

Félig-felügyelt tanulás kernelekkel és hashing módszerek

Bodó Zalán

Babeş–Bolyai Tudományegyetem, Kolozsvár
Matematika és Informatika Kar
Magyar Matematika és Informatika Intézet

Tartalom

Félig-felügyelt tanulás kernelek segítségével

Felügyelt és félig-felügyelt tanulás

► felügyelt:

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



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

► félig-felügyelt:

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


$\ell \ll u$;

- **induktív**: keressük $f : X \rightarrow \{-1, +1\}$ -et, amely egyezik D -vel + D_U felhasználása
- **transzduktív**: keressük $f : D_U \rightarrow \{-1, +1\}$ -et felhasználva a $D = D_L \cup D_U$ adatokat




Kernel módszerek a gépi tanulásban

- ▶ James Mercer (1909): minden folytonos szimmetrikus pozitív definit kernel függvény felírható skalárszorzatként egy (nagydimenziós) térben
- ▶ kernel: $k(\mathbf{x}, \mathbf{z}) = \langle \phi(\mathbf{x}), \phi(\mathbf{z}) \rangle = \phi(\mathbf{x})' \phi(\mathbf{z})$, feature leképezés: $\phi : X \rightarrow \mathcal{H}$
- ▶ alkalmazható minden geometriai konstrukció esetén, ha az szögeket, hosszokat és távolságokat használ



(a)



(b)

1. ábra. Az XOR feladat: (a) input térben, (b) másodfokú polinomiális kernel által generált térben.

Gyakran használt kernelek:

- ▶ lineáris:

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

- ▶ polynomiális:

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

- ▶ Gauss-féle, RBF:

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

- ▶ szigmoid:

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

Félig-felügyelt kernelek

Adatfüggő (data-dependent) kernelek

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

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

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


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

ahol „ \approx ”-et „nem feltétlenül egyenlő”-ként olvassuk

- ▶ felügyelt tanulás + adatfüggő kernelek = **félig-felügyelt tanulás**

Klaszter-kernelek

- ▶ **klaszter feltevés** (*cluster assumption*): ha két pont ugyanabban a klaszterben van, nagy valószínűséggel ugyanabba az osztályba is tartoznak (= ua. a címkéjük)
- ▶ **hierarchikus klaszter-kernel**:
 - ▶ használjuk a hierarchikus klaszterezésből származó távolságokat (single, complete, average linkage)
 - ▶ hasznos tulajdonság: ultrametrikus távolságmátrixot eredményez az adatokon



Tétel [Fischer, 2003]

Adott ultrametrikus \mathbf{M} esetén a $-\frac{1}{2}\mathbf{M}^c = -\frac{1}{2}\mathbf{J}\mathbf{M}\mathbf{J}$ mátrix egy Gram-mátrix lesz, amely a \mathbf{z}_i , $i = 1, 2, \dots, N$ vektorok skalárszorzatait tartalmazza, melyek euklideszi távolságai az \mathbf{M} -ben vannak ($\mathbf{J} = \mathbf{I} - (1/N)\mathbf{1}\mathbf{1}'$).

- ▶ az algoritmus: (i) pontok hierarchikus klaszterezése, (ii) M_{ij} = linkage távolság az eredő ultrametrikus fában a legközelebbi közös felmenőnél, $M_{ii} = 0$.

▶ *átsúlyozó klaszter-kernelek:*

- ▶ kernel kombinációk: $\mathbf{K}_1 + \mathbf{K}_2$, $a \cdot \mathbf{K}$, $\mathbf{K}_1 \odot \mathbf{K}_2$
- ▶ átsúlyozó klaszter-kernel: $\mathbf{K} = \mathbf{K}_{\text{rw}} \odot \mathbf{K}_b$, ahol
 - ▶ \mathbf{K}_b = alap kernel (pl. Gauss, polinomiális stb.)
 - ▶ \mathbf{K}_{rw} = átsúlyozó kernel
- ▶ Gauss-féle átsúlyozó kernel:

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

- ▶ skalárszorzat alapú átsúlyozó kernelek:

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

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

ahol \mathbf{U} a $K \times N$ méretű klaszter hovatartozási mátrix
(oszlopokban)

- ▶ **probléma:** *általánosítás* – közelítő módszerek

Legközelebbi szomszédok gyors keresése


Legközelebbi szomszédok keresése pozitív definit kernelekkel

- ▶ egyenlőtlenségek:

$$d^2(\mathbf{x}, \mathbf{z}) \geq k(\mathbf{x}, \mathbf{x}) + k(\mathbf{z}, \mathbf{z}) - 2\sqrt{k(\mathbf{x}, \mathbf{x})k(\mathbf{z}, \mathbf{z})}$$

$$d^2(\mathbf{x}, \mathbf{z}) \geq \frac{1}{2}k(\mathbf{z}, \mathbf{z}) - k(\mathbf{x}, \mathbf{x})$$

- ▶ tároljuk a maximális d_{max}^2 távolságot, és mindig megnézzük, hogy pl. $\frac{1}{2}k(\mathbf{z}, \mathbf{z}) - k(\mathbf{x}, \mathbf{x}) \geq d_{max}^2$
- ▶ a számítások akár 50%-át megtakaríthatjuk



2. ábra. Locality-sensitive hashing

Hashing módszerek

Locality-sensitive hashing¹ véletlen hipersíkokkal

- ▶ Hamming-távolság hatékonyan kiszámítható:

$$d_H(\mathbf{u}, \mathbf{v}) = \sum_{i=1}^n (\mathbf{u} \text{ XOR } \mathbf{v})$$

- ▶ a k darab hash függvényünk legyen


$$h_i(\mathbf{u}) = \begin{cases} 1, & \mathbf{r}'_i \mathbf{u} \geq 0 \\ 0, & \mathbf{r}'_i \mathbf{u} < 0 \end{cases}, i = 1, 2, \dots, k, \mathbf{r} \in \mathbb{R}^d \text{ véletlen vektor}$$

- ▶ egy \mathbf{x} ponthoz rendelt bináris hash szekvencia

$$[h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_k(\mathbf{x})]$$

- ▶ ekkor:

$$P(h_{\mathbf{r}}(\mathbf{u}) = h_{\mathbf{r}}(\mathbf{v})) = 1 - \frac{\theta(\mathbf{u}, \mathbf{v})}{\pi}$$



¹Helyérzékeny hasítás/hashelés

Hash kulcsok kiterjesztése címkézett adatok segítségével

- ▶ feltételezzük, hogy vannak címkézett pontjaink (minden osztályból)
- ▶ valamilyen hashing módszerrel előállított bináris kulcsok + hibajavító kódok segítségével tanított félig-felügyelt módszerek (ECOC)
- ▶ ECOC:
 - ▶ kódmátrix:

$$\mathbf{M} = \begin{bmatrix} 1 & 1 & 1 & -1 & -1 & -1 \\ 1 & -1 & -1 & 1 & 1 & -1 \\ -1 & 1 & -1 & 1 & -1 & 1 \\ -1 & -1 & 1 & -1 & 1 & 1 \end{bmatrix}$$

- ▶ \mathbf{M} (osztályok száma \times c) minden oszlopára betanítunk egy *félig-felügyelt* modellt
 - ▶ kimenet: $f_i(\mathbf{x}) =$ a FF módszer kimenete, $i = 1, \dots, c$
- ▶ kiterjesztett kulcsok:

$$[h_1(\mathbf{x}), \dots, h_k(\mathbf{x}), \underbrace{f_1(\mathbf{x}), \dots, f_c(\mathbf{x})}_{\text{kiterjesztés}}]$$

Köszönöm a figyelmet!