



## Blatt 4

### Aufgabe 4.1

(8 Punkte)

Führen Sie den Beweis zur folgenden effizienten Auswertung von  $Q(\vec{\theta}; \vec{\theta}^{(t)})$  im EM-Algorithmus für unabhängige Beobachtungen:

$$\begin{aligned} Q(\vec{\theta}; \vec{\theta}^{(t)}) &= \sum_{i=1}^N \sum_{\vec{u} \in \mathcal{U}} \left( \alpha_{i\vec{u}_i} \left( \prod_{j=1}^N \gamma_{j\vec{u}_j}^{(t)} \right) \right) \\ &= \sum_{i=1}^N \sum_{u_i=1}^{K_i} \alpha_{iu_i} \gamma_{ju_j}^{(t)} \\ &= \sum_{i=1}^N \sum_{u=1}^{K_i} \log P_i(U_i = u, \vec{X}_i = \vec{x}_i | \vec{\theta}) P_i(U_i = u | \vec{X}_i = \vec{x}_i, \vec{\theta}^{(t)}) \end{aligned}$$

### Aufgabe 4.2

(8 Punkte)

Leiten Sie die sieben Varianten des M-Schrittes des EM-Algorithmus für univariate Gaußsche Mischmodelle her.

### Aufgabe 4.3

(8 Punkte)

Schätzen Sie die Parameter  $\mu_1$  und  $\mu_2$  für den Datensatz aus Aufgabe 3.2 mit Hilfe des EM-Algorithmus. Definieren Sie Ihr Initialisierungsverfahren und Ihr Abbruchkriterium, und plotten Sie die Log-Likelihood für jeden Iterationsschritt. Wiederholen Sie den EM-Algorithmus 100-mal, und bestimmen Sie das Maximum der erreichten Log-Likelihoods. In wie vielen der 100 EM-Läufe wurde diese maximale Log-Likelihood erreicht? Vergleichen Sie diese maximale Log-Likelihood mit der in Aufgabe 3.2 bestimmten. Vergleichen Sie die dazugehörigen Maximalstellen, d. h. die dazugehörigen Schätzwerte.

### Aufgabe 4.4

(16 Punkte)

Der Datensatz `gauss_3` wurde durch ein bivariates Gaußsches Mischmodell mit  $K = 3$  Klassen generiert, wobei in jeder Klasse die beiden Komponenten der bivariaten Gaußverteilung statistisch unabhängig sind.

- (a) Bekannt seien die Parameter  $\pi_1 = 0.5$ ,  $\mu_{21} = 0$ ,  $\sigma_{21}^2 = 1$ ,  $\mu_{32} = 1$  und  $\sigma_{31}^2 = 16$ . Schätzen Sie die restlichen Parameter  $\pi_2$ ,  $\pi_3$ ,  $\mu_{11}$ ,  $\mu_{12}$ ,  $\mu_{22}$ ,  $\mu_{31}$ ,  $\sigma_{11}^2$ ,  $\sigma_{12}^2$ ,  $\sigma_{22}^2$
-

und  $\sigma_{32}^2$  per EM-Algorithmus, und geben Sie die Schätzwerte sowie die erreichte Log-Likelihood an. Definieren Sie außerdem Ihr Initialisierungsverfahren und Ihr Abbruchkriterium.

- (b) Bekannt sei jetzt nur noch der Parameter  $\pi_1 = 0.5$ . Außerdem sei nun aber bekannt, dass  $\mu_{21} = \mu_{31}$  und  $\sigma_{11}^2 = \sigma_{21}^2 = \sigma_{32}^2$ . Schätzen Sie für diesen Fall alle Parameter außer  $\pi_1$ , und geben Sie die Schätzwerte sowie die erreichte Log-Likelihood an. Definieren Sie außerdem Ihr Initialisierungsverfahren und Ihr Abbruchkriterium.

Wiederholen Sie beide Teilaufgaben mit dem stochastischen EM-Algorithmus. Definieren Sie hierbei wiederum Ihr Initialisierungsverfahren und Ihr Abbruchkriterium. Vergleichen Sie die Parameter und dazugehörigen Log-Likelihood Werte mit denen des EM-Algorithmus. Welche Schlussfolgerungen können Sie aus diesem Vergleich ableiten?

Wiederholen Sie beide Teilaufgaben mit dem aus dem EM-Algorithmus abgeleiteten  $k$ -means Algorithmus. Definieren Sie hierbei wiederum Ihr Initialisierungsverfahren und Ihr Abbruchkriterium. Vergleichen Sie die Parameter und dazugehörigen Log-Likelihood Werte mit denen des EM-Algorithmus und denen des stochastischen EM-Algorithmus. Welche Schlussfolgerungen können Sie aus diesem Vergleich ableiten?

**Abgabetermin: 12. Juni**

---