

STRUKTURELLE MODELLE IN DER BILDVERARBEITUNG

4. ÜBUNG – LERNEN MARKOVSCHER KETTEN

Aufgabe 1. Ein Objekt kann sich in zwei Zuständen $k = 1, 2$ befinden. Die a-priori Wahrscheinlichkeiten $p(k = 1)$ und $p(k = 2)$ seien bekannt. Die bedingten Wahrscheinlichkeiten für die Merkmale $x \in \mathbb{R}^n$ sind Gaußsch verteilt:

$$p(x|k) = \frac{1}{(\sqrt{2\pi}\sigma_k)^n} \exp\left[-\frac{\|x - \mu\|^2}{2\sigma_k^2}\right].$$

Beide Verteilungen haben dasselbe Zentrum μ aber unterschiedliche Streuungen σ_k . Gegeben sei eine klassifizierte Stichprobe $L = ((x^1, k^1), (x^2, k^2) \dots (x^l, k^l))$. Seien die Streuungen σ_k bekannt. Man schätze μ mit Hilfe des Maximum-Likelihood Prinzips.

Hinweis: Betrachten Sie das Beispiel des Lernens von μ aus der Vorlesung. Verfahren Sie hier zunächst analog. Berücksichtigen Sie allerdings, dass sich die σ_k in der jetzigen Aufgabe nicht mehr kürzen lassen.

Aufgabe 2. Die Wahrscheinlichkeitsverteilung einer skalaren Größe $x \in \mathbb{R}$ ist

$$p(x) = C \cdot \exp[-\tau|x - \mu|]$$

mit reellen Parametern τ und μ .

a) Wie ergibt sich die Normierungskonstante C aus den bekannten Parametern τ und μ ?

Hinweis: Nutzen Sie $\int_{-\infty}^{\infty} p(x) dx = 1$.

b) Die Parameter τ und μ sollen nach dem Maximum-Likelihood Prinzip anhand einer Lernstichprobe $L = (x^1, x^2 \dots x^l)$ gelernt werden. Wie ergeben sich daraus die gesuchten Größen?

c) Lösen Sie diese Aufgabe für die Wahrscheinlichkeitsverteilung (mit $\tau > 0$)

$$p(x) = \begin{cases} C \cdot \exp[-\tau(x - \mu)] & \text{wenn } x \geq \mu, \\ 0 & \text{sonst.} \end{cases}$$

Hinweis: Berücksichtigen Sie, dass bei manchen Werten von μ die Wahrscheinlichkeit bestimmter Muster x^l in der Lernstichprobe $p(x^l) = 0$ ist. Somit ist die Wahrscheinlichkeit der ganzen Lernstichprobe auch $P(L) = 0$ (und folglich nicht maximal). Offensichtlich müssen solche Werte von μ ausgeschlossen werden.

Aufgabe 3. Man betrachte das Markovsche Modell für Zustandsfolgen $y = (y_1, y_2 \dots y_n)$, mit $y_i \in K$, bei dem die Parameter nicht unbedingt Wahrscheinlichkeitswerten entsprechen, d.h.

$$p(y) = \frac{1}{Z} \cdot \prod_{i=2}^n g_i(y_{i-1}, y_i) \cdot \prod_{i=1}^n q_i(y_i),$$

mit der Partition Funktion

$$Z = \sum_y \left[\prod_{i=2}^n g_i(y_{i-1}, y_i) \cdot \prod_{i=1}^n q_i(y_i) \right].$$

Für die weiteren Betrachtungen ist es günstiger, diese Verteilung (äquivalent) in exponentieller Form zu schreiben, d.h.

$$p(y) = \exp \left[\sum_{i=2}^n g_i(y_{i-1}, y_i) + \sum_{i=1}^n q_i(y_i) \right] - \ln(Z), \quad \text{mit}$$

$$Z = \sum_y \exp \left[\sum_{i=2}^n g_i(y_{i-1}, y_i) + \sum_{i=1}^n q_i(y_i) \right].$$

Die unbekannt Parameter $\Theta = (q_i(k), 1 \leq i \leq n, k \in K, g_i(k, k'), 2 \leq i \leq n, k, k' \in K)$ in dieser Schreibweise entsprechen den logarithmierten ursprünglichen Parametern. Sie sollen anhand einer gegebenen Lernstichprobe der Zustandsfolgen $L = (y^1, y^2 \dots y^l)$ nach dem Maximum-Likelihood Prinzip gelernt werden.

Geben Sie die Ableitungen der log-Likelihood Funktion nach den Parametern

$$\frac{\partial \ln p(L; \Theta)}{\partial q_i(k)} \quad \text{und} \quad \frac{\partial \ln p(L; \Theta)}{\partial g_i(k, k')}$$

an. Berücksichtigen Sie dabei, dass die Partition Funktion auch von Parametern abhängt. Schlussfolgern Sie daraus die notwendigen Bedingungen für die optimale Parameter.