

4. Regresija II

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

Jan Šnajder, natuknice s predavanja, v1.5

1 Nelinearna regresija

- Veza između nezavisnih varijabli i zavisne varijable često je **nelinearna**
- Neki nelinearni regresijski modeli:

- Linearna višestruka regresija:

$$h(\mathbf{x}; \mathbf{w}) = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n$$

- Jednostruka polinomijalna regresija ($n = 1$):


$$h(x; \mathbf{w}) = w_0 + w_1x + w_2x^2 + \dots + w_dx^d$$

- Višestruka polinomijalna regresija ($n = 2, d = 2$):

$$h(\mathbf{x}; \mathbf{w}) = w_0 + w_1x_1 + w_2x_2 + w_3x_1x_2 + w_4x_1^2 + w_5x_2^2$$

gdje je x_1x_2 **interakcijska značajka** (*cross-term*)

- Umjesto da mijenjamo model, mijenjamo podatke \Rightarrow **preslikavanje u prostor značajki**



- **Bazne funkcije** (nelinearne funkcije ulaznih varijabli):

$$\{\phi_0, \phi_1, \phi_2, \dots, \phi_m\}, \quad \phi_j : \mathbb{R}^n \rightarrow \mathbb{R}, \quad \phi_0(\mathbf{x}) = 1$$

- **Funkcija preslikavanja** u prostor značajki:

$$\begin{aligned} \phi : \mathbb{R}^n &\rightarrow \mathbb{R}^{m+1} : \\ \phi(\mathbf{x}) &= (\phi_0(\mathbf{x}), \dots, \phi_m(\mathbf{x})) \end{aligned}$$

- Model s ugrađenom funkcijom preslikavanja:

$$h(\mathbf{x}; \mathbf{w}) = \sum_{j=0}^m w_j \phi_j(\mathbf{x}) = \mathbf{w}^T \boldsymbol{\phi}(\mathbf{x})$$


- Ova je **linearan model regresije** (linearan u parametrima) \neq linearna regresija
- Uobičajene funkcije preslikavanja:
 - Linearna višestruka regresija: $\boldsymbol{\phi}(\mathbf{x}) = (1, x_1, x_2, \dots, x_n)$
 - Jednostruka polinomijalna regresija: $\boldsymbol{\phi}(x) = (1, x, x^2, \dots, x^m)$
 - Višestruka polinomijalna regresija drugog stupnja: $\boldsymbol{\phi}(\mathbf{x}) = (1, x_1, x_2, x_1 x_2, x_1^2, x_2^2)$
- Matrica dizajna s preslikavanjem:

$$\Phi = \begin{pmatrix} 1 & \phi_1(\mathbf{x}^{(1)}) & \dots & \phi_m(\mathbf{x}^{(1)}) \\ 1 & \phi_1(\mathbf{x}^{(2)}) & \dots & \phi_m(\mathbf{x}^{(2)}) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \phi_1(\mathbf{x}^{(N)}) & \dots & \phi_m(\mathbf{x}^{(N)}) \end{pmatrix}_{N \times (m+1)} = \begin{pmatrix} \phi(\mathbf{x}^{(1)})^T \\ \phi(\mathbf{x}^{(2)})^T \\ \vdots \\ \phi(\mathbf{x}^{(N)})^T \end{pmatrix}_{N \times (m+1)}$$

- Rješenje najmanjih kvadrata: $\mathbf{w} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{y} = \Phi^+ \mathbf{y}$

2 Prenaučenost

- Odabir preslikavanja ϕ je **hiperparametar** modela
- Nelinearan model je složeniji od linearnog \Rightarrow sklonost **prenaučenosti**



- Rješenje: učiti na više primjera, odabir modela, regularizacija, bayesovska regresija

3 Regularizacija

- Složeniji model \Leftrightarrow veće magnitude parametara (težina) \mathbf{w}
- Ograničavanje rasta parametara pri učenju \Rightarrow **regularizacija**
- **Rijetki modeli** (*sparse models*) – modeli s težinama pritegnutima na nulu

- **Regularizirana funkcija pogreške:**

$$E_R(\mathbf{w}|\mathcal{D}) = E(\mathbf{w}|\mathcal{D}) + \underbrace{\lambda\Omega(\mathbf{w})}_{\text{reg. izraz}}$$

gdje je λ **regularizacijski faktor** \Rightarrow kompromis između jednostavnosti i složenosti

- Regularizacijski izraz je p -norma vektora težina:

$$\Omega(\mathbf{w}) = \|\mathbf{w}\|_p = \left(\sum_{j=1}^m |w_j|^p \right)^{\frac{1}{p}}$$


- L2-norma ($p = 2$): $\|\mathbf{w}\|_2 = \sqrt{\sum_{j=1}^m w_j^2} = \sqrt{\mathbf{w}^T \mathbf{w}}$
- L1-norma ($p = 1$): $\|\mathbf{w}\|_1 = \sum_{j=1}^m |w_j|$
- L0-norma ($p = 0$): $\|\mathbf{w}\|_0 = \sum_{j=1}^m \mathbf{1}\{w_j \neq 0\}$

- **L2-regularizacija** (Tikhonovljeva regularizacija):

$$E_R(\mathbf{w}|\mathcal{D}) = \frac{1}{2} \sum_{i=1}^N (\mathbf{w}^T \phi(\mathbf{x}^{(i)}) - y^{(i)})^2 + \frac{\lambda}{2} \|\mathbf{w}\|_2^2$$

\Rightarrow **hrbatna regresija** (*ridge regression*)

- Skica: izokonture L2-regularizirane funkcije pogreške

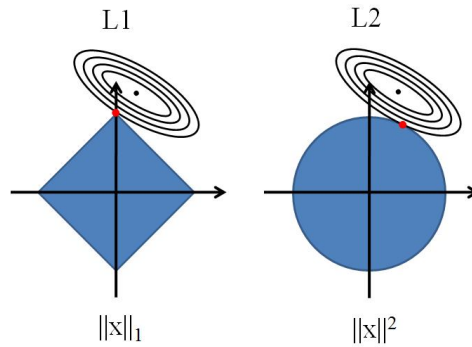


- **L1-regularizacija (LASSO):**

$$E_R(\mathbf{w}|\mathcal{D}) = \frac{1}{2} \sum_{i=1}^N (\mathbf{w}^T \phi(\mathbf{x}^{(i)}) - y^{(i)})^2 + \frac{\lambda}{2} \|\mathbf{w}\|_1$$

\Rightarrow daje rijetke modele

- Skica: usporedba izokontura L1- i L2-regulariziranih funkcija pogreške



- **L0-regularizacija:**

$$E_R(\mathbf{w}|\mathcal{D}) = \frac{1}{2} \sum_{i=1}^N (\mathbf{w}^T \phi(\mathbf{x}^{(i)}) - y^{(i)})^2 + \frac{\lambda}{2} \sum_{j=1}^m \mathbf{1}\{w_j \neq 0\}$$

⇒ efektivno provodi **odabir značajki**

- L0-regularizacija je NP-potpuna, L1-regularizacija nema rješenje u zatvorenoj formi
- Rješenje najmanjih kvadrata s L2-regularizacijom:

$$\begin{aligned} E_R(\mathbf{w}|\mathcal{D}) &= \frac{1}{2} (\Phi \mathbf{w} - \mathbf{y})^T (\Phi \mathbf{w} - \mathbf{y}) + \frac{\lambda}{2} \mathbf{w}^T \mathbf{w} \\ &= \frac{1}{2} (\mathbf{w}^T \Phi^T \Phi \mathbf{w} - 2\mathbf{y}^T \Phi \mathbf{w} + \mathbf{y}^T \mathbf{y} + \lambda \mathbf{w}^T \mathbf{w}) \\ \nabla_{\mathbf{w}} E_R &= \Phi^T \Phi \mathbf{w} - \Phi^T \mathbf{y} + \lambda \mathbf{w} \\ &= (\Phi^T \Phi + \lambda \mathbf{I}) \mathbf{w} - \Phi^T \mathbf{y} = 0 \\ \mathbf{w} &= (\Phi^T \Phi + \lambda \mathbf{I})^{-1} \Phi^T \mathbf{y} \end{aligned}$$

gdje $\lambda \mathbf{I} = \text{diag}(0, \lambda, \dots, \lambda)$ (težinu w_0 ne regulariziramo)

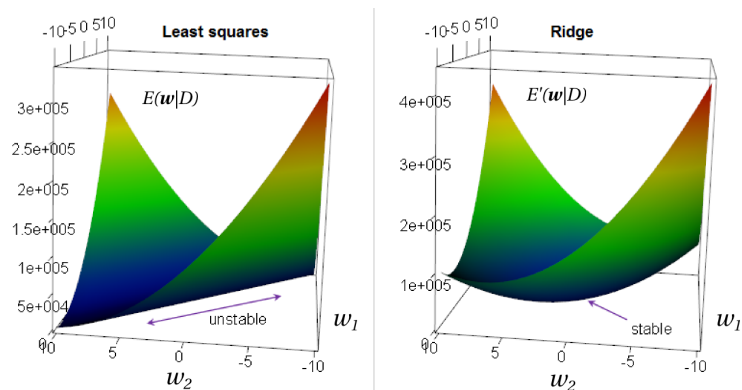
4 Regularizacija i kondicija matrice

- Rješenje najmanjih kvadrata: $\mathbf{w} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{y}$
- $(\Phi^T \Phi)^{-1}$ definiran $\Leftrightarrow \text{rang}(\Phi^T \Phi) = \text{rang}(\Phi) = m + 1 \Leftrightarrow$ linearno nezavisni stupci
- Linearno zavisni stupci \Leftrightarrow redundantne značajke \Leftrightarrow **savršena multikolinearnost**
- **Multikolinearnost** – dvije varijable ili više njih su visoko korelirane
- Multikolinearnost daje **numerički nestabilno rješenje** \Rightarrow **preinačenost**
- Nestabilnost rješenja iskazuje se **kondicijskim brojem** matrice
- $m \gg N \Leftrightarrow$ “široka i plitka” matrica dizajna $\Rightarrow \text{rang}(\Phi) < m + 1 \Rightarrow$ multikolinearnost
- Regularizacija smanjuje multikolinearnost:

$$\mathbf{w} = (\Phi^T \Phi + \lambda \mathbf{I})^{-1} \Phi^T \mathbf{y}$$

⇒ dodavanje dijagonale smanjuje linearnu zavisnost \Rightarrow **rekondicioniranje matrice**

- Regularizacijom funkcija pogreške postaje konveksnija (nestaje hrbat)



5 Napomene

- Magnituda parametra w_i odgovara **važnosti značajke**, osim ako je model prenaučan
- Regularizacija **spriječava prenaučanost** prigušujući vrijednosti značajki
- Ako je model nelinearan, regularizacijom smanjujemo nelinearnost
- Težinu w_0 treba izuzeti iz regularizacijskog izraza ili treba centrirati podatke
- Odabir hiperparametra λ najčešće se provodi **unakrsnom provjerom**