

Statystyczna Eksploracja Danych

Wykład 2 - metoda Fishera dla $g > 2$, klasyfikator Bayesa,
metody LDA i QDA

dr inż. Julian Sienkiewicz

12 marca 2021

Mamy próby należące do dwóch klas $y \in \{A, B\}$:

$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)$, gdzie \mathbf{x}_i to i -ta obserwacja, a y_i to jej przynależność do jednej z klas.

Każdy element \mathbf{x} jest wektorem **kolumnowym** o długości p

$$\bar{\mathbf{x}}_i = \begin{bmatrix} x_i^1 \\ x_i^2 \\ \dots \\ x_i^p \end{bmatrix}$$

Wartość p określa wymiar układu (ogólnie niekoniecznie przestrzeń fizyczna).

W każdej klasie możemy wyznaczyć wartość średnią

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^{i=n} \mathbf{x}_i$$

oraz macierz kowariancji

$$\mathbf{S} = \frac{1}{n-1} \sum_{i=1}^{i=n} (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T$$

Główne założenie: macierze kowariancji **w obu klasach** są takie same. W efekcie macierz kowariancji wewnątrzgrupowej **W** wyraża się wzorem:

$$\mathbf{W} = \frac{1}{n-2} \sum_{k=1}^{i=2} (n_k - 1) \mathbf{S}_k$$

S_k - macierz kowariancji w klasie k

$n = n_1 + n_2$ - liczba danych w obu klasach

(Pierwszy) wektor kanoniczny

$$\tilde{\mathbf{a}} \sim \mathbf{W}^{-1}(\bar{\mathbf{x}}_2 - \bar{\mathbf{x}}_1)$$

(Pierwszy) wektor kanoniczny

$$\tilde{\mathbf{a}} \sim \mathbf{W}^{-1}(\bar{\mathbf{x}}_2 - \bar{\mathbf{x}}_1)$$

Czyli obserwacja \mathbf{x} spełniająca warunek

Warunek dyskryminacyjny

$$|\tilde{\mathbf{a}}^T(\mathbf{x} - \bar{\mathbf{x}}_1)| < |\tilde{\mathbf{a}}^T(\mathbf{x} - \bar{\mathbf{x}}_2)|$$

zostanie uznana za przynależną do klasy A.

(Pierwszy) wektor kanoniczny

$$\tilde{\mathbf{a}} \sim \mathbf{W}^{-1}(\bar{\mathbf{x}}_2 - \bar{\mathbf{x}}_1)$$

Czyli obserwacja \mathbf{x} spełniająca warunek

Warunek dyskryminacyjny

$$|\tilde{\mathbf{a}}^T(\mathbf{x} - \bar{\mathbf{x}}_1)| < |\tilde{\mathbf{a}}^T(\mathbf{x} - \bar{\mathbf{x}}_2)|$$

zostanie uznana za przynależną do klasy A. Natomiast hiperpłaszczyzna dyskryminacyjna jest dana równaniem

Hiperpłaszczyzna dyskryminacyjna

$$(\bar{\mathbf{x}}_2 - \bar{\mathbf{x}}_1)^T \mathbf{W}^{-1} \left[\mathbf{x} - \frac{1}{2}(\bar{\mathbf{x}}_1 + \bar{\mathbf{x}}_2) \right] = 0$$

Można zauważyć, że

$$\begin{aligned} \left(\mathbf{a}^T \bar{\mathbf{x}}_2 - \mathbf{a}^T \bar{\mathbf{x}}_1 \right)^2 &= \mathbf{a}^T (\bar{\mathbf{x}}_2 - \bar{\mathbf{x}}_1) (\bar{\mathbf{x}}_2 - \bar{\mathbf{x}}_1)^T \mathbf{a} = \\ &= \frac{n_1 + n_2}{n_1 n_2} \mathbf{a}^T \sum_{k=1}^2 n_k (\bar{\mathbf{x}}_k - \bar{\mathbf{x}}) (\bar{\mathbf{x}}_k - \bar{\mathbf{x}})^T \mathbf{a} \end{aligned} \quad (1)$$

gdzie $\bar{\mathbf{x}}$ to średnia ogólna ze wszystkich obserwacji.

Można zauważyć, że

$$\begin{aligned} (\mathbf{a}^T \bar{\mathbf{x}}_2 - \mathbf{a}^T \bar{\mathbf{x}}_1)^2 &= \mathbf{a}^T (\bar{\mathbf{x}}_2 - \bar{\mathbf{x}}_1) (\bar{\mathbf{x}}_2 - \bar{\mathbf{x}}_1)^T \mathbf{a} = \\ &= \frac{n_1 + n_2}{n_1 n_2} \mathbf{a}^T \sum_{k=1}^2 n_k (\bar{\mathbf{x}}_k - \bar{\mathbf{x}}) (\bar{\mathbf{x}}_k - \bar{\mathbf{x}})^T \mathbf{a} \end{aligned} \quad (1)$$

gdzie $\bar{\mathbf{x}}$ to średnia ogólna ze wszystkich obserwacji. Możemy dzięki temu zdefiniować macierz charakteryzującą **zmienność międzygrupową**

Macierz kowariancji międzygrupowej

$$\mathbf{B} = \sum_{k=1}^2 n_k (\bar{\mathbf{x}}_k - \bar{\mathbf{x}}) (\bar{\mathbf{x}}_k - \bar{\mathbf{x}})^T$$

W efekcie maksymalizacja ze względu na \mathbf{a} ilorazu

$$\frac{(\mathbf{a}^T \bar{\mathbf{x}}_2 - \mathbf{a}^T \bar{\mathbf{x}}_1)^2}{\mathbf{a}^T \mathbf{W} \mathbf{a}}$$

W efekcie maksymalizacja ze względu na \mathbf{a} ilorazu

$$\frac{(\mathbf{a}^T \bar{\mathbf{x}}_2 - \mathbf{a}^T \bar{\mathbf{x}}_1)^2}{\mathbf{a}^T \mathbf{W} \mathbf{a}}$$

jest równoznaczna maksymalizacji wyrażenia

$$\frac{\mathbf{a}^T \mathbf{B} \mathbf{a}}{\mathbf{a}^T \mathbf{W} \mathbf{a}},$$

W efekcie maksymalizacja ze względu na \mathbf{a} ilorazu

$$\frac{(\mathbf{a}^T \bar{\mathbf{x}}_2 - \mathbf{a}^T \bar{\mathbf{x}}_1)^2}{\mathbf{a}^T \mathbf{W} \mathbf{a}}$$

jest równoznaczna maksymalizacji wyrażenia

$$\frac{\mathbf{a}^T \mathbf{B} \mathbf{a}}{\mathbf{a}^T \mathbf{W} \mathbf{a}},$$

co daje możliwość uogólnienia metody Fishera na liczbę $g > 2$ klas.

Problem dyskryminacyjny $g > 2$

Znajdź kierunek $\tilde{\mathbf{a}}$ maksymalizujący wyrażenie

$$\frac{\mathbf{a}^T \mathbf{B} \mathbf{a}}{\mathbf{a}^T \mathbf{W} \mathbf{a}}$$

Problem dyskryminacyjny $g > 2$

Znajdź kierunek $\tilde{\mathbf{a}}$ maksymalizujący wyrażenie

$$\frac{\mathbf{a}^T \mathbf{B} \mathbf{a}}{\mathbf{a}^T \mathbf{W} \mathbf{a}}$$

gdzie

Macierz kowariancji międzygrupowej

$$\mathbf{B} = \frac{1}{g-1} \sum_{k=1}^g n_k (\bar{\mathbf{x}}_k - \bar{\mathbf{x}})(\bar{\mathbf{x}}_k - \bar{\mathbf{x}})^T$$

Problem dyskryminacyjny $g > 2$

Znajdź kierunek $\tilde{\mathbf{a}}$ maksymalizujący wyrażenie

$$\frac{\mathbf{a}^T \mathbf{B} \mathbf{a}}{\mathbf{a}^T \mathbf{W} \mathbf{a}}$$

gdzie

Macierz kowariancji międzygrupowej

$$\mathbf{B} = \frac{1}{g-1} \sum_{k=1}^g n_k (\bar{\mathbf{x}}_k - \bar{\mathbf{x}})(\bar{\mathbf{x}}_k - \bar{\mathbf{x}})^T$$

i

Macierz kowariancji wewnątrzgrupowej

$$\mathbf{W} = \frac{1}{n-g} \sum_{k=1}^g n_k (n_k - 1) \mathbf{S}_k$$

Rozwiązanie $g > 2$

Wektor $\tilde{\mathbf{a}}$ maksymalizujący wyrażenie

$$\frac{\mathbf{a}^T \mathbf{B} \mathbf{a}}{\mathbf{a}^T \mathbf{W} \mathbf{a}}$$

jest **wektorem własnym** macierzy $\mathbf{W}^{-1} \mathbf{B}$, odpowiadającym największej **wartości własnej** tej macierzy

Rozwiązanie $g > 2$

Wektor $\tilde{\mathbf{a}}$ maksymalizujący wyrażenie

$$\frac{\mathbf{a}^T \mathbf{B} \mathbf{a}}{\mathbf{a}^T \mathbf{W} \mathbf{a}}$$

jest **wektorem własnym** macierzy $\mathbf{W}^{-1} \mathbf{B}$, odpowiadającym największej **wartości własnej** tej macierzy

Reguła decyzyjna


Obserwację \mathbf{x} przypisujemy do klasy j , jeżeli

$$|\tilde{\mathbf{a}}^T (\mathbf{x} - \bar{\mathbf{x}}_j)| < |\tilde{\mathbf{a}}^T (\mathbf{x} - \bar{\mathbf{x}}_k)|$$

dla wszystkich $k \neq j$.


Przykład 4 - $g = 5$

$$\bar{\mathbf{x}}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$$




Przykład 4 - $g = 5$

$$\bar{\mathbf{x}}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \quad \bar{\mathbf{x}}_2 = \begin{bmatrix} 4 \\ 4 \end{bmatrix}$$




Przykład 4 - $g = 5$


$$\bar{\mathbf{x}}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \quad \bar{\mathbf{x}}_2 = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad \bar{\mathbf{x}}_3 = \begin{bmatrix} 5 \\ 6 \end{bmatrix}$$



Przykład 4 - $g = 5$


$$\begin{aligned} \bar{x}_1 &= \begin{bmatrix} 2 \\ 2 \end{bmatrix} & \bar{x}_2 &= \begin{bmatrix} 4 \\ 4 \end{bmatrix} & \bar{x}_3 &= \begin{bmatrix} 5 \\ 6 \end{bmatrix} \\ \bar{x}_4 &= \begin{bmatrix} 9 \\ 8 \end{bmatrix} \end{aligned}$$



Przykład 4 - $g = 5$ 

$$\bar{x}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \quad \bar{x}_2 = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad \bar{x}_3 = \begin{bmatrix} 5 \\ 6 \end{bmatrix}$$


$$\bar{x}_4 = \begin{bmatrix} 9 \\ 8 \end{bmatrix} \quad \bar{x}_5 = \begin{bmatrix} 10 \\ 10 \end{bmatrix}$$

Przykład 4 - $g = 5$ 

$$\bar{\mathbf{x}}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \quad \bar{\mathbf{x}}_2 = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad \bar{\mathbf{x}}_3 = \begin{bmatrix} 5 \\ 6 \end{bmatrix}$$

$$\bar{\mathbf{x}}_4 = \begin{bmatrix} 9 \\ 8 \end{bmatrix} \quad \bar{\mathbf{x}}_5 = \begin{bmatrix} 10 \\ 10 \end{bmatrix}$$

$$\mathbf{S}_1 = \mathbf{S}_2 = \mathbf{S}_3 = \mathbf{S}_4 = \mathbf{S}_5 = \begin{bmatrix} \frac{1}{2} & 0 \\ 0 & \frac{1}{2} \end{bmatrix}$$


Przykład 4 - $g = 5$ 

$$\bar{\mathbf{x}}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \quad \bar{\mathbf{x}}_2 = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad \bar{\mathbf{x}}_3 = \begin{bmatrix} 5 \\ 6 \end{bmatrix}$$

$$\bar{\mathbf{x}}_4 = \begin{bmatrix} 9 \\ 8 \end{bmatrix} \quad \bar{\mathbf{x}}_5 = \begin{bmatrix} 10 \\ 10 \end{bmatrix}$$

$$\mathbf{S}_1 = \mathbf{S}_2 = \mathbf{S}_3 = \mathbf{S}_4 = \mathbf{S}_5 = \begin{bmatrix} \frac{1}{2} & 0 \\ 0 & \frac{1}{2} \end{bmatrix}$$

$$\bar{\mathbf{x}} = \begin{bmatrix} 6 \\ 6 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} \frac{115}{2} & \frac{105}{2} \\ \frac{105}{2} & 50 \end{bmatrix}$$

Przykład 4 - $g = 5$ 

$$\bar{\mathbf{x}}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \quad \bar{\mathbf{x}}_2 = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad \bar{\mathbf{x}}_3 = \begin{bmatrix} 5 \\ 6 \end{bmatrix}$$


$$\bar{\mathbf{x}}_4 = \begin{bmatrix} 9 \\ 8 \end{bmatrix} \quad \bar{\mathbf{x}}_5 = \begin{bmatrix} 10 \\ 10 \end{bmatrix}$$

$$\mathbf{S}_1 = \mathbf{S}_2 = \mathbf{S}_3 = \mathbf{S}_4 = \mathbf{S}_5 = \begin{bmatrix} \frac{1}{2} & 0 \\ 0 & \frac{1}{2} \end{bmatrix}$$

$$\bar{\mathbf{x}} = \begin{bmatrix} 6 \\ 6 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} \frac{115}{2} & \frac{105}{2} \\ \frac{105}{2} & 50 \end{bmatrix}$$

$$\lambda_1 \approx \frac{425}{2} \quad \mathbf{p}_1 = \begin{bmatrix} \frac{15}{14} \\ 1 \end{bmatrix}$$

$$\lambda_2 \approx \frac{5}{2} \quad \mathbf{p}_2 = \begin{bmatrix} -\frac{13}{14} \\ 1 \end{bmatrix}$$

Przykład 4 - $g = 5$ 

$$\bar{\mathbf{x}}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \quad \bar{\mathbf{x}}_2 = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad \bar{\mathbf{x}}_3 = \begin{bmatrix} 5 \\ 6 \end{bmatrix}$$

$$\bar{\mathbf{x}}_4 = \begin{bmatrix} 9 \\ 8 \end{bmatrix} \quad \bar{\mathbf{x}}_5 = \begin{bmatrix} 10 \\ 10 \end{bmatrix}$$


$$\mathbf{S}_1 = \mathbf{S}_2 = \mathbf{S}_3 = \mathbf{S}_4 = \mathbf{S}_5 = \begin{bmatrix} \frac{1}{2} & 0 \\ 0 & \frac{1}{2} \end{bmatrix}$$

$$\bar{\mathbf{x}} = \begin{bmatrix} 6 \\ 6 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} \frac{115}{2} & \frac{105}{2} \\ \frac{105}{2} & 50 \end{bmatrix}$$

$$\lambda_1 \approx \frac{425}{2} \quad \mathbf{p}_1 = \begin{bmatrix} \frac{15}{14} \\ 1 \end{bmatrix}$$

$$\lambda_2 \approx \frac{5}{2} \quad \mathbf{p}_2 = \begin{bmatrix} -\frac{13}{14} \\ 1 \end{bmatrix}$$

$$y = \frac{14}{15}x$$

Przykład 4 - $g = 5$ 

$$\bar{\mathbf{x}}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix} \quad \bar{\mathbf{x}}_2 = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad \bar{\mathbf{x}}_3 = \begin{bmatrix} 5 \\ 6 \end{bmatrix}$$

$$\bar{\mathbf{x}}_4 = \begin{bmatrix} 9 \\ 8 \end{bmatrix} \quad \bar{\mathbf{x}}_5 = \begin{bmatrix} 10 \\ 10 \end{bmatrix}$$


$$\mathbf{S}_1 = \mathbf{S}_2 = \mathbf{S}_3 = \mathbf{S}_4 = \mathbf{S}_5 = \begin{bmatrix} \frac{1}{2} & 0 \\ 0 & \frac{1}{2} \end{bmatrix}$$


$$\bar{\mathbf{x}} = \begin{bmatrix} 6 \\ 6 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} \frac{115}{2} & \frac{105}{2} \\ \frac{105}{2} & 50 \end{bmatrix}$$

$$\lambda_1 \approx \frac{425}{2} \quad \mathbf{p}_1 = \begin{bmatrix} \frac{15}{14} \\ 1 \end{bmatrix}$$

$$\lambda_2 \approx \frac{5}{2} \quad \mathbf{p}_2 = \begin{bmatrix} -\frac{13}{14} \\ 1 \end{bmatrix}$$

$$y = \frac{14}{15}x$$

Przykład 5 - $g = 3$ 

Przykład 5 - $g = 3$ 

Klasyfikator bayesowski

Zaobserwowany wektor \mathbf{x} klasyfikujemy jako pochodzący z tej klasy k , dla której wartość

$$p(k|\mathbf{x}) \quad k = 1, \dots, g$$

jest największa.

$p(k|\mathbf{x})$ - prawdopodobieństwo, że obserwacja \mathbf{x} pochodzi z klasy k

Klasyfikator bayesowski

Zaobserwowany wektor \mathbf{x} klasyfikujemy jako pochodzący z tej klasy k , dla której wartość

$$p(k|\mathbf{x}) \quad k = 1, \dots, g$$

jest największa.

$p(k|\mathbf{x})$ - prawdopodobieństwo, że obserwacja \mathbf{x} pochodzi z klasy k

Twierdzenie Bayesa

$$p(k|\mathbf{x}) = \frac{\pi_k p(\mathbf{x}|k)}{\sum_{r=1}^g \pi_r p(\mathbf{x}|r)} = \frac{\pi_k p(\mathbf{x}|k)}{p(\mathbf{x})}$$

Klasyfikator bayesowski

Zaobserwowany wektor \mathbf{x} klasyfikujemy jako pochodzący z tej klasy k , dla której wartość

$$p(k|\mathbf{x}) \quad k = 1, \dots, g$$

jest największa.

$p(k|\mathbf{x})$ - prawdopodobieństwo, że obserwacja \mathbf{x} pochodzi z klasy k

Twierdzenie Bayesa

$$p(k|\mathbf{x}) = \frac{\pi_k p(\mathbf{x}|k)}{\sum_{r=1}^g \pi_r p(\mathbf{x}|r)} = \frac{\pi_k p(\mathbf{x}|k)}{p(\mathbf{x})}$$

- $p(\mathbf{x}|k)$ - rozkład obserwacji \mathbf{x} z klasy k ,
- π_k - prawdopodobieństwo *a priori*, że obserwacja pochodzi z klasy k ,
- $p(\mathbf{x})$ - prawdopodobieństwo pojawienia się obserwacji \mathbf{x} .

Dla dwóch klas ($g = 2$)

Dla dwóch klas ($g = 2$)

$$\frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \frac{\pi_2 p(\mathbf{x}|2)}{\pi_1 p(\mathbf{x}|1)}$$

Dla dwóch klas ($g = 2$)

$$\frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \frac{\pi_2 p(\mathbf{x}|2)}{\pi_1 p(\mathbf{x}|1)}$$

Założmy teraz, że składowe wektora $\mathbf{x} = [x^1, x^2, \dots, x^p]^T$ są niezależne

Dla dwóch klas ($g = 2$)

$$\frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \frac{\pi_2 p(\mathbf{x}|2)}{\pi_1 p(\mathbf{x}|1)}$$

Założmy teraz, że składowe wektora $\mathbf{x} = [x^1, x^2, \dots, x^p]^T$ są niezależne

$$p(\mathbf{x}|k) = \prod_{i=1}^p p(x^{(i)}|k)$$

Dla dwóch klas ($g = 2$)

$$\frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \frac{\pi_2 p(\mathbf{x}|2)}{\pi_1 p(\mathbf{x}|1)}$$

Założmy teraz, że składowe wektora $\mathbf{x} = [x^1, x^2, \dots, x^p]^T$ są niezależne

$$p(\mathbf{x}|k) = \prod_{i=1}^p p(x^{(i)}|k)$$

Wtedy

$$\frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \frac{\pi_2 \prod_{i=1}^p p(x^i|2)}{\pi_1 \prod_{i=1}^p p(x^i|1)}$$



Po zlogarytmowaniu

Po zlogarytmowaniu

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\pi_2}{\pi_1} + \sum_{i=1}^p \ln \frac{p(x^i|2)}{p(x^i|1)}$$

Po zlogarytmowaniu

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\pi_2}{\pi_1} + \sum_{i=1}^p \ln \frac{p(x^i|2)}{p(x^i|1)}$$

Prowadzi to do następującej reguły klasyfikacyjnej:

Po zlogarytmowaniu

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\pi_2}{\pi_1} + \sum_{i=1}^p \ln \frac{p(x^i|2)}{p(x^i|1)}$$

Prowadzi to do następującej reguły klasyfikacyjnej:

Naiwny klasyfikator bayesowski dla $g = 2$

Jeżeli

$$\ln \frac{\pi_2}{\pi_1} + \sum_{i=1}^p \ln \frac{p(x^i|2)}{p(x^i|1)} > 0$$

sklasyfikuj obserwacje \mathbf{x} do klasy 2, w przeciwnym razie - do klasy 1.

Cechy naiwnego klasyfikatora bayesowskiego:

- **addytywny** wpływ kolejnych składowych wektora obserwacji \mathbf{x}

Cechy naiwnego klasyfikatora bayesowskiego:

- **addytywny** wpływ kolejnych składowych wektora obserwacji \mathbf{x}
- wartość prawdopodobieństw $p(x^i|k)$ są nieznane i estymujemy je jako

Cechy naiwnego klasyfikatora bayesowskiego:

- **addytywny** wpływ kolejnych składowych wektora obserwacji \mathbf{x}
- wartość prawdopodobieństw $p(x^i|k)$ są nieznane i estymujemy je jako

$$\hat{p}(x^i = l|k) = \frac{n_{ik}(l)}{n_{ik}}$$

Cechy naiwnego klasyfikatora bayesowskiego:

- **addytywny** wpływ kolejnych składowych wektora obserwacji \mathbf{x}
- wartości prawdopodobieństw $p(x^i|k)$ są nieznane i estymujemy je jako

$$\hat{p}(x^i = l|k) = \frac{n_{ik}(l)}{n_{ik}}$$

- n_{ik} - liczba wszystkich obserwacji w próbie uczącej z klasy k , dla których została zmierzona wartość i -tej składowej,
- $n_{ik}(l)$ - liczba wszystkich obserwacji w próbie uczącej z klasy k , dla których została zmierzona wartość i -tej składowej, która przyjęła poziom l

Cechy naiwnego klasyfikatora bayesowskiego:

- **addytywny** wpływ kolejnych składowych wektora obserwacji \mathbf{x}
- wartość prawdopodobieństw $p(x^i|k)$ są nieznane i estymujemy je jako

$$\hat{p}(x^i = l|k) = \frac{n_{ik}(l)}{n_{ik}}$$

- n_{ik} - liczba wszystkich obserwacji w próbie uczącej z klasy k , dla których została zmierzona wartość i -tej składowej,
- $n_{ik}(l)$ - liczba wszystkich obserwacji w próbie uczącej z klasy k , dla których została zmierzona wartość i -tej składowej, która przyjęła poziom l
- podobnie $\hat{\pi}_k$ estymujemy jako $\frac{n_k}{n}$, gdzie n liczba wszystkich obserwacji, n_k - liczba obserwacji z klasy k

Kodowanie

- Wilgotność powietrza:

Kodowanie

- Wilgotność powietrza:
 - 0-30 % 🌧️ (mała),
 - 31-70 % 🌧️🌧️ (średnia),
 - 71-100 % 🌧️🌧️🌧️ (duża),

Kodowanie

- Wilgotność powietrza:
 - 0-30 % 🌧️ (mała),
 - 31-70 % 🌧️🌧️ (średnia),
 - 71-100 % 🌧️🌧️🌧️ (duża),
- Ciśnienie atmosferyczne:









Kodowanie

- Wilgotność powietrza:
 - 0-30 % 🌧️ (mała),
 - 31-70 % 🌧️🌧️ (średnia),
 - 71-100 % 🌧️🌧️🌧️ (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa 🌡️ (niskie),
 - 990-1010 hPa 🌡️ (średnie),
 - > 1010 hPa 🌡️ (duże),

Kodowanie

- Wilgotność powietrza:
 - 0-30 % 🌧️ (mała),
 - 31-70 % 🌧️🌧️ (średnia),
 - 71-100 % 🌧️🌧️🌧️ (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa 🌡️ (niskie),
 - 990-1010 hPa 🌡️ (średnie),
 - > 1010 hPa 🌡️ (duże),
- Klasy:

Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),









dzień

wilgotność

ciśnienie

klasa

Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),

dzień

wilgotność









ciśnienie



klasa

1




















Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),









dzień	wilgotność	ciśnienie	klasa
1			
2			













Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),









dzień	wilgotność	ciśnienie	klasa
1			
2			
3			

Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),

dzień	wilgotność	ciśnienie	klasa
1			
2			
3			
4			

Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),

dzień

wilgotność

ciśnienie

klasa

1



2



3











4





















5































Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),









dzień	wilgotność	ciśnienie	klasa
1			
2			
3			
4			
5			
6			

























Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),









dzień	wilgotność	ciśnienie	klasa
1			
2			
3			
4			
5			
6			
7			




























Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),









dzień	wilgotność	ciśnienie	klasa
1			
2			
3			
4			
5			
6			
7			
8			































Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),









dzień	wilgotność	ciśnienie	klasa
1			
2			
3			
4			
5			
6			
7			
8			
9			


































Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),









dzień	wilgotność	ciśnienie	klasa
1			
2			
3			
4			
5			
6			
7			
8			
9			
10			





































Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),

dzień	wilgotność	ciśnienie	klasa
1			
2			
3			
4			
5			
6			
7			
8			
9			
10			
11			

Kodowanie

- Wilgotność powietrza:
 - 0-30 %  (mała),
 - 31-70 %  (średnia),
 - 71-100 %  (duża),
- Ciśnienie atmosferyczne:
 - < 990 hPa  (niskie),
 - 990-1010 hPa  (średnie),
 - > 1010 hPa  (duże),
- Klasy:
 - klasa 1  (pogoda),
 - klasa 2  (deszcz),

dzień	wilgotność	ciśnienie	klasa
1			
2			
3			
4			
5			
6			
7			
8			
9			
10			
11			
12			







Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7







Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Naiwny klasyfikator bayesowski - przykład





	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7





	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.

Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.

Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} =$$



Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1





Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.

Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1}$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1





Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.

Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)}$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1





Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.

Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)} + \ln \frac{\hat{p}(p = \text{wysokie}|2)}{\hat{p}(p = \text{wysokie}|1)}$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.





Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)} + \ln \frac{\hat{p}(p = \text{wysokie}|2)}{\hat{p}(p = \text{wysokie}|1)}$$

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} =$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.





Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)} + \ln \frac{\hat{p}(p = \text{wysokie}|2)}{\hat{p}(p = \text{wysokie}|1)}$$

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\frac{7}{12}}{\frac{5}{12}}$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.





Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)} + \ln \frac{\hat{p}(p = \text{wysokie}|2)}{\hat{p}(p = \text{wysokie}|1)}$$

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{7}{12} + \ln \frac{2}{5}$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.





Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)} + \ln \frac{\hat{p}(p = \text{wysokie}|2)}{\hat{p}(p = \text{wysokie}|1)}$$

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{7}{12} + \ln \frac{2}{7} + \ln \frac{1}{5}$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.





Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)} + \ln \frac{\hat{p}(p = \text{wysokie}|2)}{\hat{p}(p = \text{wysokie}|1)}$$

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{7}{12} + \ln \frac{2}{7} + \ln \frac{1}{5} = \ln \frac{7}{5} \frac{2}{7} \frac{1}{5}$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.





Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)} + \ln \frac{\hat{p}(p = \text{wysokie}|2)}{\hat{p}(p = \text{wysokie}|1)}$$

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\frac{7}{12}}{\frac{5}{12}} + \ln \frac{\frac{2}{7}}{\frac{2}{5}} + \ln \frac{\frac{1}{7}}{\frac{1}{5}} = \ln \frac{7}{5} \frac{2}{7} \frac{5}{2} \frac{1}{7} \frac{5}{1} = \ln \frac{5}{7}$$

Naiwny klasyfikator bayesowski - przykład

	wilgotność		ciśnienie	
				
niskie	2	2	1	4
średnie	2	4	3	2
wysokie	1	1	1	1
Σ	5	7	5	7

	wilgotność		ciśnienie	
				
niskie	2/5	2/7	1/5	4/7
średnie	2/5	4/7	3/5	2/7
wysokie	1/5	1/7	1/5	1/7
Σ	1	1	1	1

Estymacja prawdopodobieństw a priori: $\hat{\pi}_1 = \frac{5}{12}$, $\hat{\pi}_2 = \frac{7}{12}$.

Pojawia się nowa obserwacja $\mathbf{x} = [H = \text{niska}, p = \text{wysokie}]^T$. Do której klasy należy ją sklasyfikować?

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\hat{\pi}_2}{\hat{\pi}_1} + \ln \frac{\hat{p}(H = \text{niska}|2)}{\hat{p}(H = \text{niska}|1)} + \ln \frac{\hat{p}(p = \text{wysokie}|2)}{\hat{p}(p = \text{wysokie}|1)}$$

$$\ln \frac{p(2|\mathbf{x})}{p(1|\mathbf{x})} = \ln \frac{\frac{7}{12}}{\frac{5}{12}} + \ln \frac{\frac{2}{7}}{\frac{2}{5}} + \ln \frac{\frac{1}{7}}{\frac{1}{5}} = \ln \frac{7}{5} \frac{2}{7} \frac{5}{2} \frac{1}{7} \frac{5}{1} = \ln \frac{5}{7} < 0 \quad \text{☀}$$

Rozważmy k klas i obserwacje \mathbf{x} pochodzące z wielowymiarowego rozkładu Gaussa $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S})$, czyli:

Rozważmy k klas i obserwacje \mathbf{x} pochodzące z wielowymiarowego rozkładu Gaussa $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S})$, czyli:

- $$p(\mathbf{x}|k) = \frac{1}{(2\pi)^{\frac{p}{2}} |\mathbf{S}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{m}_k) \right]$$

Rozważmy k klas i obserwacje \mathbf{x} pochodzące z wielowymiarowego rozkładu Gaussa $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S})$, czyli:

- $p(\mathbf{x}|k) = \frac{1}{(2\pi)^{\frac{p}{2}} |\mathbf{S}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{m}_k) \right]$
- każda klasa k jest scharakteryzowana wartością oczekiwaną \mathbf{m}_k

Rozważmy k klas i obserwacje \mathbf{x} pochodzące z wielowymiarowego rozkładu Gaussa $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S})$, czyli:

- $p(\mathbf{x}|k) = \frac{1}{(2\pi)^{\frac{p}{2}} |\mathbf{S}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{m}_k) \right]$
- każda klasa k jest scharakteryzowana wartością oczekiwaną \mathbf{m}_k
- wszystkie klasy mają taką samą macierz kowariancji \mathbf{S}

Rozważmy k klas i obserwacje \mathbf{x} pochodzące z wielowymiarowego rozkładu Gaussa $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S})$, czyli:

- $p(\mathbf{x}|k) = \frac{1}{(2\pi)^{\frac{p}{2}} |\mathbf{S}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{m}_k) \right]$
- każda klasa k jest scharakteryzowana wartością oczekiwaną \mathbf{m}_k
- wszystkie klasy mają taką samą macierz kowariancji \mathbf{S}

Korzystając z reguły bayesowskiej można określić **funkcję dyskryminacyjną** dla $g = 2$

Rozważmy k klas i obserwacje \mathbf{x} pochodzące z wielowymiarowego rozkładu Gaussa $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S})$, czyli:

- $p(\mathbf{x}|k) = \frac{1}{(2\pi)^{\frac{p}{2}} |\mathbf{S}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{m}_k) \right]$
- każda klasa k jest scharakteryzowana wartością oczekiwaną \mathbf{m}_k
- wszystkie klasy mają taką samą macierz kowariancji \mathbf{S}

Korzystając z reguły bayesowskiej można określić **funkcję dyskryminacyjną** dla $g = 2$

$$\delta_{12}(\mathbf{x}) = \ln \frac{p(1|\mathbf{x})}{p(2|\mathbf{x})} = \ln \frac{\pi_1}{\pi_2} + \ln \frac{p(\mathbf{x}|1)}{p(\mathbf{x}|2)}$$

czyli

Rozważmy k klas i obserwacje \mathbf{x} pochodzące z wielowymiarowego rozkładu Gaussa $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S})$, czyli:

- $p(\mathbf{x}|k) = \frac{1}{(2\pi)^{\frac{p}{2}} |\mathbf{S}|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{m}_k) \right]$
- każda klasa k jest scharakteryzowana wartością oczekiwaną \mathbf{m}_k
- wszystkie klasy mają taką samą macierz kowariancji \mathbf{S}

Korzystając z reguły bayesowskiej można określić **funkcję dyskryminacyjną** dla $g = 2$

$$\delta_{12}(\mathbf{x}) = \ln \frac{p(1|\mathbf{x})}{p(2|\mathbf{x})} = \ln \frac{\pi_1}{\pi_2} + \ln \frac{p(\mathbf{x}|1)}{p(\mathbf{x}|2)}$$

czyli

$$\delta_{12}(\mathbf{x}) = \ln \frac{\pi_1}{\pi_2} + \frac{1}{2} (\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{S}^{-1} (\mathbf{m}_1 + \mathbf{m}_2) + (\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{S}^{-1} \mathbf{x}$$

Jeżeli $\delta_{12}(\mathbf{x}) > 0$, to obserwacja \mathbf{x} zostaje sklasyfikowana jako pochodząca z klasy 1, jeżeli $\delta_{12}(\mathbf{x}) < 0$, to \mathbf{x} jest z klasy 2.

Jeżeli $\delta_{12}(\mathbf{x}) > 0$, to obserwacja \mathbf{x} zostaje sklasyfikowana jako pochodząca z klasy 1, jeśli $\delta_{12}(\mathbf{x}) < 0$, to \mathbf{x} jest z klasy 2.


Równanie hiperpłaszczyzny dyskryminacyjnej

$$\ln \frac{\pi_1}{\pi_2} + \frac{1}{2}(\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{S}^{-1}(\mathbf{m}_1 + \mathbf{m}_2) + (\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{S}^{-1} \mathbf{x} = 0$$

Jeżeli $\delta_{12}(\mathbf{x}) > 0$, to obserwacja \mathbf{x} zostaje sklasyfikowana jako pochodząca z klasy 1, jeśli $\delta_{12}(\mathbf{x}) < 0$, to \mathbf{x} jest z klasy 2.

Równanie hiperpłaszczyzny dyskryminacyjnej

$$\ln \frac{\pi_1}{\pi_2} + \frac{1}{2}(\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{S}^{-1}(\mathbf{m}_1 + \mathbf{m}_2) + (\mathbf{m}_1 - \mathbf{m}_2)^T \mathbf{S}^{-1} \mathbf{x} = 0$$



Próba losowa z $n_1 = 60$,
 $n_2 = 10$.

$$\mathbf{S} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad \mathbf{m}_1 = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$$

$$\mathbf{m}_2 = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$

W przypadku gdy $\mathbf{W} = \mathbf{S}$ oraz $\pi_1 = \pi_2$ otrzymujemy dyskryminację Fishera (kreskowana linia).

Jeżeli $g > 2$ można podać równania hiperpłaszczyzn rozdzielających **pary klas**.

Jeżeli $g > 2$ można podać równania hiperpłaszczyzn rozdzielających **pary klas**.



Równanie hiperpłaszczyzny dyskryminacyjnej dla LDA

$$\delta_{kl}(\mathbf{x}) = \ln \frac{\pi_1}{\pi_2} + \frac{1}{2}(\mathbf{m}_k - \mathbf{m}_l)^T \mathbf{S}^{-1}(\mathbf{m}_k + \mathbf{m}_l) + (\mathbf{m}_k - \mathbf{m}_l)^T \mathbf{S}^{-1} \mathbf{x} = 0$$

Jeżeli $g > 2$ można podać równania hiperpłaszczyzn rozdzielających **pary klas**.

Równanie hiperpłaszczyzny dyskryminacyjnej dla LDA

$$\delta_{kl}(\mathbf{x}) = \ln \frac{\pi_1}{\pi_2} + \frac{1}{2}(\mathbf{m}_k - \mathbf{m}_l)^T \mathbf{S}^{-1}(\mathbf{m}_k + \mathbf{m}_l) + (\mathbf{m}_k - \mathbf{m}_l)^T \mathbf{S}^{-1} \mathbf{x} = 0$$



W przypadku metody QDA (*quadratic discriminant analysis*) zakładamy różne macierze kowariancji $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S}_k)$.

W przypadku metody QDA (*quadratic discriminant analysis*) zakładamy różne macierze kowariancji $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S}_k)$.

Równanie hiperpłaszczyzny dyskryminacyjnej dla QDA

$$\delta_{kl}(\mathbf{x}) = \ln \frac{\pi_1}{\pi_2} + \frac{1}{2} \ln \frac{|\mathbf{S}_k|}{|\mathbf{S}_l|} + \mathbf{x}^T (\mathbf{S}_l^{-1} \mathbf{m}_l - \mathbf{S}_k^{-1} \mathbf{m}_k) - \frac{1}{2} \mathbf{x}^T (\mathbf{S}_l^{-1} - \mathbf{S}_k^{-1}) \mathbf{x} - \frac{1}{2} \mathbf{m}_l^T \mathbf{S}_l^{-1} \mathbf{m}_l + \frac{1}{2} \mathbf{m}_k^T \mathbf{S}_k^{-1} \mathbf{m}_k = 0$$

W przypadku metody QDA (*quadratic discriminant analysis*) zakładamy różne macierze kowariancji $p(\mathbf{x}|k) \sim \mathcal{N}(\mathbf{m}_k, \mathbf{S}_k)$.

Równanie hiperpłaszczyzny dyskryminacyjnej dla QDA

$$\delta_{kl}(\mathbf{x}) = \ln \frac{\pi_1}{\pi_2} + \frac{1}{2} \ln \frac{|\mathbf{S}_k|}{|\mathbf{S}_l|} + \mathbf{x}^T (\mathbf{S}_l^{-1} \mathbf{m}_l - \mathbf{S}_k^{-1} \mathbf{m}_k) - \frac{1}{2} \mathbf{x}^T (\mathbf{S}_l^{-1} - \mathbf{S}_k^{-1}) \mathbf{x} - \frac{1}{2} \mathbf{m}_l^T \mathbf{S}_l^{-1} \mathbf{m}_l + \frac{1}{2} \mathbf{m}_k^T \mathbf{S}_k^{-1} \mathbf{m}_k = 0$$

