

"Maximal margin classifier"

$$(x_i, y_i) \in \mathbb{R}^p \times \{-1, 1\}$$

Zakładamy, że istnieją $\beta_0 \in \mathbb{R}, \beta_1 \in \mathbb{R}^p$:

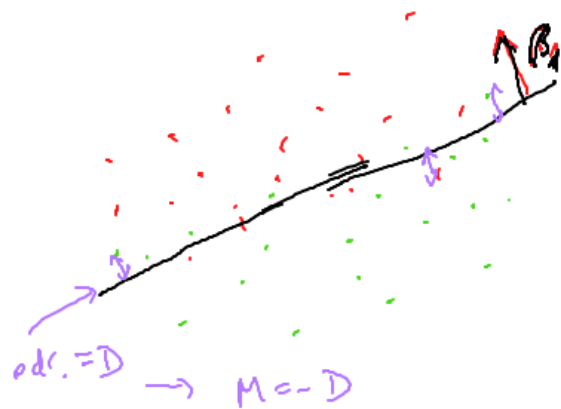


$$(\beta_0 + \beta_1 \cdot x_i) y_i > 0, \quad i=1, \dots, n$$

Wybieramy β_0, β_1 tak, aby zmaksymalizować M takie, że

$$(\beta_0 + \beta_1 \cdot x_i) y_i \geq M, \quad i=1, \dots, n$$

przy założeniu, że $\|\beta_1\|^2 = 1$.

Uklasyfikacja: $\text{sgn}(\beta_0 + \beta_1 \cdot x)$



"Support vector classification" (klasifikator relacyjny "wężki"?)

$C \geq 0$ - parameter ustalony z góry

Wybieramy β_0, β_1 tak, aby zmaksymalizować M takie, że

zachodzi $y_i \cdot (\beta_0 + \beta_1 \cdot x_i) \geq M(1 - \epsilon_i)$, $i=1, \dots, n$, $\|\beta_1\|^2 = 1$

Jeżeli parametry $\epsilon_i \geq 0$, $\sum_{i=1}^n \epsilon_i \leq C$

(tw. Karush-Kuhn-Tuckera)

Klasyfikacja: $\text{sgn}(\beta_0 + \beta_1 \cdot x)$ $\langle x_i, x_j \rangle$

Zauważamy $f(x) = \beta_0 + \beta_1 \cdot x = \sum_{i=1}^n d_i y_i \langle x_i, x \rangle + \beta_0$

nie będzie ujemne (długość tego jest)

$$\begin{bmatrix} \langle x_1, x_1 \rangle & \langle x_1, x_2 \rangle & \dots & \langle x_1, x_n \rangle \\ \vdots & & & \\ \langle x_n, x_1 \rangle & \dots & \dots & \langle x_n, x_n \rangle \end{bmatrix}$$

decyduje się, że

macierz Grama

nie będzie ujemne (długość tego jest) $\langle x_i, x_j \rangle = \langle x_i, x_j \rangle$



$\epsilon_1 = C, \epsilon_2 = \dots = \epsilon_n = 0$
 $y. C=2$

"Support vector machine" (maszyna wektorów nośnych)

w metodzie SVC rozstrzygniemy $\langle \cdot, \cdot \rangle$ przez funkcję $K(\cdot, \cdot)$ symetryczną ujemnie określony

np- $K(x, x') = \exp(-\gamma \|x - x'\|^2)$


$$K(x, x') = (1 + \|x - x'\|^2)^{-p}$$

jest w scikit

Klasteryzacja

układanie wienadzrowane

Cel: podzielić dane na pewną liczbę grup tak,
aby dane wewnątrz każdej grupy były podobne do siebie,
a dane z różnych grup niepodobne do siebie



"K-średnich" (K-means)

Zadajemy z góry liczbę klas K .

Notacja: $C_1, C_2, \dots, C_K \subset \{1, 2, \dots, n\}$

podobny
zbiór
indeksów

$$C_1 \cup \dots \cup C_K = \{1, \dots, n\}$$

$$C_i \cap C_j = \emptyset \text{ dla } i \neq j$$

$\rightarrow C_i$ - klastery i -ty $\{x_e: e \in C_i\}$ - dane z klastrem i -tego

dane:
 $x_1, \dots, x_n \in \mathbb{R}^p$

Pomysł: podział na klastry jest dobry, jeśli ^{każde} wariacje wewnętrzne klastrów jest mała:

czyli minimalizujemy
$$\sum_{j=1}^K W(C_j)$$

czyli wybieramy:
$$W(C_k) = \frac{1}{|C_k|} \sum_{i, i' \in C_k} \|x_i - x_{i'}\|^2$$

Algorytm K-Srednich pozwala znaleźć pewne разбие C_k , dla którego $\sum_{j=1}^K W(C_j)$ jest w miarę mała.

1) Losowo przydzielamy obserwacje do jednej z klas $1, \dots, K$

w ten sposób dostajemy pewien partition podział na klastry $C_1, \dots, C_k \neq \emptyset$
to trzeba zobaczyć.


2) Iterujemy:

(a) Dla każdego klastru znajdujemy jego centroid: $\bar{x}_k = \frac{1}{|C_k|} \sum_{i \in C_k} x_i \in \mathbb{R}^p$, $k=1, \dots, K$


(b) przyporządkowujemy (na nowo) każde x_i do takiego C_j , aby $\|x_i - \bar{x}_j\|$ było minimalne

tak długo, aż (b) ~~nie~~ nie zmieni. $\sum_{j=1}^K W(C_j)$ $i \in \{1, \dots, n\}$

Np. 6 punktów
 $K=2$



1)




$C_1 = \{2, 3, 6\}$ $C_2 = \{1, 4, 5\}$

a) najbliższy centroidy:

$$\bar{x}_1 = \frac{1}{3}(x_2 + x_3 + x_6)$$


$$\bar{x}_2 = \frac{1}{3}(x_1 + x_4 + x_5)$$

b) Jeśli x_i jest bliżej \bar{x}_1 niż \bar{x}_2 ,
 to $i \in \tilde{C}_1$, a w przeciwnym razie $i \in \tilde{C}_2$



$\tilde{C}_1 = \{1, 2, 3\}$ $\tilde{C}_2 = \{4, 5, 6\}$

a2) najbliższy centroidy



b2) $\tilde{C}_1 = \tilde{C}_1$, $\tilde{C}_2 = \tilde{C}_2$ nie się nie zmienia

Ostatnia część C_j nie jest zależna od (bawego) wyboru w 1)

Kroki 2a-2b ~~nie~~ nie zwracają uwagi na $\sum_{j=1}^K W(C_j)$, gdzie $W(C_j) = \frac{1}{|C_j|} \sum_{i,i' \in C_j} \|x_i - x_{i'}\|^2$,

dlatego po pewnej liczbie kroków $\sum_{j=1}^K W(C_j)$ ~~nie~~ nie będzie się zmniejszał. $\bar{x}_j = \frac{1}{|C_j|} \sum_{i \in C_j} x_i$

Różnica: $W(C_j) = \frac{1}{|C_j|} \sum_{i,k \in C_j} \|(x_i - \bar{x}_j) + (\bar{x}_j - x_k)\|^2 =$

$$= \frac{1}{|C_j|} \sum_{i,k} \langle (x_i - \bar{x}_j) + (\bar{x}_j - x_k), (x_i - \bar{x}_j) + (\bar{x}_j - x_k) \rangle = \frac{1}{|C_j|} \left(\sum_{i,k \in C_j} \|x_i - \bar{x}_j\|^2 + 2 \sum_{i,k} \langle x_i - \bar{x}_j, \bar{x}_j - x_k \rangle + \sum_{i,k} \|\bar{x}_j - x_k\|^2 \right)$$

$$= 2 \sum_i \|x_i - \bar{x}_j\|^2 + \frac{1}{|C_j|} 2 \left\langle \sum_i \underbrace{(x_i - \bar{x}_j)}_0, \sum_k \underbrace{(\bar{x}_j - x_k)}_0 \right\rangle$$

$$= \sum_{k \in C_j} \left(\sum_i \|x_i - \bar{x}_j\|^2 \right) = |C_j| \cdot \sum_i \|x_i - \bar{x}_j\|^2$$

$$\sum_i (x_i - \bar{x}_j) = \sum_i x_i - \sum_k \bar{x}_j = \sum_i x_i - |C_j| \cdot \frac{1}{|C_j|} \sum_i x_i = 0 \in \mathbb{R}^p$$

$$W(C_j) = 2 \sum_i \|x_i - \bar{x}_j\|^2$$

Druga obserwacja: $\sum_{i \in C_j} \|x_i - \bar{x}_j\|^2 = \min_{a \in \mathbb{R}^p} \sum_{i \in C_j} \|x_i - a\|^2$


Przebadanie: $\sum_{i \in C_j} \|x_i - \bar{x}_j + \bar{x}_j - a\|^2 = \sum_{i \in C_j} \langle \underbrace{(x_i - \bar{x}_j)} + (\bar{x}_j - a), \underbrace{(x_i - \bar{x}_j)} + (\bar{x}_j - a) \rangle =$

$$= \sum_{i \in C_j} \|x_i - \bar{x}_j\|^2 + 2 \underbrace{\sum_{i \in C_j} \langle x_i - \bar{x}_j, \bar{x}_j - a \rangle}_{= \langle \sum_{i \in C_j} (x_i - \bar{x}_j), \bar{x}_j - a \rangle} + \sum_{i \in C_j} \|\bar{x}_j - a\|^2 =$$

$$\underbrace{\langle \sum_{i \in C_j} (x_i - \bar{x}_j), \bar{x}_j - a \rangle}_{= 0}$$

$$= \sum_{i \in C_j} \|x_i - \bar{x}_j\|^2 + |C_j| \cdot \|\bar{x}_j - a\|^2$$

$$\sum_{j=1}^K W(C_j) = 2 \sum_{j=1}^K \sum_{i \in C_j} \|x_i - \bar{x}_j\|^2 = 2 \sum_{j=1}^K \min_{a \in \mathbb{R}^p} \sum_{i \in C_j} \|x_i - a\|^2$$



C_1, \dots, C_K a) $\bar{x}_1, \dots, \bar{x}_K$

b) umierumung C_j na $\tilde{C}_j \rightarrow$ ~~umierumung~~

$$2 \sum_{j=1}^K \sum_{i \in \tilde{C}_j} \|x_i - \bar{x}_j\|^2 \geq$$

$$\geq 2 \sum_{j=1}^K \sum_{i \in \tilde{C}_j} \|x_i - \tilde{x}_j\|^2 = \sum_{j=1}^K W(\tilde{C}_j)$$

↑
centroidy dla \tilde{C}_j

Zadanie 4

Zapamięć się z SVM lub k-means (do wyboru)



do 23 ✓

1,2,3

k-means: redukcja liczby kolorów

węsko 2^{24} kolorów $\approx 16.7 \cdot 10^6$

karty piksel — jedna obserwacja $\in \mathbb{R}^3$
(r, g, b)



(dobrze wybrać dane wymagające pewnej obsługi i w tym lub innym zadaniu)