



# SVM: Maszyny Wektorów Podpierających

Nguyen Hung Son



## 1 Wprowadzenie

## 2 Brak liniowej separowalności danych

- Nieznaczną nieseparowalność
- Zmianę przestrzeni atrybutów

## 3 Implementacja

Dana jest próbka treningowa


$$D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\} \text{ gdzie } y_i \in \{-1, 1\}, \mathbf{x}_i \in \mathbb{R}^p$$



# Liniony klasyfikator

Dana jest próbka treningowa


$$D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\} \text{ gdzie } y_i \in \{-1, 1\}, \mathbf{x}_i \in \mathbb{R}^p$$



# Liniony klasyfikator

Dana jest próbka treningowa


$$D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\} \text{ gdzie } y_i \in \{-1, 1\}, \mathbf{x}_i \in \mathbb{R}^p$$



# Liniony klasyfikator

Dana jest próbka treningowa

$$D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\} \text{ gdzie } y_i \in \{-1, 1\}, \mathbf{x}_i \in \mathbb{R}^p$$




- Klasyfikatorem liniowym nazywamy funkcję

$$f_{\mathbf{w},b}(\mathbf{x}) = \text{sgn}(\mathbf{w} \cdot \mathbf{x} + b)$$

# Liniony klasyfikator

Dana jest próbka treningowa

$$D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\} \text{ gdzie } y_i \in \{-1, 1\}, \mathbf{x}_i \in \mathbb{R}^p$$



- Klasyfikatorem liniowym nazywamy funkcję

$$f_{\mathbf{w},b}(\mathbf{x}) = \text{sgn}(\mathbf{w} \cdot \mathbf{x} + b)$$

- Próbka  $D$  jest liniowo separowana jeśli istnieje klasyfikator liniowy  $f_{\mathbf{w},b}(\cdot)$  taki, że

$$\mathbf{w} \cdot \mathbf{x}_i + b \geq +1, \text{ gdy } y_i = +1$$

$$\mathbf{w} \cdot \mathbf{x}_i + b < -1, \text{ gdy } y_i = -1$$

# Liniowy klasyfikator


---






# Liniowy klasyfikator

---




# Liniowy klasyfikator

---



# Liniowy klasyfikator




- Uproszczony warunek:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1,$$

dla każdego  $i$ .

# Liniowy klasyfikator




- Uproszczony warunek:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1,$$

dla każdego  $i$ .

- Każda z tych linii dobrze separuje punkty;

# Liniowy klasyfikator



- Uproszczony warunek:



$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1,$$

dla każdego  $i$ .

- Każda z tych linii dobrze separuje punkty;
- Która z nich jest najlepsza?

# Margines klasyfikatora liniowego



- Margines = szerokość bezpiecznego obszaru po obu stronach hiperpłaszczyzny;



# Margines klasyfikatora liniowego




- Margines = szerokość bezpiecznego obszaru po obu stronach hiperpłaszczyzny;
- Margines jest wyznaczony przez 2 hiperpłaszczyzny.



# Margines klasyfikatora liniowego



- Margines = szerokość bezpiecznego obszaru po obu stronach hiperpłaszczyzny;
- Margines jest wyznaczony przez 2 hiperpłaszczyzny.
- Chcemy znaleźć klasyfikator z maksymalnym marginesem







Maksymalizujemy  $d(H_1, H_2)$  lub minimalizujemy  $\frac{\|\mathbf{w}\|}{2}$ .



Maksymalizujemy  $d(H_1, H_2)$  lub minimalizujemy  $\frac{\|\mathbf{w}\|}{2}$ .

# Wektory podpierające

---

- Niech  $H_1, H_2$  będą brzegami marginesu;



Maksymalizujemy  $d(H_1, H_2)$  lub minimalizujemy  $\frac{\|\mathbf{w}\|}{2}$ .

# Wektory podpierające

---



- Niech  $H_1, H_2$  będą brzegami marginesu;
- Powiniśmy oprzeć brzegi o punkty z próbki treningowej

Maksymalizujemy  $d(H_1, H_2)$  lub minimalizujemy  $\frac{\|\mathbf{w}\|}{2}$ .

# Wektory podpierające

---



- Niech  $H_1, H_2$  będą brzegami marginesu;
- Powiniśmy oprzeć brzegi o punkty z próbki treningowej
- Te punkty nazywamy *wektorami podpierającymi*

Maksymalizujemy  $d(H_1, H_2)$  lub minimalizujemy  $\frac{\|\mathbf{w}\|}{2}$ .



- Niech  $H_1, H_2$  będą brzegami marginesu;
- Powiniśmy oprzeć brzegi o punkty z próbki treningowej
- Te punkty nazywamy *wektorami podpierającymi*
- Równanie  $H_1$  i  $H_2$ :

$$H_1 : \mathbf{w} \cdot \mathbf{x} + b = 1$$

$$H_2 : \mathbf{w} \cdot \mathbf{x} + b = -1$$

Maksymalizujemy  $d(H_1, H_2)$  lub minimalizujemy  $\frac{\|\mathbf{w}\|}{2}$ .


# Wektory podpierające



- Niech  $H_1, H_2$  będą brzegami marginesu;
- Powiniśmy oprzeć brzegi o punkty z próbki treningowej
- Te punkty nazywamy *wektorami podpierającymi*
- Równanie  $H_1$  i  $H_2$ :

$$H_1 : \mathbf{w} \cdot \mathbf{x} + b = 1$$

$$H_2 : \mathbf{w} \cdot \mathbf{x} + b = -1$$



Odległość między  $H_1$  a  $H_2$ :

$$d(H_1, H_2) = \frac{2}{\|\mathbf{w}\|}$$

Maksymalizujemy  $d(H_1, H_2)$  lub minimalizujemy  $\frac{\|\mathbf{w}\|}{2}$ .

## Zadanie LSVM

Znaleźć  $\mathbf{w}$  i  $b$  które minimalizują

$$\frac{\|\mathbf{w}\|^2}{2}$$

przy ograniczeniach

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) - 1 \geq 0; i = 1, \dots, n$$

Q: Jak rozwiązać tego typu zagadnienia?

A: Metodą gradientu?, symulowanego wyżrzania?,  
odwracanie macierzy? EM? Newton?  
PROGRAMOWANIE KWADRATOWE?





- Znaleźć

$$\arg \max_{\mathbf{u}} c + \mathbf{d}^T \mathbf{u} + \frac{\mathbf{u}^T R \mathbf{u}}{2}$$

To zagadnienie jest dobrze zbadane i istnieją bardzo efektywne algorytmy rozwiązujące ten problem



- Znaleźć

$$\arg \max_{\mathbf{u}} c + \mathbf{d}^T \mathbf{u} + \frac{\mathbf{u}^T R \mathbf{u}}{2}$$

- przy założeniach:

$$A_1 \mathbf{u} \leq \mathbf{b}_1$$

To zagadnienie jest dobrze zbadane i istnieją bardzo efektywne algorytmy rozwiązujące ten problem



- Znaleźć

$$\arg \max_{\mathbf{u}} c + \mathbf{d}^T \mathbf{u} + \frac{\mathbf{u}^T R \mathbf{u}}{2}$$

- przy założeniach:

$$A_1 \mathbf{u} \leq \mathbf{b}_1$$

- oraz

$$A_2 \mathbf{u} = \mathbf{b}_2$$

To zagadnienie jest dobrze zbadane i istnieją bardzo efektywne algorytmy rozwiązujące ten problem



- Rozwiązywanie zagadnienia LSVM  $\Leftrightarrow$  znalezienie punktu siodłowego wielomianu Lagrange'a:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2}(\mathbf{w} \cdot \mathbf{w}) - \sum_{i=1}^n \alpha_i \{[(\mathbf{x}_i \cdot \mathbf{w}) - b]y_i - 1\}$$

gdzie  $\alpha = (\alpha_1, \dots, \alpha_n)$  jest wektorem nieujemnych współczynników Lagrange'a



- Rozwiązywanie zagadnienia LSVM  $\Leftrightarrow$  znalezienie punktu siodłowego wielomianu Lagrange'a:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2}(\mathbf{w} \cdot \mathbf{w}) - \sum_{i=1}^n \alpha_i \{[(\mathbf{x}_i \cdot \mathbf{w}) - b]y_i - 1\}$$

gdzie  $\alpha = (\alpha_1, \dots, \alpha_n)$  jest wektorem nieujemnych współczynników Lagrange'a

- **Punkt siodłowy** = maksimum funkcji względem  $\alpha_i \geq 0$  i minimum funkcji względem  $\mathbf{w}$  i  $b$ .

**Twierdzenie Karusha-Kuhna-Tuckera:** warunkiem koniecznym istnienia punktu siodłowego jest

- zerowanie się gradientu wzg.  $\mathbf{w}$ , czyli

$$\mathbf{w} = \sum_{i=1}^n y_i \alpha_i \mathbf{x}_i \quad (1)$$

**Twierdzenie Karusha-Kuhna-Tuckera:** warunkiem koniecznym istnienia punktu siodlowego jest

- zerowanie się gradientu wzg.  $\mathbf{w}$ , czyli

$$\mathbf{w} = \sum_{i=1}^n y_i \alpha_i \mathbf{x}_i \quad (1)$$

- zerowanie się pochodnej wzg.  $b$ , czyli

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (2)$$

**Twierdzenie Karusha-Kuhna-Tuckera:** warunkiem koniecznym istnienia punktu siodłowego jest

- zerowanie się gradientu wzg.  $\mathbf{w}$ , czyli

$$\mathbf{w} = \sum_{i=1}^n y_i \alpha_i \mathbf{x}_i \quad (1)$$

- zerowanie się pochodnej wzg.  $b$ , czyli

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (2)$$

- spełnienie warunku:

$$\alpha_i \{ [(\mathbf{x}_i \cdot \mathbf{w}_0) - b_0] y_i - 1 \} = 0, \text{ for } i = 1, \dots, n \quad (3)$$





Po uwzględnieniu tych warunków (na istnienie punktu siodłowego) mamy nowy problem optymalizacyjny:

- Znaleźć wektor  $\alpha$  będący maksimum funkcji

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (4)$$



Po uwzględnieniu tych warunków (na istnienie punktu siedłowego) mamy nowy problem optymalizacyjny:

- Znaleźć wektor  $\alpha$  będący maksimum funkcji

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (4)$$

- przy ograniczeniach

$$\alpha_i \geq 0, i = 1, \dots, n \quad \text{oraz} \quad \sum_{i=1}^n \alpha_i y_i = 0 \quad (5)$$

## Metoda Lagrange'a (c.d.)

---

Niech wektor  $(\alpha_1^0, \dots, \alpha_n^0)$  będzie rozwiązaniem maksymalizującym (4) przy ograniczeniach (5).





Niech wektor  $(\alpha_1^0, \dots, \alpha_n^0)$  będzie rozwiązaniem maksymalizującym (4) przy ograniczeniach (5).

- Z (3) wynika, że jeśli  $\mathbf{x}_i$  nie jest wektorem podpierającym to  $\alpha_i^0 = 0$ ;



Niech wektor  $(\alpha_1^0, \dots, \alpha_n^0)$  będzie rozwiązaniem maksymalizującym (4) przy ograniczeniach (5).

- Z (3) wynika, że jeśli  $\mathbf{x}_i$  nie jest wektorem podpierającym to  $\alpha_i^0 = 0$ ;
- Równania (4) i (5) odbywają się faktycznie tylko po wektorach podpierających.



Niech wektor  $(\alpha_1^0, \dots, \alpha_n^0)$  będzie rozwiązaniem maksymalizującym (4) przy ograniczeniach (5).

- Z (3) wynika, że jeśli  $\mathbf{x}_i$  nie jest wektorem podpierającym to  $\alpha_i^0 = 0$ ;
- Równania (4) i (5) odbywają się faktycznie tylko po wektorach podpierających.
- Hyperpłaszczyzna rozdzielająca ma postać  $\mathbf{w}_0 \mathbf{x} - b_0 = 0$  gdzie

$$\mathbf{w}_0 = \sum_{\text{wektory podp.}} y_i \alpha_i^0 \mathbf{x}_i \quad b_0 = \frac{1}{2} [(\mathbf{w}_0 \cdot \mathbf{x}^{(1)}) + (\mathbf{w}_0 \cdot \mathbf{x}^{(-1)})]$$

tu  $\mathbf{x}^{(1)}$  i  $\mathbf{x}^{(-1)}$  są dowolnymi wektorami podpierającymi z każdej z klas.



Ostateczna funkcja decyzyjna:

$$f(\mathbf{x}) = \text{sgn}\left(\sum_{\text{wektory podp.}} y_i \alpha_i^0 (\mathbf{x}_i \cdot \mathbf{x}) + b_0\right) \quad (6)$$



## 1 Wprowadzenie

## 2 Brak liniowej separowalności danych

- Nieznaczną nieseparowalność
- Zmiana przestrzeni atrybutów

## 3 Implementacja



# Przypadek nie-separowalności

---

- Założenie o separowalności klas jest nienaturalna;



# Przypadek nie separowalności

---

- Założenie o separowalności klas jest nienaturalna;
- Modyfikacja:

$$\mathbf{w} \cdot \mathbf{x}_i + b \geq 1 - \xi_i, \text{ gdy } y_i = +1$$

$$\mathbf{w} \cdot \mathbf{x}_i + b \leq -1 + \xi_i, \text{ gdy } y_i = -1$$

gdzie stałe  $\xi_i$  spełniają warunki:

$$\xi_i \geq 0, i = 1, \dots, n.$$



# Przypadek nieseparowalności

- Założenie o separowalności klas jest nienaturalna;
- Modyfikacja:

$$\mathbf{w} \cdot \mathbf{x}_i + b \geq 1 - \xi_i, \text{ gdy } y_i = +1$$

$$\mathbf{w} \cdot \mathbf{x}_i + b \leq -1 + \xi_i, \text{ gdy } y_i = -1$$

gdzie stałe  $\xi_i$  spełniają warunki:

$$\xi_i \geq 0, i = 1, \dots, n.$$

- Zmodyfikowana funkcja do minimalizacji

$$\frac{\|\mathbf{w}\|^2}{2} + C \sum_{i=1}^n \xi_i$$

$C$  jest stałą "karą" za niespełnienie idealnych warunków.



## Ogólne zadanie SVM

Znaleźć  $\mathbf{w}$  i  $b$  które minimalizują

$$\frac{\|\mathbf{w}\|^2}{2} + C \sum_{i=1}^n \xi_i$$

przy ograniczeniach

$$\mathbf{w} \cdot \mathbf{x}_i + b \geq 1 - \xi_i, \text{ gdy } y_i = +1$$

$$\mathbf{w} \cdot \mathbf{x}_i + b \leq -1 + \xi_i, \text{ gdy } y_i = -1$$

$$\xi_i \geq 0, i = 1, \dots, n.$$

# Przypadek nie separowalności

---

Można pokazać, że zarówno i w tym przypadku, możemy sprowadzić do problemu

- Znaleźć wektor  $(\alpha_1^0, \dots, \alpha_n^0)$  będący maksimum funkcji

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (7)$$

A następnie stosować funkcję decyzyjną:

# Przypadek nie separowalności

Można pokazać, że zarówno i w tym przypadku, możemy sprowadzić do problemu

- Znaleźć wektor  $(\alpha_1^0, \dots, \alpha_n^0)$  będący maksimum funkcji

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (7)$$

- przy ograniczeniach

$$C \geq \alpha_i \geq 0, i = 1, \dots, n \quad \text{oraz} \quad \sum_{i=1}^n \alpha_i y_i = 0 \quad (8)$$

A następnie stosować funkcję decyzyjną:

# Przypadek nie separowalności

Można pokazać, że zarówno i w tym przypadku, możemy sprowadzić do problemu

- Znaleźć wektor  $(\alpha_1^0, \dots, \alpha_n^0)$  będący maksimum funkcji

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij=1}^n \alpha_i \alpha_j y_i y_j (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (7)$$

- przy ograniczeniach

$$C \geq \alpha_i \geq 0, i = 1, \dots, n \quad \text{oraz} \quad \sum_{i=1}^n \alpha_i y_i = 0 \quad (8)$$


A następnie stosować funkcję decyzyjną:

$$f(\mathbf{x}) = \text{sgn} \left( \sum_{\text{wektory podp.}} y_i \alpha_i^0 (\mathbf{x}_i \cdot \mathbf{x}) + b_0 \right) \quad (9)$$

# Zanurzenie obserwacji w bogatszej przestrzeni

- Przekształcimy dane w bogatszej przestrzeni cech:

$$\phi: \mathbb{R}^p \rightarrow \mathcal{F} \subseteq \mathbb{R}^N, \quad N \gg p$$







# Zanurzenie obserwacji w bogatszej przestrzeni

- Przekształcimy dane w bogatszej przestrzeni cech:

$$\phi : \mathbb{R}^p \rightarrow \mathcal{F} \subseteq \mathbb{R}^N, \quad N \gg p$$

- wystarczy zamienić iloczyny skalarne ( $\mathbf{x}_i \cdot \mathbf{x}_j$ ) we wszystkich wzorach na  $(\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j))$ )



- 
- PROBLEM OBLICZENIOWY: czas wykonania iloczynu skalarnego  $(\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j))$  wynosi  $O(N^2)$



- PROBLEM OBLICZENIOWY: czas wykonania iloczynu skalarnego  $(\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j))$  wynosi  $O(N^2)$
- TRIK: Kernel functions

$$K((\mathbf{x}_i \cdot \mathbf{x}_j)) = (\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j))$$



- PROBLEM OBLICZENIOWY: czas wykonania iloczynu skalarnego  $(\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j))$  wynosi  $O(N^2)$
- TRIK: Kernel functions

$$K((\mathbf{x}_i \cdot \mathbf{x}_j)) = (\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j))$$

- Zmieniona funkcja:

$$\begin{aligned} W(\alpha) &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij=1}^n \alpha_i \alpha_j y_i y_j (\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)) \\ &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij=1}^n \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i \cdot \mathbf{x}_j) \end{aligned}$$

# Example



$$\begin{pmatrix} 1 \\ \sqrt{2}a_1 \\ \sqrt{2}a_2 \\ \vdots \\ \sqrt{2}a_m \\ a_1^2 \\ a_2^2 \\ \vdots \\ a_m^2 \\ \sqrt{2}a_1a_2 \\ \sqrt{2}a_1a_3 \\ \vdots \\ \sqrt{2}a_1a_m \\ \sqrt{2}a_2a_3 \\ \vdots \\ \sqrt{2}a_1a_m \\ \vdots \\ \sqrt{2}a_{m-1}a_m \end{pmatrix} \cdot \begin{pmatrix} 1 \\ \sqrt{2}b_1 \\ \sqrt{2}b_2 \\ \vdots \\ \sqrt{2}b_m \\ b_1^2 \\ b_2^2 \\ \vdots \\ b_m^2 \\ \sqrt{2}b_1b_2 \\ \sqrt{2}b_1b_3 \\ \vdots \\ \sqrt{2}b_1b_m \\ \sqrt{2}b_2b_3 \\ \vdots \\ \sqrt{2}b_1b_m \\ \vdots \\ \sqrt{2}b_{m-1}b_m \end{pmatrix}$$

$$\begin{aligned}
 & \left. \begin{array}{l} 1 \\ + \\ \sum_{i=1}^m 2a_i b_i \\ + \\ \sum_{i=1}^m a_i^2 b_i^2 \\ + \\ \sum_{i=1}^m \sum_{j=i+1}^m 2a_i a_j b_i b_j \end{array} \right\} (\mathbf{a} \cdot \mathbf{b} + 1)^2 \\
 & = (\mathbf{a} \cdot \mathbf{b})^2 + 2\mathbf{a} \cdot \mathbf{b} + 1 \\
 & = \left( \sum_{i=1}^m a_i b_i \right)^2 + 2 \sum_{i=1}^m a_i b_i + 1 \\
 & = \sum_{i=1}^m \sum_{j=1}^m a_i b_i a_j b_j + 2 \sum_{i=1}^m a_i b_i + 1 \\
 & = \sum_{i=1}^m (a_i b_i)^2 + 2 \sum_{i=1}^m \sum_{j=i+1}^m a_i b_i a_j b_j + 2 \sum_{i=1}^m a_i b_i + 1
 \end{aligned}$$



## 1 Wprowadzenie

## 2 Brak liniowej separowalności danych

- Nieznaczną nieseparowalność
- Zmiana przestrzeni atrybutów

## 3 Implementacja



Problem



## Problem

**Wejście:**  $D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$ ;  $K$ : funkcja jądrowa.





## Problem

**Wejście:**  $D = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$ ;  $K$ : funkcja jądrowa.

**Wyjście:** wektor  $(\alpha_1^0, \dots, \alpha_n^0)$  będący maksimum funkcji

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{ij=1}^n \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i \cdot \mathbf{x}_j)$$

przy ograniczeniach

$$C \geq \alpha_i \geq 0, i = 1, \dots, n \quad \text{oraz} \quad \sum_{i=1}^n \alpha_i y_i = 0$$

# Przykład metody gradientu dla QP



$$\frac{\partial W(\alpha)}{\partial \alpha_i} = 1 - y_i \sum_{j=1}^l \alpha_j y_j K(x_i, x_j)$$

$$\alpha_i \leftarrow \alpha_i + \eta \frac{\partial W(\alpha)}{\partial \alpha_i} \quad \eta = \text{learning rate}$$

parameter  $\omega \in (0, 2)$

$$\alpha_i \leftarrow \alpha_i + \frac{\omega}{K(x_i, x_i)} \left( 1 - y_i \sum_{j=1}^l \alpha_j y_j K(x_i, x_j) \right)$$

**Given Training set  $S$  and learning rate  $\eta$**   
 $\alpha \leftarrow 0$

**Repeat**

**for all train set**  $i = 1$  to  $l$

**update**  $\alpha_i$

**if**

$\alpha < 0$ , then  $\alpha \leftarrow 0$

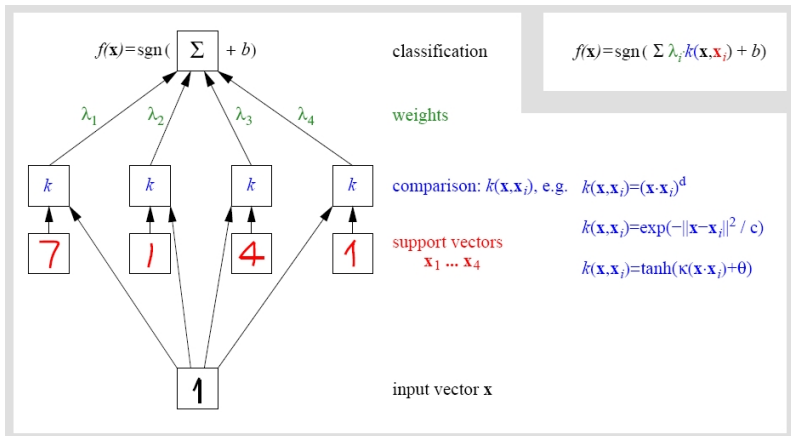
$\alpha > C$ , then  $\alpha \leftarrow C$

**End for**

**Until stop criterion satisfied**

**return**  $\alpha$

# Działanie SVM



$$f(\mathbf{x}) = \text{sgn} \left( \sum_{\text{wektory podp.}} y_i \alpha_i^0 K(\mathbf{x}_i \cdot \mathbf{x}) + b_0 \right)$$