

20. Grupiranje II

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

Jan Šnajder, natuknice s predavanja, v1.1


1 Model Gaussove mješavine

- **Model Gaussove mješavine (GMM)** \Rightarrow probabilističko meko partijsko grupiranje
- Poopćenje algoritma K-sredina: umjesto $b_k^{(i)} \in \{0, 1\}$ imamo $h_k^{(i)} \in [0, 1]$
- $h_k^{(i)}$ je **odgovornost** – vjerojatnost da je primjer $\mathbf{x}^{(i)}$ generirala grupa k
- GMM je poseban slučaj **modela miješane gustoće** (*mixture model*)
- Model miješane gustoće je linearna kombinacija K **komponenti**:

$$p(\mathbf{x}) = \sum_{k=1}^K p(\mathbf{x}, y=k) = \sum_{k=1}^K P(y=k)p(\mathbf{x}|y=k) = \sum_{k=1}^K \pi_k p(\mathbf{x}|\boldsymbol{\theta}_k)$$

gdje su π_k **koeficijenti mješavine**, a $p(\mathbf{x}|\boldsymbol{\theta}_k)$ **gustoće komponenti**

- Primjer: model bivarijatne Gaussove mješavine s $K = 3$ grupe:



- Odgovornost možemo izračunati Bayesovim pravilom:

$$h_k^{(i)} = P(y=k|\mathbf{x}^{(i)}) = \frac{P(y=k)p(\mathbf{x}^{(i)}|y=k)}{\sum_j P(y=j)p(\mathbf{x}^{(i)}|y=j)} = \frac{\pi_k p(\mathbf{x}^{(i)}|\boldsymbol{\theta}_k)}{\sum_j \pi_j p(\mathbf{x}^{(i)}|\boldsymbol{\theta}_j)}$$

- Parametri modela su $\boldsymbol{\theta} = \{\pi_k, \boldsymbol{\theta}_k\}_{k=1}^K$, $\boldsymbol{\theta}_k = (\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$
- Parametre možemo (pokušati) procijeniti metodom MLE

- Log-izglednost parametara modela (tzv. **nepotpuna izglednost**):

$$\ln \mathcal{L}(\boldsymbol{\theta} | \mathcal{D}) = \ln \prod_{i=1}^N p(\mathbf{x}^{(i)}) = \ln \prod_{i=1}^N \sum_{k=1}^K \pi_k p(\mathbf{x}^{(i)} | \boldsymbol{\theta}_k) = \sum_{i=1}^N \ln \sum_{k=1}^K \pi_k p(\mathbf{x}^{(i)} | \boldsymbol{\theta}_k)$$

\Rightarrow ne faktorizira se po komponentama \Rightarrow maksimizacija nema analitičko rješenje

2 Algoritam maksimizacije očekivanja

- Proširenje modela miješane gustoće **latentnim varijablama** (varijable koje ne opažamo)
- Latentna kategorička varijabla $\mathbf{z}^{(i)}$ definira koja je grupa generirala primjer $\mathbf{x}^{(i)}$:

$$\mathbf{z}^{(i)} = (z_1^{(i)}, \dots, z_k^{(i)}, \dots, z_K^{(i)})$$

- Distribucija kategoričke varijable $\mathbf{z}^{(i)}$:

$$P(\mathbf{z}^{(i)} = k) = \prod_{k=1}^K \pi_k^{z_k^{(i)}}$$

- Zajednička gustoća varijabli \mathbf{x} i \mathbf{z} :

$$p(\mathbf{x}, \mathbf{z} | \boldsymbol{\theta}) = P(\mathbf{z})p(\mathbf{x} | \mathbf{z}, \boldsymbol{\theta}) = \prod_{k=1}^K \pi_k^{z_k} \prod_{k=1}^K p(\mathbf{x} | \boldsymbol{\theta}_k)^{z_k} = \prod_{k=1}^K \pi_k^{z_k} p(\mathbf{x} | \boldsymbol{\theta}_k)^{z_k}$$

\Rightarrow model s **latentnim varijablama** \mathbf{z}

- Log-izglednost parametara modela (tzv. **potpuna izglednost**):

$$\begin{aligned} \ln \mathcal{L}(\boldsymbol{\theta} | \mathcal{D}, \mathbf{Z}) &= \ln \prod_{i=1}^N p(\mathbf{x}^{(i)}, \mathbf{z}^{(i)} | \boldsymbol{\theta}) = \ln \prod_{i=1}^N \prod_{k=1}^K \pi_k^{z_k^{(i)}} p(\mathbf{x} | \boldsymbol{\theta}_k)^{z_k^{(i)}} \\ &= \sum_{i=1}^N \sum_{k=1}^K z_k^{(i)} (\ln \pi_k + \ln p(\mathbf{x}^{(i)} | \boldsymbol{\theta}_k)) \end{aligned}$$

\Rightarrow ako su $\mathbf{z}^{(i)}$ poznate, maksimizacija ove log-izglednosti ima analitičko rješenje

- $\mathbf{z}^{(i)}$ su nepoznate, no možemo izračunati **očekivanje** izglednosti uz fiksirane π_k i $\boldsymbol{\theta}_k$
- Može se pokazati: povećanje očekivanja od $\mathcal{L}(\boldsymbol{\theta} | \mathcal{D}, \mathbf{Z}) \Rightarrow$ povećanje $\mathcal{L}(\boldsymbol{\theta}; \mathcal{D})$
- **Algoritam maksimizacije očekivanja (EM-algoritam)**: iterativna optimizacija $\mathcal{L}(\boldsymbol{\theta}; \mathcal{D})$
- Dva koraka algoritma: E-korak (*expectation*) i M-korak (*maximization*)
- **E-korak**: Izračun očekivanja potpune izglednosti uz fiksirane parametre u iteraciji t :

$$\begin{aligned} \mathcal{Q}(\boldsymbol{\theta} | \boldsymbol{\theta}^{(t)}) &= \mathbb{E}_{\mathbf{Z} | \mathcal{D}, \boldsymbol{\theta}^{(t)}} \left[\sum_{i=1}^N \sum_{k=1}^K z_k^{(i)} (\ln \pi_k + \ln p(\mathbf{x}^{(i)} | \boldsymbol{\theta}_k)) \right] \\ &= \sum_{i=1}^N \sum_{k=1}^K \underbrace{\mathbb{E}[z_k^{(i)} | \mathcal{D}, \boldsymbol{\theta}^{(t)}]}_{= h_k^{(i)}} (\ln \pi_k + \ln p(\mathbf{x}^{(i)} | \boldsymbol{\theta}_k)) \end{aligned}$$

- **M-korak:** Izračun parametara za iteraciju $(t + 1)$ koji maksimiziraju očekivanje:

$$\nabla_{\boldsymbol{\theta}} \mathcal{Q}(\boldsymbol{\theta} | \boldsymbol{\theta}^{(t)}) = 0$$

$$\nabla_{\pi_k} \left(\sum_{i=1}^N \sum_{k=1}^K h_k^{(i)} \ln \pi_k + \lambda \left(\sum_k \pi_k - 1 \right) \right) = 0 \quad \Rightarrow \quad \pi_k^{(t+1)} = \frac{1}{N} \sum_{i=1}^N h_k^{(i)}$$

$$\nabla_{\boldsymbol{\theta}_k} \sum_{i=1}^N h_k^{(i)} \ln p(\mathbf{x}^{(i)} | \boldsymbol{\theta}_k) = 0 \quad \Rightarrow \quad \boldsymbol{\mu}_k^{(t+1)} = \frac{\sum_i h_k^{(i)} \mathbf{x}^{(i)}}{\sum_i h_k^{(i)}}$$

$$\Rightarrow \quad \boldsymbol{\Sigma}_k^{(t+1)} = \frac{\sum_i h_k^{(i)} (\mathbf{x}^{(i)} - \boldsymbol{\mu}_k^{(t+1)}) (\mathbf{x}^{(i)} - \boldsymbol{\mu}_k^{(t+1)})^\top}{\sum_i h_k^{(i)}}$$

Algoritam GMM (model GMM + EM-algoritam)

inicijaliziraj parametre $\boldsymbol{\theta} = \{\pi_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}_{k=1}^K$
ponavlja do konvergencije log-izglednosti ili parametara

E-korak:

Za svaki primjer $\mathbf{x}^{(i)} \in \mathcal{D}$ i svaku komponentu $k = 1, \dots, K$:

$$h_k^{(i)} \leftarrow \frac{p(\mathbf{x}^{(i)} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \pi_k}{\sum_{j=1}^K p(\mathbf{x}^{(i)} | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j) \pi_j}$$

M-korak:

Za svaku komponentu $k = 1, \dots, K$:

$$\boldsymbol{\mu}_k \leftarrow \frac{\sum_i h_k^{(i)} \mathbf{x}^{(i)}}{\sum_i h_k^{(i)}}, \quad \boldsymbol{\Sigma}_k \leftarrow \frac{\sum_i h_k^{(i)} (\mathbf{x}^{(i)} - \boldsymbol{\mu}_k) (\mathbf{x}^{(i)} - \boldsymbol{\mu}_k)^\top}{\sum_i h_k^{(i)}}, \quad \pi_k \leftarrow \frac{1}{N} \sum_{i=1}^N h_k^{(i)}$$


Izračunaj trenutnu vrijednost log-izglednosti

$$\ln \mathcal{L}(\boldsymbol{\theta} | \mathcal{D}) = \sum_{i=1}^N \ln \sum_{k=1}^K \pi_k p(\mathbf{x}^{(i)} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$

- EM-algoritam konvergira, ali ne nužno u globalni optimum log-izglednosti
- Akaikeov informacijski kriterij (AIC) za odabir optimalnog broja grupa:

$$K^* = \operatorname{argmin}_K (-2 \ln \mathcal{L}(K) + 2q(K))$$

- Moguća pojednostavljenja: dijeljena matrica, dijagonalna ili izotropna matrica Σ



3 Hijerarhijsko grupiranje

- Hijerarhijsko grupiranje producira **dendrogram** – stablasti prikaz hijerarhije grupa
- Provodi se na temelju mjere udaljenosti ili mjere sličnosti/različitosti
- Može biti **aglomerativno** (bottom-up) ili **divizivno** (top-down)
- **Hijerarhijsko aglomerativno grupiranje (HAC)**: iterativno stapa najbliže parove grupa
- **Povezivanje** (*linkage*) – način izračuna udaljenosti između dvije grupe:

- **Jednostruko povezivanje** (*single linkage*)

$$d_{min}(\mathcal{G}_i, \mathcal{G}_j) = \min_{\mathbf{x} \in \mathcal{G}_i, \mathbf{x}' \in \mathcal{G}_j} d(\mathbf{x}, \mathbf{x}')$$

- **Potpuno povezivanje** (*complete linkage*)

$$d_{max}(\mathcal{G}_i, \mathcal{G}_j) = \max_{\mathbf{x} \in \mathcal{G}_i, \mathbf{x}' \in \mathcal{G}_j} d(\mathbf{x}, \mathbf{x}')$$

- **Prosječno povezivanje** (*average linkage*)

$$d_{avg}(\mathcal{G}_i, \mathcal{G}_j) = \frac{1}{N_i N_j} \sum_{\mathbf{x} \in \mathcal{G}_i} \sum_{\mathbf{x}' \in \mathcal{G}_j} d(\mathbf{x}, \mathbf{x}')$$

- **Povezivanje centroida** (*centroid linkage*)

$$d_{cent}(\mathcal{G}_i, \mathcal{G}_j) = \left\| \frac{1}{N_i} \sum_{\mathbf{x} \in \mathcal{G}_i} \mathbf{x} - \frac{1}{N_j} \sum_{\mathbf{x} \in \mathcal{G}_j} \mathbf{x} \right\|$$

Algoritam hijerarhijskog aglomerativnog grupiranja (HAC)

```

1: inicijaliziraj  $K$ ,  $k \leftarrow N$ ,  $\mathcal{G}_i \leftarrow \{\mathbf{x}^{(i)}\}$  za  $i = 1, \dots, N$ 
2: ponavljaj
3:    $k \leftarrow k - 1$ 
4:    $(\mathcal{G}_i, \mathcal{G}_j) \leftarrow \underset{\mathcal{G}_a, \mathcal{G}_b}{\operatorname{argmin}} d(\mathcal{G}_a, \mathcal{G}_b)$ 
5:    $\mathcal{G}_i \leftarrow \mathcal{G}_i \cup \mathcal{G}_j$ 
6: dok je  $k > K$ 

```

- Prostorna složenost: matrica udaljenosti za $\binom{N}{2}$ parova primjera $\Rightarrow \mathcal{O}(N^2)$
- Vremenska složenost: općenito $\mathcal{O}(N^3)$, $\mathcal{O}(N^2 \log N)$ s prioritetsnom listom