

10. Jezgrene metode

Strojno učenje 1, UNIZG FER, ak. god. 2021./2022.

Jan Šnajder, natuknice s predavanja, v1.3

1 Jezgrene funkcije

- Umjesto težina uz vektor značajki \mathbf{x} , izračunavamo **sličnost** dvaju primjera
- Naročito prikladno kada se primjeri teško vektoriziraju (npr. jer imaju strukturu)
- **Jezgrena funkcija** (*kernel function*): $\kappa : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$
- Jezgrena funkcija je **mjera sličnosti** ako zadovoljava:
 - $\kappa(\mathbf{x}, \mathbf{x}) = 1$
 - $0 \leq \kappa(\mathbf{x}, \mathbf{x}') \leq 1$
 - $\kappa(\mathbf{x}, \mathbf{x}') = \kappa(\mathbf{x}', \mathbf{x})$
- Jezgre za strukturirane podatke: **string kernels**, **tree kernels**, **graph kernels**
- Tipične jezgrene funkcije za primjere u vektorskem prostoru:
 - **Linearna jezgra**: $\kappa(\mathbf{x}, \mathbf{x}') = \mathbf{x}^T \mathbf{x}'$
 - **Radijalna bazna funkcija (RBF)**: općenito jezgra tipa $\kappa(\mathbf{x}, \mathbf{x}') = f(\|\mathbf{x} - \mathbf{x}'\|)$
 - **Gaussova RBF-jezgra**:

$$\kappa(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\sigma^2}\right) = \exp(-\gamma\|\mathbf{x} - \mathbf{x}'\|^2)$$

gdje je σ^2 je širina pojasa (*bandwidth*), $\gamma = 1/2\sigma^2$ je preciznost
(manja $\sigma^2 \Leftrightarrow$ veća $\gamma \Leftrightarrow$ primjeri su međusobno sve različitiji)

- **Ekponencijalna jezgra**: $\kappa(\mathbf{x}, \mathbf{x}') = \exp(-\gamma\|\mathbf{x} - \mathbf{x}'\|)$
- **Inverzna kvadratna jezgra**: $\kappa(\mathbf{x}, \mathbf{x}') = \frac{1}{1 + \|\mathbf{x} - \mathbf{x}'\|^2}$

- Umjesto euklidske, može se koristiti **Mahalanobisova udaljenost**:

$$\kappa(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{1}{2}(\mathbf{x} - \mathbf{x}')^T \Sigma^{-1} (\mathbf{x} - \mathbf{x}')\right)$$

gdje je Σ kovarijacijska matrica značajki

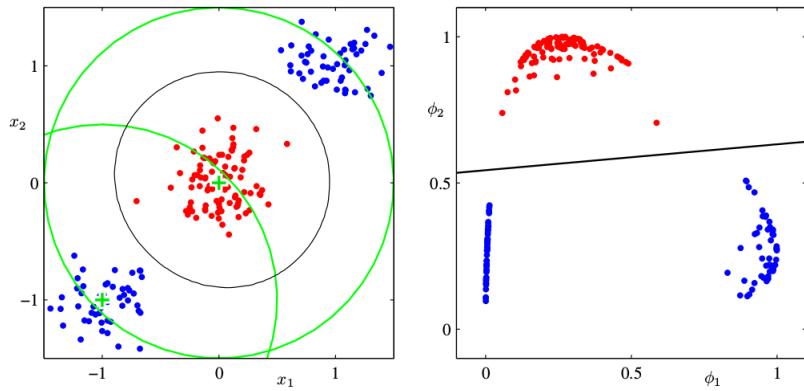
2 Jezgreni strojevi

- Preslikavanje ϕ koje za bazne funkcije ϕ_j koristi jezgrene funkcije:

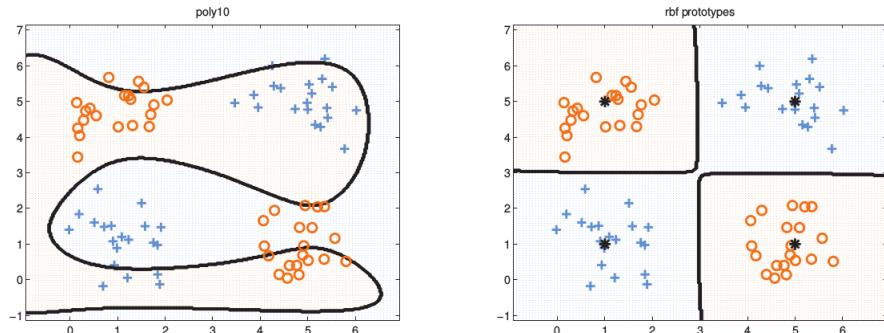
$$\phi(\mathbf{x}) = (1, \kappa(\mathbf{x}, \boldsymbol{\mu}_1), \kappa(\mathbf{x}, \boldsymbol{\mu}_2), \dots, \kappa(\mathbf{x}, \boldsymbol{\mu}_m))$$

gdje su $\boldsymbol{\mu}_j \in \mathcal{X}$ odabrane točke u prostoru primjera

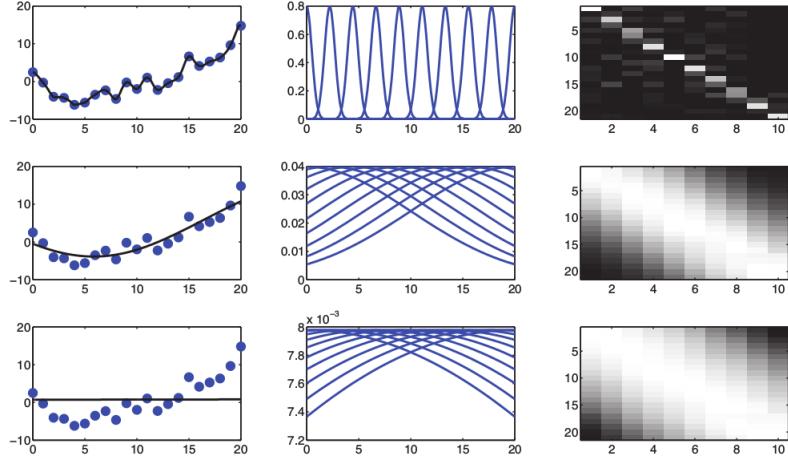
- **Jezgreni stroj** (*kernel machine*) – poopćeni linearni model s takvim preslikavanjem
- Primjer (iz MLPP) – klasifikacija:



- Primjer (iz MLPP) – klasifikacija:



- Primjer (iz MLPP) – regresija:



- Uniforman raspored $\mu_j \Rightarrow$ neprilagođen podatcima, problem visokih dimenzija
- Alternativa: μ_j su primjeri iz skupa za učenje:

$$\phi(\mathbf{x}) = (1, \kappa(\mathbf{x}, \mathbf{x}_1), \kappa(\mathbf{x}, \mathbf{x}_2), \dots, \kappa(\mathbf{x}, \mathbf{x}_N))$$

- Problem: primjera može biti puno; rješenje: **L1-regularizacija**
- **Rijetki jezgreni strojevi:** L1VM, SVM

3 Jezgreni trik

- SVM je rijedak jezgreni stroj, no umjesto preslikavanja koristi jezgreni trik
- **Jezgreni trik** – skalarni produkt vektora zamjenjuje se jezgrenom funkcijom:

$$\kappa(\mathbf{x}, \mathbf{x}') = \phi(\mathbf{x})^T \phi(\mathbf{x}')$$

- Model SVM:

$$h(\mathbf{x}) = \sum_{i=1}^N \alpha_i y^{(i)} \phi(\mathbf{x})^T \phi(\mathbf{x}^{(i)}) + w_0 = \sum_{i=1}^N \alpha_i y^{(i)} \kappa(\mathbf{x}, \mathbf{x}^{(i)}) + w_0$$

- Ciljna funkcija (kvadratno programiranje):

$$\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y^{(i)} y^{(j)} \kappa(\mathbf{x}^{(i)}, \mathbf{x}^{(j)})$$

- **Inverzno oblikovanje** – odabiremo jezgru i time implicitno definiramo ϕ
- Prednosti:
 - Manja računalna složenost (izračun κ je često jeftiniji od izračuna ϕ)
 - Nekad je lakše definirati κ nego ϕ (strukturirani podatci: nizovi, stabla, grafovi)

- Prostor koji inducira κ može biti visoko (potencijalno beskonačno) dimenzijski
- Uvjet: κ odgovara skalarnom produktu u nekom vekt. prostoru \Rightarrow **Mercerova jezgra**
- Jezgrena matrica (*kernel matrix*):

$$\mathbf{K} = \begin{pmatrix} \kappa(\mathbf{x}^{(1)}, \mathbf{x}^{(1)}) & \kappa(\mathbf{x}^{(1)}, \mathbf{x}^{(2)}) & \dots & \kappa(\mathbf{x}^{(1)}, \mathbf{x}^{(N)}) \\ \kappa(\mathbf{x}^{(2)}, \mathbf{x}^{(1)}) & \kappa(\mathbf{x}^{(2)}, \mathbf{x}^{(2)}) & \dots & \kappa(\mathbf{x}^{(2)}, \mathbf{x}^{(N)}) \\ \vdots & \vdots & \ddots & \vdots \\ \kappa(\mathbf{x}^{(N)}, \mathbf{x}^{(1)}) & \kappa(\mathbf{x}^{(N)}, \mathbf{x}^{(2)}) & \dots & \kappa(\mathbf{x}^{(N)}, \mathbf{x}^{(N)}) \end{pmatrix}$$

- $\mathbf{K} = \Phi\Phi^T \Leftrightarrow \mathbf{K}$ je **Gramova matrica** (matrica skalarnih produkata)
- Gramova matrica je uvijek pozitivno semidefinitna ($\forall \mathbf{x}, \mathbf{x}^T \mathbf{K} \mathbf{x} \geq 0$)
- **Mercerov teorem:** \mathbf{K} je pozitivno semidefinitna $\Leftrightarrow \kappa$ je Mercerova jezgra
- Inducirani prostor: skalarni produkt + proizvoljna dimenzija \Rightarrow **Hilbertov prostor**
- Mercerove jezgre: linearna, polinomijalna, RBF-jezgra, string kernels, ...
- Preslikavanje polinomijalne jezgre
 - Općenito: $\kappa(\mathbf{x}, \mathbf{x}') = (\gamma \mathbf{x}^T \mathbf{x}' + c)^d$
 - Primjer za $n = 2, d = 2, c = 0, \gamma = 1$:

$$\begin{aligned} \kappa(\mathbf{x}, \mathbf{z}) &= (\mathbf{x}^T \mathbf{z})^2 = ((x_1, x_2)^T (z_1, z_2))^2 = (x_1 z_1 + x_2 z_2)^2 \\ &= (x_1 z_1)^2 + 2(x_1 z_1)(x_2 z_2) + (x_2 z_2)^2 = x_1^2 z_1^2 + \sqrt{2} x_1 x_2 \sqrt{2} z_1 z_2 + x_2^2 z_2^2 \\ &= (x_1^2, \sqrt{2} x_1 x_2, x_2^2)^T (z_1^2, \sqrt{2} z_1 z_2, z_2^2) = \phi(\mathbf{x})^T \phi(\mathbf{z}) \\ \Rightarrow \phi(\mathbf{x}) &= (x_1^2, \sqrt{2} x_1 x_2, x_2^2) \end{aligned}$$

- Preslikavanje RBF-jezgre:
 - \mathbf{K} je punog ranga $\Leftrightarrow \phi(\mathbf{x})$ su lin. nezavisni \Rightarrow **beskonačnodimenzijski prostor**
 - $\gamma \rightarrow \infty \Leftrightarrow \kappa(\mathbf{x}, \mathbf{x}') \rightarrow 0 \Leftrightarrow \phi(\mathbf{x})^T \phi(\mathbf{x}') = 0 \Leftrightarrow$ primjeri su ortonormirani
 \Leftrightarrow primjeri su vrhovi višedimenzijskog simpleksa \Leftrightarrow linearno su odvojivi
- Složenije Mercerove jezgre gradimo operacijama koje zadržavaju to svojstvo:

$$\begin{aligned} \kappa(\mathbf{x}, \mathbf{x}') &= \alpha \kappa_1(\mathbf{x}, \mathbf{x}') & \alpha > 0 \\ \kappa(\mathbf{x}, \mathbf{x}') &= f(\mathbf{x}) \kappa_1(\mathbf{x}, \mathbf{x}') f(\mathbf{x}') & f - \text{bilo koja funkcija} \\ \kappa(\mathbf{x}, \mathbf{x}') &= q(\kappa_1(\mathbf{x}, \mathbf{x}')) & q - \text{polinom s poz. koef.} \\ \kappa(\mathbf{x}, \mathbf{x}') &= \exp(\kappa_1(\mathbf{x}, \mathbf{x}')) \\ \kappa(\mathbf{x}, \mathbf{x}') &= \kappa_1(\phi(\mathbf{x}), \phi(\mathbf{x}')) & \phi : \mathbb{R}^n \rightarrow \mathbb{R}^{m+1} \\ \kappa(\mathbf{x}, \mathbf{x}') &= \kappa_1(\mathbf{x}, \mathbf{x}') + \kappa_2(\mathbf{x}, \mathbf{x}') \\ \kappa(\mathbf{x}, \mathbf{x}') &= \kappa_1(\mathbf{x}, \mathbf{x}') \kappa_2(\mathbf{x}, \mathbf{x}') \end{aligned}$$

\Rightarrow **multiple kernel learning (MKL)**

4 Napomene

- Odabir modela kod SVM-a
 - RBF-jezgra: hiperparametri C i γ su međuovisni ($\gamma \uparrow \Leftrightarrow C \downarrow$)
 - odabir modela najčešće se radi **pretraživanjem po rešetci** (*grid search*)
- Linearna jezgra – ne daje nelinearnost, ali daje rijetka rješenja (potporni vektori)
- Jezgeni trik primjenjiv je na druge algoritme (npr. kernelizirana linearna regresija)
- **Aproksimacija kernela** (kada je N velik) – aproksimacija preslikavanja ϕ + SGD