

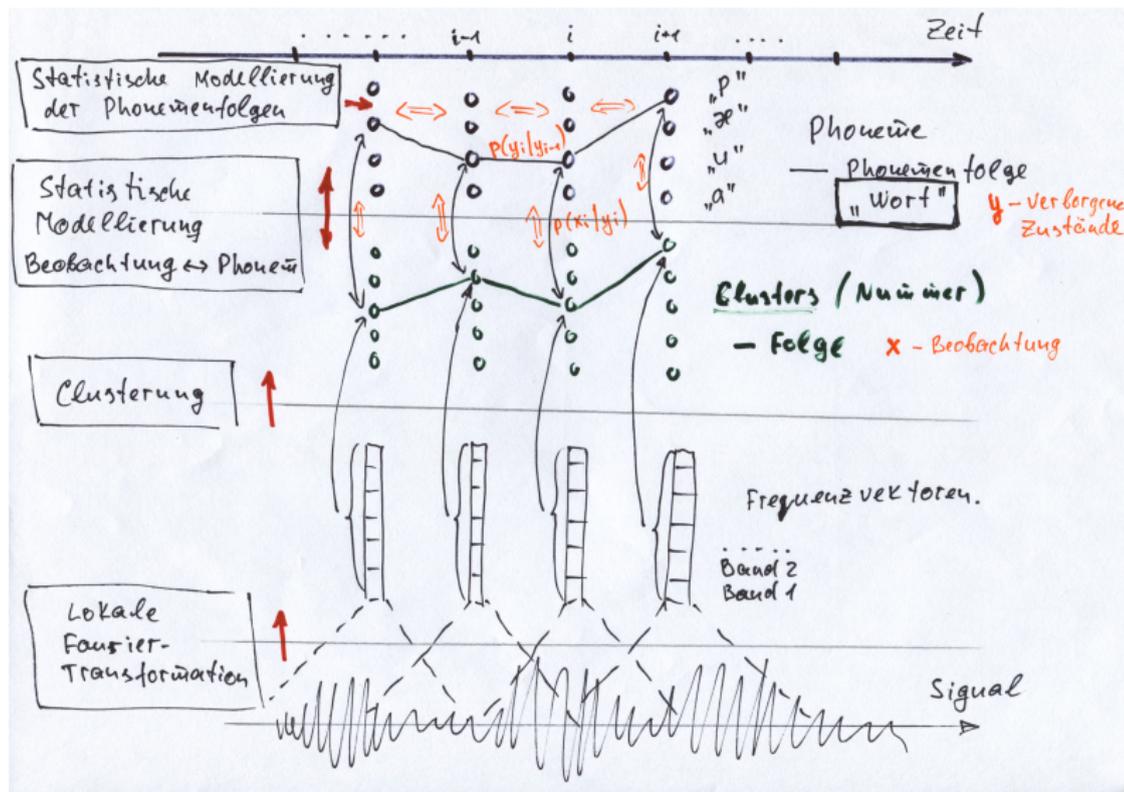
Strukturelle Modelle in der Bildverarbeitung

Markovsche Ketten I

D. Schlesinger – TUD/INF/KI/IS

- Anwendung: Sprachverarbeitung
- Wahrscheinlichkeitsmodell
- Unterschiedliche Parametrisierungen
- Berechnung der Partition Funktion

Anwendung: Sprachverarbeitung



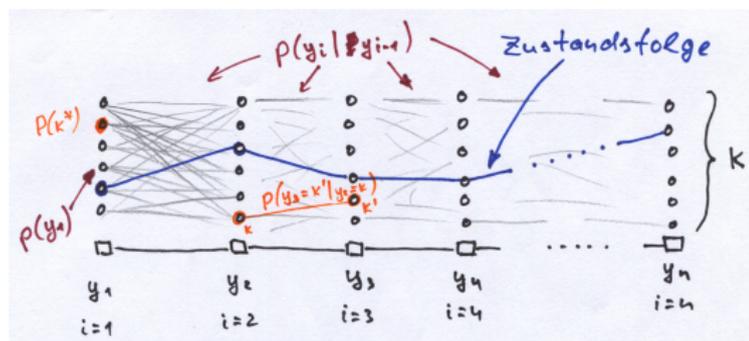
Signal \Rightarrow Lokale Fouriertransformation \Rightarrow Spektralvektoren
Eine Koordinate entspricht einem Frequenzbereich

Die Menge aller Frequenzvektoren ist (im Voraus) auf Clusters aufgeteilt
Frequenzvektoren (Kontinuierlich) werden durch Clusternummern (diskret) ersetzt
So entsteht **Beobachtung**

Die „Interpretation“ des Signals ist eine Phonemenfolge – **Zustandsfolge**

Es gibt einen statistischen Zusammenhang zwischen Beobachtungen und Phonemenfolgen
(Wahrscheinlichkeit der Beobachtung unter der Bedingung einer Phonemenfolge)

Es gibt ein statistisches Modell für Phonemenfolgen – **Markovsche Kette**



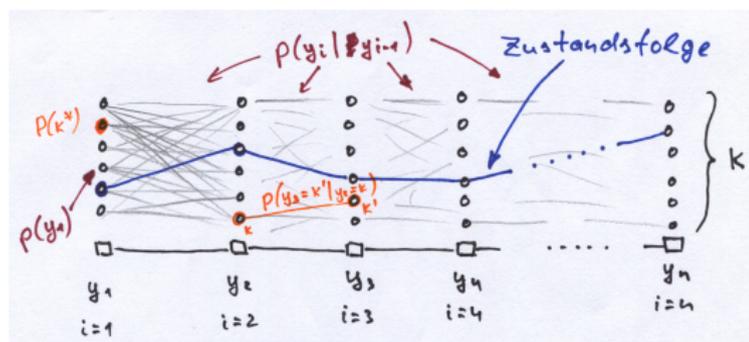
Sei $I = \{1, 2, \dots, n\}$ die Menge der Zeitpunkte

Für jeden Zeitpunkt $i \in I$ gibt es eine **statistische Variable** y_i , die die Werte aus einer endlichen diskreten Menge K (**Zustandsmenge**, Labelmenge, Phonemenmenge etc.) annehmen kann, d.h. $y_i \in K$

$y = (y_1, y_2, \dots, y_n)$ mit $y_i \in K$ ist eine **Zustandsfolge**

Die Menge aller Zustandsfolgen $\mathcal{Y} = K^n$ ist die Menge der elementaren Ereignisse

$p(y) = p(y_1, y_2, \dots, y_n)$ ist die Wahrscheinlichkeit dafür



Zunächst allgemein: $p(y_1, y_2, \dots, y_n) = p(y_1, y_2, \dots, y_{n-1})p(y_n | y_1, y_2, \dots, y_{n-1})$

Markovsche Eigenschaft (etwas vereinfacht): $p(y_n | y_1, y_2, \dots, y_{n-1}) = p(y_n | y_{n-1})$

Somit gilt:

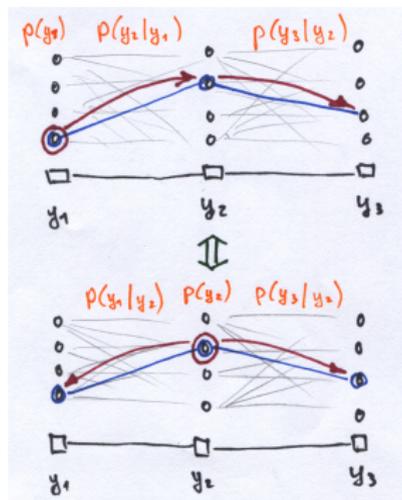
$$p(y) = p(y_1) \cdot \prod_{i=2}^n p(y_i | y_{i-1})$$

Die Parameter des Modells sind:

- Die Wahrscheinlichkeitsverteilung $p(y_1)$ der Zustände im ersten Zeitpunkt (Vektor aus $|K|$ Elementen)
- Die Übergangswahrscheinlichkeiten $p(y_i | y_{i-1})$ für alle Zeitpunkte $i = 2 \dots n$ ($|K| \times |K|$ Matrizen)

Andere Parametrisierungen

Ein Beispiel:



$$\begin{aligned} p(y) &= p(y_1, y_2, y_3) = \\ &= p(y_1)p(y_2|y_1)p(y_3|y_2) = \\ &= p(y_1) \frac{p(y_1|y_2)p(y_2)}{p(y_1)} p(y_3|y_2) = \\ &= p(y_1|y_2)p(y_2)p(y_3|y_2) \end{aligned}$$

Etwas allgemeiner:

$$p(y) = p(y_1) \cdot \prod_{i=2}^n p(y_i|y_{i-1}) = \prod_{i=2}^{i^*} p(y_{i-1}|y_i) \cdot p(y_{i^*}) \cdot \prod_{i=i^*+1}^n p(y_i|y_{i-1})$$

⇒ der „Anfang“ ist in der Mitte.

Noch anders:

$$p(y) = p(y_1) \cdot \prod_{i=2}^n p(y_i | y_{i-1}) = p(y_1) \cdot \prod_{i=2}^n \frac{p(y_i, y_{i-1})}{p(y_{i-1})} = \prod_{i=2}^n p(y_i, y_{i-1}) \cdot \prod_{i=2}^{n-1} p(y_i)^{-1}$$

⇒ Es gibt kein „Anfang“ und „Ende“ – die Parametrisierung ist symmetrisch.

Und noch etwas anders:

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

mit der **Partition Funktion**:

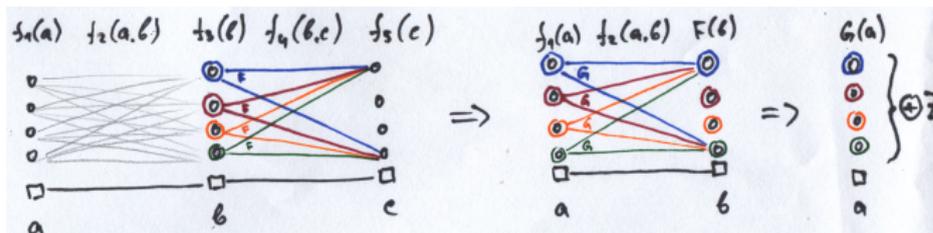
$$Z = \sum_{y \in \mathcal{Y}} \left[\prod_{i=1}^n q_i(y_i) \cdot \prod_{i=2}^n g_i(y_{i-1}, y_i) \right]$$

$q_i : K \rightarrow \mathbb{R}_+$ und $g_i : K \times K \rightarrow \mathbb{R}_+$ sind Parameter

– Funktionen, die keine Wahrscheinlichkeiten (explizit) repräsentieren

Berechnung der Partition Funktion

Beispiel: $f(a, b, c) = f_1(a)f_2(a, b)f_3(b)f_4(b, c)f_5(c)$



$$\begin{aligned}
 Z &= \sum_{abc} f(a, b, c) = \sum_a \sum_b \sum_c [f_1(a)f_2(a, b)f_3(b)f_4(b, c)f_5(c)] = \\
 &= \sum_a f_1(a) \cdot \left[\sum_b f_2(a, b)f_3(b) \cdot \left[\sum_c f_4(b, c)f_5(c) \right] \right] = \\
 &\quad \left| \text{bezeichne } F(b) = f_3(b) \sum_c f_4(b, c)f_5(c) \right| \\
 &= \sum_a f_1(a) \cdot \left[\sum_b f_2(a, b)F(b) \right] = \\
 &\quad \left| \text{bezeichne } G(a) = f_1(a) \sum_b f_2(a, b)F(b) \right| = \sum_a G(a)
 \end{aligned}$$

$$\begin{aligned}
 Z &= \sum_{y \in \mathcal{Y}} \left[\prod_{i=1}^n q_i(y_i) \cdot \prod_{i=2}^n g_i(y_{i-1}, y_i) \right] = \\
 &= \sum_{y_n \in K} \sum_{y_{n-1} \in K} \dots \sum_{y_2 \in K} \sum_{y_1 \in K} \left[\prod_{i=1}^n q_i(y_i) \cdot \prod_{i=2}^n g_i(y_{i-1}, y_i) \right] = \\
 &= \sum_{y_n} q_n(y_n) \sum_{y_{n-1}} g_n(y_{n-1}, y_n) q_{n-1}(y_{n-1}) \dots \\
 &\quad \dots \sum_{y_2} g_3(y_2, y_3) q_2(y_2) \sum_{y_1} g_2(y_1, y_2) q_1(y_1) = \\
 &= \sum_{y_n} q_n(y_n) \sum_{y_{n-1}} g_n(y_{n-1}, y_n) q_{n-1}(y_{n-1}) \dots \sum_{y_2} g_3(y_2, y_3) F_2(y_2) = \\
 &\quad \left| \text{mit } F_2(y_2) = q_2(y_2) \sum_{y_1} g_2(y_1, y_2) q_1(y_1) \right|
 \end{aligned}$$

usw.

Algorithmus:

for ($k = 1 \dots K$) $F_1(k) = q_1(k)$

for ($i = 2 \dots n$)

for ($k = 1 \dots K$)

$F_i(k) = 0$

for ($k' = 1 \dots K$)

$F_i(k) = F_i(k) + F_{i-1}(k')g_i(k', k)$

$F_i(k) = F_i(k) \cdot q_i(k)$

$Z = \sum_k F_n(k)$

Dynamische Programmierung im $(\mathbb{R}, +, \times)$ -Semiring (Matrix-Multiplikation)

Funktionen $F_i(k)$ sind Bellmannsche Funktionen

– repräsentieren (wie bei der normalen Dynamischen Optimierung) partielle Lösungen.

Zeitkomplexität – $O(nK^2)$

- HMM (Hidden Markov Models)
- Erkennung stochastisches Automaten
- Wahrscheinlichste Folge
- Bayessche Entscheidungstheorie, Folge wahrscheinlichster Zustände
- Lernen nach dem Maximum-Likelihood (überwacht und unüberwacht)
- Bäume, Chou Aufgabe
- Diskriminatives Lernen