

3. Regresija

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

Jan Šnajder, natuknice s predavanja, v1.5

1 Jednostavna regresija

- Označen skup podataka: $\mathcal{D} = \{(\mathbf{x}^{(i)}, y^{(i)})\}, \mathbf{x} \in \mathbb{R}^n, y \in \mathbb{R}$
- Hipoteza $h : \mathbb{R}^n \rightarrow \mathbb{R}$
- \mathbf{x} – ulazne/nezavisne/prediktorske varijable; y – izlazna/zavisna/kriterijska varijabla
- **Linearna regresija:**

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

- **Jednostavna regresija** ($n = 1$):

$$h(x; w_0, w_1) = w_0 + w_1x$$

- Funkcija gubitka je **kvadratni gubitak**: $L(y, h(x)) = (y - h(x))^2$
- Funkcija pogreške je zbroj kvadratnih gubitaka (**reziduala**):

$$E(h|\mathcal{D}) = \frac{1}{2} \sum_{i=1}^N (y^{(i)} - h(x^{(i)}))^2$$

- Optimizacijski postupak:

$$h^* = \operatorname{argmin}_{h \in \mathcal{H}} E(h|\mathcal{D}) = \operatorname{argmin}_{h \in \mathcal{H}} \frac{1}{2} \sum_{i=1}^N (y^{(i)} - h(x^{(i)}))^2$$

- Za jednostavnu regresiju:

$$\nabla_{w_0, w_1} E(h|\mathcal{D}) = 0$$

$$\frac{\partial}{\partial w_0} \left[\frac{1}{2} \sum_i^N (y^{(i)} - (w_1x^{(i)} + w_0))^2 \right] = 0$$

$$\frac{\partial}{\partial w_1} \left[\frac{1}{2} \sum_i^N (y^{(i)} - (w_1x^{(i)} + w_0))^2 \right] = 0$$

⋮

$$w_0 = \bar{y} - w_1\bar{x}$$

$$w_1 = \frac{\sum_i^N x^{(i)}y^{(i)} - N\bar{x}\bar{y}}{\sum_i^N (x^{(i)})^2 - N\bar{x}^2}$$

2 Vrste regresije

- Ulazne varijable: **jednostavna** ($n = 1$) ili **višestruka** ($n > 1$)
- Izlazne varijable: **univarijatna** ($f(\mathbf{x}) = y$) ili **multivarijatna** ($f(\mathbf{x}) = \mathbf{y}$)

	Jedan izlaz	Više izlaza
Jedan ulaz	(Univarijatna) jednostavna	Multivarijatna jednostavna
Više ulaza	(Univarijatna) višestruka	Multivarijatna višestruka

- Mi radimo samo univarijatnu regresiju

3 Tri komponente linearne regresije

- (1) Model:

$$h(\mathbf{x}; \mathbf{w}) = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n = \sum_{i=1}^n w_ix_i + w_0 = h(\mathbf{x}; \mathbf{w}) = \mathbf{w}^T \mathbf{x}$$

- (2) Funkcija gubitka i funkcija pogreške:

$$L(y^{(i)}, h(\mathbf{x}^{(i)})) = (y^{(i)} - h(\mathbf{x}^{(i)}))^2$$

$$E(h|\mathcal{D}) = \frac{1}{2} \sum_{i=1}^N (y^{(i)} - h(\mathbf{x}^{(i)}))^2$$

- (3) Optimizacijski postupak:

$$\underset{\mathbf{w}}{\operatorname{argmin}} E(\mathbf{w}|\mathcal{D})$$

⇒ **metoda najmanjih kvadrata** (*ordinary least squares, OLS*)

- Postoji rješenje u **zatvorenoj formi**

4 Postupak najmanjih kvadrata

- Označeni primjeri daju N jednadžbi s $(n + 1)$ nepoznanica:

$$\forall (\mathbf{x}^{(i)}, y^{(i)}) \in \mathcal{D}. \mathbf{w}^T \mathbf{x} = y^{(i)}$$

- Matrično:

$$\underbrace{\begin{pmatrix} 1 & x_1^{(1)} & x_2^{(1)} & \dots & x_n^{(1)} \\ 1 & x_1^{(2)} & x_2^{(2)} & \dots & x_n^{(2)} \\ \vdots & & & & \\ 1 & x_1^{(N)} & x_2^{(N)} & \dots & x_n^{(N)} \end{pmatrix}}_{\mathbf{X}} \cdot \underbrace{\begin{pmatrix} w_0 \\ w_1 \\ \vdots \\ w_n \end{pmatrix}}_{\mathbf{w}} = \underbrace{\begin{pmatrix} y^{(1)} \\ y^{(2)} \\ \vdots \\ y^{(N)} \end{pmatrix}}_{\mathbf{y}}$$

- Matrica \mathbf{X} je **matrica dizajna**
- Egzaktno rješenje je $\mathbf{w} = \mathbf{X}^{-1}\mathbf{y}$, ali ono ne postoji ako:
 - \mathbf{X} nije kvadratna \Rightarrow pre/pododređenost sustava
 - \mathbf{X} je kvadratna, ali je sustav nekonzistentan
- Umjesto egzaktnog, tražimo približno rješenje (najmanja kvadratna odstupanja)
- Funkcija pogreške u matričnom obliku:

$$\begin{aligned} E(\mathbf{w}|\mathcal{D}) &= \frac{1}{2}(\mathbf{X}\mathbf{w} - \mathbf{y})^T(\mathbf{X}\mathbf{w} - \mathbf{y}) \\ &= \frac{1}{2}(\mathbf{w}^T\mathbf{X}^T\mathbf{X}\mathbf{w} - \mathbf{w}^T\mathbf{X}^T\mathbf{y} - \mathbf{y}^T\mathbf{X}\mathbf{w} + \mathbf{y}^T\mathbf{y}) \\ &= \frac{1}{2}(\mathbf{w}^T\mathbf{X}^T\mathbf{X}\mathbf{w} - 2\mathbf{y}^T\mathbf{X}\mathbf{w} + \mathbf{y}^T\mathbf{y}) \end{aligned}$$

uz $(A^T)^T = A$ i $(AB)^T = B^T A^T$

- Minimizacija:

$$\begin{aligned} \nabla_{\mathbf{w}} E &= \frac{1}{2}(\mathbf{w}^T(\mathbf{X}^T\mathbf{X} + (\mathbf{X}^T\mathbf{X})^T) - 2\mathbf{y}^T\mathbf{X}) = \mathbf{w}^T\mathbf{X}^T\mathbf{X} - \mathbf{y}^T\mathbf{X} = \mathbf{0} \\ \mathbf{w}^T &= \mathbf{y}^T\mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1} \\ \mathbf{w} &= (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{y} = \mathbf{X}^+\mathbf{y} \end{aligned}$$

uz $\frac{d}{dx}Ax = A$ i $\frac{d}{dx}x^T Ax = x^T(A + A^T)$

- Matrica $\mathbf{X}^+ = (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T$ je Moore-Penroseov **pseudoinverz** matrice dizajna \mathbf{X}
- Pseudoinverz minimizira normu $\|\mathbf{X}\mathbf{w} - \mathbf{y}\|_2$
- Ako je \mathbf{X} kvadratna i punog ranga, onda $\mathbf{X}^+ = \mathbf{X}^{-1}$
- $\mathbf{X}^T\mathbf{X}$ je **Gramova matrica**; $\text{rang}(\mathbf{X}^T\mathbf{X}) = \text{rang}(\mathbf{X})$
- Ako je $\text{rang}(\mathbf{X}) = n + 1$, onda $\mathbf{X}^+ = (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T$
- Dimenzija Gramove matrice je $(n + 1) \times (n + 1) \Rightarrow$ izračun inverza je moguće skup
- Ako $\text{rang}(\mathbf{X}) < n + 1$ (plitka matrica), onda \mathbf{X}^+ računamo pomoću SVD-a

5 Probabilistička interpretacija regresije


- Opažena oznaka je zbroj vrijednosti funkcije i šuma: $y^{(i)} = f(\mathbf{x}^{(i)}) + \varepsilon_i$
- Šum modeliramo kao normalno distribuiranu **slučajnu varijablu**: $\varepsilon \sim \mathcal{N}(0, \sigma^2)$
- **Normalna razdioba**:

$$p(Y = y|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y - \mu)^2}{2\sigma^2}\right)$$

- Vjerojatnost oznake za zadani primjer: $p(y|\mathbf{x}) = \mathcal{N}(f(\mathbf{x}), \sigma^2)$
- Vjerojatnost da je cijeli skup primjera \mathbf{X} označen oznakama \mathbf{y} (uz pretpostavku **iid**):

$$p(\mathbf{y}|\mathbf{X}) = \prod_{i=1}^N p(y^{(i)}|\mathbf{x}^{(i)})$$

⇒ **izglednost** (*likelihood*) (vjerojatnost oznaka pod modelom)



- Radi matematičke jednostavnosti, radimo s logaritmom izglednosti ⇒ **log-izglednost**
- Tražimo \mathbf{w} koji oznake čini najvjerojatnijim ⇔ maksimizacija log-izglednosti
- Vrijedi $h(\mathbf{x}; \mathbf{w}) = f(\mathbf{x})$ (hipoteza treba aproksimirati funkciju $f(\mathbf{x})$)
- Log-izglednost težina \mathbf{w} :

$$\begin{aligned} \ln p(\mathbf{y}|\mathbf{X}, \mathbf{w}) &= \ln \prod_{i=1}^N p(y^{(i)}|\mathbf{x}^{(i)}) = \ln \prod_{i=1}^N \mathcal{N}(f(\mathbf{x}^{(i)}), \sigma^2) \\ &= \ln \prod_{i=1}^N \mathcal{N}(h(\mathbf{x}^{(i)}; \mathbf{w}), \sigma^2) \\ &= \ln \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y^{(i)} - h(\mathbf{x}^{(i)}; \mathbf{w}))^2}{2\sigma^2}\right) \\ &= \underbrace{-N \ln(\sqrt{2\pi}\sigma)}_{=\text{konst.}} - \frac{1}{2\sigma^2} \sum_{i=1}^N (y^{(i)} - h(\mathbf{x}^{(i)}; \mathbf{w}))^2 \\ &\propto -\frac{1}{2} \sum_{i=1}^N (y^{(i)} - h(\mathbf{x}^{(i)}; \mathbf{w}))^2 \end{aligned}$$

⇒ maksimizacija izglednosti ⇔ minimizacija pogreške kvadratnog gubitka