

# Akustisch-phonetische Wortmodellierung

Franz Pernkopf

Institute of Communications and Wave Propagation

University of Technology Graz

Inffeldgasse 16c , 8010 Graz, Austria

Tel: +43 316 873 4431

E-Mail: [pernkopf@inw.tugraz.at](mailto:pernkopf@inw.tugraz.at)

## Bayes-Regel

$$\mathbf{w}^* = \operatorname{argmax}_{\mathbf{w} \in \mathcal{W}^*} P(\mathbf{w} | \mathbf{X})$$

mit den *a posteriori* Wahrscheinlichkeiten

$$P(\mathbf{w} | \mathbf{X}) = \frac{\overbrace{P(\mathbf{X} | \mathbf{w})}^{\text{ASM}} \cdot \overbrace{P(\mathbf{w})}^{\text{LSM}}}{P(\mathbf{X})}$$

GEGEBEN:

- Eine Wortfolge  $\mathbf{w} = w_1 \dots w_n$

GESUCHT:

- Ein Markovmodell  $\lambda(\mathbf{w})$  mit  $P(\mathbf{X} | \lambda(\mathbf{w})) \approx P(\mathbf{X} | \mathbf{w})$

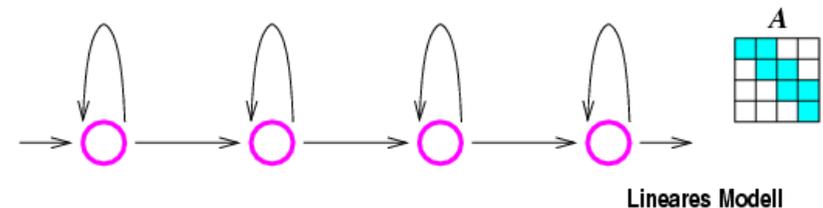
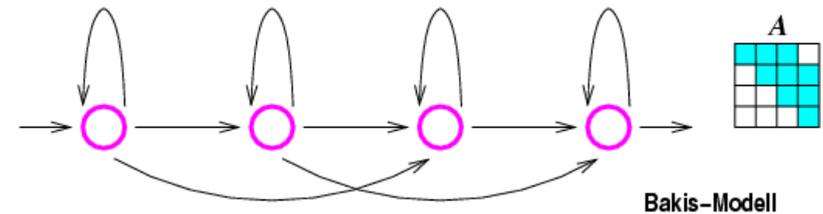
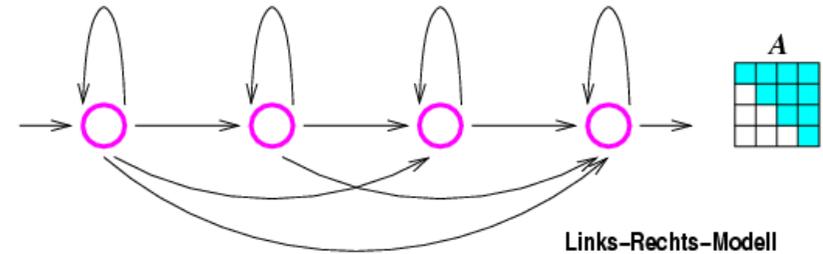
Praktisch gibt es eine unbeschränkte Anzahl von Wortfolgen =>  
Sequentielle Verkettung von Wortmodellen

$$\lambda(\mathbf{w}) = \lambda(w_1) \circ \lambda(w_2) \circ \dots \circ \lambda(w_n)$$

- ➡ Erzeuge Wortmodelle  $\lambda_l = \lambda(W_l)$  mit der Eigenschaft

$$P(\mathbf{X} | \lambda_l) \approx P(\mathbf{X} | W_l)$$

## Unterschiedliche Modelltopologien:



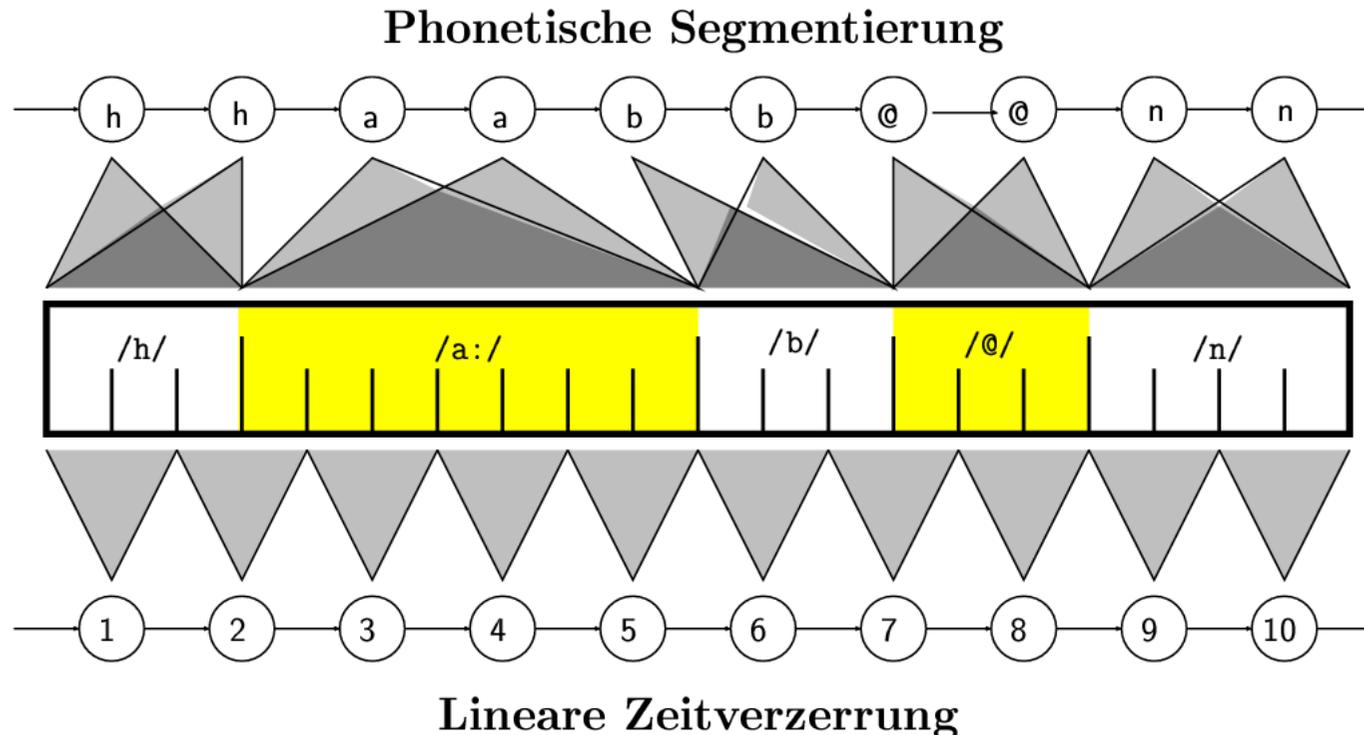
## Modelldimension

- Anzahl  $N_l$  der HMM-Zustände des Modells  $\lambda_l$
- Ziffernwörter  $\Rightarrow N_l = 5$
- $N_l = N(W_l) \propto$  „Anzahl der Phoneme von  $W_l$ “ Individuelle Wörter: Wortabhängige Modelldimension

## Parameterinitialisierung

Vorbesetzen der HMM-Parameter zu Beginn des Baum-Welch-Trainings

- Anfangs- und Übergangswahrscheinlichkeiten  $\pi_i, a_{ij}$  unkritisch
- Diskrete Ausgabeverteilung / Mischungskoeff.  $b_{jk}, c_{jk}$  uniform
- Kontinuierliche - und Mischverteilungsparameter  $\mu_{jk}, \Sigma_{jk} = ?$

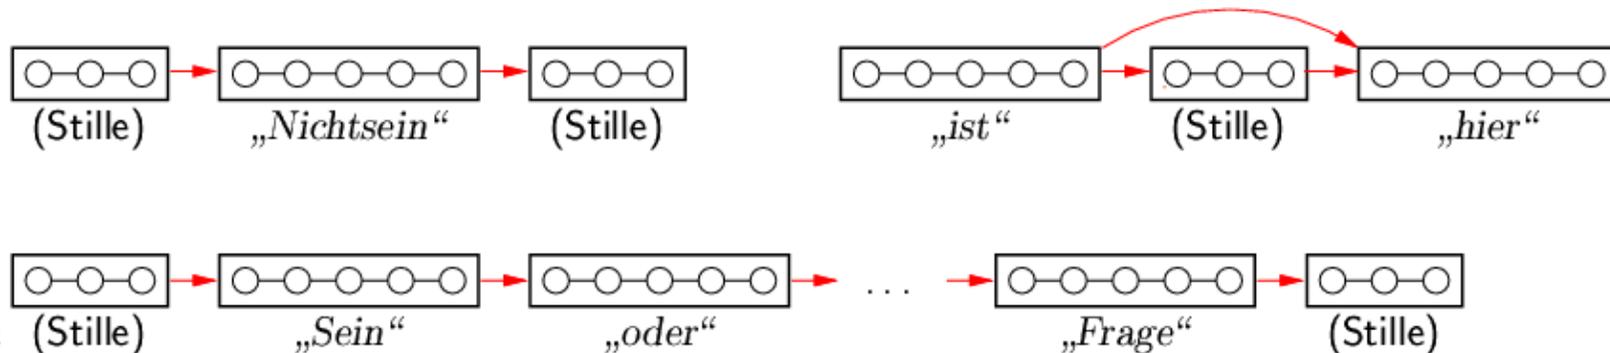


## Aufbau der Lernstichprobe

- **Ein Sprecher:**  
mindestens 10, besser 50 oder 100 Aussprachebeispiele/Wort
  - **Viele Sprecher:**  
ausgewogene Population von mindestens 100 SprecherInnen  
(Geschlecht, Anatomie, Dialekt, Ideolekt, Soziolekt)
- ➔ Kompensation von **Anzahl** & **Ergiebigkeit** von Sprechern

## Eingebettetes Lernen

- **Einzelwortprobe:**  
Wortrealisierungen liegen in Sprechpausen eingebettet vor
- **Verbundwortprobe:**  
Wortrealisierungen liegen in komplette Sätze eingebettet vor
- Wortfolgenrealisierungen sind u.U. durch *Stillebereiche* unterbrochen



Warum ist das Wort keine geeignete Modellierungseinheit für die autom. Spracherkennung?

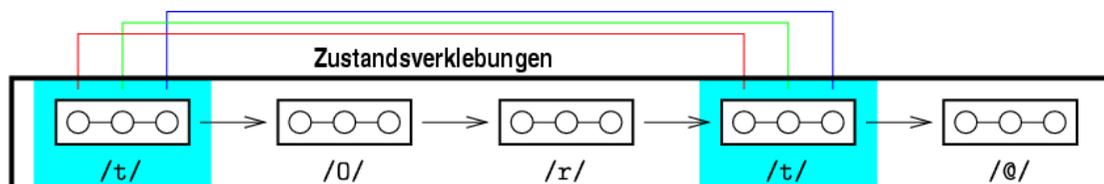
- erforderliches Trainingsmaterial  $\propto$  Wortschatzumfang  $L$
- enorme Zahl freier HMM-Parameter
  - *labile Schätzwerte & hoher Rechen- und Speicheraufwand*
- geringe Flexibilität monolithischer Modelle
  - *Trainingsvokabular = Erkennungsvokabular*
- keine Berücksichtigung wortübergreifender Ausspracheverschleifungen



## Analyse–durch–Synthese

Beispielwort: „Torte“

$$\lambda(/t_0rt@/) = \lambda(/t/) \circ \lambda(/0/) \circ \lambda(/r/) \circ \lambda(/t/) \circ \lambda(/@/)$$



Entwurfskriterien für geeignete Wortuntereinheiten (WUE)

⇒ **Präzision**

die WUE ist *hochspezialisiert* und folglich *trennscharf*

⇒ **Robustheit**

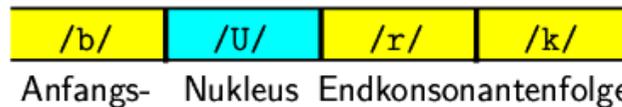
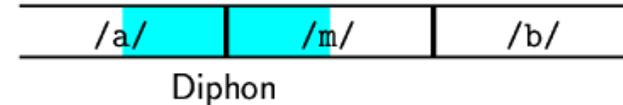
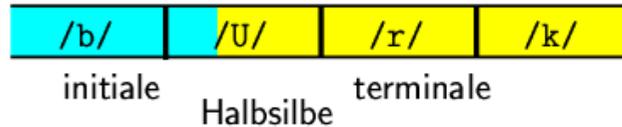
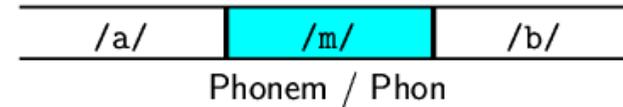
großer *Trainingsmaterialvorrat* & wirksame  
*Glättungsmaßnahmen* ⇒ gute *Schätzwerte*

⇒ **Modularität**

festes, *endliches Inventar* moderaten Umfangs für alle  
potentiellen Sprechakte

⇒ **Transfer**

*Synthese neuer Wortmodelle* aus vorhandenen WUE



<b>Phoneme</b>	je nach Sprache 20–60 ( <i>+modular, –präzis</i> )
<b>Silben</b>	20 000 im Englischen, 100 im Japanischen; Koartikulation primär innerhalb ( <i>+präzis, –modular</i> )
<b>Halbsilben</b>	800/2560 initiale/terminale im Deutschen ( <i>+trennscharf, ±modular</i> )
<b>Sylparts</b>	47 AKF, 20 Nuklei, 159 EKF im Deutschen ( <i>guter Kompromiß</i> )
<b>Diphone</b>	1000–1500 Einheiten (engl./ital.), ungünstige Nahtstellen ( <i>besser: Transeme</i> )

## GRUNDIDEE:

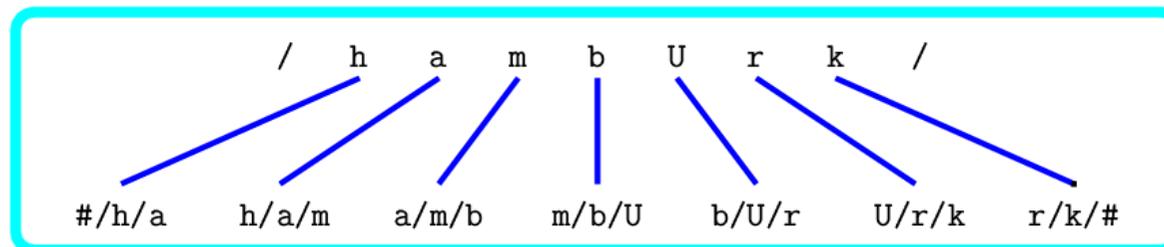
- Segmentelle Basisspracheinheit **kurzer Dauer**  
— Modellierung **kontextabhängig**
  - Basiseinheit kontextueller Modellierung ist das **Phonem**
- ⇒ „[...] *Aufgliederung eines Phonems in allophonische Klassen mit scharf umrissenen artikulatorischen oder akustischen Eigenschaften unter Kontrolle seiner unmittelbaren lautlichen Nachbarschaft [...]*“

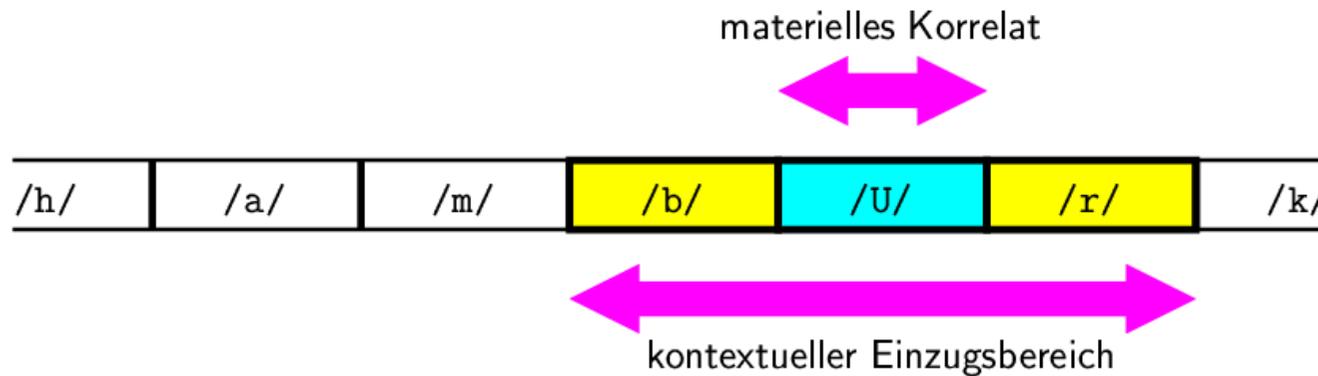
## Schreibweise für **Triphone**

r in hambUrK → U/r/k

und für **rechte / linke Biphone** und **Monophone**

r → /r/k      r → U/r/      r → /r/





## Training von Triphon-HMM's

1. Initialisierung / Training gewöhnlicher **Monophonmodelle**
2. Training der **Biphonmodelle** (↔ Monophonparameter)
3. Training der **Triphonmodelle** (↔ Biphonparameter)
4. Konstruktion der Wortmodelle des Erkennungsvokabulars:

- **Rückgriffstrategie:**

$$\boxed{\lambda(b/U/r)} \rightsquigarrow \boxed{\lambda(/U/r)} \rightsquigarrow \boxed{\lambda(b/U/)} \rightsquigarrow \boxed{\lambda(/U/)}$$

- **Interpolation:**

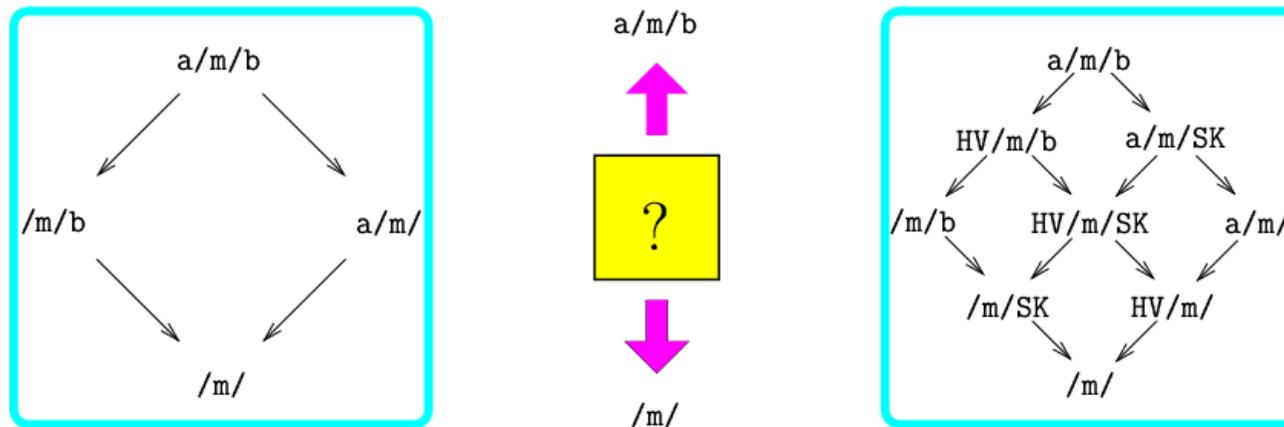
PROBLEM:

- Seltene Triphone  $\Rightarrow$  statistisch labile Markovmodelle

LÖSUNG:

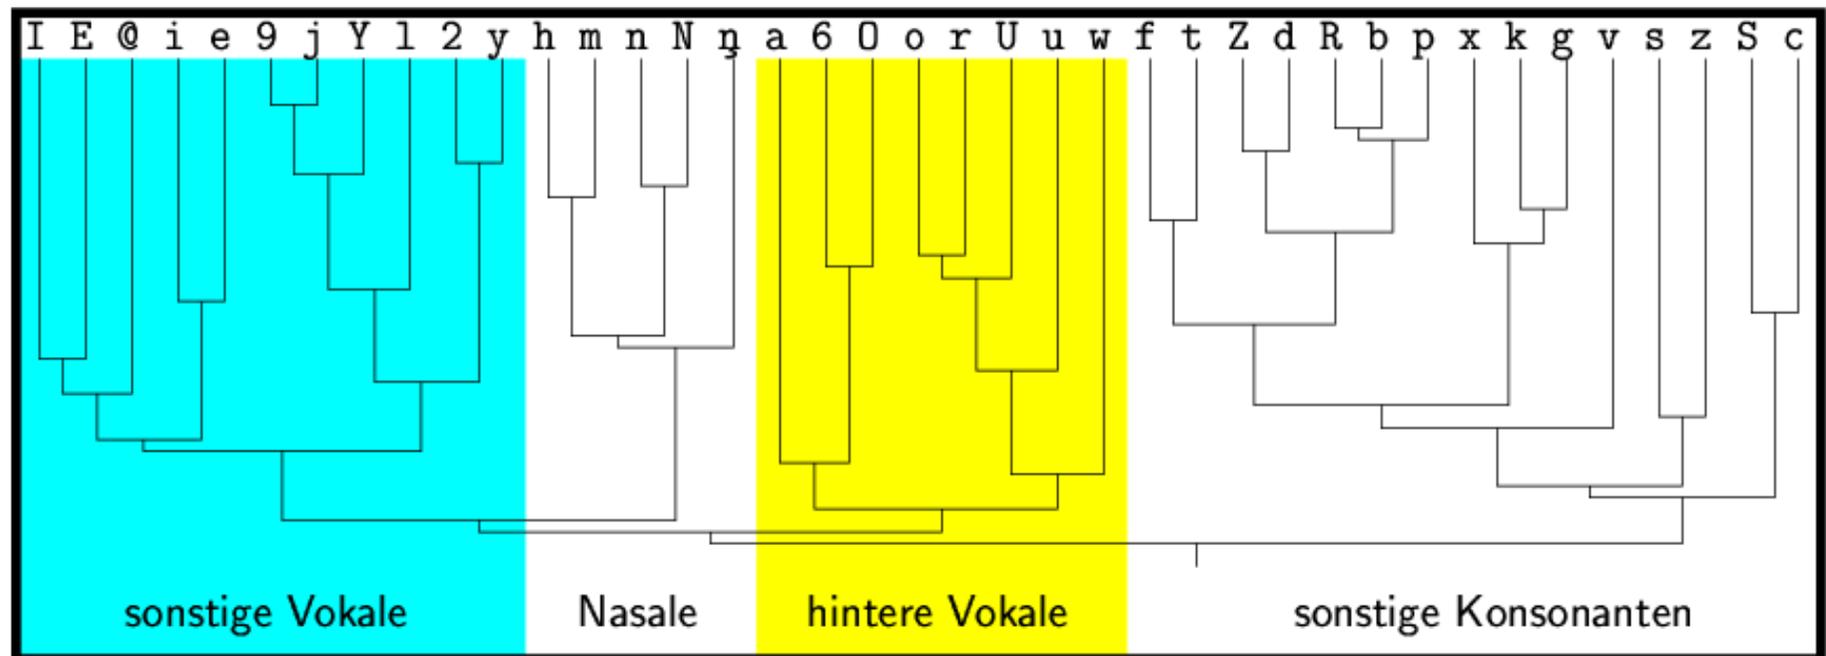
- **Bündeln** geeigneter Gruppen **kernegleicher Triphone** mit verwandten akustischen Eigenschaften

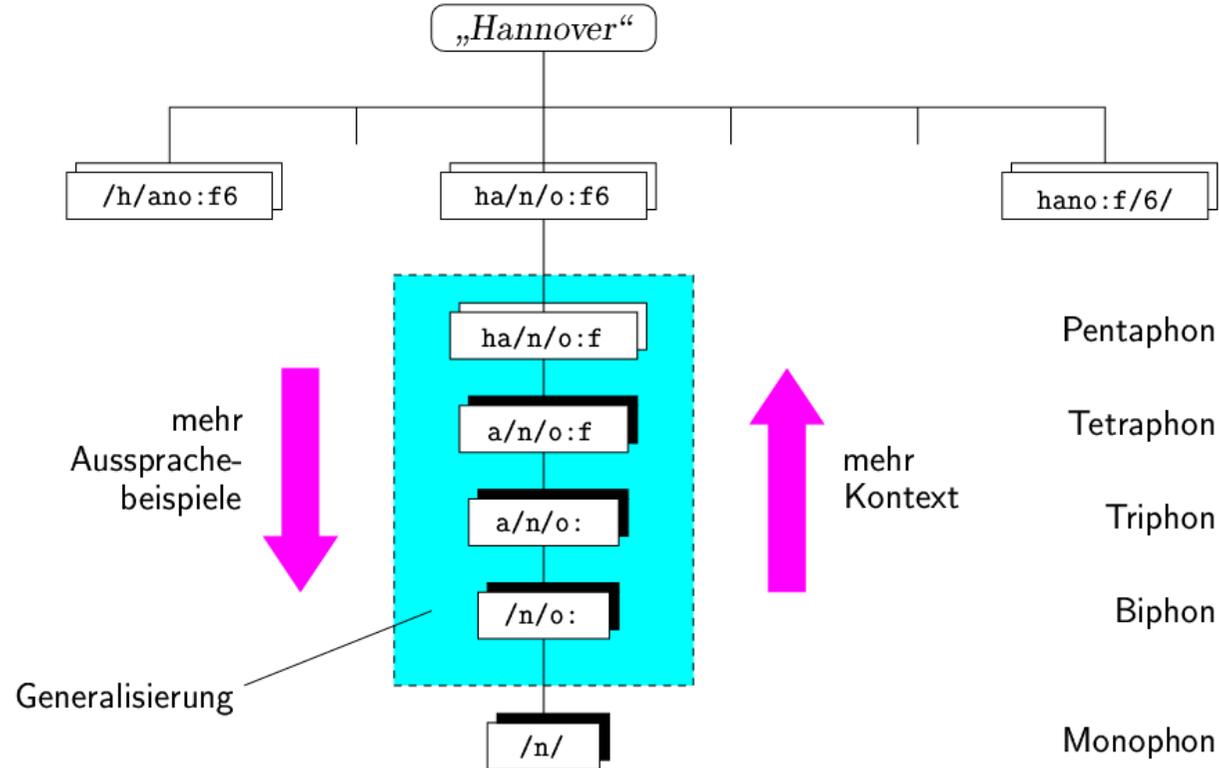
**Resultierende Generalisierungsbeziehungen:**



## Umschriftgetriebene Generalisierung

Phonetisches Klassensystem für Nachbarphoneme





- häufige Spracheinheiten sind modellierungsfähig
  - ➡ robuste Schätzwerte
- häufige Spracheinheiten sind modellierungsbedürftig
  - ➡ Redundanz & Verschleifung
- Phoneme in **beliebig breitem** R/L Kontext

Wortübergreifende Verschleifungseffekte:

„in München“

/In/ + /mYnc@n/  /ImYnc@n/

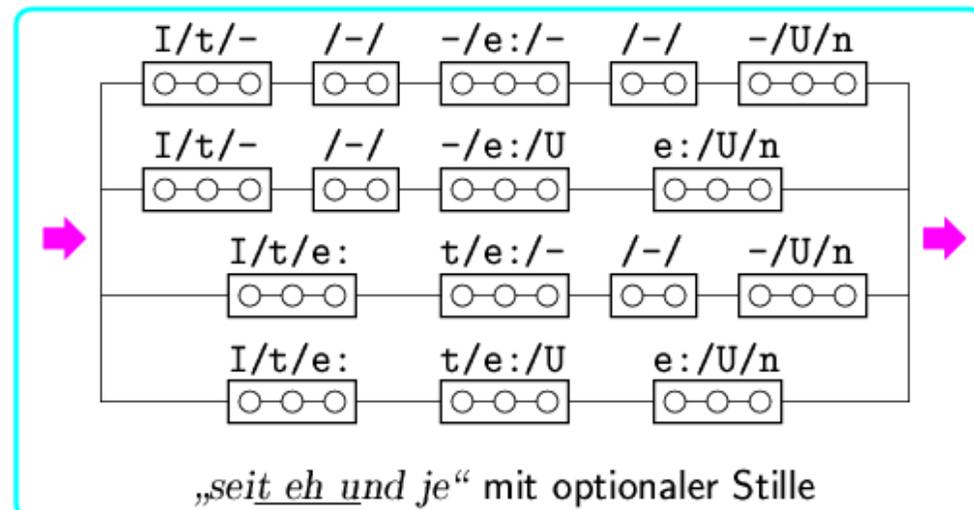
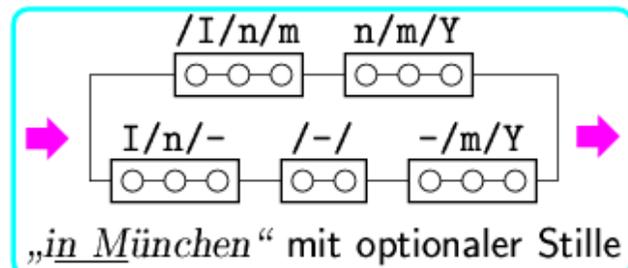
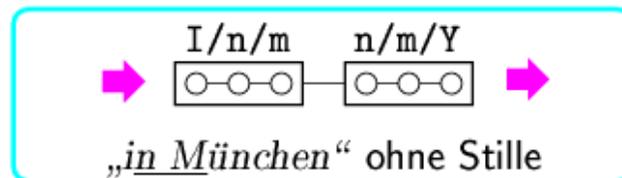
„Verstümmelung“ kurzer Funktionswörter:

„Roß und Reiter“

/r0s/ + /Unt/ + /raIt6/  /r0snraIt6/

## Wortgrenzenübergreifende Triphonmodelle

für die Lernphase des Spracherkenners



**„Performanzlücke“**  
FEHLERFREI GELESENER TEXT  
—  
SPONTAN PRODUZIERTE SPRACHE

- ***Unbekannte Wörter***
  - ➔ *Wörter außerhalb des Erkennungswortschatzes*
- ***Außerlexikalische Einheiten***
  - ➔ *Ungefüllte Pausen*
  - ➔ *Gefüllte Pausen („äh“, „mmh“, ...)*
- ***Nichtverbale Realisierungen***
  - ➔ *Räuspern, Husten*
  - ➔ *Lachen*
  - ➔ *Atemgeräusche, Schmatzlaute*
- ***Nichtartikulatorische Störproduktionen***
  - ➔ *Türenschnagen, Rascheln, Klopfen, ...*

- Duda, R.O. and Hart, P.E. , *Pattern Classification and Scene Analysis*. Wiley&Sons, Inc., 1973.
- Bolter R., *Bildverarbeitung und Mustererkennung*, Vorlesung ICG Graz, 2000.
- S. Bengio, *An Introduction to Statistical Machine Learning – EM for GMMs*, Dalle Molle Institute for Perceptual Artificial Intelligence.
- E.G. Schukat-Talamazzini, *Automatische Spracherkennung*, Vieweg-Verlag, 1995.
- F. Pernkopf, *Automatic Visual Inspection of Metallic Surfaces*, PhD Thesis, Leoben 2002.
- C.R. Houck, J.A. Joines, G.M. Kay, *A Genetic Algorithm for Function Optimization: A Matlab Implementation*, North Carolina State University.
- M. Obikito, *Introduction to Genetic Algorithms*, Hochschule für Technik und Wirtschaft Dresden, 1998.