

# Maschinelles Übersetzen natürlicher Sprachen

---

## Aufgabe 1

1. Die Wahrscheinlichkeit einer Wortfolge  $w_1 \cdots w_n$  kann auf die folgenden beiden Weisen dekomponiert werden (beachten Sie, dass wir in der hier verwendeten Kurzschreibweise die benutzten Zufallsvariablen unterschlagen):

$$\begin{aligned} P(w_1 \cdots w_n) &= P(w_1) \cdot P(w_2 | w_1) \cdot P(w_3 | w_1, w_2) \\ &\quad \cdots P(w_n | w_1, \dots, w_{n-1}) \cdot P(n | w_1, \dots, w_n) \\ &= P(w_n) \cdot P(w_{n-1} | w_n) \cdot P(w_{n-2} | w_{n-1}, w_n) \\ &\quad \cdots P(w_1 | w_2, \dots, w_n) \cdot P(n | w_1, \dots, w_n). \end{aligned}$$

Heißt das also, dass  $P(w_1 \cdots w_n) = P(w_n \cdots w_1)$  gilt?

2. Sei  $b$  eine Bigramm-Wahrscheinlichkeitsverteilung über einem Alphabet  $X$  mit dem Stoppsymbol  $\#$  (natürlich nehmen wir an, dass  $\# \notin X$ ) und sei  $w_1 \cdots w_n \in X^*$ .

Ist die Gleichung

$$b(w_1 | \#) \cdot \left( \prod_{i \in \{2, \dots, n\}} b(w_i | w_{i-1}) \right) \cdot b(\# | w_n) = b(w_n | \#) \cdot \left( \prod_{i \in \{n-1, \dots, 1\}} b(w_i | w_{i+1}) \right) \cdot b(\# | w_1)$$

allgemeingültig?

## Aufgabe 2

1. Erweitern Sie das Bigramm-Modell aus der Vorlesung zu einem Trigramm-Modell, also einem Sprachmodell mit der Annahme, dass die Wahrscheinlichkeit eines jeden Worts von den *zwei* Worten vor ihm abhängt.
2. Definieren Sie ein allgemeines  $n$ -gramm-Modell!

## Aufgabe 3

Gegeben seien  $m, n \in \mathbb{N}$  und eine Abbildung  $f: [m] \times [n] \rightarrow \mathbb{R}$ , dabei sei  $[n] = \{1, \dots, n\}$  für jedes  $n \in \mathbb{N}$ . Zeigen Sie die Gültigkeit der Gleichung

$$\sum_{a \in [n]^{[m]}} \prod_{i \in [m]} f(i, a(i)) = \prod_{i \in [m]} \sum_{j \in [n]} f(i, j)$$

und setzen Sie sie in Bezug mit dem IBM-Modell 1.

Zur Erinnerung:  $A^B$  bezeichnet die Menge aller totalen Funktionen von der Menge  $B$  in die Menge  $A$ .

#### Aufgabe 4

Gegeben sei das folgende Wörterbuch  $t$ .

$t(f   e)$	$f$			
	kra	ban	las	gha
du	0.2	0.4	0.4	0
e su	0	0.1	0.8	0.1
ur	0.3	0.4	0.3	0
fur	0.4	0.3	0.1	0.2

1. Zusätzlich dazu betrachten wir das Längenmodell  $\varepsilon$ , wobei

$$\varepsilon(m | l) = \begin{cases} 0.5 & \text{falls } m = l, \\ 0.25 & \text{falls } |m - l| = 1, \\ 0 & \text{sonst} \end{cases}$$

für alle  $n, m \in \mathbb{N}^+$ .

Bestimmen Sie, für alle  $i \in \{1, 2, 3\}$ , mit dem IBM-Modell 1 die Übersetzungswahrscheinlichkeiten  $P(f_i | e_i)$ . Dabei seien

- $f_1 = \text{kra las gha}, e_1 = \text{du su ur}$ ,
- $f_2 = \text{kra las gha}, e_2 = \text{du su}$
- $f_3 = \text{gha gha}, e_3 = \text{su du su}$ .

2. Nun betrachten wir ein anderes Längenmodell  $\varepsilon'$ . Für dieses gelte

$$\varepsilon'(m | l) = 2^{-m},$$

wieder für alle  $n, m \in \mathbb{N}^+$ .

Bestimmen Sie  $\arg \max_f P(f | e_i)$ ,  $i \in \{1, 2, 3\}$ , für

- $e_1 = \text{du}$ ,
- $e_2 = \text{du su ur}$ ,
- $e_3 = \text{fur du fur su fur}$ .

Wie verändern sich die besten Übersetzungen, wenn wir stattdessen das Längenmodell  $\varepsilon''$  mit

$$\varepsilon''(m | l) = \begin{cases} 1 & \text{falls } l = m \\ 0 & \text{sonst} \end{cases}$$

für alle  $n, m \in \mathbb{N}^+$ , verwenden?