

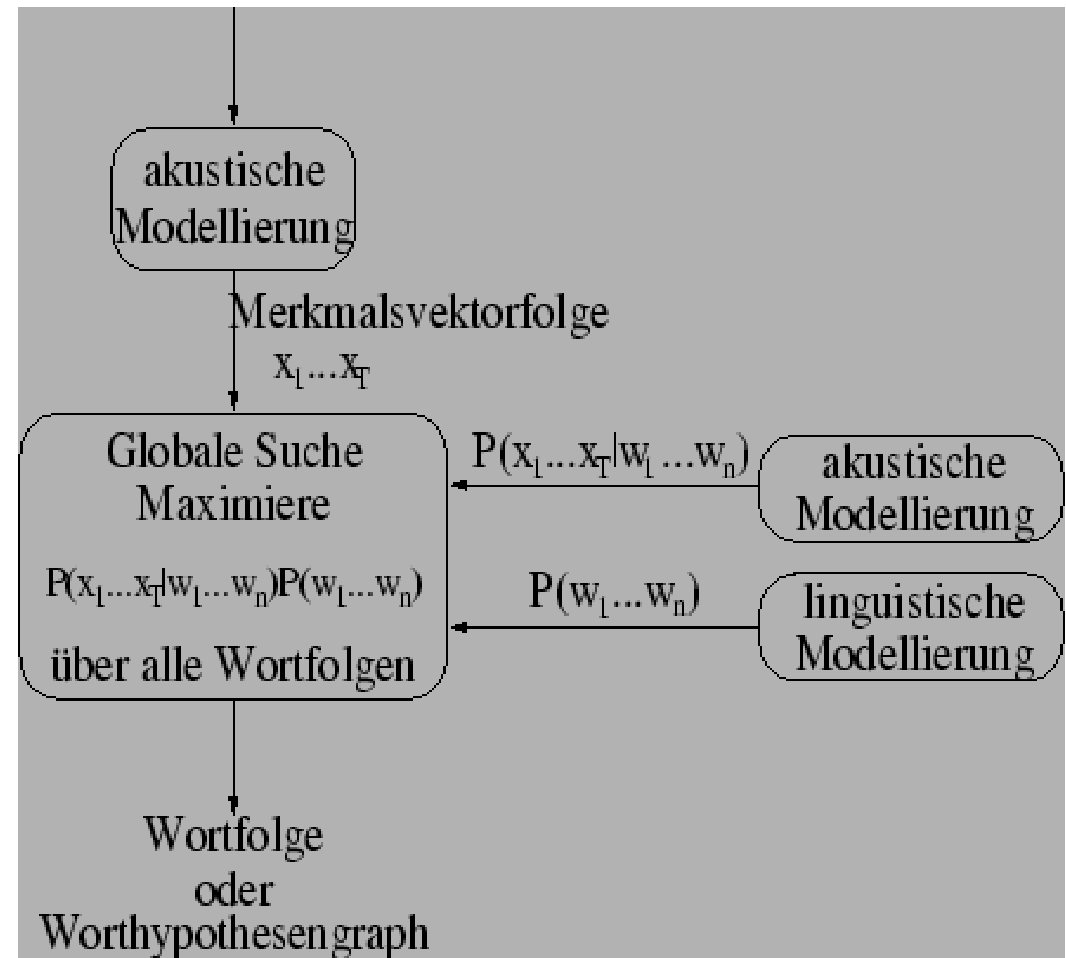
Einführung in die Computerlinguistik

Spracherkennung und Hidden Markov Modelle

Dozentin: Wiebke Petersen

WS 2004/2005

Spracherkennung




- die klassenbedingte Verteilung $P(x_1^T | w_1^N)$

Dies ist die Wahrscheinlichkeit, die Vektoren x_1^T zu beobachten, gegeben die Wortfolge w_1^N . Dies wird als akustisches Modell bezeichnet.


- die a-priori-Wahrscheinlichkeit einer Wortfolge $P(w_1^N)$.

Dies ist die Wahrscheinlichkeit, mit der die Wortfolge w_1^N auftreten kann. Sie ist unabhängig von den aktuell gemachten Beobachtungen. Dies wird linguistisches Modell bzw. Sprachmodell (LM) genannt.

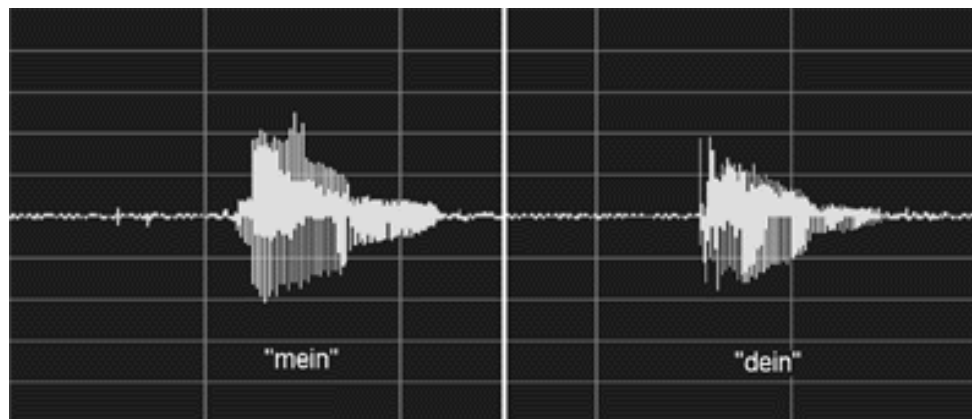
Merkmalsextraktion




Frequenzdiagramme (Beispiele)



Die Abbildung zeigt den Unterschied der Frequenzdiagramme für den kontinuierlich (1) und den diskret (2) gesprochenen Satz "Die Sonne lacht".



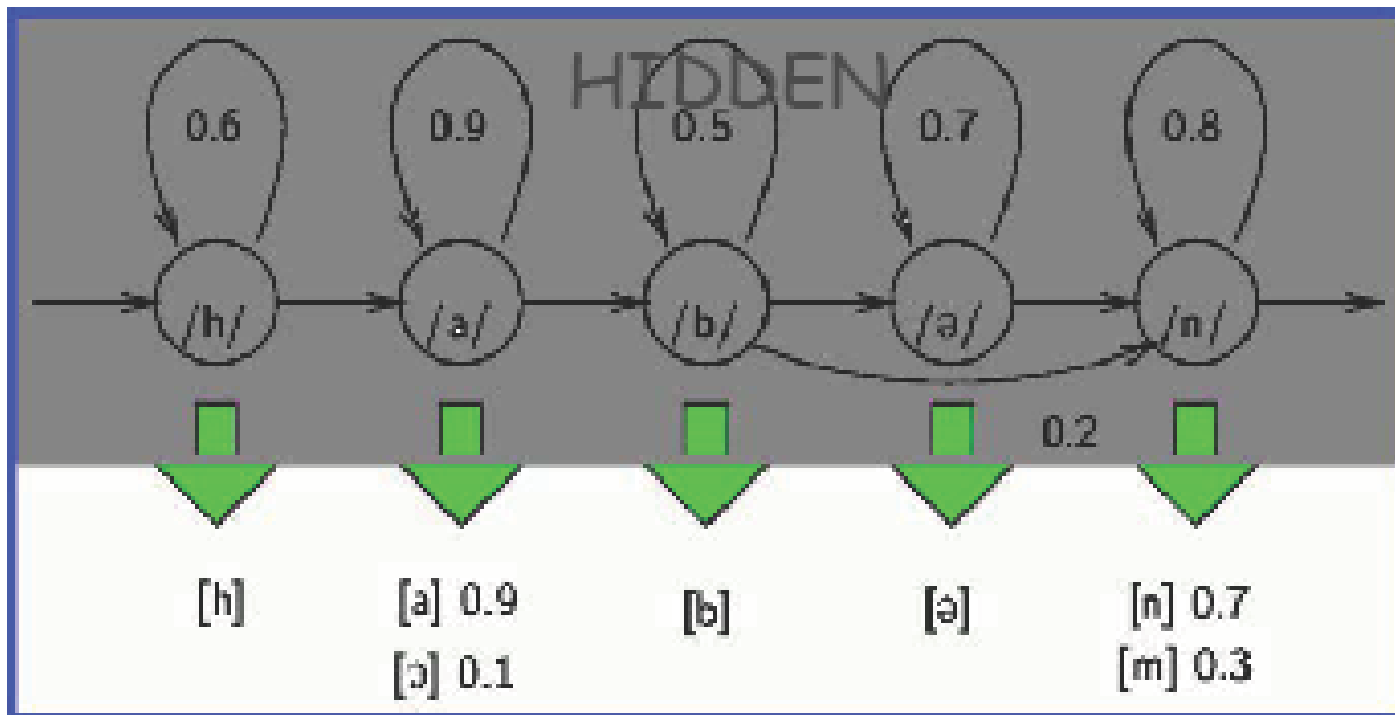
Frequenzdiagramme (Segmentierungsproblem)





Hidden Markov Modell HMM für 'haben'

Der Beobachter sieht beim HMM von außen nur die Folge der ausgegebenen Symbole. Die Folge der Zustände bleibt ihm verborgen.



Markov-Kette

Definition 3

Eine **Markov-Kette** ist ein spezieller stochastischer Prozess,
bei dem zu jedem Zeitpunkt
die Wahrscheinlichkeiten aller zukünftigen Zustände
nur vom momentanen Zustand abhängen
(= **Markov-Eigenschaft**)

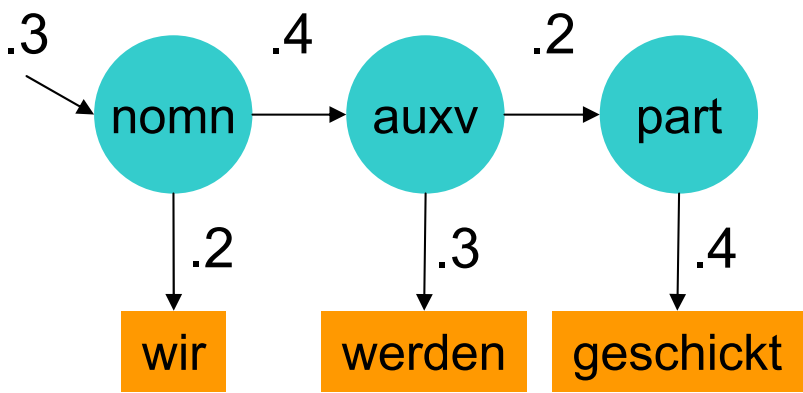
d.h. es gilt:

$$P(X_{t+1} = x_{t+1} \mid X_1 = x_1, X_2 = x_2, \dots, X_t = x_t) = \\ P(X_{t+1} = x_{t+1} \mid X_t = x_t)$$

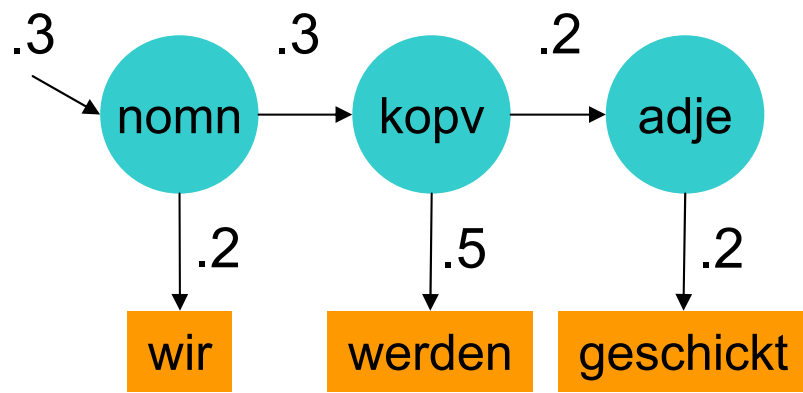
Brants, 1999: 30

Hidden Markov-Modell: Beispiel

- in einem Text lassen sich nur die **Ausgaben** (= produzierte Wörter) beobachten (visible)
- die Sequenz von **Zuständen** (= Wortarten), die die Wörter ausgeben, (Satzmuster) lässt sich nicht beobachten (hidden)
- mehrere Sequenzen können dieselbe Ausgabe erzeugen:



$$.3 \times .2 \times .4 \times .3 \times .2 \times .4 = 0.000576$$



$$.3 \times .2 \times .3 \times .5 \times .2 \times .2 = 0.000360$$

Ein Hidden Markov-Modell

	Übergangsmatrix					Emissionsmatrix				Startwahrscheinlichkeit
X_t	X_{t+1}					O_t				π
	Adje	AuxV	KopV	Nomn	Part	geschickt	werden	wir	...	
Adje	.2	.1	.1	.4	.2	.2	0	0	.8	.3
AuxV	.2	.3	.1	.2	.2	0	.3	0	.7	.2
KopV	.2	.2	.1	.4	.1	0	.5	0	.5	.1
Nomn	.1	.4	.3	.1	.1	0	0	.2	.8	.3
Part	.3	.1	.2	.1	.3	.4	0	0	.6	.1

Hidden Markov-Modell: Gewinnung der Daten – Übersicht

- Annotation eines Corpus
- Auszählung der Sequenzen
- Umrechnung der Häufigkeiten in prozentuale Anteile

Hidden Markov-Modell: Gewinnung der Daten (1)

- Annotation eines Corpus
- Auszählung der Sequenzen
- Umrechnung der Häufigkeiten in prozentuale Anteile

<i>Wir</i>	<i>werden</i>	<i>geschickt</i>	.	<i>Wir</i>	<i>werden</i>	<i>geschickt</i>
nomn	auxv	part	Ω	nomn	kopv	adje	Ω

Hidden Markov-Modell: Gewinnung der Daten (2)

- Annotation eines Corpus
- Auszählung der Sequenzen
- Umrechnung der Häufigkeiten in prozentuale Anteile

	Adje	AuxV	KopV	Nomn	Part	Ω	geschickt	werden	wir	.
Adje	-	-	-	-	-	1	1	-	-	-
AuxV	-	-	-	-	1	-	-	1	-	-
KopV	1	-	-	-	-	-	1	-	-	-
Nomn	-	1	1	-	-	-	-	-	2	-
Part	-	-	-	-	-	1	-	-	-	-
Ω	-	-	1	-	-	-	-	-	-	2

Hidden Markov-Modell: Gewinnung der Daten (3)

- Annotation eines Corpus
- Auszählung der Sequenzen
- Umrechnung der Häufigkeiten in prozentuale Anteile

	Adje	AuxV	KopV	Nomn	Part	Ω	geschickt	werden	wir	.
Adje	-	-	-	-	-	1.0	1.0	-	-	-
AuxV	-	-	-	-	1.0	-	-	1.0	-	-
KopV	1.0	-	-	-	-	-	1.0	-	-	-
Nomn	-	0.5	0.5	-	-	-	-	-	1.0	-
Part	-	-	-	-	-	1.0	-	-	-	-
Ω	-	-	1.0	-	-	-	-	-	-	1.0

Drei grundlegende Aufgaben, die mit HMMs bearbeitet werden

1. Dekodierung: Wahrscheinlichkeit einer Beobachtung finden
 - brute force
 - Forward-Algorithmus / Backward-Algorithmus
2. Beste Pfad-Sequenz finden
 - brute force
 - Viterbi-Algorithmus
3. Training: Aufbau des besten Modells aus Trainingsdaten

A1: Wahrscheinlichkeit einer Beobachtung finden

gegeben eine Sequenz von Beobachtungen $O = (o_1, \dots, o_T)$
 $O = (\text{wir}, \text{werden}, \text{geschickt})$

ein Modell $\mu = (A, B, \Pi)$

	Adje	AuxV	KopV	Nomn	Part	g'schickt	werden	wir	..	π
Adje	.2	.1	.1	.4	.2	.2	0	0	.8	.3
AuxV	.2	.3	.1	.2	.2	0	.3	0	.7	.2
KopV	.2	.2	.1	.4	.1	0	.5	0	.5	.1
Nomn	.1	.4	.3	.1	.1	0	0	.2	.8	.3
Part	.3	.1	.2	.1	.3	.4	0	0	.6	.1

gesucht die Wahrscheinlichkeit $P(O | \mu)$

$P(\text{wir}, \text{werden}, \text{geschickt} | \mu)$

A1: Wahrscheinlichkeit einer Beobachtung finden

Lösungsweg 1: brute force

Für alle möglichen Zustandsfolgen

- Berechnung der Wahrscheinlichkeit der Beobachtungen
- Summierung der Wahrscheinlichkeiten

$$\begin{aligned} P(O | \mu) &= \sum_X P(O | X, \mu) P(X | \mu) \\ &= \sum_{X_1 \dots X_{t+1}} \pi_{X_1} \prod_{t=1}^{T-1} a_{X_t X_{t+1}} b_{X_t X_{t+1}} o_t \end{aligned}$$

↑ state transition ↑ symbol emission

A1: Wahrscheinlichkeit einer Beobachtung finden

Lösungsweg 1: brute force: Beispiel

$$P(O | \mu) = \sum_{X_1 \dots X_{t+1}} \pi_{X_1} \prod_{t=1}^{T-1} a_{X_t X_{t+1}} b_{X_t X_{t+1} o_t}$$

Beispiel für
state emission HMM

$$\begin{aligned}
 & P(\text{wir, werden, geschickt} | \text{Adje Adje Adje}, \mu) && = 0.0 \\
 + & P(\text{wir, werden, geschickt} | \text{Adje Adje AuxV}, \mu) \\
 + & \dots \\
 + & P(\text{wir, werden, geschickt} | \text{Nomn AuxV Part}, \mu) && \color{green}.3 \times \color{orange}.2 \times \color{cyan}.4 \times \color{orange}.3 \times \color{cyan}.2 \times \color{orange}.4 = 0.000576 \\
 + & \dots \\
 + & P(\text{wir, werden, geschickt} | \text{Nomn KopV Adje}, \mu) && \color{green}.3 \times \color{orange}.2 \times \color{cyan}.3 \times \color{orange}.5 \times \color{cyan}.2 \times \color{orange}.2 = 0.000360 \\
 + & \dots \\
 + & P(\text{wir, werden, geschickt} | \text{Part Part Part}, \mu) && = 0.0 \\
 \hline
 = & \dots && = 0.000936
 \end{aligned}$$

HMM [Aufgabe]: Beste Pfadsequenz finden

gegeben eine Sequenz von Beobachtungen $O = (o_1, \dots, o_T)$
 $O = (\text{wir}, \text{werden}, \text{geschickt})$

ein Modell $\mu = (A, B, \Pi)$

	Adje	AuxV	KopV	Nomn	Part	g'schickt	werden	wir	..	π
Adje	.2	.1	.1	.4	.2	.2	0	0	.8	.3
AuxV	.2	.3	.1	.2	.2	0	.3	0	.7	.2
KopV	.2	.2	.1	.4	.1	0	.5	0	.5	.1
Nomn	.1	.4	.3	.1	.1	0	0	.2	.8	.3
Part	.3	.1	.2	.1	.3	.4	0	0	.6	.1

gesucht die wahrscheinlichste Pfadsequenz

$$P(\text{wir}, \text{werden}, \text{geschickt} \mid \mu) \quad \arg_x \max P(O \mid \mu)$$

HMM [Aufgabe]: Beste Pfadsequenz finden

Modellvariante:

mit Startsymbol

statt (mit Tabelle der Startwahrscheinlichkeiten)

	Adje	AuxV	KopV	Nomn	Part	Ω
Adje	.2	.1	.1	.4	.2	0
AuxV	.2	.3	.1	.2	.2	0
KopV	.2	.2	.1	.4	.1	0
Nomn	.1	.4	.3	.1	.1	0
Part	.3	.1	.2	.1	.3	0
Ω	.3	.2	.1	.3	.1	0

g'schickt	werden	wir
.2	0	0	.8	0
0	.3	0	.7	0
0	.5	0	.5	0
0	0	.2	.8	0
.4	0	0	.6	0
0	0	0	0	1

Ineffiziente Lösung

1	$\Omega \rightarrow$	<i>wir</i> Adje	\rightarrow	<i>werden</i> Adje	\rightarrow	<i>geschickt</i> Adje
2						<i>geschickt</i> AuxV
3						<i>geschickt</i> KopV
4						<i>geschickt</i> Nom
5						<i>geschickt</i> Part
6				<i>werden</i> AuxV	\rightarrow	<i>geschickt</i> Adje
7						<i>geschickt</i> AuxV
..						...
..	
85		<i>wir</i> Nomn	\rightarrow	<i>werden</i> AuxV	\rightarrow	<i>geschickt</i> Part
86		<i>wir</i> Nomn	\rightarrow	<i>werden</i> KopV	\rightarrow	<i>geschickt</i> Adje
..				...		
125		<i>wir</i> Part	\rightarrow	<i>werden</i> Part	\rightarrow	<i>geschickt</i> Part

Für 3 Beobachtungen und 5 Kategorien 5^3 Schritte

Beispiel

ineffiziente Suche der besten Lösung

$$P(\text{Adje Adje Adje} \mid \text{wir, werden, geschickt}, \mu) = 0.0$$

$$P(\text{Adje Adje AuxV} \mid \text{wir, werden, geschickt}, \mu)$$

...

$$P(\text{Nomn AuxV Part} \mid \text{wir, werden, geschickt}, \mu) = .3 \times .2 \times .4 \times .3 \times .2 \times .4 = 0.000576$$

...

$$P(\text{Nomn KopV Adje} \mid \text{wir, werden, geschickt}, \mu) = .3 \times .2 \times .3 \times .5 \times .2 \times .2 = 0.000360$$

...

$$P(\text{Part Part Part} \mid \text{wir, werden, geschickt}, \mu) = 0.0$$


Viterbi-Lösung

- Kompakte Darstellung der Pfade als Gitter (Trellis)
- Wiederverwendung partieller Ergebnisse statt Neuberechnung
- Speichert für jeden Zeitpunkt t
 - die Wahrscheinlichkeit des wahrscheinlichsten Pfades, der zu einem Knoten führt
 - den Vorgängerknoten auf diesem Pfad



11.05.2002

Daten 1: Wahrscheinlichkeit des wahrscheinlichsten Pfades



wir|Nomn

Knoten

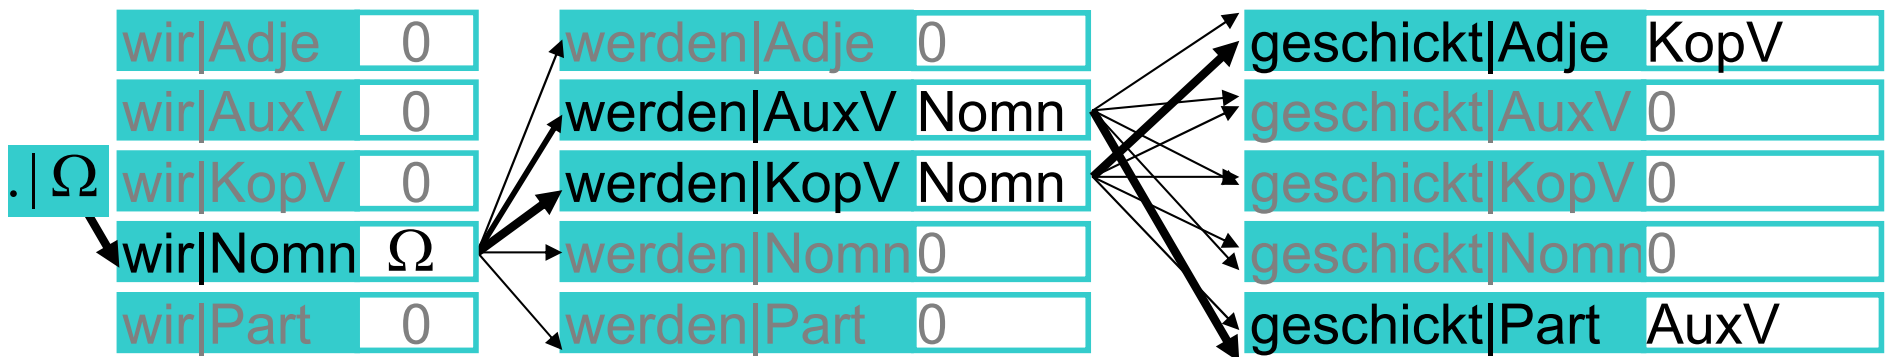
>0

Wahrscheinlichkeit des wahrscheinlichsten Pfades

0

unwahrscheinlicher Pfad

Daten 2: Vorgängerknoten auf wahrscheinlichstem Pfad



wir|Nomn

Knoten



Ω

Vorgänger-Knoten auf wahrscheinlichstem Pfad

0

Vorgänger-Knoten auf wahrscheinlichstem Pfad bei $P(X_i) = 0$ (= unwahrscheinlicher Pfad)

Daten 1 und 2: Übersicht



11.05.2002

12

Tracing (1): Initialisierung

Setzen der Startknoten für Verfolgung

- Wahrscheinlichkeit der wahrscheinlichsten Pfade
- Vorgängerknoten auf den wahrscheinlichsten Pfaden

.|Ω

.|Ω

Tracing (2): 1. Iteration

	wir Adje	0
	wir AuxV	0
. Ω	wir KopV	0
↙	wir Nomn	0.06
	wir Part	0

Funktion δ

Berechnung der Wahrscheinlichkeit des wahrscheinlichsten Pfades



	wir Adje	0
	wir AuxV	0
. Ω	wir KopV	0
↙	wir Nomn	Ω
	wir Part	0

Funktion ψ

Ermittlung des Vorgängerknotens auf dem wahrscheinlichsten Pfad

11.05.2002

Tracing (3): 2. Iteration



Tracing (4): 3. Iteration



Tracing (5): Terminierung und Pfadausgabe

