


Gépi tanulás a gyakorlatban

SVM


Klasszifikáció

- Feladat: előre meghatározott csoportok elkülönítése egymástól
 - Osztályokat elkülönítő felület
 - Osztályokhoz rendelt döntési függvények



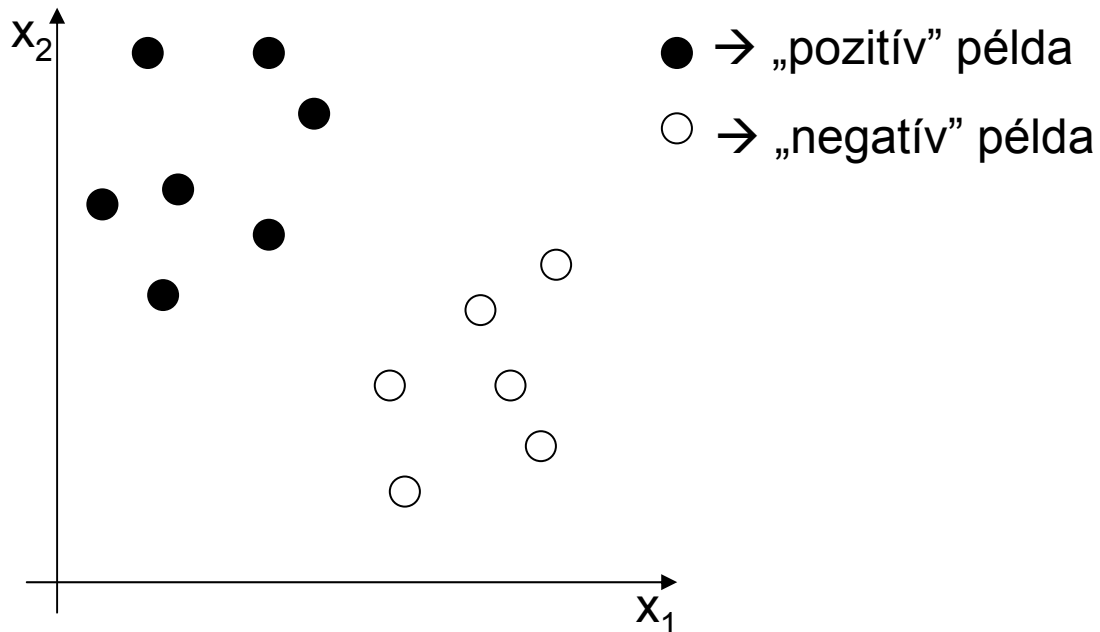
Klasszifikáció

- Feladat: előre meghatározott csoportok elkülönítése egymástól
 - **Osztályokat elkülönítő felület**
 - Osztályokhoz rendelt döntési függvények




Lineáris klasszifikáció

- Feladat: lineáris diszkriminancia függvény meghatározása



Lineáris klasszifikáció

- Feladat: lineáris diszkriminancia függvény meghatározása → **szeparáló hipersík**




Lineáris klasszifikáció

- Feladat: lineáris diszkriminancia függvény meghatározása \rightarrow szeparáló hipersík

– Amelyre teljesül:

$$w^T x^{(i)} \geq 0, \text{ ha } x^{(i)} \text{ „pozitív” példa}$$

$$w^T x^{(i)} < 0, \text{ ha } x^{(i)} \text{ „negatív” példa}$$




Lineáris klasszifikáció

- Feladat: lineáris diszkriminancia függvény meghatározása \rightarrow szeparáló hipersík

– Amelyre teljesül:


$$w^T x^{(i)} \geq 0, \text{ ha } x^{(i)} \text{ „pozitív” példa}$$

$$w^T x^{(i)} < 0, \text{ ha } x^{(i)} \text{ „negatív” példa}$$




Lineáris klasszifikáció

- Feladat: lineáris diszkriminancia függvény meghatározása → szeparáló hipersík
- De melyiket???




Lineáris klasszifikáció

- Feladat: lineáris diszkriminancia függvény meghatározása \rightarrow szeparáló hipersík
- De melyiket??? „A legjobbat \Leftrightarrow SVM”



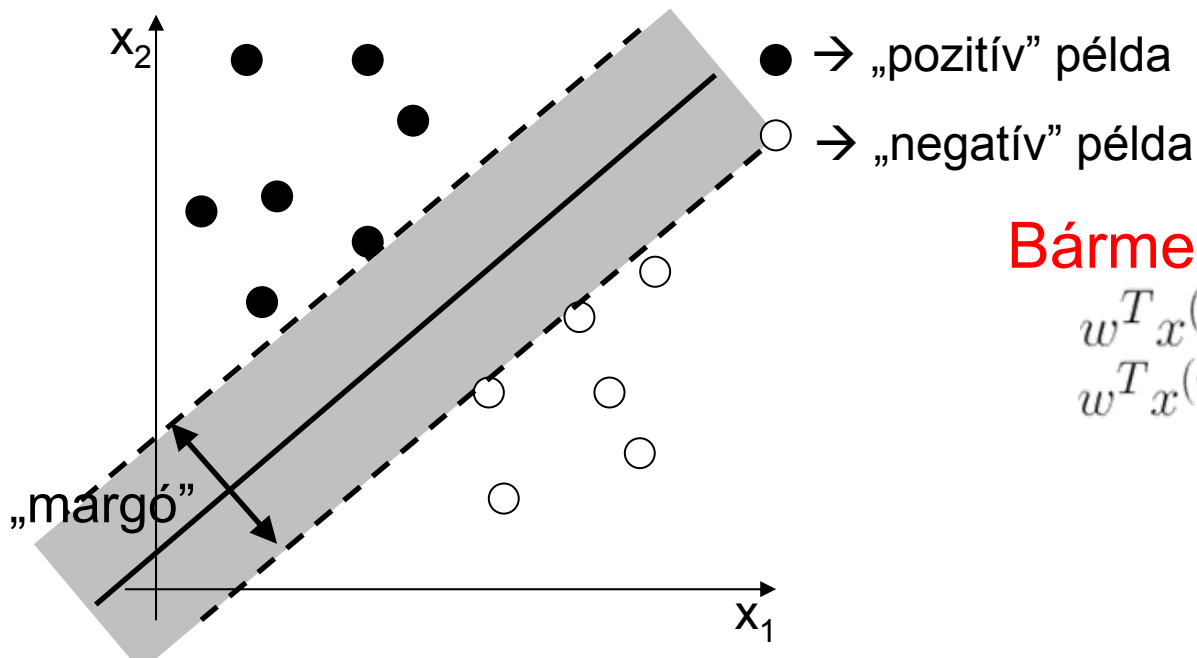
SVM (Support Vector Machine)

- Melyik a legjobb??? → Amelyik maximalizálja a „margó” méretét



SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???
- Azaz keressük azt a w -t amelyre:




Bármely i példára:

$$w^T x^{(i)} \geq 1, \text{ ha } x^{(i)} \text{ „pozitív”}$$

$$w^T x^{(i)} \leq -1, \text{ ha } x^{(i)} \text{ „negatív”}$$

SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???
- Azaz keressük azt a w -t amelyre:



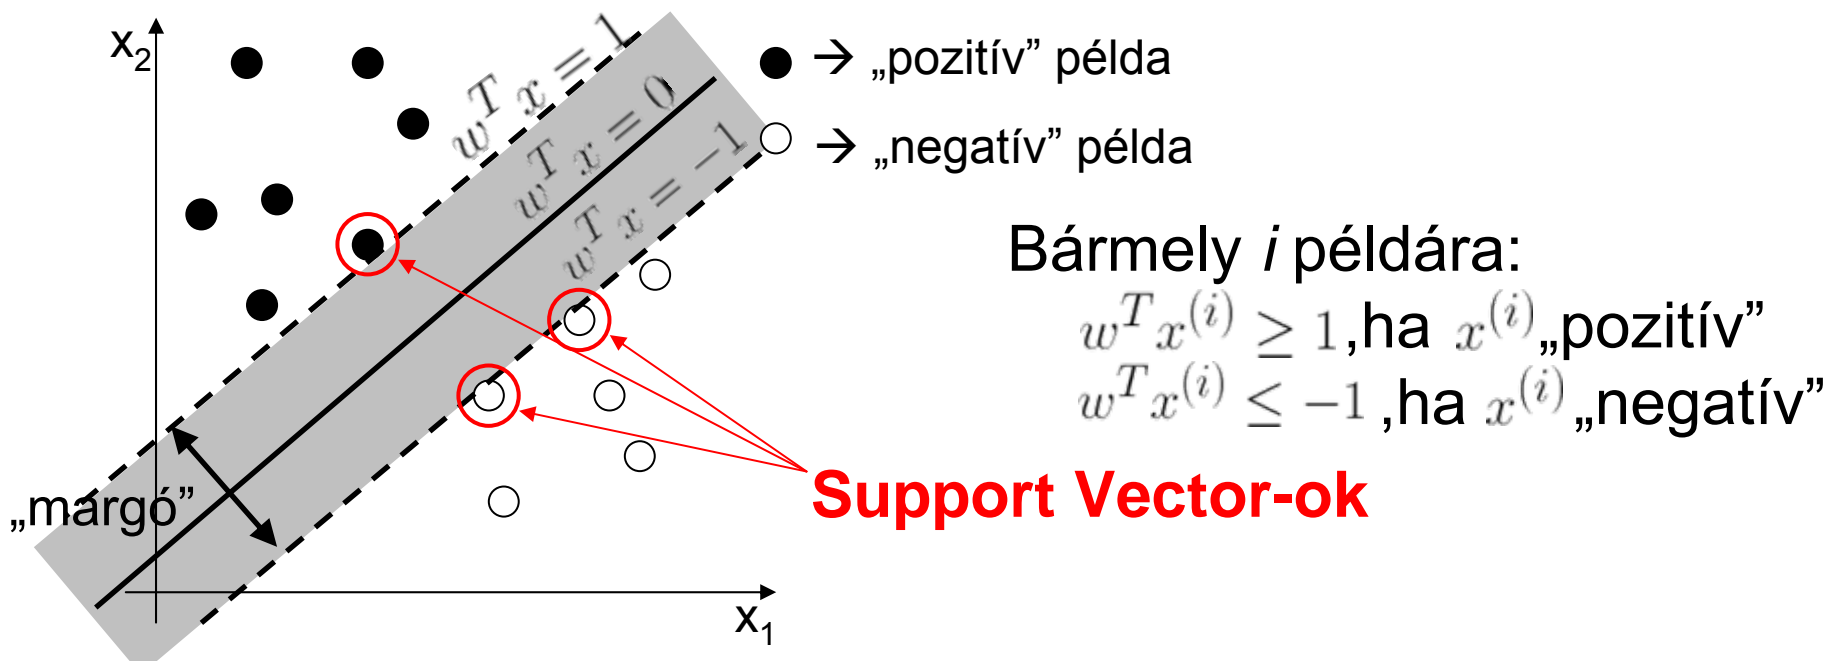
Bármely i példára:

$$w^T x^{(i)} \geq 1, \text{ ha } x^{(i)} \text{ „pozitív”}$$

$$w^T x^{(i)} \leq -1, \text{ ha } x^{(i)} \text{ „negatív”}$$


SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???
- Azaz keressük azt a w -t amelyre:



SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???




Support Vector (SV): A margó egyeneseire eső példák, azaz i példa SV, ha $|w^T x| = 1$ teljesül rá

SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???


x példa w egyenestől mért
(előjeles) távolsága: $\frac{w^T x}{\|w\|}$




SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???

x példa w egyenestől mért $w^T x$ (előjeles) távolsága: $\frac{w^T x}{\|w\|}$



Mivel:



$$A_B = \|A\| \cos \theta$$

$$A \cdot B = \|A\| \|B\| \cos \theta$$


$$A_B = \frac{A \cdot B}{\|B\|}$$

SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???

Egy SV példa w egyenestől mért távolsága:


$$\frac{1}{\|w\|}$$



SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???

Egy SV példa w egyenestől mért távolsága: $\frac{1}{\|w\|}$




Mivel:

$$|w^T x| = 1, \text{ ha } x \text{ SV}$$

SVM (Support Vector Machine)

- Keressük azt a egyenest amelyik maximalizálja a „margó” méretét. Hogyan???

Egy SV példa w egyenestől mért távolsága: $\frac{1}{\|w\|}$



Mivel:


$$|w^T x| = 1, \text{ ha } x \text{ SV}$$

Így a margó mérete:

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

SVM (Support Vector Machine)

- Tehát az SVM feladata: maximalizálni a margó, amellett hogy jól osztályozza a példákat:



● → „pozitív” példa


○ → „negatív” példa

A margó mérete: $\frac{2}{\|w\|}$

$$\min_w \frac{1}{2} \|w\|^2$$
$$s.t. \quad y^{(i)} (w^T x^{(i)}) \geq 1, \quad i = 1 \dots m$$

SVM (Support Vector Machine)

- Tehát az SVM feladata: maximalizálni a margó, amellet hogy jól osztályozza a példákat (**nem szeparálható eset**):



● → „pozitív” példa

○ → „negatív” példa

A margó mérete: $\frac{2}{\|w\|}$

$$\min_{w, \xi} \frac{1}{2} \|w\|^2 + C \sum_i \xi_i$$

$$s.t. \quad y^{(i)}(w^T x^{(i)}) \geq 1 - \xi_i, \quad i = 1 \dots m$$

Pegasos SVM

- A feladatot a primál alakban oldja meg

$$\min_{w, \xi} \frac{1}{2} \|w\|^2 + C \sum_i \xi_i$$

$$s.t. \quad y^{(i)}(w^T x^{(i)}) \geq 1 - \xi_i, \quad i = 1 \dots m$$

INPUT: S, λ, T

INITIALIZE: Set $\mathbf{w}_1 = 0$

FOR $t = 1, 2, \dots, T$

 Choose $i_t \in \{1, \dots, |S|\}$ uniformly at random.

 Set $\eta_t = \frac{1}{\lambda t}$

 If $y_{i_t} \langle \mathbf{w}_t, \mathbf{x}_{i_t} \rangle < 1$, then:

 Set $\mathbf{w}_{t+1} \leftarrow (1 - \eta_t \lambda) \mathbf{w}_t + \eta_t y_{i_t} \mathbf{x}_{i_t}$

 Else (if $y_{i_t} \langle \mathbf{w}_t, \mathbf{x}_{i_t} \rangle \geq 1$):

 Set $\mathbf{w}_{t+1} \leftarrow (1 - \eta_t \lambda) \mathbf{w}_t$

 [Optional: $\mathbf{w}_{t+1} \leftarrow \min \left\{ 1, \frac{1/\sqrt{\lambda}}{\|\mathbf{w}_{t+1}\|} \right\} \mathbf{w}_{t+1}$]

OUTPUT: \mathbf{w}_{T+1}

Duális SVM

- A primál feladat átírható duális alakra a Lagrange-multiplikátorok segítségével:

$$\max_{\alpha} \quad W(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m y^{(i)} y^{(j)} \alpha_i \alpha_j \langle x^{(i)}, x^{(j)} \rangle.$$

$$\text{s.t.} \quad \alpha_i \geq 0, \quad i = 1, \dots, m$$

$$\sum_{i=1}^m \alpha_i y^{(i)} = 0,$$

Duális SVM

- Megmutatható: $\alpha_i(y^{(i)}(w^T x^{(i)})) - 1 = 0$
teljesül minden példára, azaz

$$y^{(i)}(w^T x^{(i)}) - 1 = 0 \quad \text{vagy}$$
$$\alpha_i = 0$$

- \rightarrow csak a SV-ok esetén $\alpha_i \neq 0$
- Tehát a hipersík megadható:

$$w = \sum_{\forall i} \alpha_i y^{(i)} x^{(i)} = \sum_{i \in SV} \alpha_i y^{(i)} x^{(i)}$$

Duális SVM

- A hipersík megadható:

$$w = \sum_{\forall i} \alpha_i y^{(i)} x^{(i)} = \sum_{i \in SV} \alpha_i y^{(i)} x^{(i)}$$

- Azaz az egyenes egyenlete:

$$w^T x = \sum_{i \in SV} \alpha_i y^{(i)} x^{(i)T} x$$

- Kernel trükk:

$$w^T x = \sum_{i \in SV} \alpha_i y^{(i)} K(x^{(i)}, x)$$

Duális SVM kernel trükk

- Ha lineárisan nem szeparálhatóak a példák, transzformáljuk őket olyan térbe ahol igen!

$$K(x_i, x_j) \equiv \Phi(x_i)^T \Phi(x_j)$$

