

## Vorlesung 17 Support vector machines

Erinnerung: Wir haben das Modell

$$f_{\Theta}: \mathbb{R}^D \rightarrow \{-1, 1\}$$

mit  $f_{\Theta}(x) = \text{sgn}(\langle \alpha, x \rangle + b)$ ,  $\Theta = (\alpha, b) \in \mathbb{R}^D \times \mathbb{R}$ .

Soft-Margin SVM:

$$\begin{cases} \min_{\alpha, b, \xi} & \|\alpha\|^2 + C \sum_{k=1}^n \xi_k \\ \text{s.t.} & y_k (\langle \alpha, x_k \rangle + b) \geq 1 - \xi_k, \end{cases}$$

wobei  $(x_1, y_1), \dots, (x_n, y_n) \in \mathbb{R}^D \times \{-1, 1\}$  Trainingsdaten sind.

Dual SVM

$$\begin{cases} \max_{\alpha} & -\frac{1}{2} \sum_{k=1}^n \alpha_k + \sum_{k=1}^n \alpha_k \\ \text{s.t.} & \sum_{k=1}^n \alpha_k y_k = 0 \quad \text{und} \quad 0 \leq \alpha_i \leq C \quad i=1, \dots, n. \end{cases}$$

mit  $u = (\frac{1}{2} \alpha_k y_k)_{k=1}^n$ ,  $G = (\langle x_k, x_l \rangle)_{k,l=1}^n$ .

Proposition 17.1

Sei  $\alpha \in \mathbb{R}^n$  eine Lösung für Dual SVM. Dann haben optimale Parameter  $(\alpha^*, b^*) \in \mathbb{R}^D \times \mathbb{R}$  für Soft-Margin-SVM:

$$1) \quad \alpha^* = \sum_{k=1}^n u_k x_k, \quad u_k = \frac{1}{2} \alpha_k y_k.$$

2)  $b^*$  ist der Median-Wert von  $y_k - \langle \alpha^*, x_k \rangle$  für  $\alpha_k \neq 0$ .

Beweis

1) folgt aus Gleichung (xxx) von VL 16.

2) Erinnerung: Soft Margin SVM ist äquivalent zu

$$\min_{\alpha, b, \xi} \quad \max_{\alpha, \beta} \quad \mathcal{L}(a, b, \xi_1, \alpha, \beta) \quad (\alpha_k, \beta_k \geq 0)$$

wobei  $\mathcal{L} = \|a\|^2 + C \sum_{k=1}^n \xi_k - \sum_{k=1}^n \alpha_k (y_k (\langle a, x_k \rangle + b) - 1 - \xi_k) - \sum_{k=1}^n \beta_k \xi_k$ .

Im optimalen Fall haben wir  $\alpha + \beta = C$  (siehe VL 16). Daher,


$$\mathcal{L} = \|a\|^2 - \sum_{k=1}^n \alpha_k (y_k (\langle a, x_k \rangle + b) - 1).$$

Da wir über  $\alpha$  maximieren gilt:

$$y_k (\langle a, x_k \rangle + b) - 1 \leq 0 \Rightarrow \alpha_k = 0$$

so dass:


$$\begin{aligned} \mathcal{L} &= \|a\|^2 - \sum_{k: \alpha_k > 0} |y_k (\langle a, x_k \rangle + b) - 1| \\ &= \|a\|^2 - \sum_{k: \alpha_k > 0} |\langle a, x_k \rangle + b - y_k| \end{aligned}$$



D.h.  $b^* = \text{median}_{k: \alpha_k > 0} (y_k - \underbrace{\langle a^*, x_k \rangle}_{p_k})$ . (Beweis: Übung).  $\square$

### Beispiel 17.2

Nicht alle Dokumenten lassen sich gut mit Hyperebenen trennen, auch nicht per Soft-Margin-SVM:



Für nicht-lineare Separation führen wir wieder eine Feature Map ein  $\phi: \mathbb{R}^D \rightarrow \mathbb{R}^P$ .

Bsp für Hyperbelsuche:  $\phi(x_1) = (1, x_1, x_2, x_1x_2, x_1^2, x_2^2)$ .  
 $(D=2)$

Beachte In Dual SVM müssen wir nur  $\langle \phi(x_k), \phi(x_l) \rangle$  kennen, nicht unbedingt  $\phi$  selbst.

### Definition 17.3

Eine Funktion der Form

$$K(x_1, x_2) = \langle \phi(x_1), \phi(x_2) \rangle$$

für  $\phi: \mathbb{R}^D \rightarrow \mathbb{R}^P$  nicht-linear, heißt Kernel-Map.

Eine Kernel-Map gibt uns die Kernelf-Matrix  
 $G = (K(x_k, x_l))_{k,l=1}^n \in \mathbb{R}^{n \times n}$

für Dual-SVM.

### Lemma 17.4

Sei  $G \in \mathbb{R}^{n \times n}$ . Dann ist  $G$  positiv-semidefinit, genau dann wenn  $P$  existiert und  $z_1, \dots, z_n \in \mathbb{R}^P$  mit

$$G = (\langle z_k, z_l \rangle)_{k,l=1}^n.$$

### Beweis

Sei  $Z = [z_1 \dots z_n] \in \mathbb{R}^{P \times n}$ .

1) Falls  $G = Z^T Z$ , dann gilt für alle  $a \in \mathbb{R}^n$ :

$$a^T G a = a^T Z^T Z a = (Za)^T (Za) \geq 0.$$

2) Falls  $G$  positiv-semidefinit ist, finden wir eine Cholesky-Zerlegung  $G = ZZ^T$ . Die Spalten von  $Z$  sind dann die  $z_i$ .

Nach Prop. 17.1. haben wir die Optimalwerte (für nichtlineares  $\phi$ )

$$\alpha^* = \sum_{u=1}^n \alpha_u \phi(x_u)$$

$$b^* = \text{median } y_u - \langle \alpha^*, x_u \rangle, \alpha_u \neq 0.$$

D.h. wenn wir folgende Funktion definieren

$$\Psi(x) = \sum_{u=1}^n \alpha_u K(x_u, x). = \langle \alpha^*, \phi(x) \rangle$$

Dann:  $b^* = \text{median } |y_u - \Psi(x_u)|, \alpha_u \neq 0$  und

$$f_\Theta(x) = \text{sgn}(\Psi(x) + b^*).$$

Dies führt zu folgendem Algorithmus:

- Input:
- Training data  $(x_1, y_1), \dots, (x_n, y_n) \in \mathbb{R}^d \times \{-1, 1\}$
  - Kernel map  $K(x_1, x_2)$
  - Regularisierungsparameter  $C$

Output: Funktion der Form  $f_\Theta(x) = \text{sgn}(\langle \alpha x \rangle + b)$

- 1) Berechne die Kernel-Matrix  $G = (K(x_u, x_e))_{u,e=1}^n$
- 2) Löse Dual-SVM mit  $G$  und  $C$ , erhält  $\alpha$
- 3) Definiere  $\Psi(x) = \sum_{u=1}^n \frac{1}{2} \alpha_u y_u K(x_u, x)$ .
- 4)  $b = \text{median von } y_u - \Psi(x_u), \alpha_u \neq 0$ .
- 5) Return  $f_\Theta(x) = \text{sgn}(\Psi(x) + b)$ .

Das folgende Lemma illustriert, warum Kernel maps hilfreich sind, um  $\phi$  nicht direkt auswerten zu müssen.

### Lemma 17.3

Sei für  $x \in \mathbb{R}^D$   $\phi(x) = (x_1^{i_1} \cdots x_D^{i_D})$  |  $i_1 + \dots + i_D \leq d$

Dann:

$$\langle \phi(u), \phi(v) \rangle = (\langle u, v \rangle + 1)^d.$$

Beweis

$$\langle \phi(u), \phi(v) \rangle = \sum_{\substack{i_0, i_1, \dots, i_D \\ i_0 + i_1 + \dots + i_D = d}} u_0^{i_0} u_1^{i_1} \cdots u_D^{i_D} v_0^{i_0} v_1^{i_1} \cdots v_D^{i_D}, \quad u_0 = v_0 = 1$$

$$= \sum_{i_0 + i_1 + \dots + i_D = d} (u_0 v_0)^{i_0} (u_1 v_1)^{i_1} \cdots (u_D v_D)^{i_D}$$

$$= (u_0 v_0 + u_1 v_1 + \dots + u_D v_D)^d = (\langle u, v \rangle + 1)^d.$$

Da  $(x_0 + \dots + x_D)^d = \sum_{i_0 + \dots + i_D = d} x_0^{i_0} \cdots x_D^{i_D}$ .

o