Computerlinguistik I

Vorlesung im WiSe 2017/2018
(M-GSW-09)

Prof. Dr. Udo Hahn

Lehrstuhl für Computerlinguistik
Institut für Germanistische Sprachwissenschaft
Friedrich-Schiller-Universität Jena

http://www.julielab.de

Informatischer Problemlösungszyklus

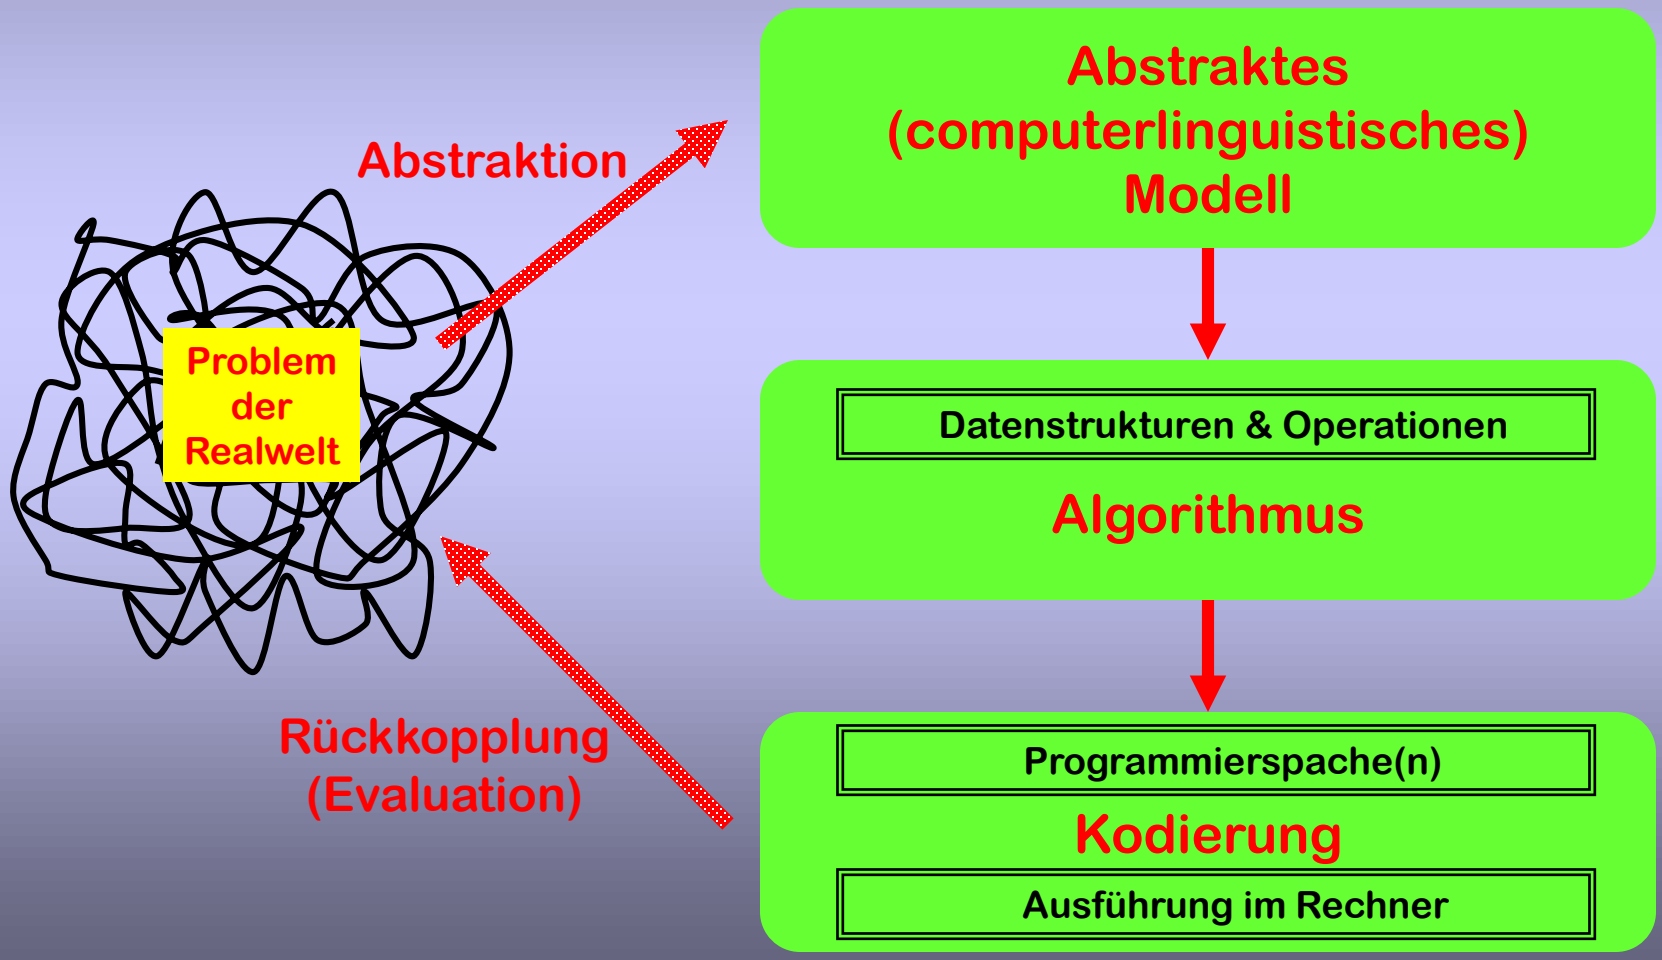

Informatischer Problemlösungszyklus

- **Modellbildung**
  - **Abstraktion von allen unwesentlichen Details der Problemstellung im Hinblick auf die algorithmische Lösung**
  - **Spezifikation der logischen Abhängigkeiten zwischen problemlösungsrelevanten Objekten**
  - **(computer)linguistisches Wissen**

Informatischer Problemlösungszyklus

- Algorithmisierung
  - Übersetzung der modellbezogenen Spezifikation in
    - eine Menge von Objekten (Datenstrukturen) mit bestimmten Eigenschaften und Beziehungen zueinander
    - die erlaubten Operationen auf diesen Objekten
  - Algorithmus: (möglichst präzise) Beschreibung einer Folge zulässiger Operationen auf den Objekten, um das Problem zu lösen
  - Computerlinguistische Kernexpertise

Informatischer Problemlösungszyklus

- Kodierung (Programmierung)
  - Übersetzung der algorithmischen Spezifikation in Konstrukte einer (geeigneten) Programmiersprache
- Ausführung des Programms
  - Hier erst Bezug auf konkrete Maschinen (Datenstrukturen und Algorithmen sind abstrakte Konstruktionen)
  - Test-Modifikationszyklus ... Dokumentation !
  - Informatisches Know-How

Morphologische Prozesse: Flexion - Deflexion

- Kombination von Grundformen mit Flexionsaffixen (Kasus, Numerus, Tempus)
  - Deklination
    - Land: Land, Landes, Lande, Länder, Ländern
  - Konjugation
    - landen: lande, landest, landet, landeten , gelandet
- primär syntaktische, nur minimale semantische Information, keine grundlegenden Wortartwechsel

Morphologische Prozesse: Derivation - Dederivation

- Kombination von Grundformen mit Derivationsaffixen
  - Land: landen, verlanden, anlanden,
  - Land: Landung, Verlandung , Anlandung
  - Land: ländlich, verländlichen, Verländlichung
- modifizierende semantische Information, häufig mit Wortartwechsel verbunden

Morphologische Prozesse: Komposition - Dekomposition

- Kombination von Grundformen mit Grundformen (mittels Fugeninfixen)
  - Land: Landnahme, Landflucht, Landgang
  - Land: Heimatland, Ausland, Bauland
  - Land: Landesrekord, Landesverrat, Landsmann
  - Land: Inlandsflug, Landesratspräsidentengattin
- starke semantische Modifikation, fast keine Wortartwechsel
  - … aber: Rotkehlchen, Weichteile

Lemmatisierung vs. Wort-Parsing

Eingabe	Lemma	Wort-Parse
Töchtern	Tochter	Tochter [+N, +FEM, +PL, +DAT]
Hauses	Haus	Haus [+N, +NEU, +SG, +GEN]
sagte	sagen	sagen [+V, +SG, {1P,3P}, +PAST]
Spiegelungen	Spiegelung	$[\text{Spiegel}]_{N}[\text{ung}]_{ds}$ [+N, +FEM, +PL, {NOM,GEN,DAT,AKK}]
leichter	leicht	leicht [+Adj, +POS, +MAS, +SG, +NOM] [+Adj, +KOM]
verlängerte	verlängert	$[\text{ver}]_{dp}[[\text{lang}]_{Adj}[\text{er}]_{ds}]_{Adj}[\text{t}]_{ds}$ [+Part, {MAS,FEM,NEU}, +SG, + DEF, +NOM] [+Part, {FEM,NEU}, +SG, + DEF, +AKK]
	verlängern	$[\text{ver}]_{dp}[[\text{lang}]_{Adj}[\text{er}]_{ds}]_{Adj}[\text{n}]_{ds}$ [+V, +SG, {1P,3P}, +PAST]

Automat für Dederivation

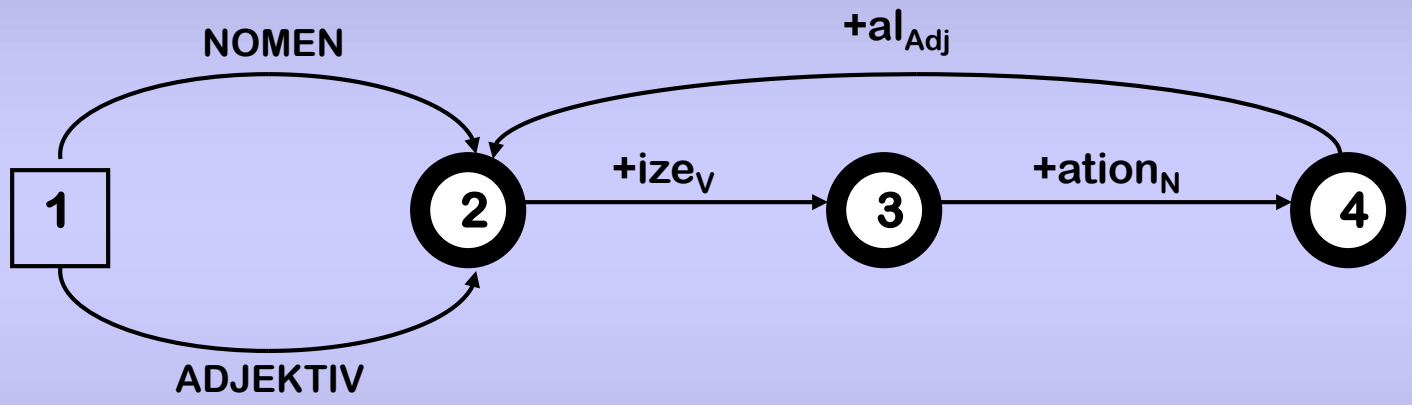

NOMEN: hospital, motor, category, …

ADJEKTIV: moral, concrete, tender, …

n Anfangszustand

n möglicher Endzustand

Automat für englische Zahlen von 1 bis 99

one, two, three, four, five, six, seven, eight, nine, ten,
eleven, twelve, thirteen, fourteen, fifteen, sixteen, seventeen, eighteen, nineteen

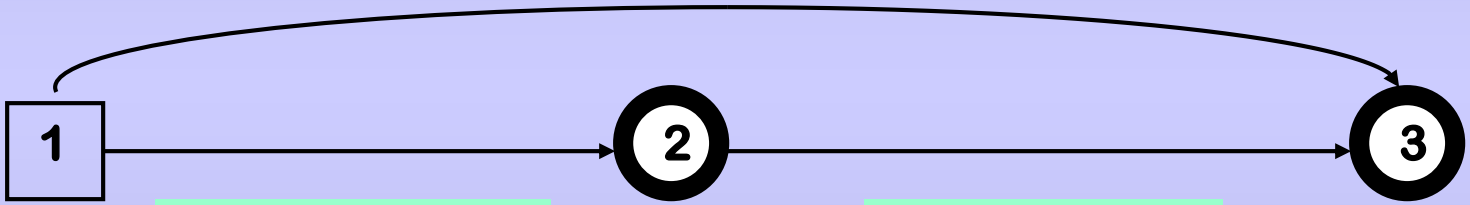

twenty, thirty, forty,
fifty, sixty, seventy,
eighty, ninety

one, two, three,
four, five, six,
seven, eight, nine

n Anfangszustand

n möglicher Endzustand

Mengentheoretische Grundbegriffe

- Die Zusammenfassung aller Elemente x, die eine Eigenschaft $\mathcal{E}$ haben, wird als **Menge** M bezeichnet:

  $$M := \{x \mid x \text{ hat die Eigenschaft } \mathcal{E}\}$$

  Beispiele:

  LAUF := {x | x ist deutsches Lexem, das mit „LAUF“ beginnt }

  EoR := {x | x ist deutsches Lexem, das auf „E“ oder „R“ endet }

Mengentheoretische Grundbegriffe

- Seien M_1 und M_2 Mengen. M_1 ist **Teilmenge** von M_2, falls aus $x \in M_1$ stets $x \in M_2$ folgt; symbolisch: $M_1 \subseteq M_2$.
- Gilt für zwei Mengen, M_1 und M_2 , einerseits $M_1 \subseteq M_2$ und andererseits $M_1 \neq M_2$, dann ist M_1 **echte Teilmenge** von M_2 ; symbolisch: $M_1 \subset M_2$

Beispiele:

LAUF* := {Laufbahn, laufen, Lauffeuer, Laufmasche, Laufsteg} $\subseteq$ LAUF

LAUF $\subset$ LA := {x | x ist deutsches Lexem, das mit „LA“ beginnt }

R := {x | x ist deutsches Lexem, das auf „R“ endet } $\subseteq$ EoR

Mengentheoretische Grundbegriffe

- Gilt für zwei Mengen, M_1 und M_2 , sowohl $M_1 \subseteq M_2$ als auch $M_2 \subseteq M_1$, so folgt: $M_1 = M_2$ (Mengengleichheit).
- Die leere Menge ist die Menge, die kein Element enthält; symbolisch: {} oder Ø.
  - Bemerkung: Ø ist Teilmenge jeder Menge.
- Die Kardinalität einer endlichen Menge M ist die Anzahl ihrer Elemente; symbolisch: |M|

Mengentheoretische Grundbegriffe

- **Wenn M und N Mengen sind, dann charakterisiert die Menge**

  $M \cap N$:= $\{x \mid x \in M$ und $x \in N\}$

  den Durchschnitt

  $M \cup N$:= $\{x \mid x \in M$ oder $x \in N\}$

  die Vereinigung

  von M und N

Mengentheoretische Grundbegriffe

- **Beispiele:**

  LAUF*:= {Laufbahn, laufen, Lauffeuer, Laufmasche, Laufsteg}

  LAUF* ∩ EoR

  = { Lauffeuer, Laufmasche }

  { Lauffeuer, Laufmasche } ∪ { Lauffeuer, Laufpass }

  = { Lauffeuer, Laufmasche, Laufpass }

Mengentheoretische Grundbegriffe

- Wenn I = {1,...,n} eine nichtleere Indexmenge ist und jedes $i \in$ I für M_i eine Menge charakterisiert, dann gilt als
  - Verallgemeinerung des Durchschnitts

$$\bigcap_{i \in I} M_i := \{x \mid x \in M_i \text{ für alle } i \in I\} = \bigcap_{i=1}^{n} M_i$$

  - Verallgemeinerung der Vereinigung

$$\bigcup_{i \in I} M_i := \{x \mid x \in M_i \text{ f.mind.ein } i \in I\} = \bigcup_{i=1}^{n} M_i$$

Mengentheoretische Grundbegriffe

- **Die Menge aller Teilmengen einer Menge M heißt Potenzmenge:**

$$\wp(M) := \{ N \mid N \subseteq M \} = 2^M$$

Beispiel:

LAUFS := { Laufschritt, Laufstall, Laufsteg }

2^{LAUFS} = { Ø, {Laufschritt}, {Laufstall}, {Laufsteg},
{Laufschritt, Laufstall}, {Laufschritt, Laufsteg},
{Laufstall, Laufsteg}, LAUFS }

$| 2^{LAUFS} | = 2^3 = 8$

Mengentheoretische Grundbegriffe

- Das Kartesische Produkt von endlich vielen Mengen $M_1,.., M_n$, $n \geq 2$, ist die Menge aller n-tupel:

  $M_1 \times M_2 \times ... \times M_n := \{ (m_1,..,m_n) \mid m_i \in M_i , 1 \leq i \leq n \}$

  Beispiel:

  LAUFB := { Laufbahn, Laufbursche }

  LAUFS := { Laufschritt, Laufstall, Laufsteg }

  LAUFB x LAUFS = { (Laufbahn, Laufschritt), (Laufbahn, Laufstall), (Laufbahn, Laufsteg), (Laufbursche, Laufschritt), (Laufbursche, Laufstall), (Laufbursche, Laufsteg) }

Grundbegriffe zu Relationen

- **Eine (zweistellige) Relation ρ zwischen zwei Mengen M_1 und M_2 ist eine Teilmenge von $M_1 \times M_2$, d.h. $\rho \subseteq M_1 \times M_2$. Man schreibt auch $m \rho n$ für $(m,n) \in \rho$.**

Beispiel:

GleicheLänge $\subseteq$ DLexeme x DLexeme

GleicheLänge = { (du, da), (da, Ei), (er, es), (Dom, Bor),
(Aal, Tor), (Bild, Tier), (Tiger, Sekte),... }

Grundbegriffe zu Relationen

- **Eine Relation ρ auf einer nichtleeren Menge M heißt Äquivalenzrelation, wenn**
  - $m \rho m$ **für jedes** $m \in$ **M** **(reflexiv)**
  - **aus** $m \rho n$ **folgt** $n \rho m$ **(symmetrisch)**
  - **aus** $k \rho m$ **und** $m \rho n$ **folgt** $k \rho n$ **(transitiv)**

Beispiel:

GleicheLänge ist Äquivalenzrelation:

(1) reflexiv: (du, du), (da, da), (Ei, Ei), (Aal, Aal), (Tiger, Tiger), ...
(2) symmetrisch: (Aal, Tor) $\Rightarrow$ (Tor, Aal), (Tiger, Sekte) $\Rightarrow$ (Sekte, Tiger), ...
(3) transitiv: (du, da), (da, Ei) $\Rightarrow$ (du, Ei),
(Bild, Tier), (Tier, Rand) $\Rightarrow$ (Bild, Rand), ...

Grundbegriffe zu Relationen

- Ist ρ eine Äquivalenzrelation auf einer Menge M, dann heißt jede Menge $[m] := \{ n \mid m \rho n \}$ für ein $m \in M$ die von m repräsentierte Äquivalenzklasse.
- Jede Äquivalenzrelation auf M bewirkt eine Einteilung von M in paarweise disjunkte (d.h. elementfreie) Äquivalenzklassen.

Beispiele:

[da] = { Ei, er, es, du, ... }
[Aal] = { Tor, Bor, elf, vom, ... }
[Bild]= { Tier, Rand, grün, hell, ... }

Grundbegriffe zu Relationen

- Eine Halbordnung (partielle Ordnung) auf einer Menge M ist eine Relation „<“ auf M mit den Eigenschaften
  - aus $k < m$ und $m < n$ folgt: $k < n$ (transitiv)
  - für kein $m \in$ M gilt: $m < m$ (irreflexiv)

Beispiel:

Ist_Unterbegriff $\subseteq$ DLexeme x DLexeme

Ist_Unterbegriff
= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt),
(Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

Grundbegriffe zu Relationen

- **Eine lineare Ordnung (totale Ordnung) auf einer Menge M ist eine Halbordnung „<“ auf M, bei der für beliebige $m, n \in$ M entweder $m < n$ oder $n < m$ oder $m = n$ gilt.**

Beispiel:

Lexikographisch_Vor $\subseteq$ DLexeme x DLexeme
Lexikographisch_Vor
= { (Aal, Bild), (Bild, Rand), (Rand, Tiger), (Stelle, Stiel),
(Stiel, Stil), (Stil, Stunde), (Klee, Zone), ... }

Grundbegriffe zu Relationen

- **Das Produkt zweier Relationen, ρ und σ auf M, ist festgelegt durch**

  $\rho\ \sigma$ **:= { (x,z) | (x,y)** $\in \rho$ **und (y,z)** $\in \sigma$ **f.e. y** $\in$ **M }**

Grundbegriffe zu Relationen

- **Für eine beliebige Relation ρ auf M definiert**
  - $\rho^0 := \{ (m,m) \mid m \in M \}$ **die Diagonale,**
  - $\rho^1 := \rho$ **und** $\rho^i := \rho^{i-1}\ \rho$ **für** $i>1$
  - $\rho^+ := \bigcup_{i \geq 1} \rho^i = \rho^1 \cup \rho^2 \cup \ldots \cup \rho^n$

    die transitive Hülle von ρ,
  - $\rho^* := \bigcup_{i \geq 0} \rho^i = \rho^0 \cup \rho^1 \cup \rho^2 \cup \ldots \cup \rho^n$

    die reflexive und transitive Hülle von ρ

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

Transitive Hülle von *„Ist_Unterbegriff“*

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^1$ = Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^1$ = Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^1$ = Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

Ist_Unterbegriff^1 = Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

Ist_Unterbegriff^2 = Ist_Unterbegriff^1 Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^1$ = Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^1$ = Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^1$ = Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

$Ist\_Unterbegriff^3$ = $Ist\_Unterbegriff^2$ Ist_Unterbegriff

= { (VW-Golf, KFZ) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

$Ist\_Unterbegriff^3$ = $Ist\_Unterbegriff^2$ Ist_Unterbegriff

= { (VW-Golf, KFZ), (VW-PKW, Artefakt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2 = Ist\_Unterbegriff^1\ Ist\_Unterbegriff$

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

$Ist\_Unterbegriff^3 = Ist\_Unterbegriff^2\ Ist\_Unterbegriff$

= { (VW-Golf, KFZ), (VW-PKW, Artefakt), (PKW, Objekt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

$Ist\_Unterbegriff^3$ = $Ist\_Unterbegriff^2$ Ist_Unterbegriff

= { (VW-Golf, KFZ), (VW-PKW, Artefakt), (PKW, Objekt), (Schreibtisch, Objekt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

$Ist\_Unterbegriff^3$ = $Ist\_Unterbegriff^2$ Ist_Unterbegriff

= { (VW-Golf, KFZ), (VW-PKW, Artefakt), (PKW, Objekt), (Schreibtisch, Objekt) }

$Ist\_Unterbegriff^4$ = $Ist\_Unterbegriff^3$ Ist_Unterbegriff

= { (VW-Golf, Artefakt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2$ = $Ist\_Unterbegriff^1$ Ist_Unterbegriff

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

$Ist\_Unterbegriff^3$ = $Ist\_Unterbegriff^2$ Ist_Unterbegriff

= { (VW-Golf, KFZ), (VW-PKW, Artefakt), (PKW, Objekt), (Schreibtisch, Objekt) }

$Ist\_Unterbegriff^4$ = $Ist\_Unterbegriff^3$ Ist_Unterbegriff

= { (VW-Golf, Artefakt), (VW-PKW, Objekt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2 = Ist\_Unterbegriff^1\ Ist\_Unterbegriff$

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

$Ist\_Unterbegriff^3 = Ist\_Unterbegriff^2\ Ist\_Unterbegriff$

= { (VW-Golf, KFZ), (VW-PKW, Artefakt), (PKW, Objekt), (Schreibtisch, Objekt) }

$Ist\_Unterbegriff^4 = Ist\_Unterbegriff^3\ Ist\_Unterbegriff$

= { (VW-Golf, Artefakt), (VW-PKW, Objekt) }

$Ist\_Unterbegriff^5 = Ist\_Unterbegriff^4\ Ist\_Unterbegriff$

= { (VW-Golf, Objekt) }

Transitive Hülle von „*Ist_Unterbegriff*“

Ist_Unterbegriff

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ), (KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch, Möbel), (Möbel, Artefakt) }

$Ist\_Unterbegriff^2 = Ist\_Unterbegriff^1\ Ist\_Unterbegriff$

= { (VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt), (KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel, Objekt) }

$Ist\_Unterbegriff^3 = Ist\_Unterbegriff^2\ Ist\_Unterbegriff$

= { (VW-Golf, KFZ), (VW-PKW, Artefakt), (PKW, Objekt), (Schreibtisch, Objekt) }

$Ist\_Unterbegriff^4 = Ist\_Unterbegriff^3\ Ist\_Unterbegriff$

= { (VW-Golf, Artefakt), (VW-PKW, Objekt) }

$Ist\_Unterbegriff^5 = Ist\_Unterbegriff^4\ Ist\_Unterbegriff$

= { (VW-Golf, Objekt) }

$Ist\_Unterbegriff^6 = Ist\_Unterbegriff^5\ Ist\_Unterbegriff = \{\}$

Transitive Hülle von „*Ist_Unterbegriff*“

$$\bigcup_{i \geq 1} \text{Ist\_Unterbegriff}^i = \text{Ist\_Unterbegriff}^1 \cup \text{Ist\_Unterbegriff}^2 \cup \ldots \cup \text{Ist\_Unterbegriff}^n$$

= { (VW-Golf, VW-PKW), (VW-PKW, PKW), (PKW, KFZ),
(KFZ, Artefakt), (Artefakt, Objekt), (Schreibtisch,
Möbel), (Möbel, Artefakt),
(VW-Golf, PKW), (VW-PKW, KFZ), (PKW, Artefakt),
(KFZ, Objekt), (Schreibtisch, Artefakt), (Möbel,
Objekt),
(VW-Golf, KFZ), (VW-PKW, Artefakt), (PKW, Objekt),
(Schreibtisch, Objekt),
(VW-Golf, Artefakt), (VW-PKW, Objekt),
(VW-Golf, Objekt) }

Grundlagen formaler Sprachen:
Alphabet

- Sei Σ ein beliebiges Alphabet, d.i. eine Menge von Symbolen oder Zeichen
  - Beispiele für verbreitete Alphabete:
    - {A,B,C, …, X,Y,Z} lateinisches Alphabet
    - {1,2,3, …, 7,8,9, 0} indisch-arabisches Zahlensystem
    - {0,1} Binärzahlen
    - {  } internat. Ampelalphabet
    - {A[denin], G[uanin], T[hymin], C[ytosin]} Basen-Alphabet der DNA

Grundlagen formaler Sprachen: Wörter

- Seien Wörter (Sätze, Strings, Ketten) über einem Alphabet Σ in der folgenden Weise definiert:
  1. ε ist ein Wort über Σ (ε ist das Leerwort, das keine Symbole hat)
  2. falls χ ein Wort über Σ und $\alpha \in \Sigma$ ist, dann ist $\chi\,\alpha$ ein Wort über Σ
  3. γ ist ein Wort über Σ genau dann, wenn sein Bildung aus (1) oder (2) folgt

Grundlagen formaler Sprachen:
Konkatenation von Wörtern

- Das Wort $\omega \circ \tau := \omega\tau := \omega_1 \ldots \omega_m \tau_1 \ldots \tau_n$ heißt **Konkatenation** von ω und τ, falls $\omega = \omega_1 \ldots \omega_m$ und $\tau = \tau_1 \ldots \tau_n$ ($\omega_i, \tau_j \in \Sigma$) Wörter über Σ sind;
  „o“ (sprich: „Kringel“) ist der Konkatenationsoperator.
  - Für alle Wörter ω gilt: $\omega \circ \varepsilon = \varepsilon \circ \omega = \omega$

Beispiele für Konkatenationen:

- ABC o X = ABCX
- 24 o 24 = 2424
- wort o stamm = wortstamm

Formale Grundlagen von Automaten: formale Sprache

- Eine (formale) Sprache $\mathcal{L}$ über einem Alphabet Σ ist eine Menge von Ketten über Σ .
- Sei ferner Σ^* (bzw. Σ^+) die Menge *aller* Ketten über Σ unter Einschluss (bzw. Ausschluss) von ε.
- Dann gilt für jede Sprache $\mathcal{L}$ über Σ :

$$\mathcal{L} \subseteq \Sigma^*$$

Beispiele für formale Sprachen

- Σ = {A,B,C, …, X,Y,Z,_}
  - $\mathcal{L}_1$ = {GUTEN_TAG, GUTEN, TAG}
    = {GUTEN, GUTEN_TAG, TAG}
  - $\mathcal{L}_2$ = {GTNTG, GTN, TG}
  - $\mathcal{L}_3$ = {TNT, TN, T}
  - $\mathcal{L}_4$ = {GG, GTTG, GGGG, GGTTGG, …}
  - $\mathcal{L}_5$ = {A, C, G, T, ACCGTG, …}

Beispiele für formale Sprachen

- Σ = {0,1,2,3, …, 7,8,9,+,-,=}
  - $\mathcal{L}_1$ = {5+7=20-8, 5+7=5+8, 5759=57-59}
  - $\mathcal{L}_2$ = {5+=7-2=, +++, 1-11782---3}
  - $\mathcal{L}_3$ = {3, 33, 333, 3333, 33333, …}

Beispiele für formale Sprachen

Σ = {NOMEN, ADJEKTIV, +ize$_V$, +ation$_N$, +al$_{Adj}$}

- $\mathcal{L}_1$ = { hospital, hospital+ize$_V$,
  hospital +ize$_V$+ation$_N$, ... }
- $\mathcal{L}_2$ = { hospital, moral,
  hospital+ize$_V$, moral+ize$_V$, ... }
- $\mathcal{L}_3$ = { +ize$_V$, +ize$_V$+ize$_V$, +ize$_V$+ize$_V$hospital, ... }

NOMEN: hospital, motor, category, ...

ADJEKTIV: moral, concrete, tender, ...

Grundlagen formaler Sprachen:
Wortmengen

- Eine Wortmenge (Sprache) $\mathcal{F}$ bezüglich eines Alphabets Σ ist gegeben durch

$$\mathcal{F} := \{ \omega \mid \omega \text{ ist Wort über } \Sigma \}$$

Grundlagen formaler Sprachen:
Konkatenation von Wortmengen

- Die Zusammensetzung (Konkatenation) von Wortmengen $\mathcal{F}$ und $\mathcal{M}$ ist gegeben durch

$$\mathcal{F} \circ \mathcal{M} := \mathcal{F}\,\mathcal{M} := \{\, \omega\tau \mid \omega \in \mathcal{F}, \tau \in \mathcal{M} \,\}$$

- Dabei gilt:

$$\mathcal{F}\ \{\varepsilon\} = \{\varepsilon\}\ \mathcal{F} = \mathcal{F}$$
$$\mathcal{F}\ \emptyset = \emptyset\ \mathcal{F} = \emptyset$$

Beispiele für Konkatenationen:

- DLex := {Fisch, Fest, Fleck}; DEnd := {e, es, er}
- DLex ∘ DEnd = {Fische, Fisches, Fischer, Feste, Festes, Fester, Flecke, Fleckes, Flecker}

Grundlagen formaler Sprachen:
Potenzen von Wörtern bzw. Wortmengen

- **Potenzen von Wörtern ω bzw. Wortmengen $\mathcal{F}$ sind gegeben durch:**
  - $\omega^0 := \varepsilon \qquad \omega^1 := \omega \qquad \omega^i := \omega^{i-1}\,\omega$, für $i \geq 1$
  - $\mathcal{F}^0 := \{\varepsilon\} \qquad \mathcal{F}^1 := \mathcal{F} \qquad \mathcal{F}^i := \mathcal{F}^{i-1}\,\mathcal{F}$, für $i \geq 1$

Beispiele für Potenzen von Wortmengen:

- DSilbe := {ba, di, ko}
- $\text{DSilbe}^0 = \{\varepsilon\}$, $\text{DSilbe}^1 = \{\text{ba, di, ko}\}$
- $\text{DSilbe}^2 = \text{DSilbe}^1\ \text{DSilbe}$
  = { baba, badi, bako, diba, didi, diko , koba, kodi, koko}
- $\text{DSilbe}^3 = \text{DSilbe}^2\ \text{DSilbe}$

Grundlagen formaler Sprachen:
Plus- und Sternhülle – formale Sprache

- Die **Plushülle** bzw. **Sternhülle** einer Wortmenge $\mathcal{F}$ werden definiert durch:

$$\mathcal{F}^{+} := \bigcup_{i \geq 1} \mathcal{F}^{i} \qquad \mathcal{F}^{*} := \bigcup_{i \geq 0} \mathcal{F}^{i}$$

- Ist Σ ein Alphabet, dann ist Σ^* die Gesamtheit aller Wörter über Σ. Jede Teilmenge dieser Sternhülle, $\mathcal{L} \subseteq \Sigma^*$, heißt **formale Sprache** über Σ .

Endlicher Automat (1/2)

- Ein endlicher Automat (*finite-state automaton, FSA*) ist ein formales System zur Erkennung von ([einer beschränkten Menge! von] formalen) Sprachen.
- Ein FSA beginnt den Erkennungsprozess in seinem ausgezeichneten Startzustand. Falls der FSA die Eingabe komplett gelesen hat und er sich in einem der ausgezeichneten Endzustände befindet, hat er die Eingabe akzeptiert, sonst nicht.

Endlicher Automat (2/2)

- Ein FSA besteht i.A. aus einem Eingabeband, auf dem der zu akzeptierende Ausdruck steht, und einem endlichen Steuerungs-mechanismus, der die Form der erlaubten Zustandsänderungen (Bewegungen) determiniert.
- Die Zustandsänderungsfunktion gibt an, welche möglichen Folgezustände aus dem aktuellen Zustand und dem aktuellen Symbol auf dem Eingabeband erreichbar sind.

Formale Grundlagen von Automaten: endlicher Automat

- Ein (nicht-deterministischer) endlicher Automat ist ein 5-Tupel $(Q, \Sigma, \delta, q_o, F)$ mit
  - Q: endliche Menge von (Steuerungs-)Zuständen $q_o, q_1, q_2, \ldots, q_n$
  - Σ: endliches Eingabealphabet
  - δ: Zustandsübergangsfunktion, die das Steuerungsverhalten des FSA determiniert

$$\delta : Q \times \Sigma \mapsto \wp(Q)$$

  - $q_o \in Q$: der ausgezeichnete Startzustand
  - $F \subseteq Q$: Menge der ausgezeichneten Endzustände

Graph- und Funktionsnotation für Dederivationsautomaten (1/2)

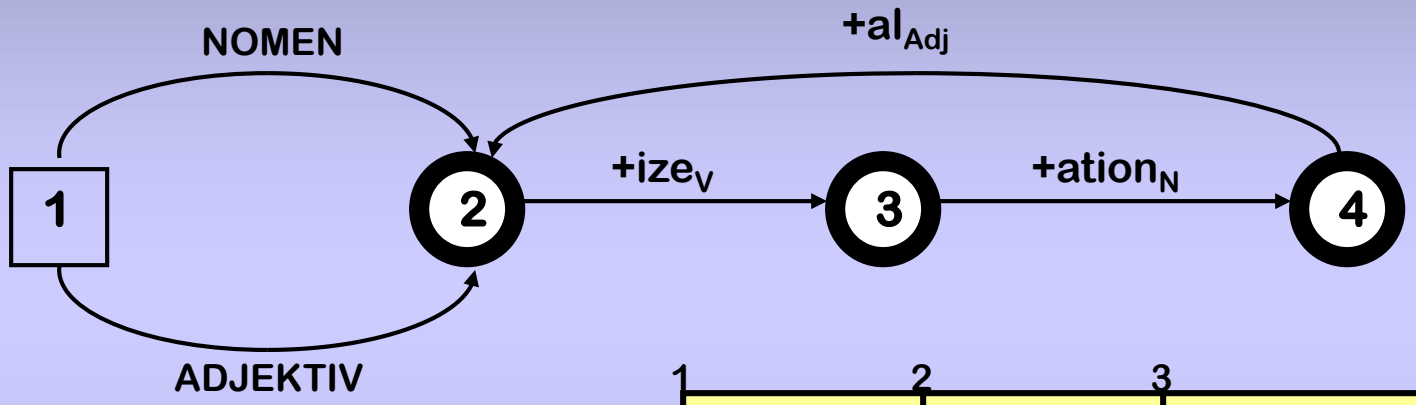

NOMEN: hospital, motor, category, ...

ADJEKTIV: moral, concrete, tender, ...

$\delta(1,\text{hospital}) = 2$
$\delta(2,+\text{ize}_V) = 3$
$\delta(3,+\text{ation}_N) = 4$

n Anfangszustand

n möglicher Endzustand

Graph- und Funktionsnotation für Dederivationsautomaten (2/2)

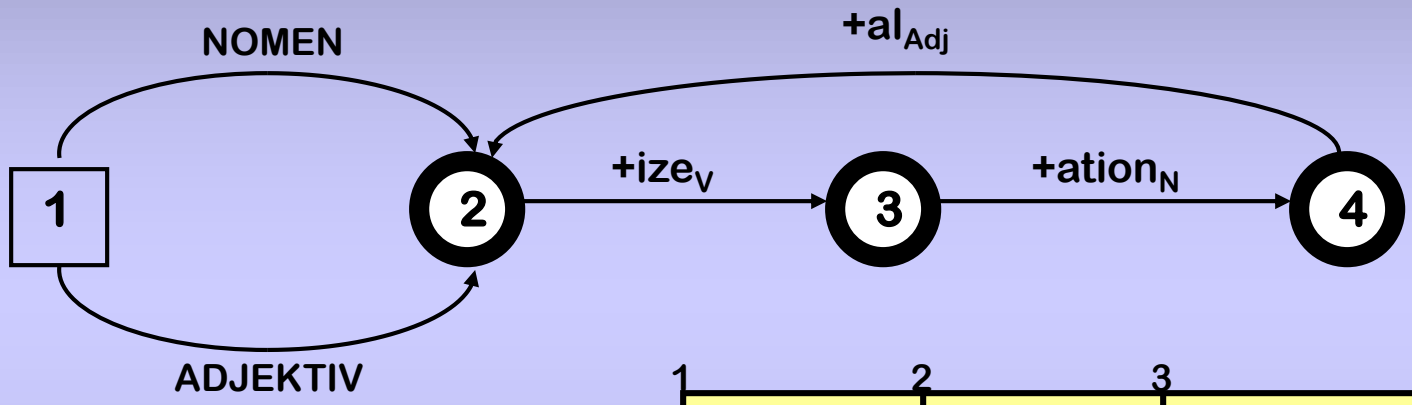

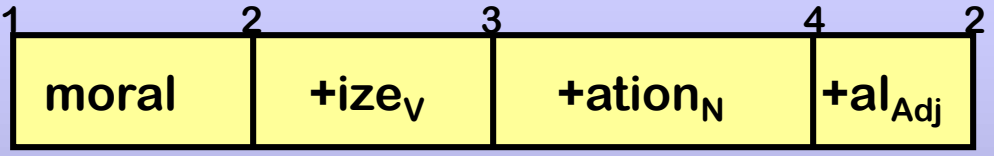

NOMEN: hospital, motor, category, …

ADJEKTIV: moral, concrete, tender, …

$\delta(1,\text{hospital}) = 2$ $\quad \delta(1,\text{moral}) = 2$

$\delta(2,+\text{ize}_V) = 3$ $\quad \delta(2,+\text{ize}_V) = 3$

$\delta(3,+\text{ation}_N) = 4$ $\quad \delta(3,+\text{ation}_N) = 4$

$\delta(4,+\text{al}_{Adj}) = 2$

n **Anfangszustand** (n) **möglicher Endzustand**

Graph- und Tabellennotation für Dederivationsautomaten

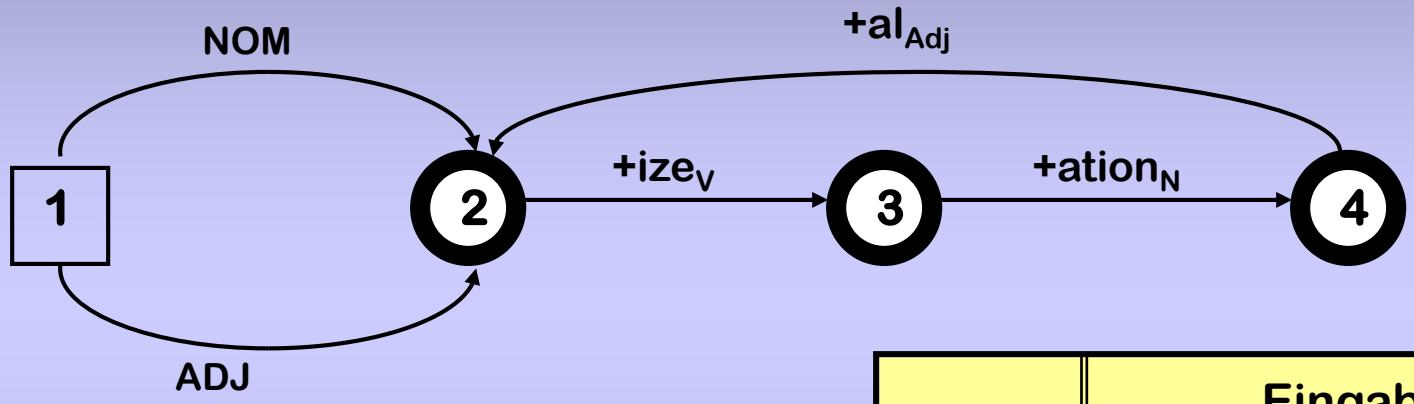

n **Anfangszustand**

n **möglicher Endzustand**

Zustand	Eingabesymbol			
	NOM|ADJ	+ize$_V$	+ation$_N$	+al$_{Adj}$
1	2	0	0	0
2	0	3	0	0
3	0	0	4	0
4	0	0	0	2

Graph- und Tabellennotation für Dederivationsautomaten

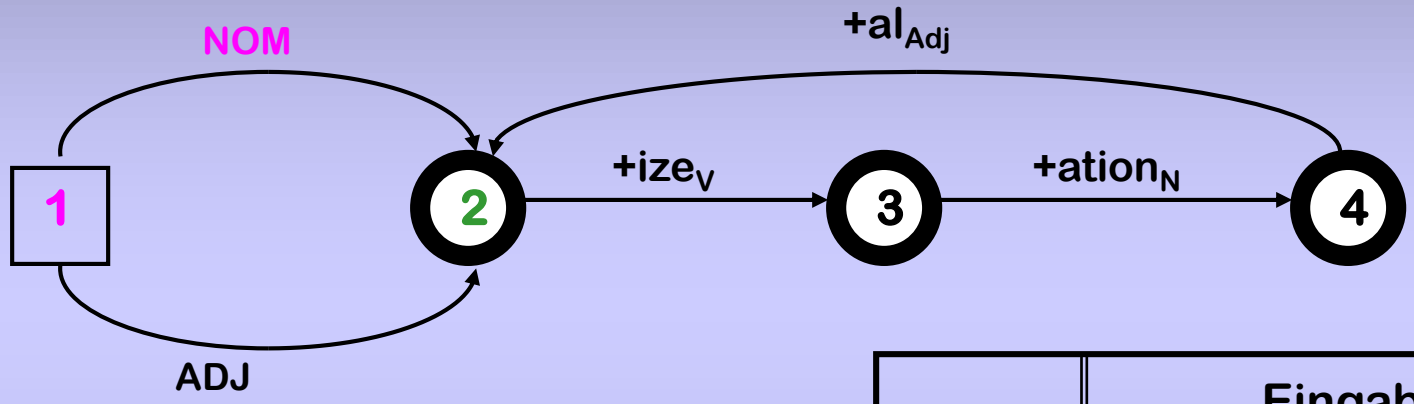

n **Anfangszustand**

n **möglicher Endzustand**

Zustand	Eingabesymbol			
	NOM|ADJ	+ize$_V$	+ation$_N$	+al$_{Adj}$
1	2	0	0	0
2	0	3	0	0
3	0	0	4	0
4	0	0	0	2

Graph- und Tabellennotation für Dederivationsautomaten

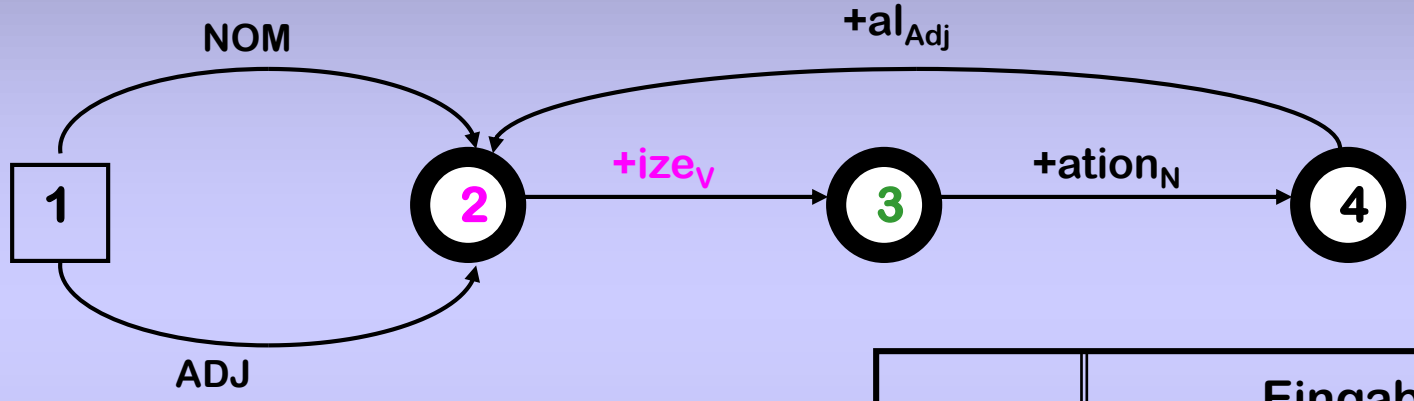

n **Anfangszustand**

n **möglicher Endzustand**

Zustand	Eingabesymbol			
	NOM|ADJ	+ize$_V$	+ation$_N$	+al$_{Adj}$
1	2	0	0	0
2	0	3	0	0
3	0	0	4	0
4	0	0	0	2

Graph- und Tabellennotation für Dederivationsautomaten

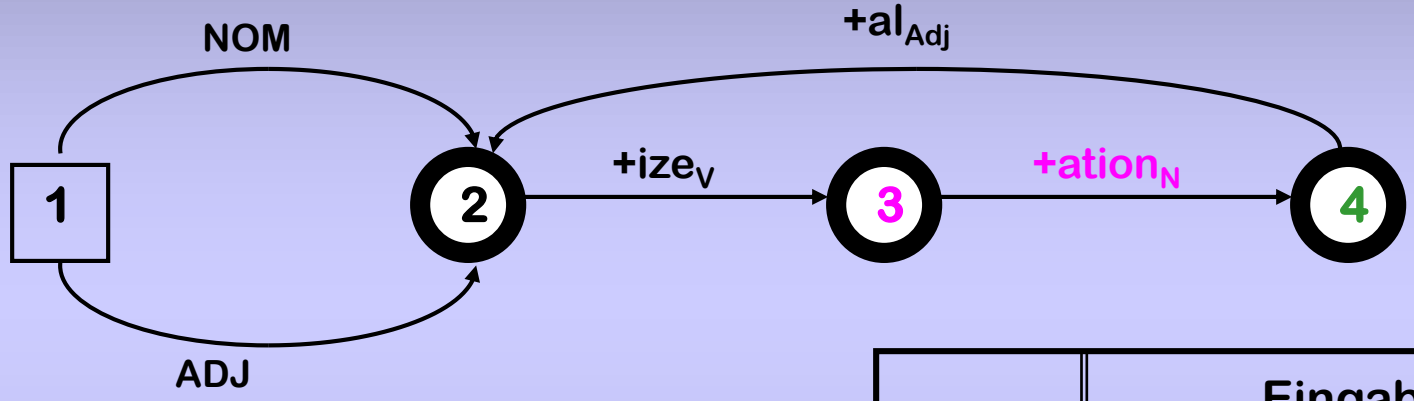

n Anfangszustand

n möglicher Endzustand

Zustand	Eingabesymbol			
	NOM|ADJ	+ize$_V$	+ation$_N$	+al$_{Adj}$
1	2	0	0	0
2	0	3	0	0
3	0	0	4	0
4	0	0	0	2

Graph- und Tabellennotation für Dederivationsautomaten

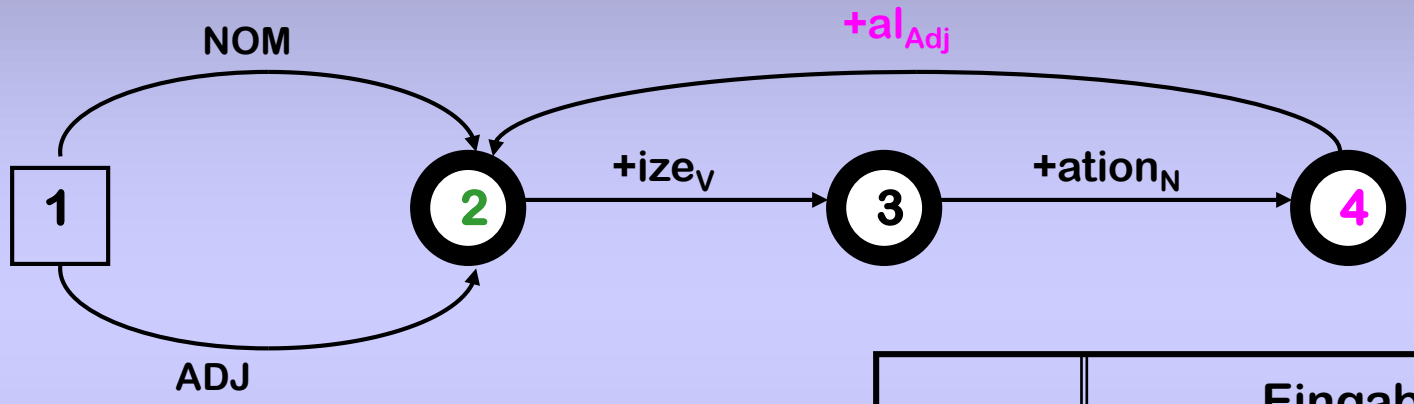

n **Anfangszustand**

n **möglicher Endzustand**

Zustand	Eingabesymbol			
	NOM|ADJ	+ize$_V$	+ation$_N$	+al$_{Adj}$
1	2	0	0	0
2	0	3	0	0
3	0	0	4	0
4	0	0	0	2

Komplexerer Dederivationsautomat

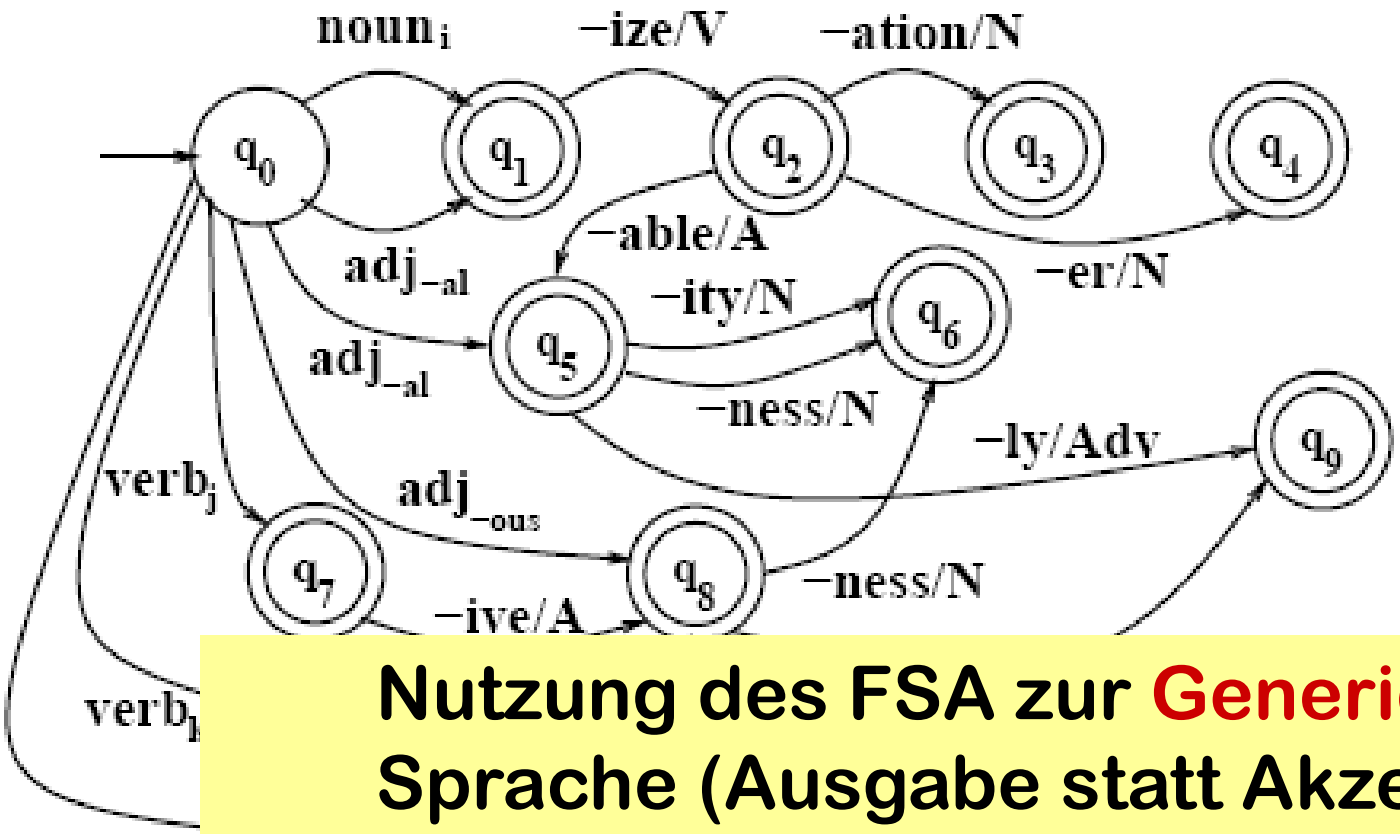

Nutzung des FSA zur Generierung von Sprache (Ausgabe statt Akzeptanz von Symbolen bei Kantentraversierung);
FSA definiert Sprache!

Formale Grundlagen von Automaten: endlicher Automat

- Ein (nicht-deterministischer) endlicher Automat ist ein 5-Tupel $(Q, \Sigma, \delta, q_o, F)$ mit
  - Q: endliche Menge von (Steuerungs-)Zuständen $q_o, q_1, q_2, \ldots, q_n$
  - Σ: endliches Eingabealphabet
  - δ: Zustandsübergangsfunktion, die das Steuerungsverhalten des FSA determiniert

$$\delta : Q \times \Sigma \mapsto \wp(Q)$$

  - $q_o \in Q$: der ausgezeichnete Startzustand
  - $F \subseteq Q$: Menge der ausgezeichneten Endzustände

Formale Grundlagen von Automaten: Konfiguration

- Sei FSA = $(Q, \Sigma, \delta, q_o, F)$ ein (nicht-deterministischer) endlicher Automat.

  Dann heiße ein Paar $(q,\omega) \in Q \times \Sigma^*$ eine Konfiguration von FSA.

  Eine Konfiguration der Form (q_o,ω) heiße initiale Konfiguration, eine der Form (q,ε), wobei $q \in F$, heiße akzeptierende bzw. Endkonfiguration.

Formale Grundlagen von Automaten: Bewegung

- Sei FSA = $(Q, \Sigma, \delta, q_o, F)$ ein (nicht-deterministischer) endlicher Automat.

  Eine **Bewegung** in FSA wird durch eine binäre Relation $\vdash_{FSA}$ *(„geht unter FSA nach“)* über Konfigurationen repräsentiert:

$$\vdash_{FSA} \subseteq Q \times \Sigma^*$$

Formale Grundlagen von Automaten: Bewegung

- Sei FSA = $(Q, \Sigma, \delta, q_o, F)$ ein (nicht-deterministischer) endlicher Automat.

  Eine **Bewegung** in FSA wird durch eine binäre Relation $\vdash_{FSA}$ *(„geht unter FSA nach“)* über Konfigurationen repräsentiert.

  Falls $q' \in \delta(q,\tau)$ (q' ist also ein möglicher Folgezustand von q, $\tau \in \Sigma$), dann gilt:

  $$(q,\tau\gamma) \vdash_{FSA} (q',\gamma) \text{ für alle } \gamma \in \Sigma^*$$

Formale Grundlagen von Automaten: Akzeptanz

- Sei FSA = $(Q, \Sigma, \delta, q_o, F)$ ein (nicht-deterministischer) endlicher Automat und $\vdash^*_{FSA}$ die reflexive und transitive Hülle von $\vdash_{FSA}$.
  - **reflexive Hülle**:
    - $(q, \tau) \vdash_{FSA} (q, \tau)$ für alle $(q, \tau) \in Q \times \Sigma^*$
  - **transitive Hülle**:
    - $(q', \tau_1) \vdash_{FSA} (q'', \tau_2)$ und $(q'', \tau_2) \vdash_{FSA} (q''', \tau_3)$ $\Rightarrow (q', \tau_1) \vdash_{FSA} (q''', \tau_3)$ für alle $(q, \tau) \in Q \times \Sigma^*$

Formale Grundlagen von Automaten: Akzeptanz

- Sei FSA = $(Q, \Sigma, \delta, q_o, F)$ ein (nicht-deterministischer) endlicher Automat und $\vdash^*_{FSA}$ die reflexive und transitive Hülle von $\vdash_{FSA}$.

  Eine Eingabekette ω wird durch den FSA akzeptiert, wenn

  $(q_o, \omega) \vdash^*_{FSA} (q, \varepsilon)$ für ein $q \in F$.

Formale Grundlagen von Automaten: akzeptierte Sprache

- Sei FSA = $(Q, \Sigma, \delta, q_0, F)$ ein (nicht-deterministischer) endlicher Automat und $\vdash^*_{FSA}$ die reflexive und transitive Hülle von $\vdash_{FSA}$.

  Die (formale) Sprache $\mathcal{L}_{FSA}$, die durch FSA definiert wird, ist die Menge von Eingabeketten, die vom FSA akzeptiert wird:

  $\mathcal{L}_{FSA} := \{ \omega | \omega \in \Sigma^*, (q_0,\omega) \vdash^*_{FSA} (q,\varepsilon) \text{ für ein } q \in F \}$

  $\subseteq \Sigma^*$

Automat für Dederivation

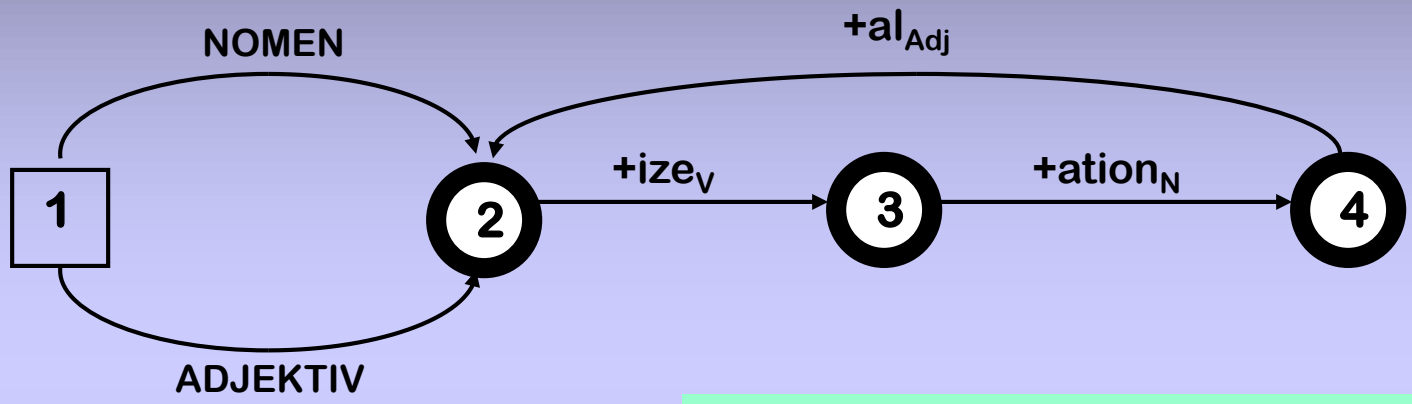

NOMEN: hospital, motor, category, …

ADJEKTIV: moral, concrete, tender, …

n Anfangszustand

n möglicher Endzustand

$$\text{hospital+ize}_V\text{+ation}_N \in \mathcal{L}_{FSA}$$?

Automat für Dederivation

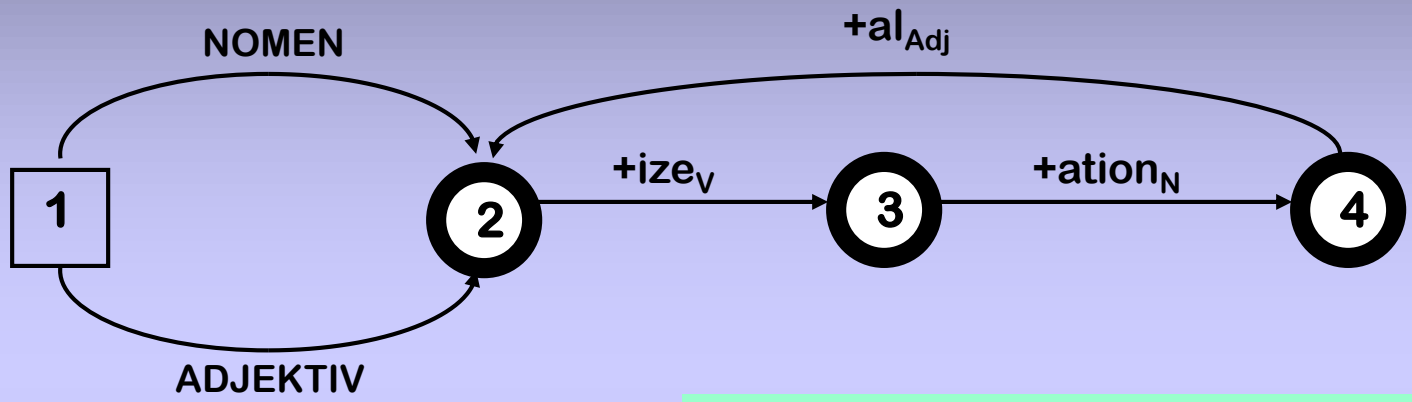

NOMEN: hospital, motor, category, …

ADJEKTIV: moral, concrete, tender, …

n Anfangszustand

(n) möglicher Endzustand

$hospital+ize_V+ation_N \in \mathcal{L}_{FSA}$!

$\{ ((1, hospital+ize_V+ation_N), (4, \varepsilon)) \} \subseteq \vdash^*_{FSA};$

$((1, hospital+ize_V+ation_N), (4, \varepsilon)) \in \vdash^*_{FSA}$

Endlicher Automat

- Das Verhalten eines FSAs hängt von zwei Arten von Informationen ab:
  - dem aktuellen Zustand des endlichen Steuerungssystems,
  - der Symbolkette auf dem Eingabeband, die aus dem aktuellen Symbol unter dem Lesekopf und allen folgenden Symbolen rechts vom aktuellen Symbol besteht

Deterministischer FSA-Erkennungsalgorithmus

- **Band** (für die zu testende Kette)
  - in n Zellen aufgeteilt
  - jede Zelle hält ein Symbol der Kette
- **Zustandstransitionstabelle** (2-D Matrix)
  - Zeilen: Zustandsmarken des FSA
  - Spalten: Symbole des Alphabets
  - Zelle: Folgezustand

Automat für Dederivation

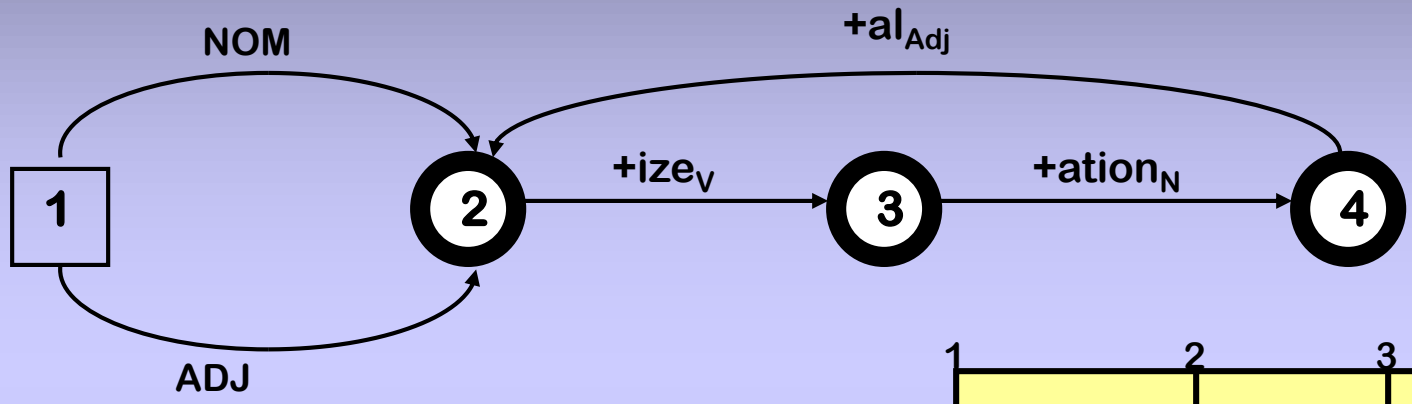

1	2	3	4
hospital	+ize$_V$	+ation$_N$	ε

NOM: hospital, motor, category, …

ADJ: moral, concrete, tender, …

n Anfangszustand

n möglicher Endzustand

Zustand	Eingabe			
	NOM|ADJ	+ize$_V$	+ation$_N$	+al$_{Adj}$
1	2	0	0	0
2	0	3	0	0
3	0	0	4	0
4	0	0	0	2

Deterministischer FSA-Erkennungsalgorithmus

Funktion D-Erkenner(↓Band,↓FSA) = „accept“ oder **„reject“**

```
Index ⇐ Bandanfang
AktualZustand ⇐ Anfangszustand des FSA
LOOP
IF   Ende der Eingabekette ist erreicht   THEN
     IF     AktualZustand ist ein Endzustand   THEN return „accept“
     ELSE   return „reject“
ELSE-IF   Zustandstransitionstabelle[ AktualZustand, Band(Index) ] = 0   THEN
          return „reject“
       ELSE   AktualZustand ⇐ Zustandstransitionstabelle[ AktualZustand, Band(Index) ]
              Index ⇐ Index + 1
LOOPEND
```


Funktion Band(Index) ermittelt das Symbol, das auf der Position **Index** im **Band** steht

Morphologisches Parsing

- Lexikon
  - Liste von Stämmen und Affixen sowie geeigneten morphologischen Merkmalen
- Morphotaktik
  - Modell der Ordnung von Morphemklassen in flektierten Wortformen
    - Beispiel: Pluralsuffix nach Stamm
- Orthographieregeln
  - Regeln zur Beschreibung von Kombinationseffekten bei Morphemen
    - Beispiel aus dem Englischen: y ↦ ie

Zwei-Ebenen-Morphologie

- **Lexikalische Ebene**
  - Wortrepräsentation als Konkatenation von Morphemen

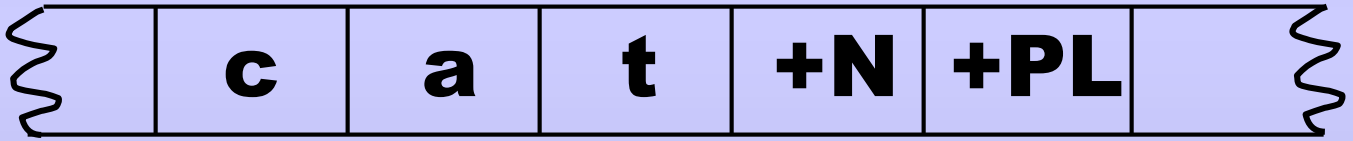

- **Oberflächenebene**
  - Wortrepräsentation als Abfolge von Buchstaben

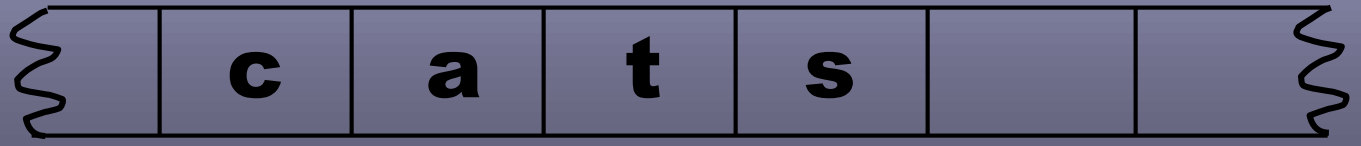

Zwei-Ebenen-Morphologie

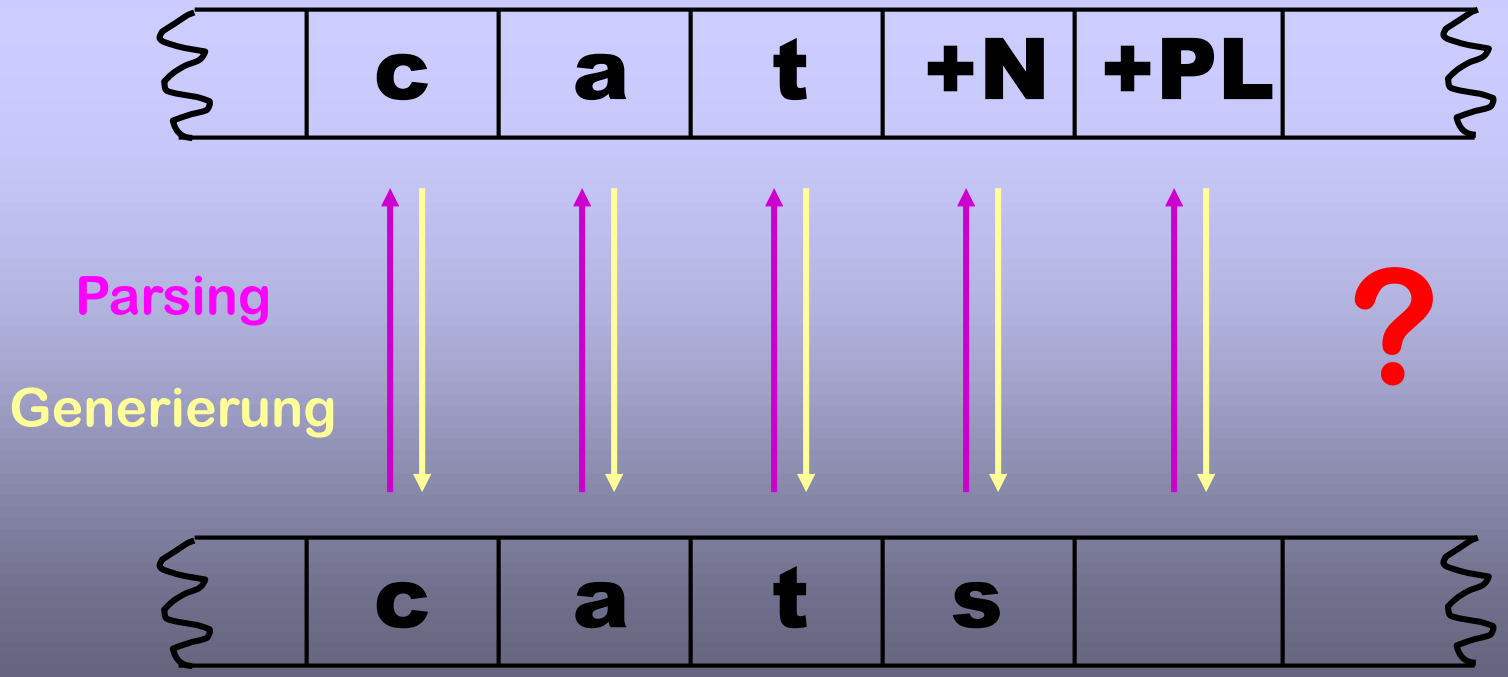

Erinnerung: endlicher Automat

- Ein (nicht-deterministischer) endlicher Automat ist ein 5-Tupel $(Q, \Sigma, \delta, q_o, F)$ mit
  - Q: endliche Menge von (Steuerungs-)Zuständen $q_o, q_1, q_2, \ldots, q_n$
  - Σ: endliches Eingabealphabet
  - δ: Zustandsübergangsfunktion, die das Steuerungsverhalten des FSA determiniert

$$\delta : Q \times \Sigma \mapsto \wp(Q)$$

  - $q_o \in Q$: der ausgezeichnete Startzustand
  - $F \subseteq Q$: Menge der ausgezeichneten Endzustände

Formale Grundlagen von Automaten: endlicher Transduktor

- Ein (nicht-deterministischer) endlicher Transduktor ist ein 5-Tupel $(Q, \Sigma, \delta, q_o, F)$ mit
  - Q: endliche Menge von (Steuerungs-)Zuständen
  - $\Sigma \subseteq I \times O$: endliches Alphabet mit komplexen Symbolen, die aus Eingabe-Ausgabe-Paaren *i:o* bestehen, $i \in I$ (Eingabealphabet), $o \in O$ (Ausgabealphabet), beide inkl. ε
  - δ: Zustandsübergangsfunktion $\delta(q, i{:}o)$, die das Steuerungsverhalten des FST determiniert

$$\delta : Q \times \Sigma \mapsto \wp(Q)$$

  - $q_o \in Q$: der ausgezeichnete Startzustand
  - $F \subseteq Q$: Menge der ausgezeichneten Endzustände

Formale Grundlagen von Automaten: endlicher Transduktor

- Ein (nicht-deterministischer) endlicher Transduktor ist ein 6-Tupel $(Q, \Sigma, \Delta, \delta, q_o, F)$ mit
  - Q: endliche Menge von (Steuerungs-)Zuständen
  - Σ: endliches Eingabealphabet (inkl. ε)
  - Δ: endliches Ausgabealphabet (inkl. ε)
  - δ: Zustandsübergangsfunktion, die das Steuerungsverhalten des FST determiniert

$$\delta : Q \times \Sigma \mapsto \wp(Q \times \Delta^*)$$

  - $q_o \in Q$: der ausgezeichnete Startzustand
  - $F \subseteq Q$: Menge der ausgezeichneten Endzustände

Akzeptierte Sprache: FSA *vs.* FST

- Ein FSA akzeptiert eine Sprache, die über einem Alphabet *einzelner* Symbole spezifiziert ist
- Ein FST akzeptiert eine Sprache, die über *Paaren* von Symbolen spezifiziert ist. Diese werden auch *zulässige Paare (feasible pairs)* genannt.

Konventionen zur Zwei-Ebenen-Morphologie

- Zeichenpaare für FSTs (α:γ) werden so kodiert, dass α das Zeichen auf dem Lexikalischen Band und γ das auf dem Oberflächenband bezeichnet.
- Identische Zeichenpaare für FSTs (α:α) heißen Default-Paare und werden auch kurz als α notiert.
- @ (oder =) steht für ein beliebiges Symbol
- ^ ist das Morphembegrenzungssymbol
- # ist das Wortbegrenzungssymbol

FSA für Flexionsmorphologie: Englische Nomen

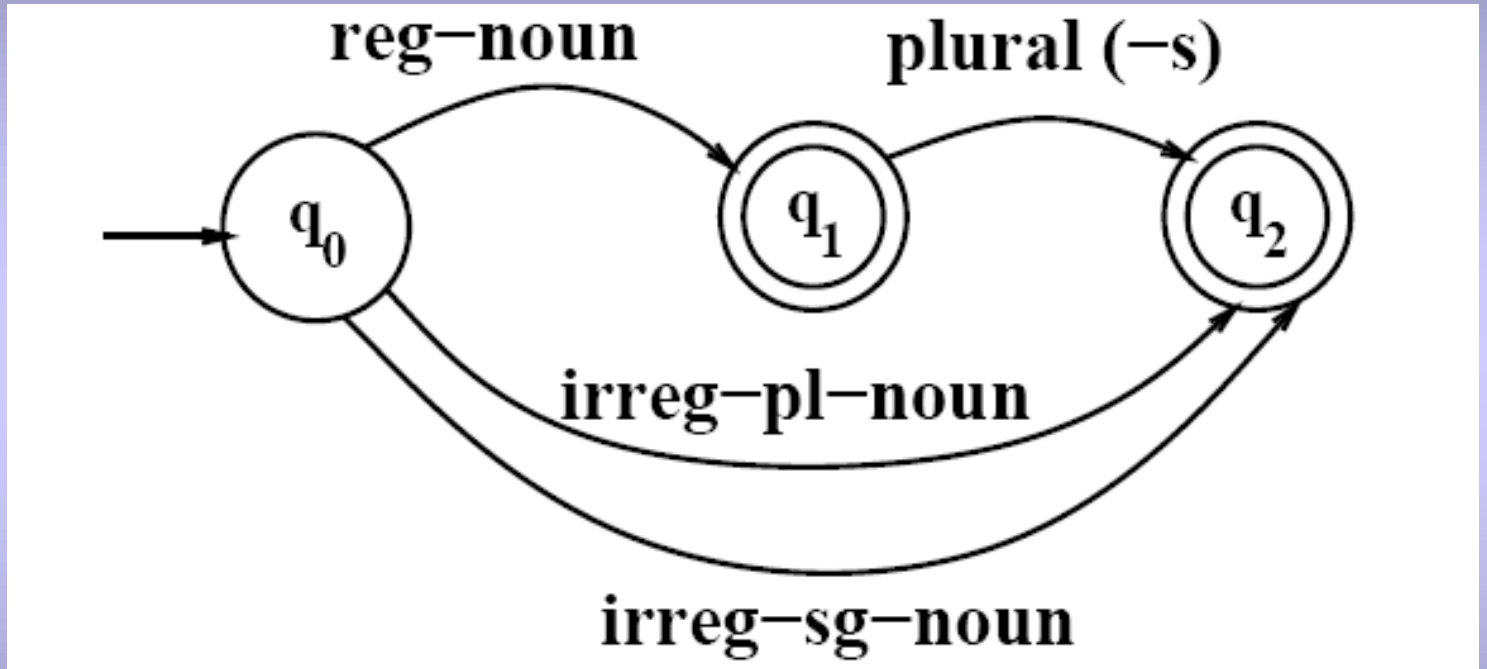

reg-noun	irreg-pl-noun	irreg-sg-noun	plural
aardvark cat dog fox	geese sheep mice	goose sheep mouse	-s

FSAs als Erkenner mit integrierten Sublexika als TRIE

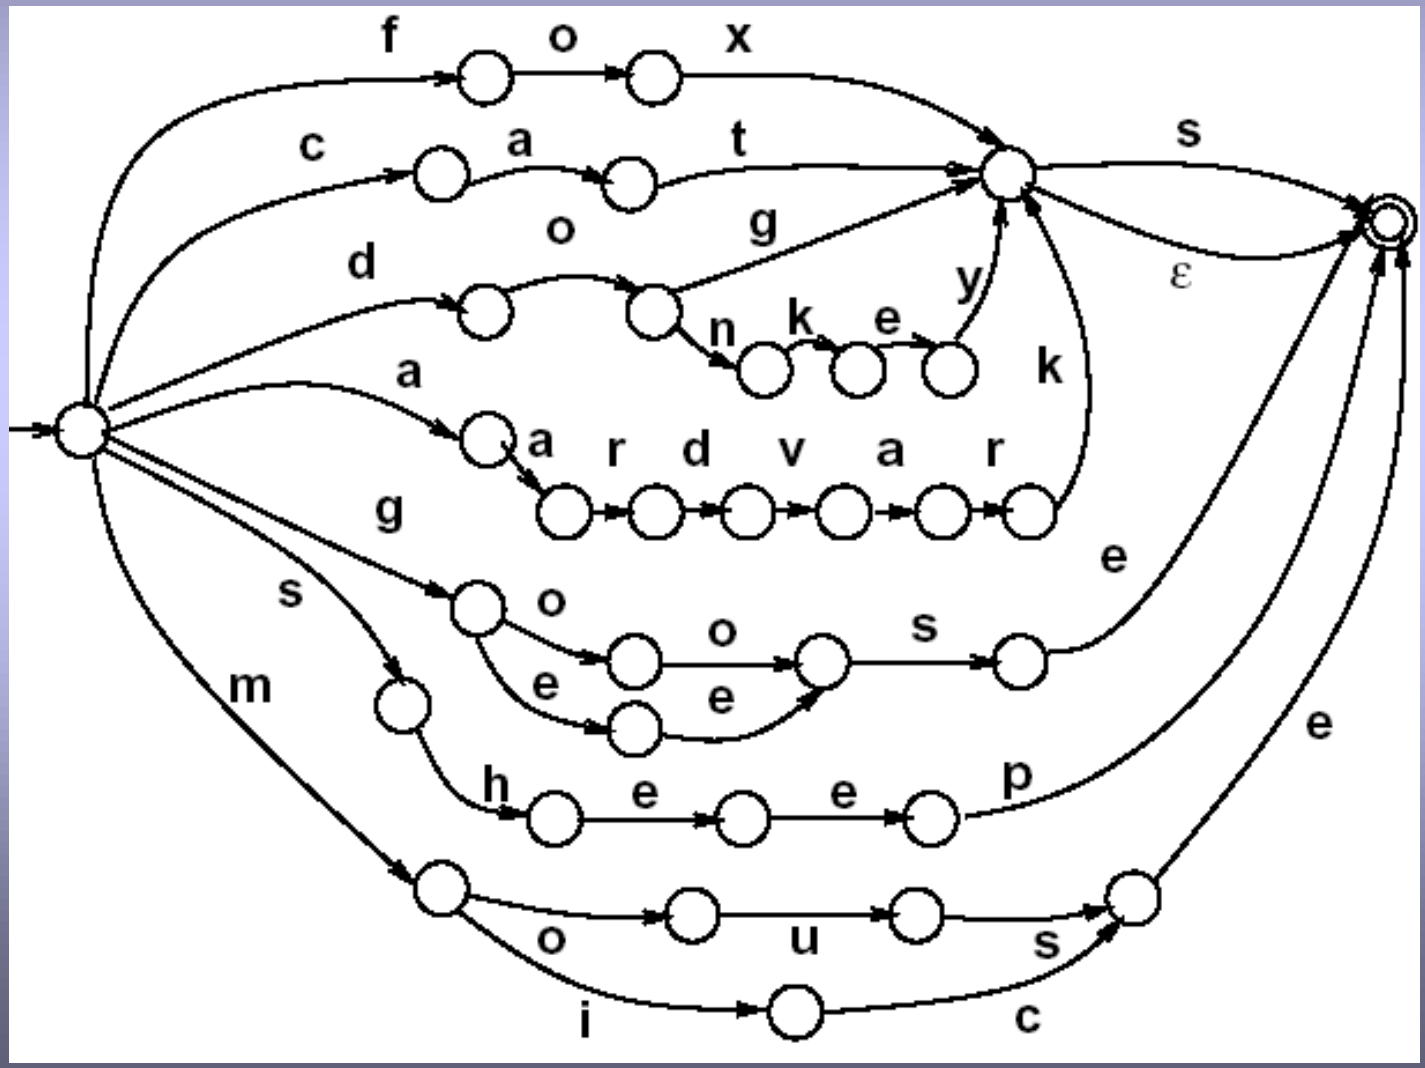

FST für Flexionsmorphologie: Englische Nomen

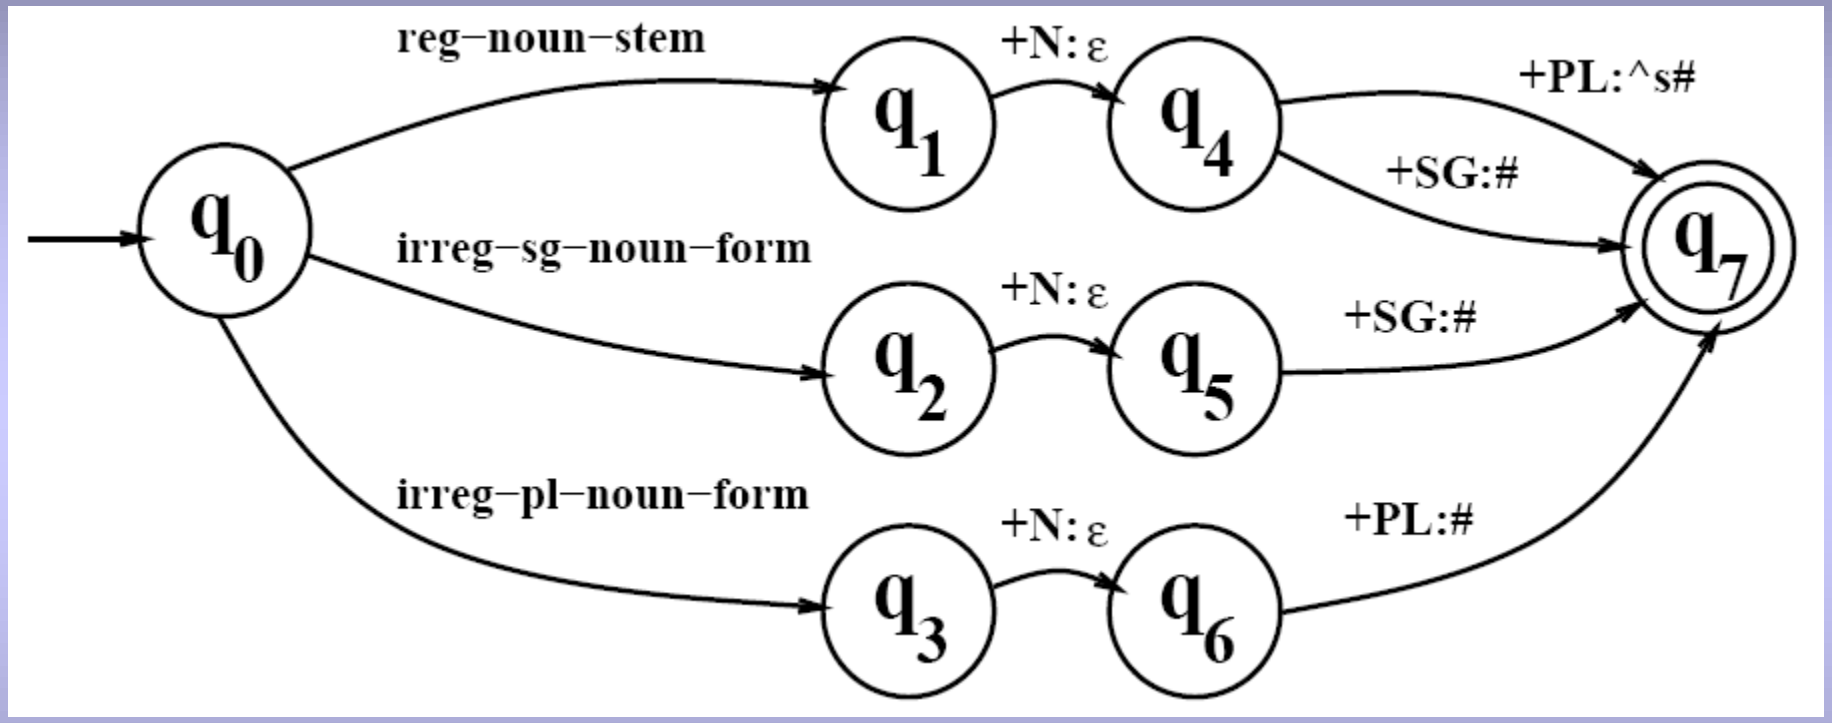

reg-noun	irreg-pl-noun	irreg-sg-noun
aardvark	g o:e o:e s e	goose
cat	sheep	sheep
dog	m o:i u:ε s:c e	mouse
fox		

FSTs als Wort-Parser mit Fortsetzungslexikon als TRIE

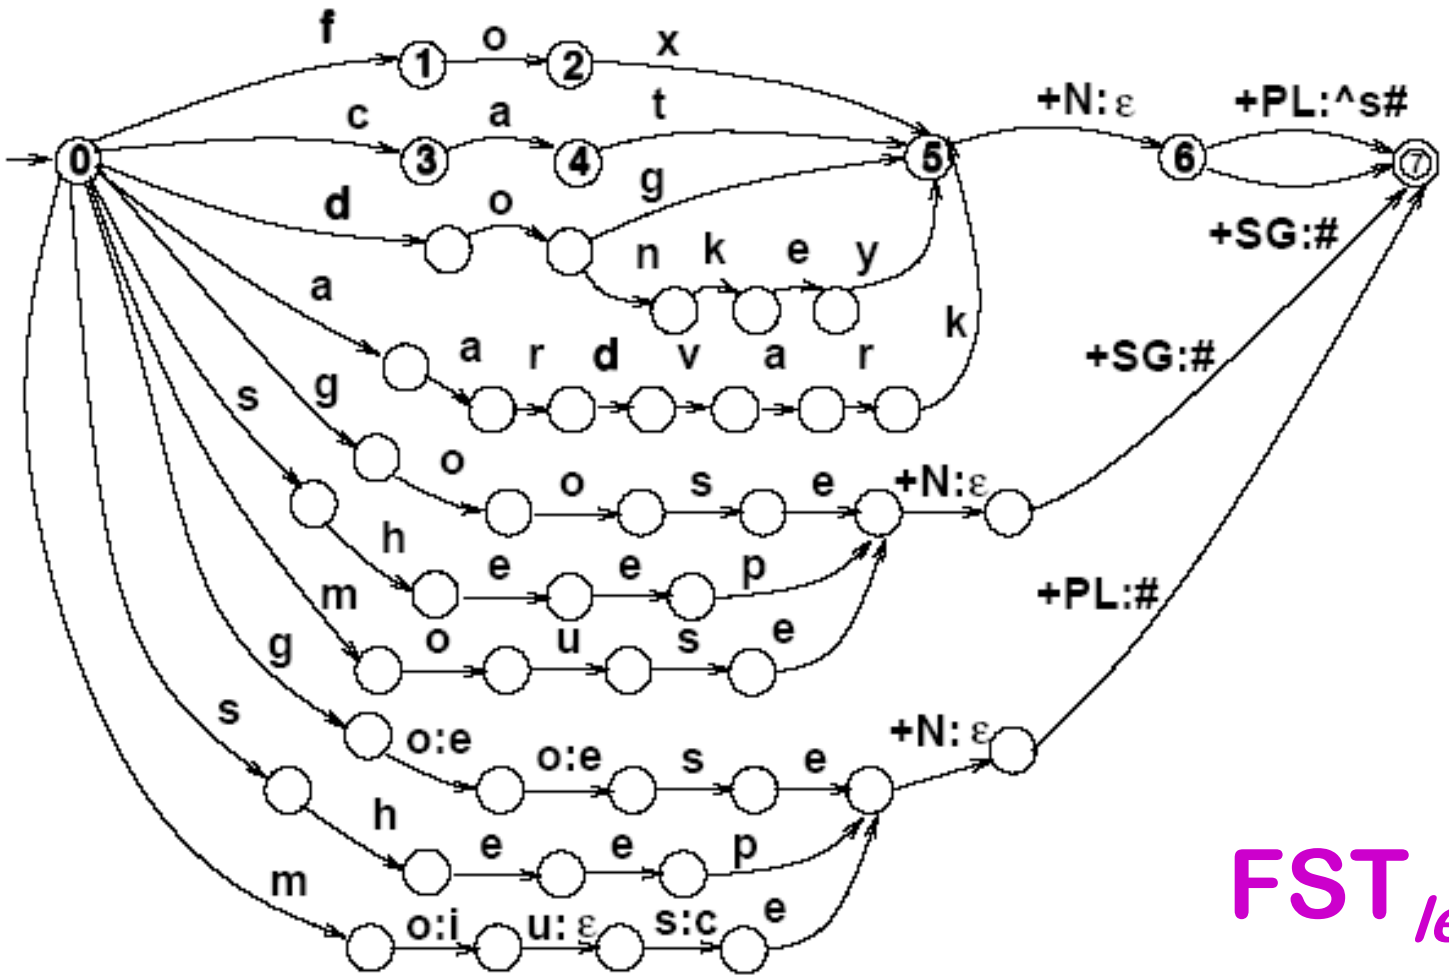

Lexikalische und Intermediäre Bänder

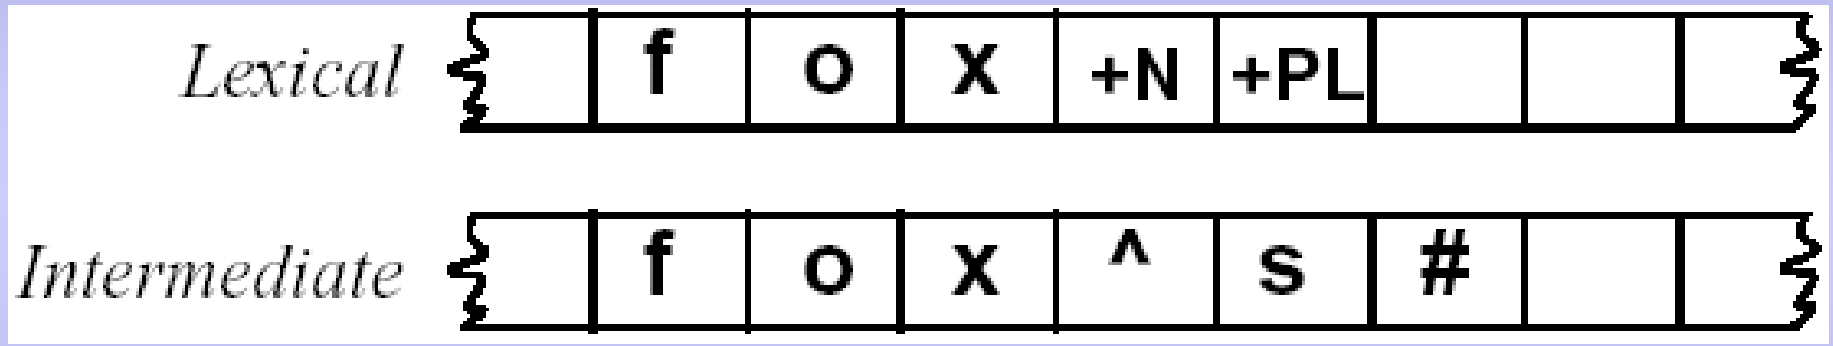

Problem:

Orthographische Regeln:

FST würde korrekte Form *foxes* zurückweisen, aber inkorrekte Form *foxs* akzeptieren

Einige englische Orthographieregeln

Für jede Regel einen Transduktor!

Name	Regelbeschreibung	Beispiel
Consonant Doubling	1-letter consonant doubled before *-ing/-ed*	beg/begging
E-deletion	Silent *e* dropped before *-ing* and *-ed*	make/making
E-insertion	*e* added after *s,z,x,ch,sh* before *s*	watch/watches
Y-replacement	*-y* changes to *-ie* before *-s*, to *-i* before *-ed*	try/tries, try/tried
K-insertion	verbs ending with vowel *+ -c* add *-k*	panic/panicked

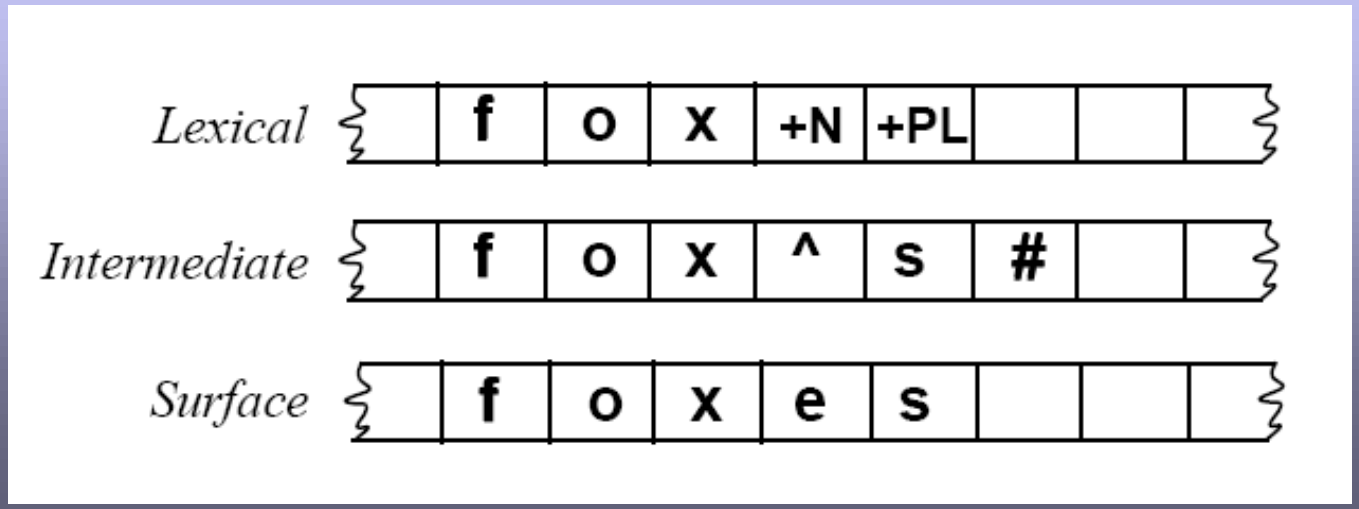

Intermediär-Oberflächenband-Transduktor (E-Insertion)

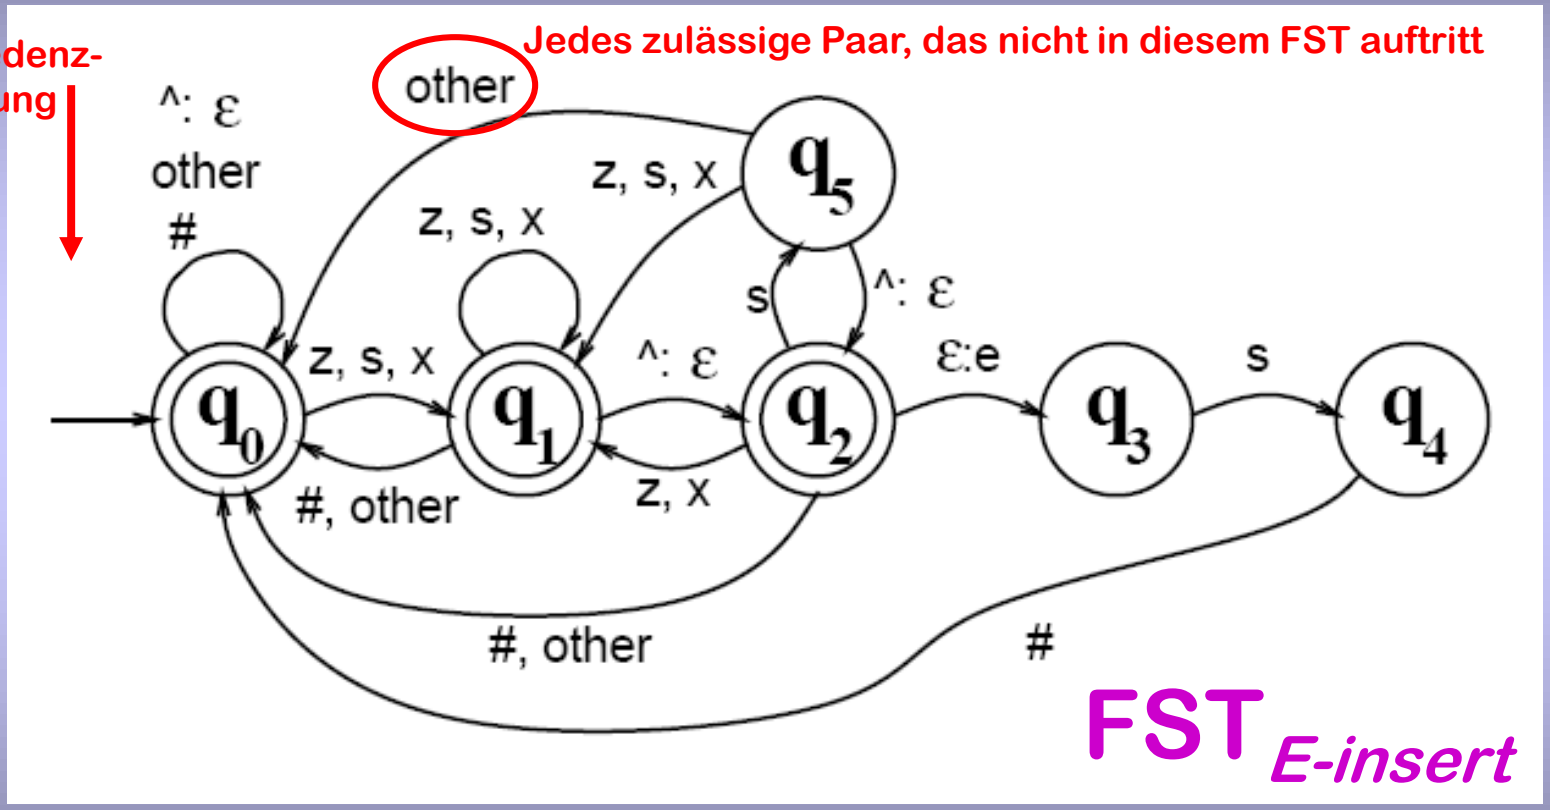

„Füge ein „e" auf dem Oberflächenband ein, wenn auf dem Lexikalischen Band ein Morphem auf „x", „s" oder „z" endet und das nächste Morphem ein „s" ist."

Zustandstransitionstabelle für E-Insertion

State \ Input	s : s	x : x	z : z	^:ε	ε : e	#	other
q_0:	1	1	1	0	-	0	0
q_1:	1	1	1	2	-	0	0
q_2:	5	1	1	0	3	0	0
q_3	4	-	-	-	-	-	-
q_4	-	-	-	-	-	0	-
q_5	1	1	1	2	-	-	0

Explizite Markierung illegaler Transitionen

FST-Akzeptanz-Beispiel

FST *lex*

FST *E-insert*

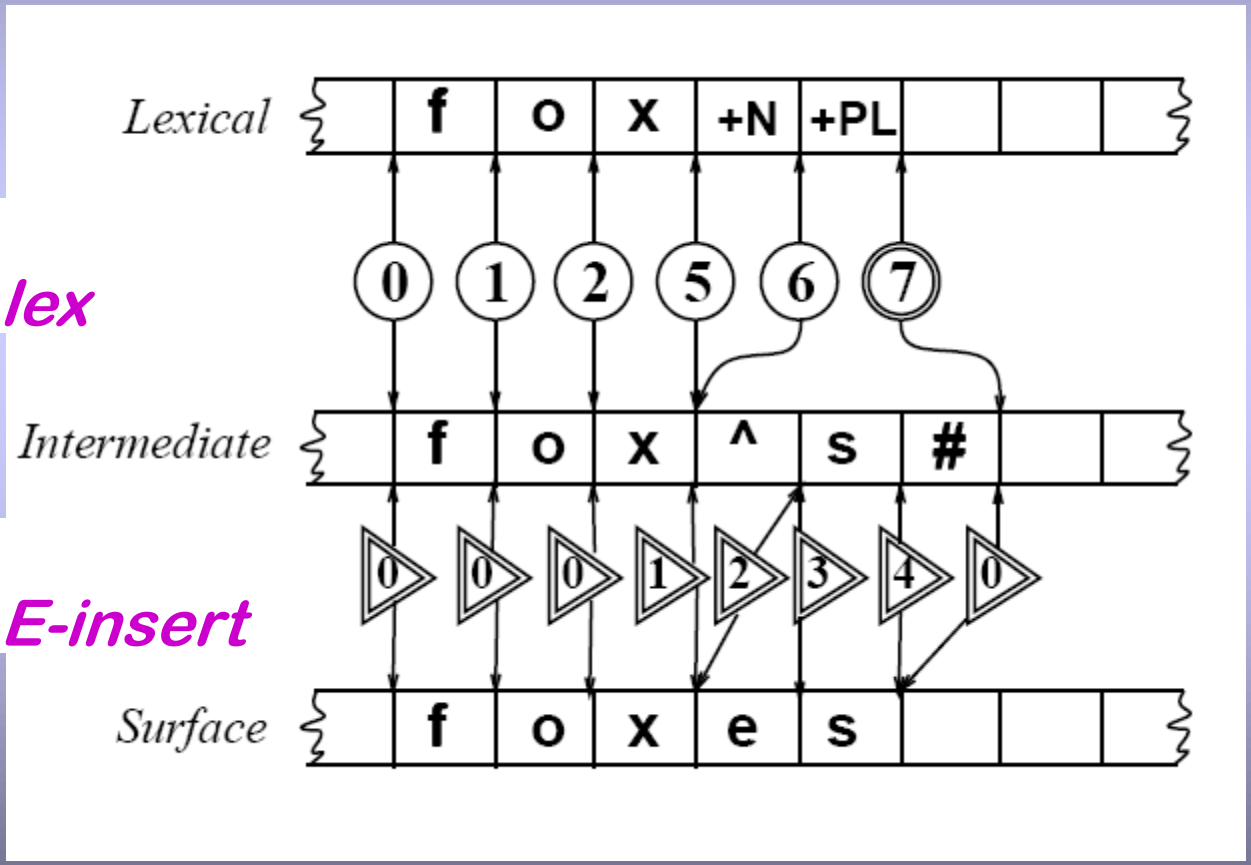

FST-Akzeptanz-Beispiel

FST *lex*

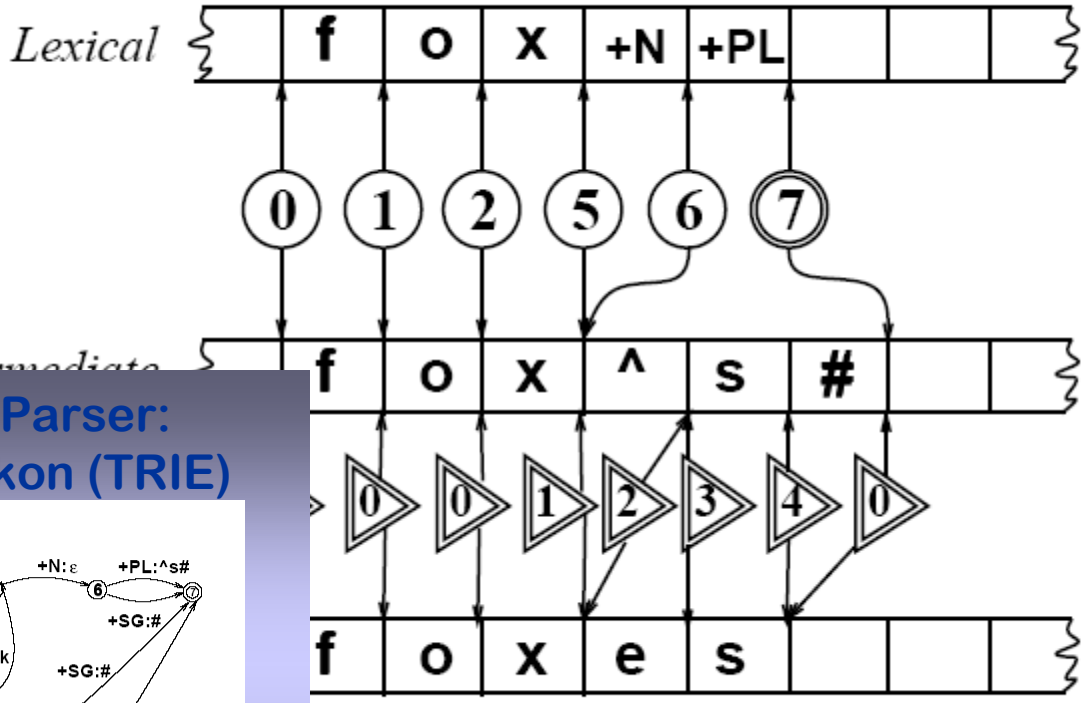

FSTs als Wort-Parser: Fortsetzungslexikon (TRIE)

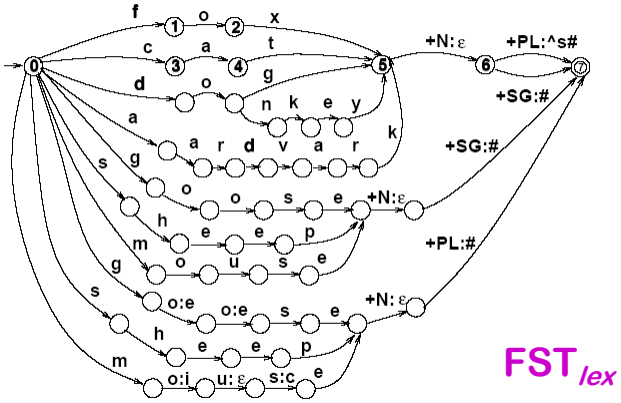

FST-Akzep

Intermediär-Oberflächenband-Transduktor (E-Insertion)

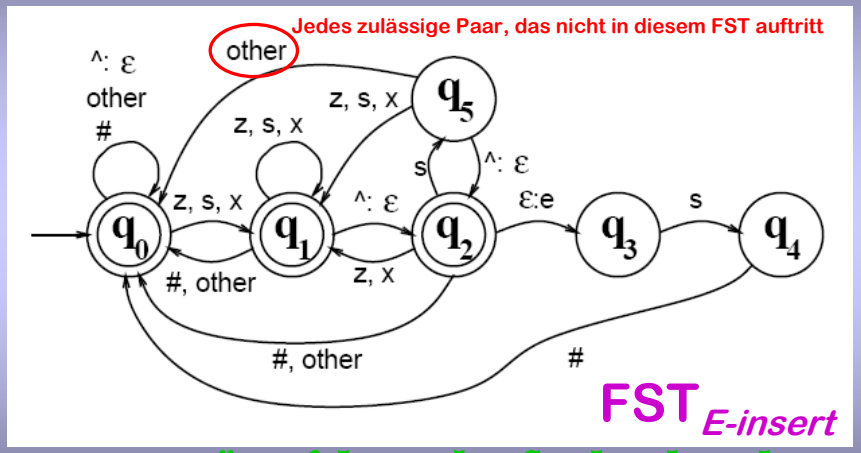

„Füge ein „e" auf dem Oberflächenband ein, wenn auf dem lexikalischen Band ein Morphem auf „x", „s" oder „z" endet und das nächste Morphem ein „s" ist."

49

FST *lex*

FST *E-insert*

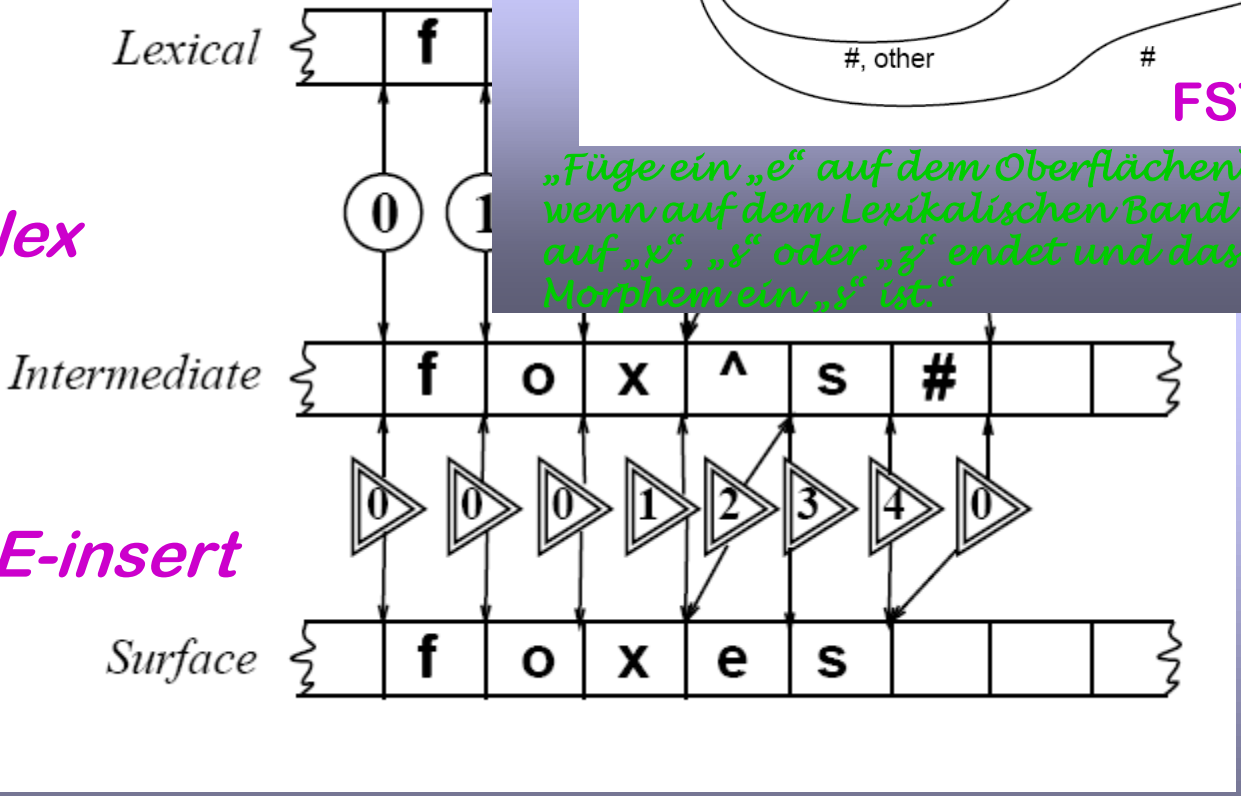

Zwei-Ebenen-Morphologie: Parser/Generator

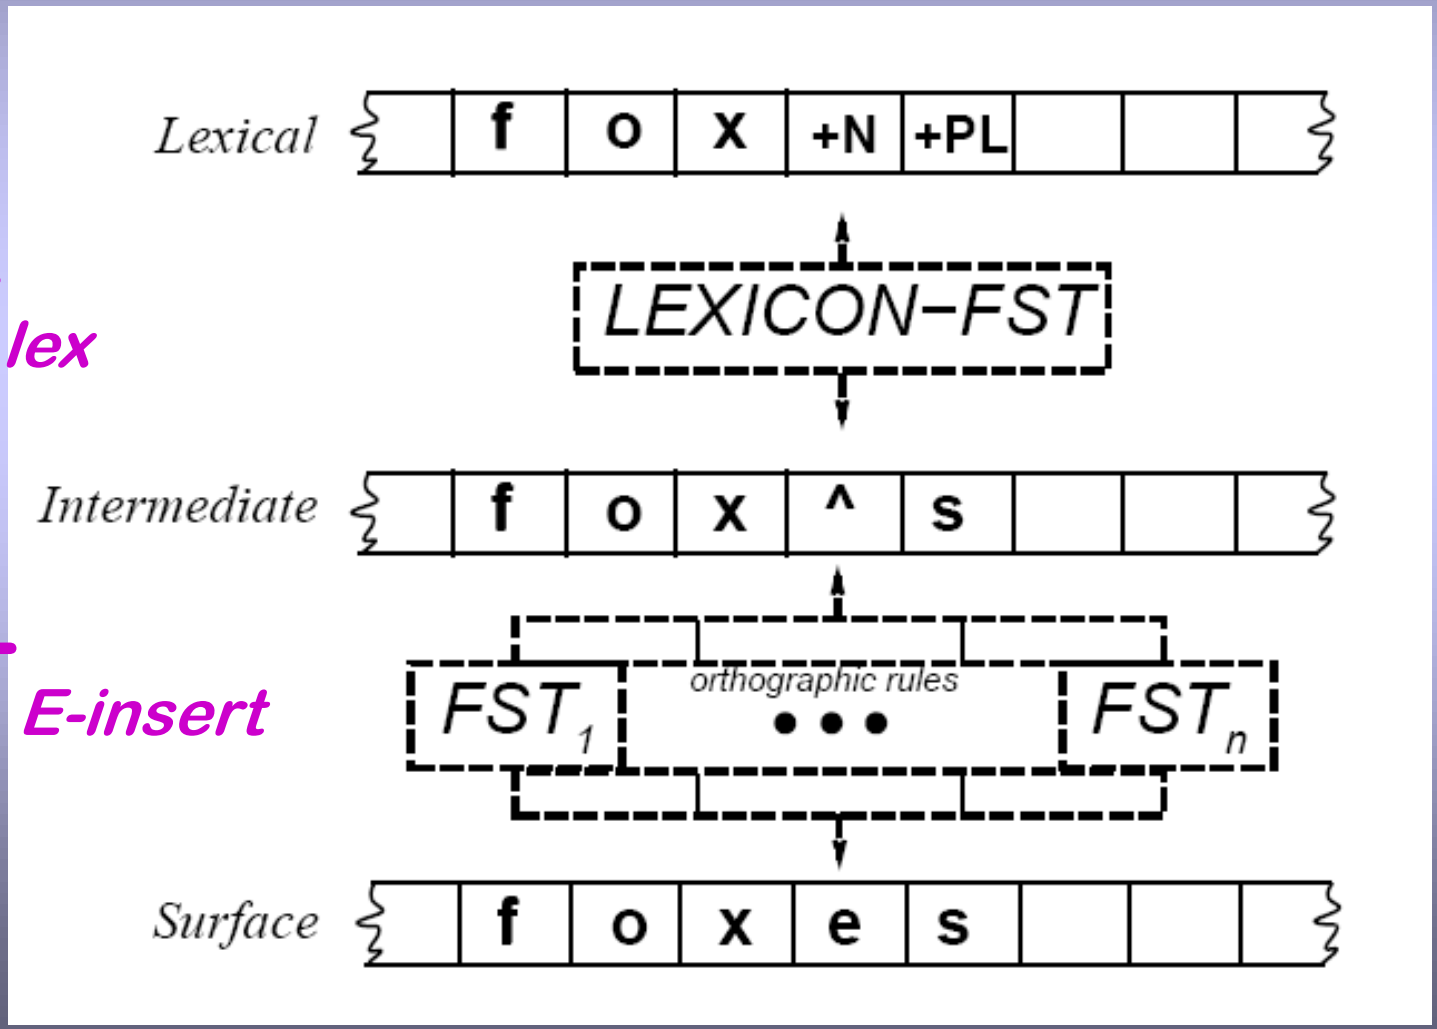

FST *lex*

FST *E-insert*

Fazit

- Zwei-Ebenen-Morphologie (ZEM) ist das dominierende Modell der automatischen morphologischen Analyse (falls eine umfassende, „tiefe“ morphologische Analyse nötig ist)
- ZEM-Systeme gibt es für eine Fülle von Sprachen, aber für das Deutsche ist dieses Modell problematisch (nicht-konkatenative Morphologie, z.B. Umlautung)
- ZEM-Systeme sind überschaubar groß
- Online-Version PC-KIMMO
  http://www.sil.org/pckimmo/index.html