



Kernel alapú félig-felügyelt tanuló algoritmusok

Kernel alapú tanulás

Kernelek
SVM

Néhány (általános
célú) kernel

Félig-felügyelt tanulás

Kernel alapú
félig-felügyelt tanulás

LapSVM
Szomszédsági kernel
ISOMAP

Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

Bodó Zalán

zbodo@cs.ubbcluj.ro

BBTE, Matematika és Informatika Kar

Az előadás tartalma

Kernel alapú tanulás

- Kelelek
- SVM

Néhány (általános célú) kernel

Félig-felügyelt tanulás

Kernel alapú félig-felügyelt tanulás

- LapSVM
- Szomszédsági kernel
- ISOMAP
- Hierarchikus klaszter kernel
- Átsúlyozó klaszter kelelek

Kernel alapú tanulás

Gépi tanulás

- ▶ **felügyelt tanulás**
- ▶ felügyelet nélküli tanulás
- ▶ megerősítéses tanulás

Felügyelt tanulás

- ▶ diszkrét eset: **osztályozás**
- ▶ $\hat{f} : X \rightarrow Y$ keresése, amely legjobban közelíti $f : X \rightarrow Y$ -t; f tanulási példák által van megadva: (\mathbf{x}_i, y_i) , $\mathbf{x}_i \in X \subseteq \mathbb{R}^d$, $y_i \in Y$
 - ▶ $|Y| = 2$ (általában $Y = \{-1, 1\}$) – bináris osztályozás
 - ▶ $|Y| > 2$, $Y = \{c_1, c_2, \dots, c_K\}$, K az osztályok száma – többosztályos tanulás
 - ▶ $f : X \rightarrow Y$ – egycímkés tanulás
 - ▶ $f : X \rightarrow 2^Y$ – többcímkés tanulás

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Félfig-felügyelt tanulás

Kernel alapú
félfig-felügyelt tanulásLapSVM
Szomszédsági kernel
ISOMAP
Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

Kernel alapú tanulás

Gépi tanulás

- ▶ **felügyelt tanulás**
- ▶ felügyelet nélküli tanulás
- ▶ megerősítéses tanulás

Felügyelt tanulás

- ▶ diszkrét eset: **osztályozás**
- ▶ $\hat{f} : X \rightarrow Y$ keresése, amely legjobban közelíti $f : X \rightarrow Y$ -t; f tanulási példák által van megadva: (\mathbf{x}_i, y_i) , $\mathbf{x}_i \in X \subseteq \mathbb{R}^d$, $y_i \in Y$
 - ▶ $|Y| = 2$ (általában $Y = \{-1, 1\}$) – bináris osztályozás
 - ▶ $|Y| > 2$, $Y = \{c_1, c_2, \dots, c_K\}$, K az osztályok száma – többosztályos tanulás
 - ▶ $f : X \rightarrow Y$ – egycímkés tanulás
 - ▶ $f : X \rightarrow 2^Y$ – többcímkés tanulás

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Félfig-felügyelt tanulás

Kernel alapú
félfig-felügyelt tanulásLapSVM
Szomszédsági kernel

ISOMAP

Hierarchikus klaszter
kernelÁtsúlyozó klaszter
kernelek

Kernelek

- ▶ gépi tanulás → adatok közötti hasonlóság
- ▶ **kernel** = hasonlósági metrika
- ▶ kernel: $k(\mathbf{x}, \mathbf{z}) = \langle \phi(\mathbf{x}), \phi(\mathbf{z}) \rangle = \phi(\mathbf{x})' \phi(\mathbf{z})$, ahol $\phi : X \rightarrow \mathcal{H}$ -t feature-leképezésnek nevezzük
- ▶ James Mercer (1909): “Minden folytonos szimmetrikus pozitív szemidefinit kernel függvény kifejezhető skalárszorzatként egy nagydimenziós térben.”
- ▶ **kernel-trükk**: adott algoritmus esetén $k(\cdot, \cdot) \rightarrow \tilde{k}(\cdot, \cdot)$

Egyszerű bináris osztályozó: centroid módszer

- ▶ keressük meg a két osztály középpontját (centroidját)
- ▶ új pont: ahhoz az osztályhoz rendeljük, melynek középpontjához közelebb esik

$$\mathbf{c}_+ = \frac{1}{N_+} \sum_{\mathbf{x}_i \in X_+} \mathbf{x}_i \quad \text{és} \quad \mathbf{c}_- = \frac{1}{N_-} \sum_{\mathbf{x}_i \in X_-} \mathbf{x}_i$$

Kernel alapú tanulás

Kernel
SVM

Néhány (általános
célú) kernel

Fél-felügyelt tanulás

Kernel alapú
fél-felügyelt tanulás

LapSVM
Szomszédsági kernel
ISOMAP
Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

Kernelek

- ▶ gépi tanulás → adatok közötti hasonlóság
- ▶ **kernel** = hasonlósági metrika
- ▶ kernel: $k(\mathbf{x}, \mathbf{z}) = \langle \phi(\mathbf{x}), \phi(\mathbf{z}) \rangle = \phi(\mathbf{x})' \phi(\mathbf{z})$, ahol $\phi : X \rightarrow \mathcal{H}$ -t feature-leképezésnek nevezzük
- ▶ James Mercer (1909): “Minden folytonos szimmetrikus pozitív szemidefinit kernel függvény kifejezhető skalárszorzatként egy nagydimenziós térben.”
- ▶ **kernel-trükk**: adott algoritmus esetén $k(\cdot, \cdot) \rightarrow \tilde{k}(\cdot, \cdot)$

Egyszerű bináris osztályozó: centroid módszer

- ▶ keressük meg a két osztály középpontját (centroidját)
- ▶ új pont: ahhoz az osztályhoz rendeljük, melynek középpontjához közelebb esik

$$\mathbf{c}_+ = \frac{1}{N_+} \sum_{\mathbf{x}_i \in X_+} \mathbf{x}_i \quad \text{és} \quad \mathbf{c}_- = \frac{1}{N_-} \sum_{\mathbf{x}_i \in X_-} \mathbf{x}_i$$

Kernel alapú tanulás

Kernelek
SVM

Néhány (általános
célú) kernel

Fél-felügyelt tanulás

Kernel alapú
fél-felügyelt tanulás

LapSVM
Szomszédsági kernel

ISOMAP

Hierarchikus klaszter
kernel

Átsúlyozó klaszter
kernelek

$$\begin{aligned}
 f(\mathbf{x}) &= \frac{1}{2} \text{sign} [\|\mathbf{x} - \mathbf{c}_-\|^2 - \|\mathbf{x} - \mathbf{c}_+\|^2] \\
 &= \text{sign} \left[\mathbf{x}'(\mathbf{c}_+ - \mathbf{c}_-) + \frac{\|\mathbf{c}_-\|^2 - \|\mathbf{c}_+\|^2}{2} \right]
 \end{aligned}$$

$$\mathbf{w} = \mathbf{c}_+ - \mathbf{c}_- \quad \text{és} \quad b = \frac{\mathbf{c}_-^2 - \mathbf{c}_+^2}{2}$$

$$\begin{aligned}
 f(\mathbf{x}) &= \text{sign}(\mathbf{x}'\mathbf{w} + b) \\
 &= \text{sign} \left(\frac{1}{N_+} \sum_{\mathbf{x}_i \in X_+} \langle \mathbf{x}, \mathbf{x}_i \rangle - \frac{1}{N_-} \sum_{\mathbf{x}_i \in X_-} \langle \mathbf{x}, \mathbf{x}_i \rangle + b \right)
 \end{aligned}$$

Kernel alapú tanulás

Kernel
SVM

Néhány (általános
célú) kernel

Félfig-felügyelt tanulás

Kernel alapú
félfig-felügyelt tanulás


LapSVM
Szomszédsági kernel
ISOMAP
Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

SVM

- ▶ bináris osztályozó: szeparáló hipersíkot keres (**Boser, Guyon, Vapnik 1992**)
- ▶ melyik hipersíkot válasszuk? – amelyik **maximális szegéllyel** választja szét a pozitív és negatív adatokat
- ▶ hipersík: $H = \{\mathbf{x} \mid \mathbf{w}'\mathbf{x} + b = 0\}$
- ▶ hipersík szegélye: $2/\|\mathbf{w}\| \Rightarrow$ minimalizáljuk $\frac{1}{2}\|\mathbf{w}\|^2$ -et

$$\min \quad \lambda_A \|\mathbf{w}\|^2 + \frac{1}{\ell} \sum_{i=1}^{\ell} \xi_i$$

úgy, hogy $y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, \ell$



Kernel alapú tanulás

Kernelek
SVM

Néhány (általános
célú) kernel

Fél-felügyelt tanulás

Kernel alapú
fél-felügyelt tanulás


LapSVM
Szomszédsági kernel
ISOMAP
Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

SVM

- ▶ bináris osztályozó: szeparáló hipersíkot keres (**Boser, Guyon, Vapnik 1992**)
- ▶ melyik hipersíkot válasszuk? – amelyik **maximális szegéllyel** választja szét a pozitív és negatív adatokat
- ▶ hipersík: $H = \{\mathbf{x} \mid \mathbf{w}'\mathbf{x} + b = 0\}$
- ▶ hipersík szegélye: $2/\|\mathbf{w}\| \Rightarrow$ minimalizáljuk $\frac{1}{2}\|\mathbf{w}\|^2$ -et

$$\min \quad \lambda_A \|\mathbf{w}\|^2 + \frac{1}{\ell} \sum_{i=1}^{\ell} \xi_i$$

úgy, hogy $y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, \ell$



Kernel alapú tanulás

Kernel
SVM

Néhány (általános
célú) kernel

Fél-felügyelt tanulás

Kernel alapú
fél-felügyelt tanulás

LapSVM
Szomszédsági kernel
ISOMAP
Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

Néhány (általános célú) kernel

- ▶ lineáris:

$$k(\mathbf{x}, \mathbf{z}) = \mathbf{x}'\mathbf{z}$$

- ▶ polinomiális:

$$k(\mathbf{x}, \mathbf{z}) = (a\mathbf{x}'\mathbf{z} + b)^c$$

- ▶ Gauss típusú:

$$k(\mathbf{x}, \mathbf{z}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{z}\|^2}{2\sigma^2}\right)$$

- ▶ szigmoid:

$$k(\mathbf{x}, \mathbf{z}) = \tanh(a\mathbf{x}'\mathbf{z} + r)$$

Néhány (általános célú) kernel

- ▶ lineáris:

$$k(\mathbf{x}, \mathbf{z}) = \mathbf{x}'\mathbf{z}$$

- ▶ polinomiális:

$$k(\mathbf{x}, \mathbf{z}) = (\mathbf{ax}'\mathbf{z} + b)^c$$

- ▶ Gauss típusú:

$$k(\mathbf{x}, \mathbf{z}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{z}\|^2}{2\sigma^2}\right)$$

- ▶ szigmoid:

$$k(\mathbf{x}, \mathbf{z}) = \tanh(\mathbf{ax}'\mathbf{z} + r)$$

Néhány (általános célú) kernel

- ▶ lineáris:

$$k(\mathbf{x}, \mathbf{z}) = \mathbf{x}'\mathbf{z}$$

- ▶ polinomiális:

$$k(\mathbf{x}, \mathbf{z}) = (a\mathbf{x}'\mathbf{z} + b)^c$$

- ▶ Gauss típusú:

$$k(\mathbf{x}, \mathbf{z}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{z}\|^2}{2\sigma^2}\right)$$

- ▶ szigmoid:

$$k(\mathbf{x}, \mathbf{z}) = \tanh(ax'\mathbf{z} + r)$$

Kernel alapú tanulás

Kernelek

SVM

Néhány (általános
célú) kernel

Félfig-felügyelt tanulás

Kernel alapú

félfig-felügyelt tanulás

LapSVM

Szomszédsági kernel

ISOMAP

Hierarchikus klaszter

kernel

Átsúlyozó klaszter

kernelek

Néhány (általános célú) kernel

- ▶ lineáris:

$$k(\mathbf{x}, \mathbf{z}) = \mathbf{x}'\mathbf{z}$$

- ▶ polinomiális:

$$k(\mathbf{x}, \mathbf{z}) = (a\mathbf{x}'\mathbf{z} + b)^c$$

- ▶ Gauss típusú:

$$k(\mathbf{x}, \mathbf{z}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{z}\|^2}{2\sigma^2}\right)$$

- ▶ szigmoid:

$$k(\mathbf{x}, \mathbf{z}) = \tanh(a\mathbf{x}'\mathbf{z} + r)$$

Kernel alapú tanulás

Kernelek

SVM

Néhány (általános
célú) kernel

Félfig-felügyelt tanulás

Kernel alapú

félfig-felügyelt tanulás

LapSVM

Szomszédsági kernel

ISOMAP

Hierarchikus klaszter

kernel

Átsúlyozó klaszter

kernelek

Félig felügyelt tanulás

- ▶ felügyelt tanulás:

$$D = \{(\mathbf{x}_i, y_i) \mid \mathbf{x}_i \in X \subseteq \mathbb{R}^d, y_i \in \{-1, +1\}, i = 1, \dots, \ell\};$$



keressük $\hat{f} : X \rightarrow \{-1, +1\}$ -et, amely "egyezik" D -vel

- ▶ félig-felügyelt tanulás:

$$D = \{(\mathbf{x}_i, y_i) \mid i = 1, \dots, \ell\} \cup \{\mathbf{x}_j \mid j = \ell + 1, \dots, \ell + u\},$$

$$\ell \ll u, N = \ell + u;$$

- ▶ **induktív:** keressük $\hat{f} : X \rightarrow \{-1, +1\}$ -et, amely "egyezik" D -vel + felhasználjuk a D_U által közvetített információt
- ▶ **transzduktív:** keressük $\hat{f} : D_U \rightarrow \{-1, +1\}$ -et felhasználva a $D = D_L \cup D_U$ halmazt



Kernel alapú tanulás

Kernelek
SVM

Néhány (általános
célú) kernel

Félig-felügyelt tanulás

Kernel alapú
félig-felügyelt tanulás

LapSVM
Szomszédsági kernel
ISOMAP
Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

Félig felügyelt tanulás



- ▶ felügyelt tanulás:

$D = \{(\mathbf{x}_i, y_i) \mid \mathbf{x}_i \in X \subseteq \mathbb{R}^d, y_i \in \{-1, +1\}, i = 1, \dots, \ell\}$;
keressük $\hat{f} : X \rightarrow \{-1, +1\}$ -et, amely “egyezik” D -vel

- ▶ félig-felügyelt tanulás:

$D = \{(\mathbf{x}_i, y_i) \mid i = 1, \dots, \ell\} \cup \{\mathbf{x}_j \mid j = \ell + 1, \dots, \ell + u\}$,
 $\ell \ll u, N = \ell + u$;

- ▶ **induktív**: keressük $\hat{f} : X \rightarrow \{-1, +1\}$ -et, amely “egyezik”
 D -vel + felhasználjuk a D_U által közvetített információt
- ▶ **transzduktív**: keressük $\hat{f} : D_U \rightarrow \{-1, +1\}$ -et felhasználva a
 $D = D_L \cup D_U$ halmazt



Kernel alapú tanulás

Kernelek
SVM

Néhány (általános
célú) kernel

Félig-felügyelt tanulás

Kernel alapú
félig-felügyelt tanulás

LapSVM
Szomszédsági kernel
ISOMAP
Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

Kernel alapú félig-felügyelt tanulás

- ▶ *megváltoztatjuk* a reprezentációs teret, az összes adatot figyelembe véve
- ▶ felügyelt tanulás + adatfüggő kernelek = **félig-felügyelt tanulás**
- ▶ “hagyományos” kernelek: adott $D_1 \neq D_2$ adathalmazok esetén, $\mathbf{x}, \mathbf{z} \in D_1 \cap D_2$

$$k(\mathbf{x}, \mathbf{z}) = k(\mathbf{x}, \mathbf{z})$$

- ▶ **adatfüggő kernelek**: adott $D_1 \neq D_2$ adathalmazok esetén, $\mathbf{x}, \mathbf{z} \in D_1 \cap D_2$

$$k(\mathbf{x}, \mathbf{z}; D_1) \not\approx k(\mathbf{x}, \mathbf{z}; D_2)$$

“ $\not\approx$ ” = “nem feltétlenül egyenlő”

Kernel alapú félíg-felügyelt tanulás

- ▶ *megváltoztatjuk* a reprezentációs teret, az összes adatot figyelembe véve
- ▶ felügyelt tanulás + adatfüggő kernelek = **félíg-felügyelt tanulás**
- ▶ “hagyományos” kernelek: adott $D_1 \neq D_2$ adathalmazok esetén, $\mathbf{x}, \mathbf{z} \in D_1 \cap D_2$

$$k(\mathbf{x}, \mathbf{z}) = k(\mathbf{x}, \mathbf{z})$$

- ▶ **adatfüggő kernelek**: adott $D_1 \neq D_2$ adathalmazok esetén, $\mathbf{x}, \mathbf{z} \in D_1 \cap D_2$

$$k(\mathbf{x}, \mathbf{z}; D_1) \approx k(\mathbf{x}, \mathbf{z}; D_2)$$

“ \approx ” = “nem feltétlenül egyenlő”

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Félíg-felügyelt tanulás

Kernel alapú
félíg-felügyelt tanulásLapSVM
Szomszédsági kernel
ISOMAP
Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

LapSVM

- ▶ induktív tanulási módszer: SVM + “simasági” feltétel: *ha két pont egy nagy sűrűségű régióban közel található egymáshoz, akkor azok címkéi is hasonlóan kell viselkedjenek*
- ▶ új optimalizálási feladat (Sindhwani, Niyogi, Belkin 2005):

$$\min \quad \lambda_A \|\mathbf{w}\|^2 + \frac{1}{\ell} \sum_{i=1}^{\ell} \xi_i + \frac{\lambda_I}{N^2} \sum_{i=1}^N W_{ij} (f(\mathbf{x}_i) - f(\mathbf{x}_j))^2$$

$$\text{úgy, hogy} \quad y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, \ell$$

- ▶ \equiv megoldani az SVM optimalizálási feladatát az alábbi kernellel:

$$k_{\text{LapSVM}}(\mathbf{x}, \mathbf{z}) = k(\mathbf{x}, \mathbf{z}) - \mathbf{k}'_{\mathbf{x}} \left(\frac{N^2}{2} \frac{\lambda_A}{\lambda_I} \mathbf{I} + \mathbf{L}^t \mathbf{K} \right)^{-1} \mathbf{L} \mathbf{k}_{\mathbf{z}}$$

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Félfigyelt tanulás

Kernel alapú
félfigyelt tanulás**LapSVM**Szomszédsági kernel
ISOMAPHierarchikus klaszter
kernelÁtsúlyozó klaszter
kernelek

LapSVM

- ▶ induktív tanulási módszer: SVM + “simasági” feltétel: *ha két pont egy nagy sűrűségű régióban közel található egymáshoz, akkor azok címkéi is hasonlóan kell viselkedjenek*
- ▶ új optimalizálási feladat (**Sindhwani, Niyogi, Belkin 2005**):

$$\min \quad \lambda_A \|\mathbf{w}\|^2 + \frac{1}{\ell} \sum_{i=1}^{\ell} \xi_i + \frac{\lambda_I}{N^2} \sum_{i=1}^N W_{ij} (f(\mathbf{x}_i) - f(\mathbf{x}_j))^2$$

$$\text{úgy, hogy} \quad y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, \ell$$

- ▶ \equiv megoldani az SVM optimalizálási feladatát az alábbi kernellel:

$$k_{\text{lsvm}}(\mathbf{x}, \mathbf{z}) = k(\mathbf{x}, \mathbf{z}) - \mathbf{k}'_{\mathbf{x}} \left(\frac{N^2}{2} \frac{\lambda_A}{\lambda_I} \mathbf{I} + \mathbf{L}^t \mathbf{K} \right)^{-1} \mathbf{L} \mathbf{k}_{\mathbf{z}}$$

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Fél-felügyelt tanulás

Kernel alapú
fél-felügyelt tanulás

LapSVM

Szomszédsági kernel
ISOMAPHierarchikus klaszter
kernelÁtsúlyozó klaszter
kernelek

LapSVM

- ▶ induktív tanulási módszer: SVM + “simasági” feltétel: *ha két pont egy nagy sűrűségű régióban közel található egymáshoz, akkor azok címkéi is hasonlóan kell viselkedjenek*
- ▶ új optimalizálási feladat (**Sindhwani, Niyogi, Belkin 2005**):

$$\min \quad \lambda_A \|\mathbf{w}\|^2 + \frac{1}{\ell} \sum_{i=1}^{\ell} \xi_i + \frac{\lambda_I}{N^2} \sum_{i=1}^N W_{ij} (f(\mathbf{x}_i) - f(\mathbf{x}_j))^2$$

$$\text{úgy, hogy} \quad y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, \ell$$

- ▶ \equiv megoldani az SVM optimalizálási feladatát az alábbi kernellel:

$$k_{\text{LapSVM}}(\mathbf{x}, \mathbf{z}) = k(\mathbf{x}, \mathbf{z}) - \mathbf{k}'_{\mathbf{x}} \left(\frac{N^2}{2} \frac{\lambda_A}{\lambda_I} \mathbf{I} + \mathbf{L}^t \mathbf{K} \right)^{-1} \mathbf{L} \mathbf{k}_{\mathbf{z}}$$

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Félfig-felügyelt tanulás

Kernel alapú
félfig-felügyelt tanulás

LapSVM

Szomszédsági kernel
ISOMAPHierarchikus klaszter
kernelÁtsúlyozó klaszter
kernelek

Szomszédsági kernel

- ▶ klaszter-feltételen alapszik: *ha két pont azonos klaszterben van, akkor nagy valószínűséggel azonos osztályban is*
- ▶ ötlet: minden pontot helyettesítünk a pont szomszédainak átlagával (**Weston, Leslie, Zhou, Elisseeff, Noble 2004**):

$$\phi_{\text{nbd}}(\mathbf{x}) = \frac{1}{|N(\mathbf{x})|} \sum_{\mathbf{x}' \in N(\mathbf{x})} \phi_{\text{b}}(\mathbf{x}')$$

ahol $N(\cdot)$ a szomszédsági függvény

- ▶ a kernel így:

$$k_{\text{nbd}}(\mathbf{x}, \mathbf{z}) = \frac{\sum_{\mathbf{x}' \in N(\mathbf{x}), \mathbf{z}' \in N(\mathbf{z})} k(\mathbf{x}', \mathbf{z}')}{|N(\mathbf{x})||N(\mathbf{z})|}$$

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Félíg-felügyelt tanulás

Kernel alapú
félíg-felügyelt tanulás

LapSVM

Szomszédsági kernel
ISOMAPHierarchikus klaszter
kernelÁtsúlyozó klaszter
kernelek

Szomszédsági kernel

- ▶ klaszter-feltételen alapszik: *ha két pont azonos klaszterben van, akkor nagy valószínűséggel azonos osztályban is*
- ▶ ötlet: minden pontot helyettesítünk a pont szomszédainak átlagával (**Weston, Leslie, Zhou, Elisseeff, Noble 2004**):

$$\phi_{\text{nbd}}(\mathbf{x}) = \frac{1}{|N(\mathbf{x})|} \sum_{\mathbf{x}' \in N(\mathbf{x})} \phi_{\text{b}}(\mathbf{x}')$$

ahol $N(\cdot)$ a szomszédsági függvény

- ▶ a kernel így:

$$k_{\text{nbd}}(\mathbf{x}, \mathbf{z}) = \frac{\sum_{\mathbf{x}' \in N(\mathbf{x}), \mathbf{z}' \in N(\mathbf{z})} k(\mathbf{x}', \mathbf{z}')}{|N(\mathbf{x})||N(\mathbf{z})|}$$

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Félíg-felügyelt tanulás

Kernel alapú
félíg-felügyelt tanulás

LapSVM

Szomszédsági kernel
ISOMAPHierarchikus klaszter
kernelÁtsúlyozó klaszter
kernelek

ISOMAP

- ▶ valójában dimenziócsökkentő módszer (**Tenenbaum, de Silva, Langford 2000**)
- ▶ ha az adatok egy manifoldon helyezkednek el, akkor a gráf alapú távolságok (**legrövidebb utak**) megközelítik a manifoldon vett távolságokat
- ▶ gráfok: k legközelebbi szomszéd, vagy ε -szomszédsági
- ▶ $\Rightarrow \mathbf{G}$ távolsági mátrix
- ▶ az ISOMAP kernel abba a térbe transzformálja a pontokat, ahol az euklideszi távolságok megegyeznek a gráftávolságokkal
- ▶ a kernel:

$$\mathbf{K}_{\text{isomap}} = \tau(\mathbf{G}) = -\frac{1}{2}\mathbf{J}\mathbf{G}^{(2)}\mathbf{J},$$

ahol $\mathbf{J} = \mathbf{I} - \frac{1}{N}\mathbf{1}\mathbf{1}'$ a centrálási mátrix, és a $\tau(\mathbf{G}) = -\frac{1}{2}\mathbf{J}\mathbf{G}^{(2)}\mathbf{J}$ operátor a távolságokat skalárszorzáttá alakítja

Kernel alapú tanulás

Kernel
SVM

Néhány (általános
célú) kernel

Fél-felügyelt tanulás

Kernel alapú
fél-felügyelt tanulás

LapSVM
Szomszédsági kernel

ISOMAP

Hierarchikus klaszter
kernel

Átsúlyozó klaszter
kernelek

ISOMAP

- ▶ valójában dimenziócsökkentő módszer (**Tenenbaum, de Silva, Langford 2000**)
- ▶ ha az adatok egy manifoldon helyezkednek el, akkor a gráf alapú távolságok (**legrövidebb utak**) megközelítik a manifoldon vett távolságokat
- ▶ gráfok: k legközelebbi szomszéd, vagy ε -szomszédsági
- ▶ $\Rightarrow \mathbf{G}$ távolsági mátrix
- ▶ az ISOMAP kernel abba a térbe transzformálja a pontokat, ahol az euklideszi távolságok megegyeznek a gráftávolságokkal
- ▶ a kernel:

$$\mathbf{K}_{\text{isomap}} = \tau(\mathbf{G}) = -\frac{1}{2}\mathbf{J}\mathbf{G}^{(2)}\mathbf{J},$$

ahol $\mathbf{J} = \mathbf{I} - \frac{1}{N}\mathbf{1}\mathbf{1}'$ a centrálási mátrix, és a $\tau(\mathbf{G}) = -\frac{1}{2}\mathbf{J}\mathbf{G}^{(2)}\mathbf{J}$ operátor a távolságokat skalárszorozattá alakítja

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Fél-felügyelt tanulás

Kernel alapú
fél-felügyelt tanulásLapSVM
Szomszédsági kernel
ISOMAPHierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek

Hierarchikus klaszter kernel

- ▶ hierarchikus klaszterezésen alapuló kernelek (**Bodó 2008**)
- ▶ hierarchikus klaszterezés:
 - ▶ **ponttávolság** mérése: $d(\mathbf{x}, \mathbf{z})$ (általában euklideszi)
 - ▶ **klasztertávolság** mérése: $D(C_1, C_2)$

1. egyszerű láncmódszer (*single linkage*)

$$D(C_1, C_2) = \min \{d(\mathbf{x}, \mathbf{z}) \mid \mathbf{x} \in C_1, \mathbf{z} \in C_2\}$$

2. teljes láncmódszer (*complete linkage*)

$$D(C_1, C_2) = \max \{d(\mathbf{x}, \mathbf{z}) \mid \mathbf{x} \in C_1, \mathbf{z} \in C_2\}$$

3. átlagos láncmódszer (*average linkage*)

$$D(C_1, C_2) = \frac{1}{|C_1| \cdot |C_2|} \sum_{i=1}^{|C_1|} \sum_{j=1}^{|C_2|} d(\mathbf{x}_i, \mathbf{z}_j)$$

Kernel alapú tanulás

Kernelek
SVM

Néhány (általános
célú) kernel

Félfig-felügyelt tanulás

Kernel alapú
félfig-felügyelt tanulás

LapSVM
Szomszédsági kernel
ISOMAP

Hierarchikus klaszter
kernel

Átsúlyozó klaszter
kernelek



► **ultrametricitás:** ha

$$D(C_1, C_2) \leq D(C_1, C_3)$$

$$D(C_1, C_2) \leq D(C_2, C_3)$$

akkor

$$D(C_1, C_2) \leq D(C_{12}, C_3)$$



► *Tétel:* ha M ultrametrikus, akkor $-\frac{1}{2}JMJ$ egy Gram-mátrix, amely azon vektorok skalárszorzatait tartalmazza, melyek négyzetes euklideszi távolságai az M -ben vannak

► kernel:

$$K_{\text{hck}} = -\frac{1}{2}JMJ$$

► kiterjesztés: ISOMAP módszerrel való kombinálás: $d(\cdot, \cdot) \rightarrow$ gráftávolságok; nem összefüggő gráf esetén a gráf összefüggővé alakítása

Kernel alapú tanulás

Kernelek
SVM

Néhány (általános
célú) kernel

Félfig-felügyelt tanulás

Kernel alapú
félfig-felügyelt tanulás

LapSVM
Szomszédsági kernel
ISOMAP

Hierarchikus klaszter
kernel
Átsúlyozó klaszter
kernelek



- ▶ **ultrametricitás:** ha

$$D(C_1, C_2) \leq D(C_1, C_3)$$

$$D(C_1, C_2) \leq D(C_2, C_3)$$

akkor

$$D(C_1, C_2) \leq D(C_{12}, C_3)$$



- ▶ **Tétel:** ha M ultrametrikus, akkor $-\frac{1}{2}JMJ$ egy Gram-mátrix, amely azon vektorok skalárszorzatait tartalmazza, melyek négyzetes euklideszi távolságai az M -ben vannak

- ▶ kernel:

$$K_{\text{hck}} = -\frac{1}{2}JMJ$$

- ▶ kiterjesztés: ISOMAP módszerrel való kombinálás: $d(\cdot, \cdot) \rightarrow$ gráftávolságok; nem összefüggő gráf esetén a gráf összefüggővé alakítása

Átsúlyozó klaszter kernelek

- ▶ az alapkernel átsúlyozása a klaszterbe tartozás alapján (**Bodó, Csató 2010**)
- ▶ kernelek kombinációja (néhány tulajdonság):
 - ▶ ha $\mathbf{K}_1, \mathbf{K}_2$ p.szd., akkor $\mathbf{K}_1 + \mathbf{K}_2$ is p.szd.
 - ▶ ha \mathbf{K} p.szd., $a > 0$, akkor $a\mathbf{K}$ is p.szd.
 - ▶ ha $\mathbf{K}_1, \mathbf{K}_2$ p.szd., akkor $\mathbf{K}_1 \odot \mathbf{K}_2$ is p.szd., ahol \odot a Hadamard-szorzatot jelöli
- ▶ átsúlyozó kernelek:

$$\mathbf{K}_{\text{rck}} = \mathbf{K}_{\text{rw}} \odot \mathbf{K}_{\text{b}}$$

$$k_{\text{rw}}(\mathbf{x}, \mathbf{z}) = \exp\left(-\frac{\|\mathbf{U}\cdot\mathbf{x} - \mathbf{U}\cdot\mathbf{z}\|^2}{2\sigma^2}\right) \quad (1)$$

$$\mathbf{K}_{\text{rw}} = \mathbf{U}'\mathbf{U} + \frac{\alpha}{N}\mathbf{1}\mathbf{1}', \quad \alpha \in [0, 1) \quad (2)$$

$$\mathbf{K}_{\text{rw}} = \beta\mathbf{U}'\mathbf{U} + \frac{1}{N}\mathbf{1}\mathbf{1}', \quad \beta \in (0, \infty) \quad (3)$$

Kernel alapú tanulás

Kernelek
SVMNéhány (általános
célú) kernel

Fél-felügyelt tanulás

Kernel alapú
fél-felügyelt tanulásLapSVM
Szomszédsági kernel
ISOMAPHierarchikus klaszter
kernelÁtsúlyozó klaszter
kernelek

Kernel alapú tanulás

Kernelek
SVM

Néhány (általános
célú) kernel

Félfigyelt tanulás

Kernel alapú
félfigyelt tanulás

LapSVM
Szomszédsági kernel
ISOMAP

Hierarchikus klaszter
kernel

Átsúlyozó klaszter
kernelek

Köszönöm a figyelmet!

