 0.7 + 0.8 = 1.6 \underset{\xi_1}{\vee} \underset{\xi_2}{\wedge} 1.32 \Rightarrow x_u \in \omega_2$$

$$\mu_1 = [0 \ 0 \ 0]^T; \mu_2 = [1 \ 1 \ 1]^T; \Sigma_1 = \Sigma_2 = \begin{bmatrix} 1/4 & 0 & 0 \\ 0 & 1/4 & 0 \\ 0 & 0 & 1/4 \end{bmatrix}; p(\omega_2) = 2p(\omega_1)$$

$$g_i(x) = -\frac{1}{2\sigma^2}(x - \mu_i)^T(x - \mu_i) + \log P(\omega_i) = -\frac{1}{2} \begin{bmatrix} x - \mu_x \\ y - \mu_y \\ z - \mu_z \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x - \mu_x \\ y - \mu_y \\ z - \mu_z \end{bmatrix} + \log P(\omega_i)$$

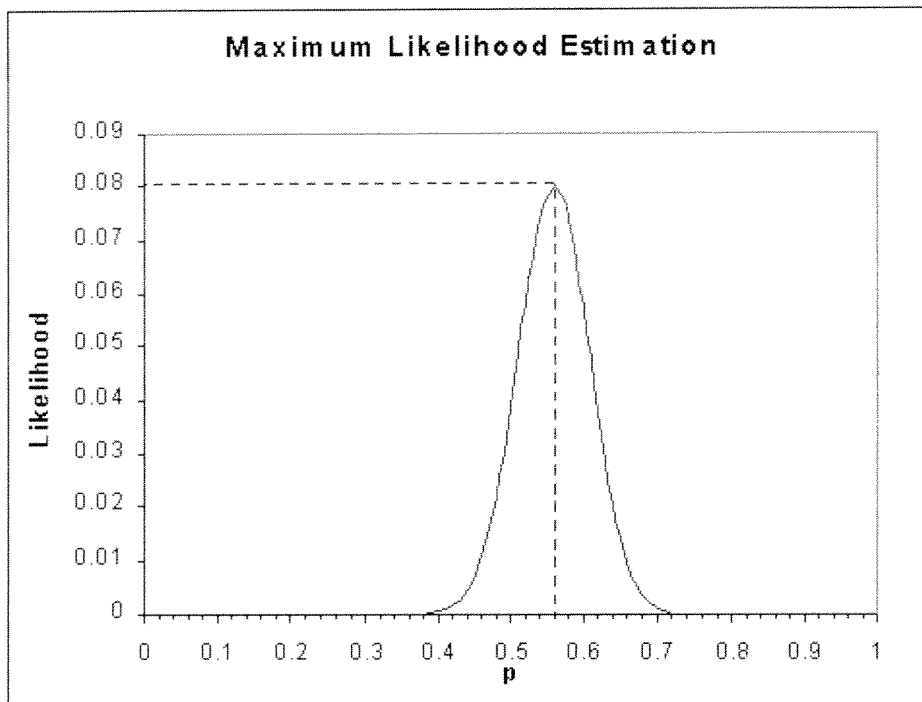
$$g_1(x) = -\frac{1}{2} \begin{bmatrix} x-0 \\ y-0 \\ z-0 \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x-0 \\ y-0 \\ z-0 \end{bmatrix} + \log \frac{1}{3}; \quad g_2(x) = -\frac{1}{2} \begin{bmatrix} x-1 \\ y-1 \\ z-1 \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x-1 \\ y-1 \\ z-1 \end{bmatrix} + \log \frac{2}{3}$$

$$g_1(x) \underset{\xi_1}{\vee} \underset{\xi_2}{\wedge} g_2(x) \Rightarrow -2(x^2 + y^2 + z^2) + \log \frac{1}{3} \underset{\omega_1}{\vee} \underset{\omega_2}{\wedge} -2((x-1)^2 + (y-1)^2 + (z-1)^2) + \log \frac{2}{3}$$

$$\underset{\xi_1}{\vee} \underset{\xi_2}{\wedge} x + y + z \underset{\omega_1}{\vee} \underset{\omega_2}{\wedge} \frac{6 - \log 2}{4} = 1.32$$

$$x_u = [0.1 \ 0.7 \ 0.8]^T$$

$$0.1 + 0.7 + 0.8 = 1.6 \underset{\xi_1}{\vee} \underset{\xi_2}{\wedge} 1.32 \Rightarrow x_u \in \omega_2$$



Μπεϋζιανή Εκμάθηση -Κανονική κατανομή

Αριθμητικό παράδειγμα


Έστω ότι ο πραγματικός μέσος όρος της $p(x)$ είναι $\mu=0.8$, με τυπική απόκλιση $\sigma=0.3$

➤ Στην πραγματικότητα δεν θα γνωρίζαμε τον πραγματικό μέσο όρο...

Παράγουμε έναν αριθμό από δείγματα της κατανομή αυτής

Εκφράζουμε την γνώση μας για τον μέσο όρο, θεωρώντας ότι η εκ των προτέρων πιθανότητα ακολουθεί κανονική κατανομή με $\mu_0=0.0$ και $\sigma_0=0.3$

Όσο αυξάνει ο αριθμός των δειγμάτων εκπαίδευσης, η εκτίμηση μ_N , πλησιάζει την πραγματική τιμή $\mu=0.8$ και η τυπική απόκλιση (δηλ. η αβεβαιότητα της εκτίμησης) ελαττώνεται.



ΚΕΦΑΛΑΙΟ 4^ο

Μη Παραμετρικές Τεχνικές

Παράδειγμα

Classify cars on UNR campus whether they are more or less than \$50K:

- C1: price > \$50K
- C2: price < \$50K
- Feature x: height of car

From Bayes' rule, we know how to compute the posterior probabilities:

$$P(C_i | x) = \frac{p(x | C_i)P(C_i)}{p(x)}$$

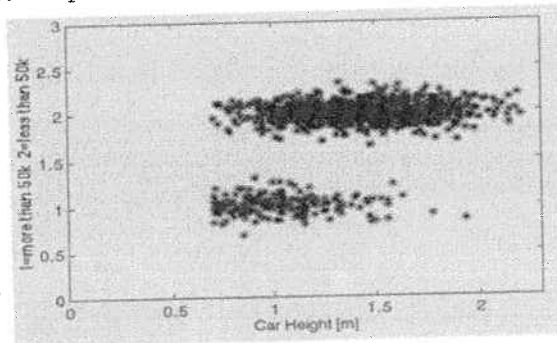
Need to compute $p(x/C_1)$, $p(x/C_2)$, $P(C_1)$, $P(C_2)$

Determine prior probabilities

- Collect data: ask drivers how much their car was and measure height.
- e.g., 1209 samples: #C₁=221 #C₂=988

$$P(C_1) = \frac{221}{1209} = 0.183$$

$$P(C_2) = \frac{988}{1209} = 0.817$$



ΚΕΦΑΛΑΙΟ 3^ο

Bias Variance Trade-off

Παράδειγμα

Υποτιθέμενο μοντέλο: $P(x | \theta) = \theta^x (1 - \theta)^{1-x}$ $x = 0, 1$

Σενάριο: πελάτες σε σουπερ μάρκετ είτε αγοράζουν είτε δεν αγοράζουν γάλα.
 θ είναι η πιθανότητα ότι ένας τυχαίος πελάτης αγοράζει γάλα

$$P(\theta | x_1, x_2, \dots, x_n) = \prod_{i=1}^n \theta^{x_i} (1 - \theta)^{1-x_i} = \theta^r (1 - \theta)^{n-r}$$

όπου r είναι ο αριθμός των πελατών, του δείγματος των n πελατών, που αγόρασαν γάλα

$$l(\theta) = r \ln \theta + (n - r) \ln(1 - \theta)$$

$$\frac{\partial}{\partial \theta} l(\theta) = \frac{r}{\theta} - \frac{n-r}{1-\theta} = 0 \qquad \hat{\theta}_{ML} = \frac{r}{n}$$

Παράδειγμα

$n=100$ Ρίψεις κέρματος

$h=56$ Ρίψεις κορώνας

$t=44$ Ρίψεις γράμματα

Είναι το κέρμα «πειραμαγμένο»?

Έστω ότι $p=0.5$.

Τότε :


$$L(p = 0.5 | data) = \frac{100!}{56!44!} 0.5^{56} 0.5^{44} = 0.0389$$

$$L(p = 0.52 | data) = \frac{100!}{56!44!} 0.52^{56} 0.48^{44} = 0.0581$$

P	L
0.48	0.0222
0.50	0.0389
0.52	0.0581
0.54	0.0739
0.56	0.0801
0.58	0.0738
0.60	0.0576
0.62	0.0378


Determine class conditional probabilities (*likelihood*)

- Discretize car height into bins and use normalized histogram



Calculate the posterior probability for each bin:

$$\begin{aligned}
 P(C_1 / x = 1.0) &= \frac{p(x = 1.0 / C_1) P(C_1)}{p(x = 1.0 / C_1) P(C_1) + p(x = 1.0 / C_2) P(C_2)} = \\
 &= \frac{0.2081 * 0.183}{0.2081 * 0.183 + 0.0597 * 0.817} = 0.438
 \end{aligned}$$




Παράθυρα Parzen

Παράδειγμα 1-D

$$p_{\varphi}(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h^d} \varphi\left(\frac{x - x_i}{h}\right)$$

Υποθέτουμε ότι έχουμε 7 δείγματα

$$D = \{2, 3, 4, 8, 10, 11, 12\}$$



Θέλουμε να βρούμε την πυκνότητα στο σημείο $x=1$ για $h=3$

$$p_{\varphi}(1) = \frac{1}{7} \sum_{i=1}^7 \frac{1}{3} \varphi\left(\frac{1 - x_i}{3}\right) = \frac{1}{21} \left[\varphi\left(\frac{1-2}{3}\right) + \varphi\left(\frac{1-3}{3}\right) + \varphi\left(\frac{1-4}{3}\right) + \dots + \varphi\left(\frac{1-12}{3}\right) \right]$$

$\left| \frac{-1}{3} \right| \leq 1/2 \quad \left| \frac{-2}{3} \right| > 1/2 \quad \left| -1 \right| > 1/2 \quad \left| \frac{-11}{3} \right| > 1/2$

$$p_{\varphi}(1) = \frac{1}{7} \sum_{i=1}^7 \frac{1}{3} \varphi\left(\frac{1 - x_i}{3}\right) = \frac{1}{21} [1 + 0 + 0 + \dots + 0] = \frac{1}{21}$$


Παράδειγμα

Παράθυρο πλάτους 4

$p(x)$ $y=3,10,15$

$h=4$

- $X = \{x^{(1)}, x^{(2)}, \dots, x^{(N)}\} = \{4, 5, 5, 6, 12, 14, 15, 15, 16, 17\}$



$p(y=3):$

$$p_{KDE}(y=3) = \frac{1}{Nh^D} \sum_{i=1}^N K\left(\frac{y-x^{(i)}}{h}\right) = \frac{1}{10 \times 4^1} \left[K\left(\frac{3-4}{4}\right) + K\left(\frac{3-5}{4}\right) + K\left(\frac{3-5}{4}\right) + K\left(\frac{3-6}{4}\right) + \dots + K\left(\frac{3-17}{4}\right) \right] =$$
$$= \frac{1}{10 \times 4^1} [1+0+0+0+0+0+0+0+0+0] = \frac{1}{10 \times 4} = 0.025$$

$$p_{KDE}(y=10) = \frac{1}{10 \times 4^1} [0+0+0+0+0+0+0+0+0+0] = \frac{0}{10 \times 4} = 0$$

$$p_{KDE}(y=15) = \frac{1}{10 \times 4^1} [0+0+0+0+0+1+1+1+1+0] = \frac{4}{10 \times 4} = 0.1$$

Αριθμητικό Παράδειγμα

5 δείγματα: $D=\{2, 2.5, 3, 1, 6\}$

Υπολογίστε την σ.π.π. για $x=3$ χρησιμοποιώντας ως συνάρτηση παραθύρου συνάρτηση Gauss με $\sigma=1$

Λύση:

$x_1 = 2$

$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_1 - x)^2}{2}\right)$$
$$= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(2 - 3)^2}{2}\right) = 0.2420$$

$$x_2 = 2.5$$

$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_2 - x)^2}{2}\right)$$
$$= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(2.5 - 3)^2}{2}\right) = 0.3521$$

Με τον ίδιο τρόπο υπολογίζουμε για $x_3 = 3$, $x_4 = 1$ και $x_5 = 6$ αντίστοιχα:

$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_3 - x)^2}{2}\right) = 0.3989$$


$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_4 - x)^2}{2}\right) = 0.0540$$


$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_5 - x)^2}{2}\right) = 0.0044$$

Οπότε:

$$p(x = 3) = (0.2420 + 0.3521 + 0.3989$$

$$+ 0.0540 + 0.0044)/5 = 0.2103$$





Κεφάλαιο 5^ο

Γραμμικές Διακρίνουσες Συναρτήσεις

Παράδειγμα

	features				grade
<i>name</i>	<i>good attendance?</i>	<i>tall?</i>	<i>sleeps in class?</i>	<i>chews gum?</i>	
Jane	<i>yes (1)</i>	<i>yes (1)</i>	<i>no (-1)</i>	<i>no (-1)</i>	<i>A</i>
Steve	<i>yes (1)</i>	<i>yes (1)</i>	<i>yes (1)</i>	<i>yes (1)</i>	<i>F</i>
Mary	<i>no (-1)</i>	<i>no (-1)</i>	<i>no (-1)</i>	<i>yes (1)</i>	<i>F</i>
Peter	<i>yes (1)</i>	<i>no (-1)</i>	<i>no (-1)</i>	<i>yes (1)</i>	<i>A</i>

- **class 1**: students who get grade *A*
- **class 2**: students who get grade *F*

	features					grade
<i>name</i>	<i>extra</i>	<i>good attendance?</i>	<i>tall?</i>	<i>sleeps in class?</i>	<i>chews gum?</i>	
Jane	<i>1</i>	<i>yes (1)</i>	<i>yes (1)</i>	<i>no (-1)</i>	<i>no (-1)</i>	<i>A</i>
Steve	<i>1</i>	<i>yes (1)</i>	<i>yes (1)</i>	<i>yes (1)</i>	<i>yes (1)</i>	<i>F</i>
Mary	<i>1</i>	<i>no (-1)</i>	<i>no (-1)</i>	<i>no (-1)</i>	<i>yes (1)</i>	<i>F</i>
Peter	<i>1</i>	<i>yes (1)</i>	<i>no (-1)</i>	<i>no (-1)</i>	<i>yes (1)</i>	<i>A</i>

Αντικατάσταση όλων των δειγμάτων της κλάσης c_2 από τα αρνητικά τους

$$y_i \rightarrow -y_i \quad \forall y_i \in c_2$$

Αναζήτηση διανύσματος βαρών a , ώστε

$$a^T y_i > 0 \quad \forall y_i$$

	features					grade
<i>name</i>	<i>extra</i>	<i>good attendance?</i>	<i>tall?</i>	<i>sleeps in class?</i>	<i>chews gum?</i>	
Jane	1	yes (1)	yes (1)	no (-1)	no (-1)	A
Steve	-1	yes (-1)	yes (-1)	yes (-1)	yes (-1)	F
Mary	-1	no (1)	no (1)	no (1)	yes (-1)	F
Peter	1	yes (1)	no (-1)	no (-1)	yes (1)	A

- Sample is misclassified if $\mathbf{a}'\mathbf{y}_i = \sum_{k=0}^4 \mathbf{a}_k \mathbf{y}_i^{(k)} < 0$
- gradient descent single sample rule: $\mathbf{a}^{(k+1)} = \mathbf{a}^{(k)} + \eta^{(k)} \mathbf{y}_M$
- Set *fixed* learning rate to $\eta^{(k)} = 1$: $\mathbf{a}^{(k+1)} = \mathbf{a}^{(k)} + \mathbf{y}_M$

Θέτουμε ίσα αρχικά βάρη

- set equal initial weights $\mathbf{a}^{(1)} = [0.25, 0.25, 0.25, 0.25]$
- visit all samples sequentially, modifying the weights for after finding a misclassified example

<i>name</i>	$\mathbf{a}'\mathbf{y}$	<i>misclassified?</i>
Jane	$0.25*1+0.25*1+0.25*1+0.25*(-1)+0.25*(-1) > 0$	no
Steve	$0.25*(-1)+0.25*(-1)+0.25*(-1)+0.25*(-1)+0.25*(-1) < 0$	yes

- new weights

$$\begin{aligned} \mathbf{a}^{(2)} &= \mathbf{a}^{(1)} + \mathbf{y}_M = [0.25 \ 0.25 \ 0.25 \ 0.25 \ 0.25] + \\ &\quad + [-1 \ -1 \ -1 \ -1 \ -1] = \\ &= [-0.75 \ -0.75 \ -0.75 \ -0.75 \ -0.75] \end{aligned}$$

$$\mathbf{a}^{(2)} = [-0.75 \ -0.75 \ -0.75 \ -0.75 \ -0.75]$$

<i>name</i>	$\mathbf{a}^t \mathbf{y}$	<i>misclassified?</i>
Mary	$-0.75 * (-1) - 0.75 * 1 - 0.75 * 1 - 0.75 * 1 - 0.75 * (-1) < 0$	yes

- new weights

$$\begin{aligned} \mathbf{a}^{(3)} &= \mathbf{a}^{(2)} + \mathbf{y}_M = [-0.75 \ -0.75 \ -0.75 \ -0.75 \ -0.75] + \\ &\quad + [-1 \ 1 \ 1 \ 1 \ -1] = \\ &= [-1.75 \ 0.25 \ 0.25 \ 0.25 \ -1.75] \end{aligned}$$

$$\mathbf{a}^{(3)} = [-1.75 \ 0.25 \ 0.25 \ 0.25 \ -1.75]$$

<i>name</i>	$\mathbf{a}^t \mathbf{y}$	<i>misclassified?</i>
Peter	$-1.75 * 1 + 0.25 * 1 + 0.25 * (-1) + 0.25 * (-1) - 1.75 * 1 < 0$	yes

- new weights

$$\begin{aligned} \mathbf{a}^{(4)} &= \mathbf{a}^{(3)} + \mathbf{y}_M = [-1.75 \ 0.25 \ 0.25 \ 0.25 \ -1.75] + \\ &\quad + [1 \ 1 \ -1 \ -1 \ 1] = \\ &= [-0.75 \ 1.25 \ -0.75 \ -0.75 \ -0.75] \end{aligned}$$

$$\mathbf{a}^{(4)} = [-0.75 \quad 1.25 \quad -0.75 \quad -0.75 \quad -0.75]$$

<i>name</i>	$\mathbf{a}^T \mathbf{y}$	<i>misclassified?</i>
Jane	$-0.75 * 1 + 1.25 * 1 - 0.75 * 1 - 0.75 * (-1) - 0.75 * (-1) + 0$	<i>no</i>
Steve	$-0.75 * (-1) + 1.25 * (-1) - 0.75 * (-1) - 0.75 * (-1) - 0.75 * (-1) > 0$	<i>no</i>
Mary	$-0.75 * (-1) + 1.25 * 1 - 0.75 * 1 - 0.75 * 1 - 0.75 * (-1) > 0$	<i>no</i>
Peter	$-0.75 * 1 + 1.25 * 1 - 0.75 * (-1) - 0.75 * (-1) - 0.75 * 1 > 0$	<i>no</i>

- Thus the discriminant function is

$$g(\mathbf{y}) = -0.75 * y^{(0)} + 1.25 * y^{(1)} - 0.75 * y^{(2)} - 0.75 * y^{(3)} - 0.75 * y^{(4)}$$


- Converting back to the original features \mathbf{x} :

$$g(\mathbf{x}) = 1.25 * x^{(1)} - 0.75 * x^{(2)} - 0.75 * x^{(3)} - 0.75 * x^{(4)} - 0.75$$

- Converting back to the original features \mathbf{x} :

$$1.25 * x^{(1)} - 0.75 * x^{(2)} - 0.75 * x^{(3)} - 0.75 * x^{(4)} > 0.75 \Rightarrow \text{grade A}$$

$$1.25 * x^{(1)} - 0.75 * x^{(2)} - 0.75 * x^{(3)} - 0.75 * x^{(4)} < 0.75 \Rightarrow \text{grade F}$$



- This is just one possible solution vector
- If we started with weights $\mathbf{a}^{(1)} = [0, 0.5, 0.5, 0, 0]$, solution would be $[-1, 1.5, -0.5, -1, -1]$

$$1.5 * x^{(1)} - 0.5 * x^{(2)} - x^{(3)} - x^{(4)} > 1 \Rightarrow \text{grade A}$$


$$1.5 * x^{(1)} - 0.5 * x^{(2)} - x^{(3)} - x^{(4)} < 1 \Rightarrow \text{grade F}$$
 - In this solution, being tall is the least important feature

Παράδειγμα - Μη γραμμικά διαχωρίσιμα δεδομένα

- Suppose we have 2 features and samples are:

- Class 1: [2,1], [4,3], [3,5]
- Class 2: [1,3] and [5,6]

- These samples are not separable by a line



- Still would like to get approximate separation by a line, good choice is shown in green

- some samples may be “noisy”, and it’s ok if they are on the wrong side of the line

- Get y_1, y_2, y_3, y_4 by adding extra feature and “normalizing”


$$y_1 = \begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} \quad y_2 = \begin{bmatrix} 1 \\ 4 \\ 3 \end{bmatrix} \quad y_3 = \begin{bmatrix} 1 \\ 3 \\ 5 \end{bmatrix} \quad y_4 = \begin{bmatrix} -1 \\ -1 \\ -3 \end{bmatrix} \quad y_5 = \begin{bmatrix} -1 \\ -5 \\ -6 \end{bmatrix}$$

- Let’s apply Perceptron single sample algorithm

- initial equal weights $a^{(1)} = [1 \ 1 \ 1]$
- this is line $x^{(1)} + x^{(2)} + 1 = 0$

- fixed learning rate $\eta = 1$

$$a^{(k+1)} = a^{(k)} + y_M$$



$$y_1 = \begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} \quad y_2 = \begin{bmatrix} 1 \\ 4 \\ 3 \end{bmatrix} \quad y_3 = \begin{bmatrix} 1 \\ 3 \\ 5 \end{bmatrix} \quad y_4 = \begin{bmatrix} -1 \\ -1 \\ -3 \end{bmatrix} \quad y_5 = \begin{bmatrix} -1 \\ -5 \\ -6 \end{bmatrix}$$

$$\bullet \quad y_1^t a^{(1)} = [1 \ 1 \ 1] * [1 \ 2 \ 1]^t > 0 \quad \checkmark$$

$$\bullet \quad y_2^t a^{(1)} = [1 \ 1 \ 1] * [1 \ 4 \ 3]^t > 0 \quad \checkmark$$

$$\bullet \quad y_3^t a^{(1)} = [1 \ 1 \ 1] * [1 \ 3 \ 5]^t > 0 \quad \checkmark$$

$$a^{(1)} = [1 \ 1 \ 1] \quad a^{(k+1)} = a^{(k)} + y_M$$

$$y_1 = \begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} \quad y_2 = \begin{bmatrix} 1 \\ 4 \\ 3 \end{bmatrix} \quad y_3 = \begin{bmatrix} 1 \\ 3 \\ 5 \end{bmatrix} \quad y_4 = \begin{bmatrix} -1 \\ -1 \\ -3 \end{bmatrix} \quad y_5 = \begin{bmatrix} -1 \\ -5 \\ -6 \end{bmatrix}$$


$$\blacksquare y_4^t a^{(1)} = [1 \ 1 \ 1]^* [-1 \ -1 \ -3]^t = -5 < 0$$

$$a^{(2)} = a^{(1)} + y_M = [1 \ 1 \ 1] + [-1 \ -1 \ -3] = [0 \ 0 \ -2]$$

$$\blacksquare y_5^t a^{(2)} = [0 \ 0 \ -2]^* [-1 \ -5 \ -6]^t = 12 > 0 \quad \checkmark$$

$$\blacksquare y_1^t a^{(2)} = [0 \ 0 \ -2]^* [1 \ 2 \ 1]^t < 0$$

$$a^{(3)} = a^{(2)} + y_M = [0 \ 0 \ -2] + [1 \ 2 \ 1] = [1 \ 2 \ -1]$$



$$a^{(3)} = [1 \ 2 \ -1] \quad a^{(k+1)} = a^{(k)} + y_M$$


$$y_1 = \begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} \quad y_2 = \begin{bmatrix} 1 \\ 4 \\ 3 \end{bmatrix} \quad y_3 = \begin{bmatrix} 1 \\ 3 \\ 5 \end{bmatrix} \quad y_4 = \begin{bmatrix} -1 \\ -1 \\ -3 \end{bmatrix} \quad y_5 = \begin{bmatrix} -1 \\ -5 \\ -6 \end{bmatrix}$$

$$\blacksquare y_2^t a^{(3)} = [1 \ 4 \ 3]^* [1 \ 2 \ -1]^t = 6 > 0 \quad \checkmark$$

$$\blacksquare y_3^t a^{(3)} = [1 \ 3 \ 5]^* [1 \ 2 \ -1]^t > 0 \quad \checkmark$$


$$\blacksquare y_4^t a^{(3)} = [-1 \ -1 \ -3]^* [1 \ 2 \ -1]^t = 0$$

$$a^{(4)} = a^{(3)} + y_M = [1 \ 2 \ -1] + [-1 \ -1 \ -3] = [0 \ 1 \ -4]$$



$$a^{(4)} = [0 \ 1 \ -4] \quad a^{(k+1)} = a^{(k)} + y_M$$

$$y_1 = \begin{bmatrix} 1 \\ 2 \\ 1 \end{bmatrix} \quad y_2 = \begin{bmatrix} 1 \\ 4 \\ 3 \end{bmatrix} \quad y_3 = \begin{bmatrix} 1 \\ 3 \\ 5 \end{bmatrix} \quad y_4 = \begin{bmatrix} -1 \\ -1 \\ -3 \end{bmatrix} \quad y_5 = \begin{bmatrix} -1 \\ -5 \\ -6 \end{bmatrix}$$



$$\blacksquare y_2^t a^{(3)} = [1 \ 4 \ 3]^t [1 \ 2 \ -1]^t = 6 > 0 \quad \checkmark$$

$$\blacksquare y_3^t a^{(3)} = [1 \ 3 \ 5]^t [1 \ 2 \ -1]^t > 0 \quad \checkmark$$

$$\blacksquare y_4^t a^{(3)} = [-1 \ -1 \ -3]^t [1 \ 2 \ -1]^t = 0$$

$$a^{(4)} = a^{(3)} + y_M = [1 \ 2 \ -1]^t + [-1 \ -1 \ -3]^t = [0 \ 1 \ -4]^t$$

Μπορούμε να συνεχίσουμε για πάντα !!

Δεν υπάρχει διάνυσμα λύσης a το οποίο να ικανοποιεί για κάθε i τη σχέση:


$$a^t y_i = \sum_{k=0}^5 a_k y_i^{(k)} > 0$$

Πρέπει να σταματήσουμε αλλά σε «καλό» σημείο.

Οι λύσεις για επαναλήψεις 900 ως 915.

Κάποιες είναι καλές, κάποιες όχι

Πώς θα σταματήσουμε σε καλή λύση?



Μέθοδος Ho-Kashyap

Class 1: (6 9), (5 7)

Class 1: (5 9), (0 10)

$$Y = \begin{bmatrix} 1 & 6 & 9 \\ 1 & 5 & 7 \\ -1 & -5 & -9 \\ -1 & 0 & -10 \end{bmatrix}$$

Αρχικές τιμές:


$$\mathbf{a}^{(1)} = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \quad \mathbf{b}^{(1)} = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}$$

Θέτουμε :

$$\eta = 0.9$$

Οπότε:

$$Y\mathbf{a}^{(1)} = \begin{bmatrix} 16 \\ 13 \\ -15 \\ -11 \end{bmatrix}$$



Πρώτη επανάληψη:

$$\mathbf{e}^{(1)} = Y\mathbf{a}^{(1)} - \mathbf{b}^{(1)} = \begin{bmatrix} 16 \\ 13 \\ -15 \\ -11 \end{bmatrix} - \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 15 \\ 12 \\ -16 \\ -12 \end{bmatrix}$$

Επίλυση για $b^{(2)}$ χρησιμοποιώντας $a^{(1)}$ και $b^{(1)}$

$$b^{(2)} = b^{(1)} + 0.9[e^{(1)} + /e^{(1)} /] = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} + 0.9 \left[\begin{bmatrix} 15 \\ 12 \\ -16 \\ -12 \end{bmatrix} + \begin{bmatrix} 15 \\ 12 \\ 16 \\ 12 \end{bmatrix} \right] = \begin{bmatrix} 28 \\ 22.6 \\ 1 \\ 1 \end{bmatrix}$$

Επίλυση για $a^{(2)}$ χρησιμοποιώντας $b^{(2)}$ και

$$a^{(2)} = (Y^T Y)^{-1} Y^T b^{(2)} = \begin{bmatrix} -2.6 & 4.7 & 1.6 & -0.5 \\ 0.16 & -0.1 & -0.1 & 0.2 \\ 0.26 & -0.5 & -0.2 & -0.1 \end{bmatrix} * \begin{bmatrix} 28 \\ 22.6 \\ 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 34.6 \\ 2.7 \\ -3.8 \end{bmatrix}$$

Συνεχίζουμε τις επαναλήψεις ώσπου

$$Ya > 0$$

Στη πράξη, συνεχίζουμε ώσπου το μικρότερο στοιχείο του Ya να είναι μικρότερο του 0.01

Μετά απο 104 επαναλήψεις συγκλίνει σε λύση

$$a = \begin{bmatrix} -34.9 \\ 27.3 \\ -11.3 \end{bmatrix} \quad b = \begin{bmatrix} 28 \\ 23 \\ 1 \\ 147 \end{bmatrix}$$

Το διάνυσμα a ορίζει ένα διαχωριστικό υπερεπίπεδο

$$Ya = \begin{bmatrix} 27.2 \\ 22.5 \\ 0.14 \\ 1.48 \end{bmatrix}$$

