

13. Procjena parametara

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

Jan Šnajder, natuknice s predavanja, v1.3

1 Motivacija

- **Probabilistički modeli** modeliraju vjerojatnosnu razdiobu primjera \mathbf{x} i/ili oznaka y
- **Prednosti:** (1) temeljeni na teoriji vjerojatnosti, (2) vjerojatnosna predikcija, (3) ugradnja apriornog znanja, (4) prikladni za male skupove podataka
- Npr. **Bayesov klasifikator** – $P(y|\mathbf{x}) \propto P(\mathbf{x}|y)P(y)$
 - odabrati prikladne razdiobe za $P(\mathbf{x}|y)$ i $P(y)$
 - **procijeniti parametre** razdioba na temelju podataka \Leftrightarrow učenje modela

2 Slučajne varijable

- X – slučajna varijabla (s.v.) sa skupom mogućih vrijednosti $\{x_i\}$
- **Diskretna s.v.:**
 - $P(X = x)$, kraće $P(x)$ – **vjerojatnost** da diskretna s.v. poprimi vrijednost x
 - $P(x_i) \geq 0, \sum_i P(x_i) = 1 \Rightarrow$ **diskretna razdioba (distribucija) vjerojatnosti**
- **Kontinuirana s.v.:**
 - $p(x)$ – **funkcija gustoće vjerojatnosti (PDF)**
 - $p(x) \geq 0, \int_{-\infty}^{\infty} p(x) dx = 1 \Rightarrow$ **kontinuirana razdioba (distribucija) vjerojatnosti**
- **Očekivanje** – prosječna vrijednost: $\mathbb{E}[X] = \sum_x xP(x)$ odnosno $\mathbb{E}[X] = \int_{-\infty}^{\infty} x p(x) dx$
- **Varijanca** – očekivano odstupanje od očekivanja: $\text{Var}(X) = \sigma_X^2 = \mathbb{E}[(X - \mathbb{E}[X])^2]$
- **Kovarijanca** – zajednička varijabilnost dviju varijabli:

$$\text{Cov}(X, Y) = \sigma_{X,Y} = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])]$$

$$\Rightarrow \text{Cov}(X, Y) = \text{Cov}(Y, X), \text{Cov}(X, X) = \text{Var}(X)$$

- **Pearsonov koeficijent korelacije:** $\rho_{X,Y} = \frac{\text{Cov}(X,Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}} = \frac{\sigma_{X,Y}}{\sigma_X\sigma_Y} \in [-1, +1]$

- $\rho_{X,Y} = +1 \Leftrightarrow$ pozitivna **linearna zavisnost**
- $\rho_{X,Y} = 0 \Leftrightarrow$ **linearna nezavisnost**
- $\rho_{X,Y} = -1 \Leftrightarrow$ negativna **linearna zavisnost**

\Rightarrow ne mjeri **nelinearnu zavisnost!**

- **Matrica kovarijancije** – kovarijancija svih parova varijabli **slučajnog vektora** (X_1, \dots, X_n) :

$$\Sigma = \begin{pmatrix} \text{Var}(X_1) & \text{Cov}(X_1, X_2) & \dots & \text{Cov}(X_1, X_n) \\ \text{Cov}(X_2, X_1) & \text{Var}(X_2) & \dots & \text{Cov}(X_2, X_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(X_n, X_1) & \text{Cov}(X_n, X_2) & \dots & \text{Var}(X_n) \end{pmatrix} = \mathbb{E} \left[(\mathbf{X} - \mathbb{E}[\mathbf{X}])(\mathbf{X} - \mathbb{E}[\mathbf{X}])^T \right]$$

- simetrična i pozitivno semidefinitna
- singularna (tj. nema inverz) ako postoje linearno zavisni retci ili ako $\sigma_i^2 = 0$
- $\text{Cov}(X_i, X_j) = 0 \Rightarrow$ **dijagonalna** kovarijancijska matrica, $\Sigma = \text{diag}(\sigma_i^2)$
- $\sigma_i^2 = \sigma \Rightarrow$ **izotropna** kovarijancijska matrica, $\Sigma = \sigma^2 \mathbf{I}$

- **Nezavisne varijable** $\Leftrightarrow P(X, Y) = P(X)P(Y)$

- nezavisne varijable su nekorelirane, $\text{Cov}(X, Y) = \rho_{X,Y} = 0$, ali obrat ne vrijedi!

3 Osnovne vjerojatnosne distribucije

- Diskretna varijabla:

- Jednodimenzijaska binarna: **Bernoullijeva razdioba**
- Jednodimenzijaska viševrijednosna: **kategorička (multinulijeva) razdioba**
- Višedimenzijaska: Konkatenirani vektor binarnih/viševrijednosnih varijabli

- Kontinuirana varijable:

- Jednodimenzijaska: **univarijatna normalna (Gaussova) razdioba**
- Višedimenzijaska: **multivarijatna normalna (Gaussova) razdioba**

- **Bernoullijeva razdioba** – binarna s.v.:

$$P(x|\mu) = \mu^x(1 - \mu)^{1-x}$$

$$\Rightarrow \mathbb{E}[X] = \mu, \text{Var}(X) = \mu(1 - \mu)$$

- **Kategorička (multinulijeva) razdioba** – viševrijednosna diskretna s.v.:


$$P(\mathbf{x}|\boldsymbol{\mu}) = \prod_{k=1}^K \mu_k^{x_k}$$

- $\mathbf{x} = (x_1, x_2, \dots, x_K)^T$ – vektor indikatorskih varijabli (**one-hot encoding**)
- $\boldsymbol{\mu} = (\mu_1, \dots, \mu_K)$ – vjerojatnosti pojedinih vrijednosti, $\sum_k \mu_k = 1, \mu_k \geq 0$

- **Normalna (Gaussova) razdioba** – kontinuirana vrijednost uz prisustvo **šuma**:

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

$$\Rightarrow \mathbb{E}[X] = \mu, \text{Var}(X) = \sigma^2$$




- **Multivarijatna (višedimenzijaska) normalna (Gaussova) razdioba**:


$$p(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{n/2}|\boldsymbol{\Sigma}|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x}-\boldsymbol{\mu})\right)$$

$$\Rightarrow \mathbb{E}[X] = \boldsymbol{\mu}, \text{Cov}(X_i, X_j) = \boldsymbol{\Sigma}_{ij}$$

- značajke su savršeno **multikolinearne** $\Leftrightarrow \boldsymbol{\Sigma}$ je singularna $\Leftrightarrow p(\mathbf{x})$ je nedefinirana
- $\Delta^2 = (\mathbf{x}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x}-\boldsymbol{\mu})$ – **kvadratna forma**
- Δ – **Mahalanobisova udaljenost** između \mathbf{x} i $\boldsymbol{\mu}$




- Kovarijacijska matrica određuje izgled Gaussove razdiobe:



4 Procjena parametara

- Raspoložemo konačnim i slučajnim (= reprezentativnim) uzorkom iz **populacije**
- Na temelju uzorka **procjenjujemo parametre** modela koji opisuje populaciju
- **Uzorak** – niz s.v. (X_1, X_2, \dots, X_N) koje su **iid** (identično i nezavisno distribuirane)
- **Statistika** – funkcija slučajnog uzorka, $\Theta = g(X_1, X_2, \dots, X_N)$
- **Procjenitelj (estimator)** – statistika koja odgovara parametru populacije θ
- **Procjena (estimacija)** – vrijednost procjenitelja za dani uzorak, $\hat{\theta} = g(x_1, x_2, \dots, x_N)$
- Procjenitelj je s.v., pa ima svoje očekivanje i varijancu



- **Pristranost (bias)** – razlika između očekivanja procjenitelja i parametra populacije:

$$b(\Theta) = \mathbb{E}[\Theta] - \theta$$

- **Nepristran procjenitelj (unbiased estimator)** $\Leftrightarrow \mathbb{E}[\Theta] = \theta \Leftrightarrow b(\Theta) = 0$

- Primjeri:

- $\hat{\mu} = \frac{1}{N} \sum_i x^{(i)}$ – nepristran procjenitelj srednje vrijednosti μ
- $\hat{\sigma}^2 = \frac{1}{N} \sum_{i=1}^N (x^{(i)} - \hat{\mu})^2$ – pristran procjenitelj varijance σ^2 (podcjenjuje!)
- $\hat{\sigma}^2 = \frac{1}{N-1} \sum_{i=1}^N (x^{(i)} - \hat{\mu})^2$ – nepristran procjenitelj varijance σ^2

- Postupci za izvođenje procjenitelja:

- **Procjenitelj najveće izglednosti** (maximum likelihood estimator, **MLE**)
- **Procjenitelj maximum a posteriori (MAP)**
- **Bayesovski procjenitelj** (bayesian estimator)

- Radit ćemo MLE i MAP