

# Maschinelles Übersetzen natürlicher Sprachen

## Aufgabe 1

Wir betrachten folgendes Experiment: Ein Freund wirft insgesamt hundert mal ein Paar – möglicherweise gezinkter – Würfel. Statt der geworfenen Augenzahlen erfahren Sie jedoch nur die Summe der beiden Würfe. Es soll der EM-Algorithmus verwendet werden, um aus diesen unvollständigen Daten die wahrscheinlichsten Wurfwahrscheinlichkeiten für die beiden Würfel zu schätzen.

- a) Bestimmen Sie für dieses Problem
- die Menge der unvollständigen Daten  $X$ ,
  - die Menge der vollständigen Daten  $Y$  sowie den Analysator  $H: X \rightarrow \mathcal{P}(Y)$ ,
  - und das Wahrscheinlichkeitsmodell  $\mathcal{M} \subseteq \mathcal{M}(Y)$  auf den vollständigen Daten.
- b) Werden die Anzahlen der geworfenen Augensummen in einem Korpus  $h: X \rightarrow \mathbb{N}$  zusammengefasst, ergeben sich die folgenden Werte.

$x$	2	3	4	5	6	7	8	9	10	11	12
$h(x)$	2	3	5	9	10	12	16	20	13	7	3

Nutzen Sie, ausgehend von einer geeigneten Startverteilung, den EM-Algorithmus, um für diesen Korpus  $h$  die wahrscheinlichsten Parameter zu schätzen (Bestimmung des maximum likelihood estimators).

## Aufgabe 2

Seien  $X_1, X_2$  endliche Mengen. Gegeben  $p_1: X_1 \rightarrow [0, 1]$  und  $p_2: X_2 \rightarrow [0, 1]$ , sei die Wahrscheinlichkeitsverteilung  $p_1 \times p_2: X_1 \times X_2 \rightarrow [0, 1]$  definiert durch

$$(p_1 \times p_2)(x_1, x_2) = p_1(x_1) \cdot p_2(x_2)$$

für alle  $x_1 \in X_1$  und  $x_2 \in X_2$ .

Wir betrachten das Wahrscheinlichkeitsmodell  $\mathcal{M} = \{p_1 \times p_2 \mid p_1 \in \mathcal{M}(X_1), p_2 \in \mathcal{M}(X_2)\}$ . Es sei ein beliebiger Korpus  $h: X_1 \times X_2 \rightarrow \mathbb{R}_{\geq 0}$  gegeben. Zeigen Sie, dass

$$\text{mle}(h, \mathcal{M}) = \text{rfe}(h_1) \cdot \text{rfe}(h_2)$$

gilt, wobei die marginalisierten Korpora  $h_1: X_1 \rightarrow \mathbb{R}_{\geq 0}$  und  $h_2: X_2 \rightarrow \mathbb{R}_{\geq 0}$  für alle  $x_1 \in X_1, x_2 \in X_2$  definiert sind durch

$$h_1(x_1) = \sum_{y \in X_2} h(x_1, y) \quad \text{und} \quad h_2(x_2) = \sum_{y \in X_1} h(y, x_2).$$