Einführung in die Computerlinguistik

Finite State Transducers und Morphologie

Laura Kallmeyer

Heinrich-Heine-Universität Düsseldorf

Summer 2020

Morphologische Grundbegriffe (1)

- Wort / Lexem: abstrakte Einheit, die verschiedenen Formen zugrunde liegt.
  Bsp.: *komm-*

Morphologische Grundbegriffe (1)

- Wort / Lexem: abstrakte Einheit, die verschiedenen Formen zugrunde liegt.
  Bsp.: *komm-*
- Wortform: verschiedene Formen eines Lexems
  Bsp.: *kommen, komme, kommst, kommt, kommend, kommenden, ...*

Morphologische Grundbegriffe (1)

- Wort / Lexem: abstrakte Einheit, die verschiedenen Formen zugrunde liegt.
  Bsp.: *komm-*
- Wortform: verschiedene Formen eines Lexems
  Bsp.: *kommen, komme, kommst, kommt, kommend, kommenden, ...*
- Paradigma: Menge von Wortformen eines Lexems.
  Bsp.: *geh-e*, *geh-st*, *geh-t*, *geh-en*

Morphologische Grundbegriffe (1)

- Wort / Lexem: abstrakte Einheit, die verschiedenen Formen zugrunde liegt.
  Bsp.: *komm-*
- Wortform: verschiedene Formen eines Lexems
  Bsp.: *kommen, komme, kommst, kommt, kommend, kommenden, ...*
- Paradigma: Menge von Wortformen eines Lexems.
  Bsp.: *geh-e*, *geh-st*, *geh-t*, *geh-en*
- Synkretismus: Zusammenfallen verschiedener Wortformen
  Bsp.: 1. und 3. Pers. Plural des Lexems *geh*: *gehen*

Morphologische Grundbegriffe (2)

Wortbildungsprozesse:

- Komposition: Wort + Wort $\mapsto$ Wort
  Kinder + Garten = Kindergarten
- Derivation: Wort + (gebundenes Morphem) $\mapsto$ Wort
  Zwerg + -lein = Zwerglein
- Flexion (Beugung): Wort + Flexionsmorphem $\mapsto$ Wortform
  Zwerg + -e = Zwerge

Morphologische Grundbegriffe (3)

Welche Wortbildungsprozesse liegen hier vor?

Kindchen	Haustür
gibst	Balls
Dummheit	Vereinsamung
Lauf	Jagdhund
Bälle	verkaufte
Diebe	Hausboot
Verlierer	Korkenzieher

Morphologische Grundbegriffe (4)

- Morphem: Kleinste bedeutungstragende Einheit
  Bsp.: Zwerg, garten in *Gartenzwerg*, *geh* und *-st* in *gehst*

Morphologische Grundbegriffe (4)

- Morphem: Kleinste bedeutungstragende Einheit
  Bsp.: Zwerg, garten in *Gartenzwerg*, *geh* und *-st* in *gehst*
- freies Morphem: ein Morphem, das auch isoliert als Wortform auftreten kann
  Bsp.: Hund, Kind, auf, und, …

Morphologische Grundbegriffe (4)

- Morphem: Kleinste bedeutungstragende Einheit
  Bsp.: Zwerg, garten in *Gartenzwerg*, *geh* und *-st* in *gehst*
- freies Morphem: ein Morphem, das auch isoliert als Wortform auftreten kann
  Bsp.: Hund, Kind, auf, und, …
- gebundenes Morphem: Morphem, das nicht frei ist.
  Bsp.: -s, ver-, -lein, …

Morphologische Grundbegriffe (4)

- Morphem: Kleinste bedeutungstragende Einheit
  Bsp.: Zwerg, garten in *Gartenzwerg*, *geh* und *-st* in *gehst*
- freies Morphem: ein Morphem, das auch isoliert als Wortform auftreten kann
  Bsp.: Hund, Kind, auf, und, …
- gebundenes Morphem: Morphem, das nicht frei ist.
  Bsp.: -s, ver-, -lein, …
- Wurzel: Morphem, das Ausgangspunkt für Flexion und Derivation ist.
  Bsp.: lauf, Kind, Hund, schwarz, …

Morphologische Grundbegriffe (5)

- Affixe: periphere gebundene Morpheme. Präfixe/Suffixe, je nachdem, ob sie vor oder hinter der Wurzel stehen.
  Bsp.: Suffix -st, Präfix ent-

Morphologische Grundbegriffe (5)

- Affixe: periphere gebundene Morpheme. Präfixe/Suffixe, je nachdem, ob sie vor oder hinter der Wurzel stehen.
  Bsp.: Suffix -st, Präfix ent-
- Stamm: Morphemcluster ohne Flexionsaffixe
  Bsp.: vergleich, verkauf, enthalt, …

Morphologische Grundbegriffe (5)

- Affixe: periphere gebundene Morpheme. Präfixe/Suffixe, je nachdem, ob sie vor oder hinter der Wurzel stehen.
  Bsp.: Suffix -st, Präfix ent-
- Stamm: Morphemcluster ohne Flexionsaffixe
  Bsp.: vergleich, verkauf, enthalt, ...
- Allomorphe: bedeutungsgleiche Morpheme.
  Bsp. Pluralmorphem: $\{-e, -er, -s, \ldots\}$ (*-e*, *-er* und *-s* sind allomorph)

Morphologische Grundbegriffe (6)

Aus welchen Morphemen sind die folgenden Wortformen entstanden?

Kindchen	Haustür
gibst	Balls
Dummheit	Vereinsamung
Lauf	Jagdhund
Bälle	verkaufte
Diebe	Hausboot
Verlierer	Korkenzieher

Morphologie mit endlichen Automaten (1)

Flektierte Formen von *geh-*

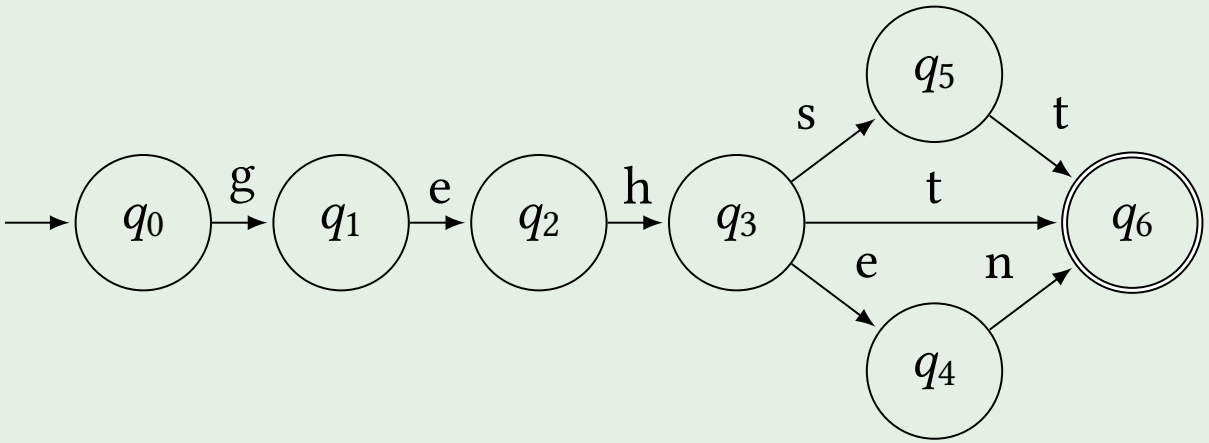

Morphologie mit endlichen Automaten (1)

Flektierte Formen von *geh-*

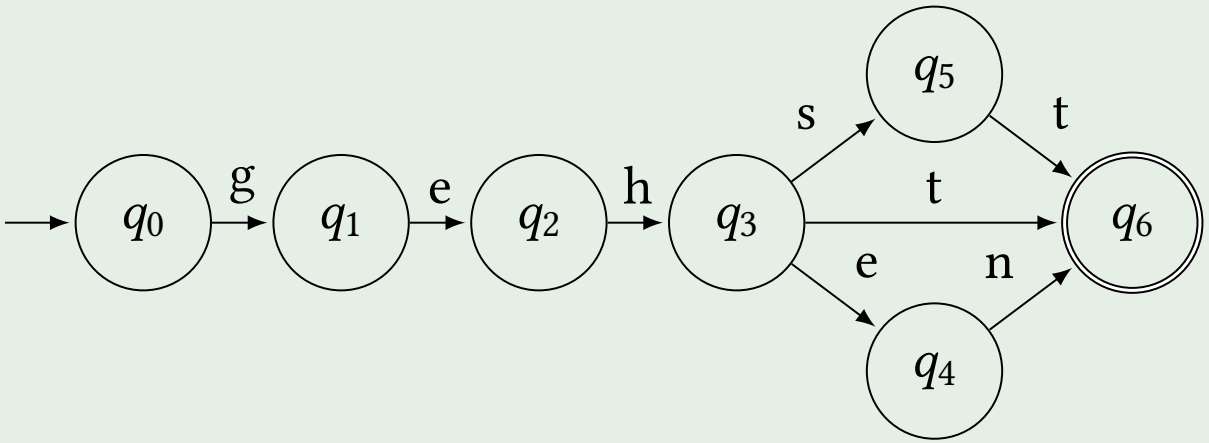

Vereinfachung: Kanten können Konkatenationen von Eingabesymbolen als Labels haben.

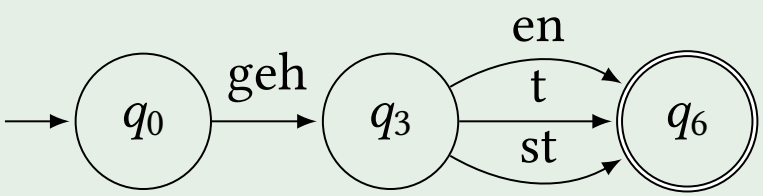

Morphologie mit endlichen Automaten (2)

Englische Verben *walk speak, eat*

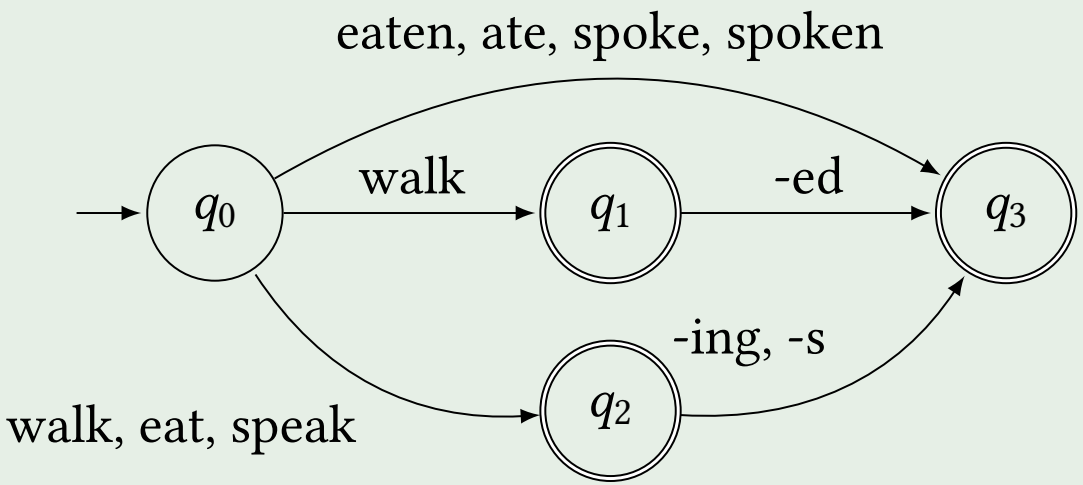

Finite State Transducer (1)

Ziel: morphologisches Parsing, d.h. nicht nur das Erkennen korrekter Wortformen sondern auch eine Analyseausgabe

Finite State Transducer (1)

Ziel: morphologisches Parsing, d.h. nicht nur das Erkennen korrekter Wortformen sondern auch eine Analyseausgabe

Ausgabe morph. Parsing

Eingabe	Ausgabe
cats	cat N Pl
cat	cat N Sg

Finite State Transducer (1)

Ziel: morphologisches Parsing, d.h. nicht nur das Erkennen korrekter Wortformen sondern auch eine Analyseausgabe

Ausgabe morph. Parsing

Eingabe	Ausgabe
cats	cat N Pl
cat	cat N Sg

Eingabe	Ausgabe
gehst	geh V 2.Sg
gehen	geh V Inf
gehen	geh V 3.Pl
gehen	geh V 1.Pl

Finite State Transducer (2)

Idee: Der FSA wird mit einer zusätzlichen Ausgabe versehen.

FST für Flexion von *geh-*

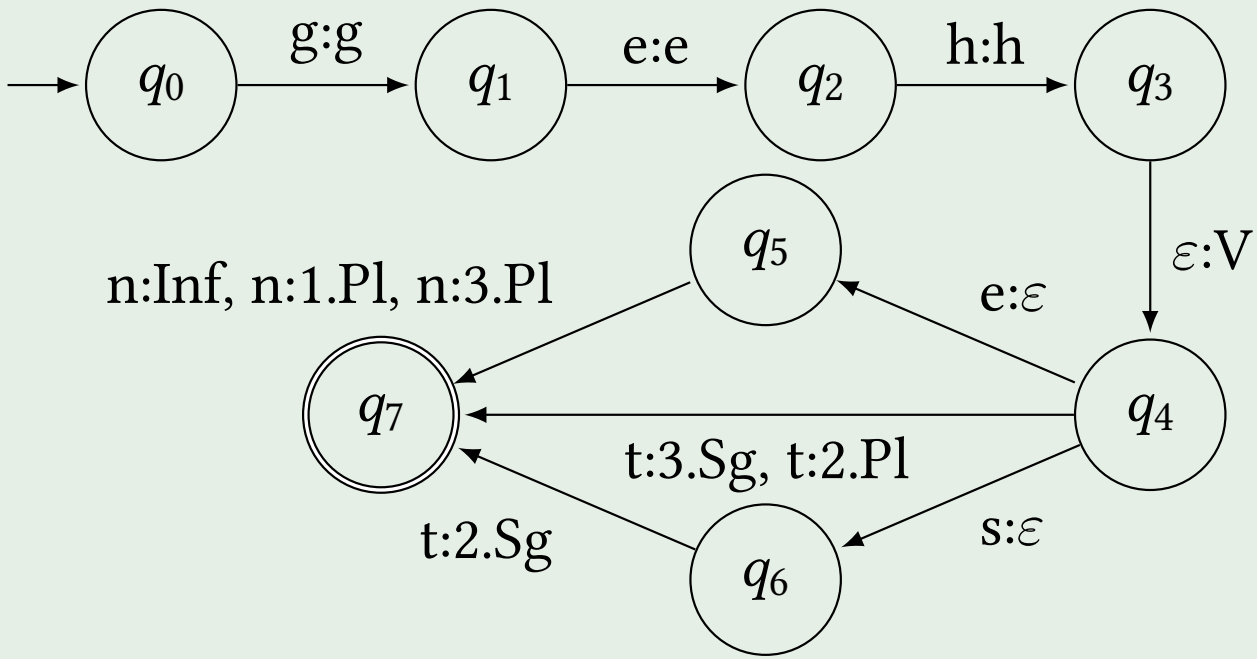

String “gehst” wird akzeptiert und erzeugt “gehV2.Sg”

Finite State Transducer (3)

Ein finite state transducer (FST) M ist ein Tupel $\langle Q, \Sigma, \Delta, \delta, q_0, F \rangle$ so dass

Finite State Transducer (3)

Ein finite state transducer (FST) M ist ein Tupel $\langle Q, \Sigma, \Delta, \delta, q_0, F \rangle$ so dass

- $\langle Q, \Sigma, q_0, F \rangle$ sind wie bei einem NFA,

Finite State Transducer (3)

Ein finite state transducer (FST) M ist ein Tupel $\langle Q, \Sigma, \Delta, \delta, q_0, F \rangle$ so dass

- $\langle Q, \Sigma, q_0, F \rangle$ sind wie bei einem NFA,
- Δ ist das Ausgabealphabet, und

Finite State Transducer (3)

Ein finite state transducer (FST) M ist ein Tupel $\langle Q, \Sigma, \Delta, \delta, q_0, F \rangle$ so dass

- $\langle Q, \Sigma, q_0, F \rangle$ sind wie bei einem NFA,
- Δ ist das Ausgabealphabet, und
- $\delta : Q \times (\Sigma \cup \{\varepsilon\} \times \Delta \cup \{\varepsilon\}) \to \mathcal{P}(Q)$ ist die Übergangsfunktion.

Finite State Transducer (3)

Ein finite state transducer (FST) M ist ein Tupel $\langle Q, \Sigma, \Delta, \delta, q_0, F \rangle$ so dass

- $\langle Q, \Sigma, q_0, F \rangle$ sind wie bei einem NFA,
- Δ ist das Ausgabealphabet, und
- $\delta : Q \times (\Sigma \cup \{\varepsilon\} \times \Delta \cup \{\varepsilon\}) \to \mathcal{P}(Q)$ ist die Übergangsfunktion.

D.h., δ gibt für einen Zustand und ein Paar aus Eingabe- und Ausgabesymbol einen Menge von möglichen neuen Zuständen an. Dabei ist ε bei Ein- und Ausgabesymbol mit eingeschlossen.

Finite State Transducer (3)

Ein finite state transducer (FST) M ist ein Tupel $\langle Q, \Sigma, \Delta, \delta, q_0, F \rangle$ so dass

- $\langle Q, \Sigma, q_0, F \rangle$ sind wie bei einem NFA,
- Δ ist das Ausgabealphabet, und
- $\delta : Q \times (\Sigma \cup \{\varepsilon\} \times \Delta \cup \{\varepsilon\}) \to \mathcal{P}(Q)$ ist die Übergangsfunktion.

D.h., δ gibt für einen Zustand und ein Paar aus Eingabe- und Ausgabesymbol einen Menge von möglichen neuen Zuständen an. Dabei ist ε bei Ein- und Ausgabesymbol mit eingeschlossen.

$$\delta(q_4, \langle \text{t}, \text{2.Pl} \rangle) = \{q_7\}$$

Finite State Transducer (4)

Beispiel: FST

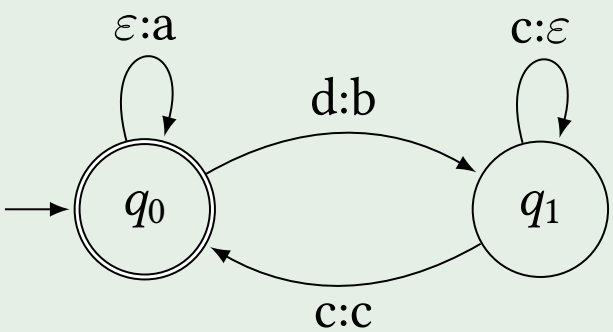

Finite State Transducer (4)

Beispiel: FST

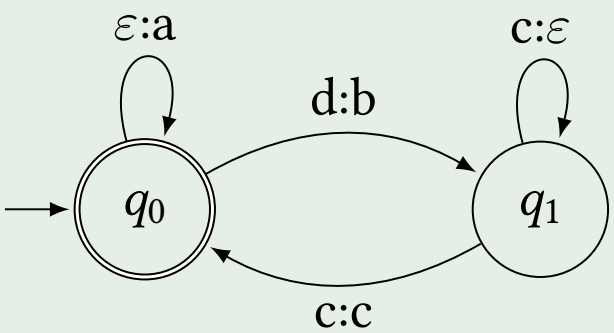

Eingabe	Ausgabe
ε	

Finite State Transducer (4)

Beispiel: FST

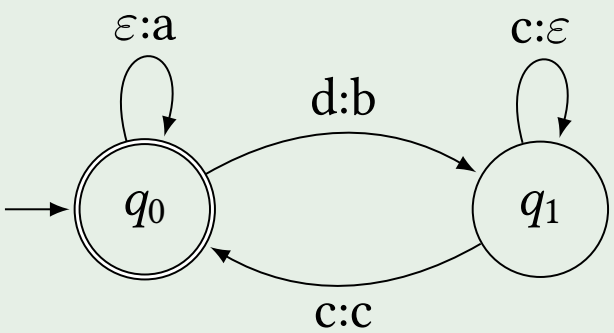

Eingabe	Ausgabe
ε	a^*
dc	

Finite State Transducer (4)

Beispiel: FST

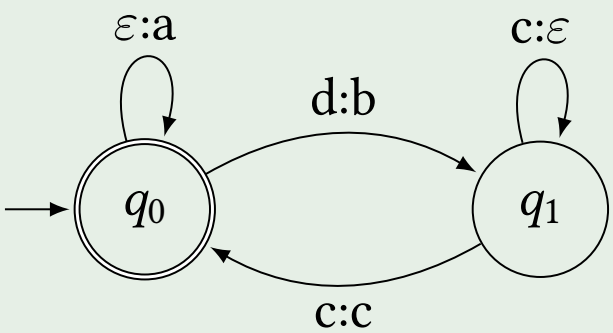

Eingabe	Ausgabe
ε	a^*
dc	$a^* bca^*$
$dccc$	

Finite State Transducer (4)

Beispiel: FST

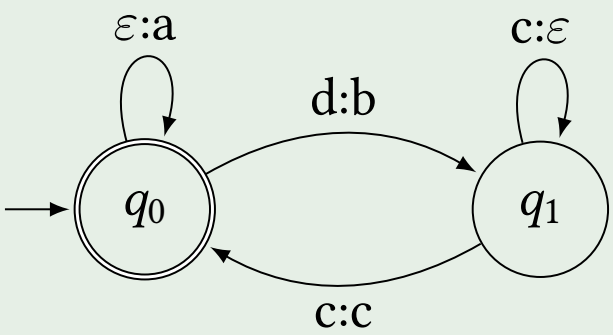

Eingabe	Ausgabe
ε	a^*
dc	a^*bca^*
$dccc$	a^*bca^*
$dcdcc$	

Finite State Transducer (4)

Beispiel: FST

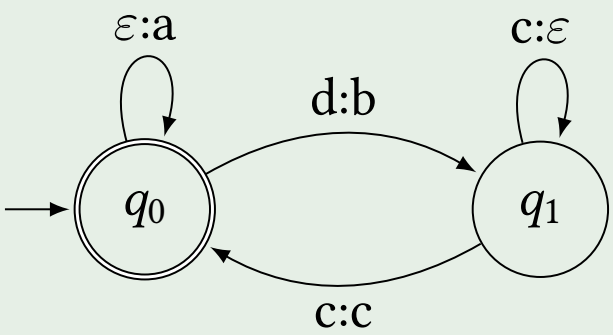

Eingabe	Ausgabe
ε	a^*
dc	a^*bca^*
$dccc$	a^*bca^*
$dcdcc$	$a^*bca^*bca^*$

Finite State Transducer (4)

Beispiel: FST

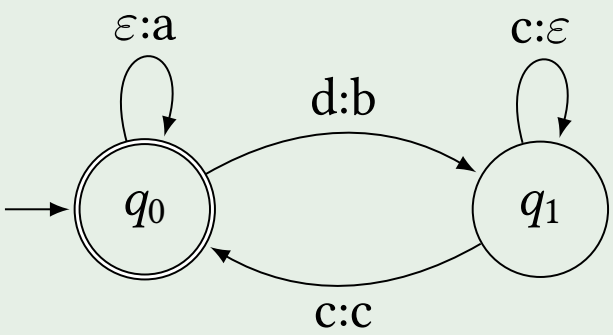

Eingabe	Ausgabe
ε	a^*
dc	a^*bca^*
$dccc$	a^*bca^*
$dcdcc$	$a^*bca^*bca^*$

Dieser FST macht folgendes:

- Akzeptiert wird $L(dc^+)^*$.
- Ausgabe ist jeweils ein Wort, in dem
  - jedes d in der Eingabe durch ein b ersetzt wird,
  - von jeder c-Folge nur das letzte c in die Ausgabe übernommen wird,
  - und am Wortanfang und Ende und vor jedem b im Ausgabewort beliebig viele (eventuell auch 0) as eingefügt werden.

Finite State Transducer (5)

FST für Steigerungsformen von Adjektiven

Positiv, Komparativ, Superlativ der Adjektive “alt”, “hübsch und “gut”

Ausgabe: lexikalischen Ebene	Eingabe: Oberflächenebene
alt Pos	alt
alt Komp	älter
alt Sup	ältesten
hübsch Pos	hübsch
hübsch Komp	hübscher
hübsch Sup	hübschesten
gut Pos	gut
gut Komp	besser
gut Sup	besten

Finite State Transducer (6)

FST für Steigerungsformen von Adjektiven

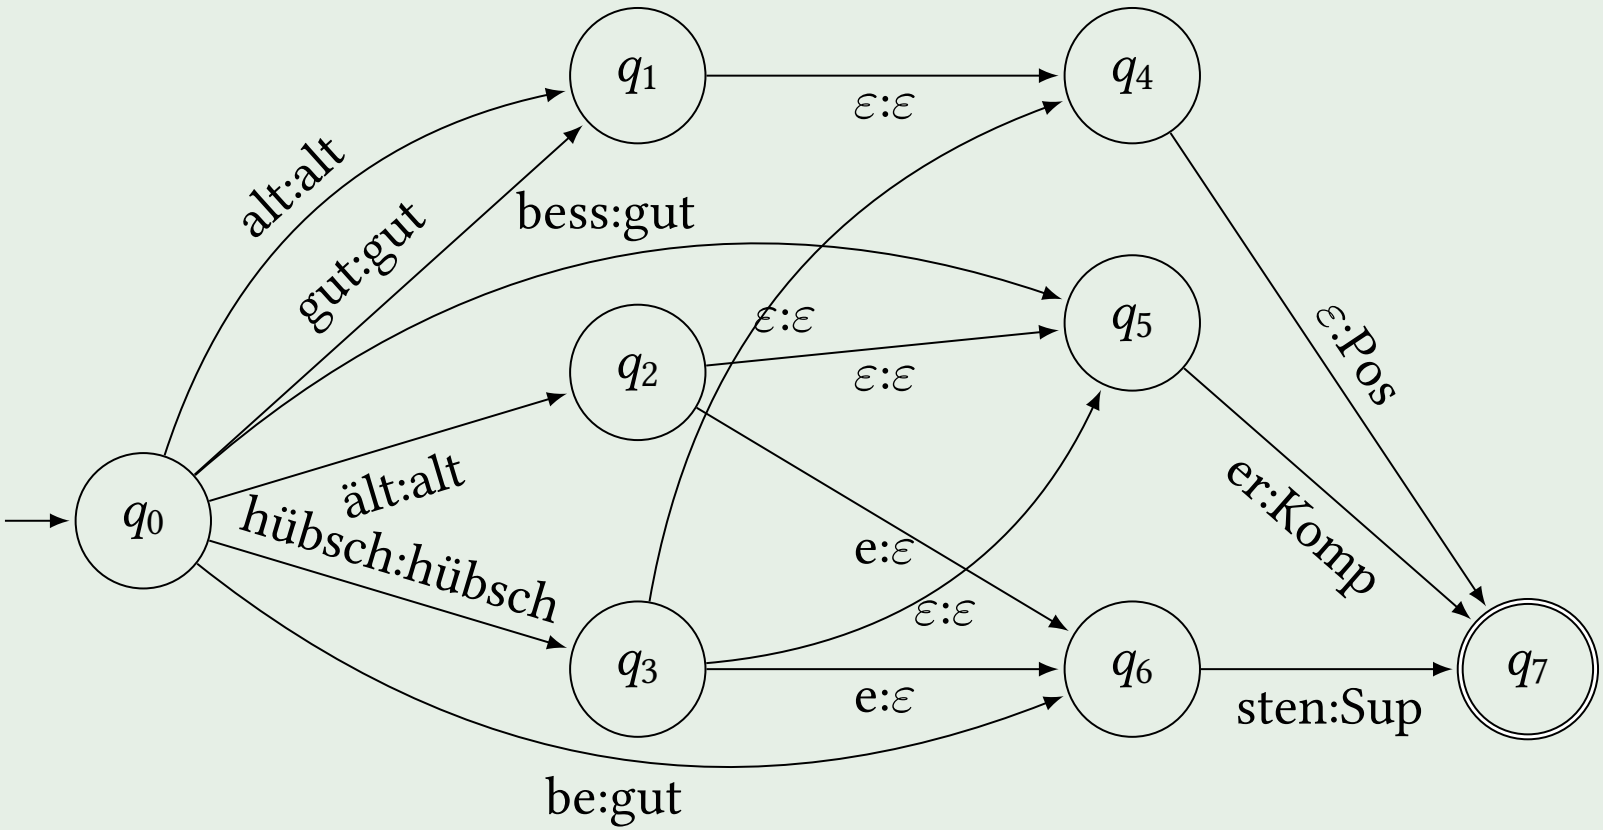

Finite State Transducer (7)

Ein FST kann auch als Generierer verwendet werden. D.h., Ein- und Ausgabe werden gewissermaßen vertauscht.

FST als Generierer

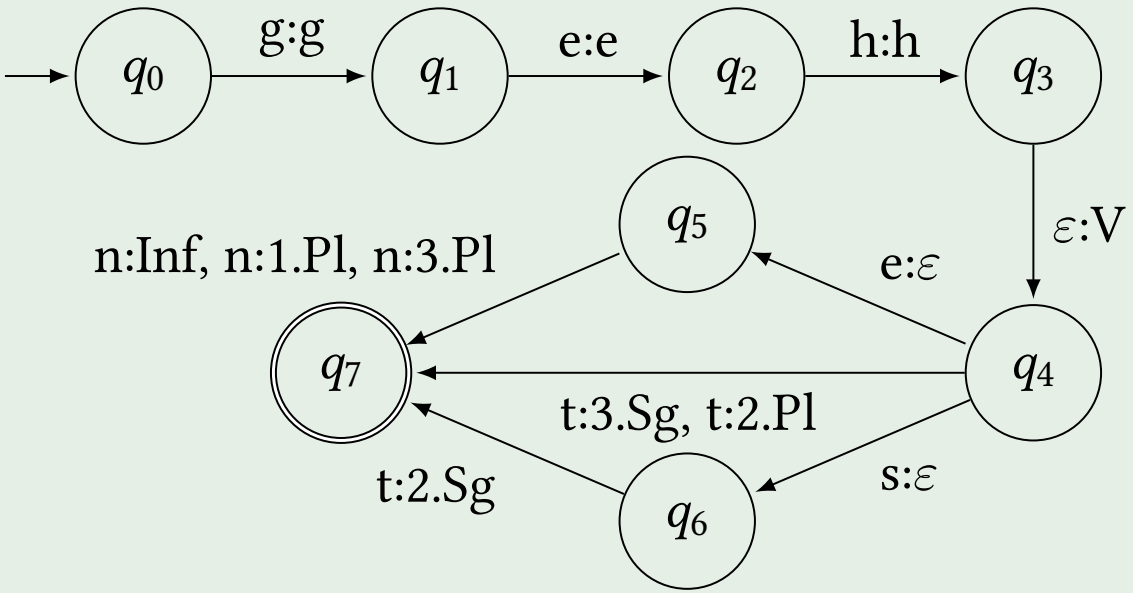

String “ gehV2.Sg” wird akzeptiert und erzeugt “gehst”

Finite State Transducer (8)

- Ein FST kann als ein Automat mit zwei Bändern betrachtet werden.

Lexikalische Ebene:	…	c	a	t	N	Pl	…
Oberfläche:	…	c	a	t	s		…

  $\Rightarrow$ Two-level morphology (Koskenniemi)

- Zusätzlich führen wir im Eingabealphabet Symbole ^ und # ein für Morphemgrenze und Wortgrenze.

Finite State Transducer (9)

FST für englische Singular- und Pluralmorphologie

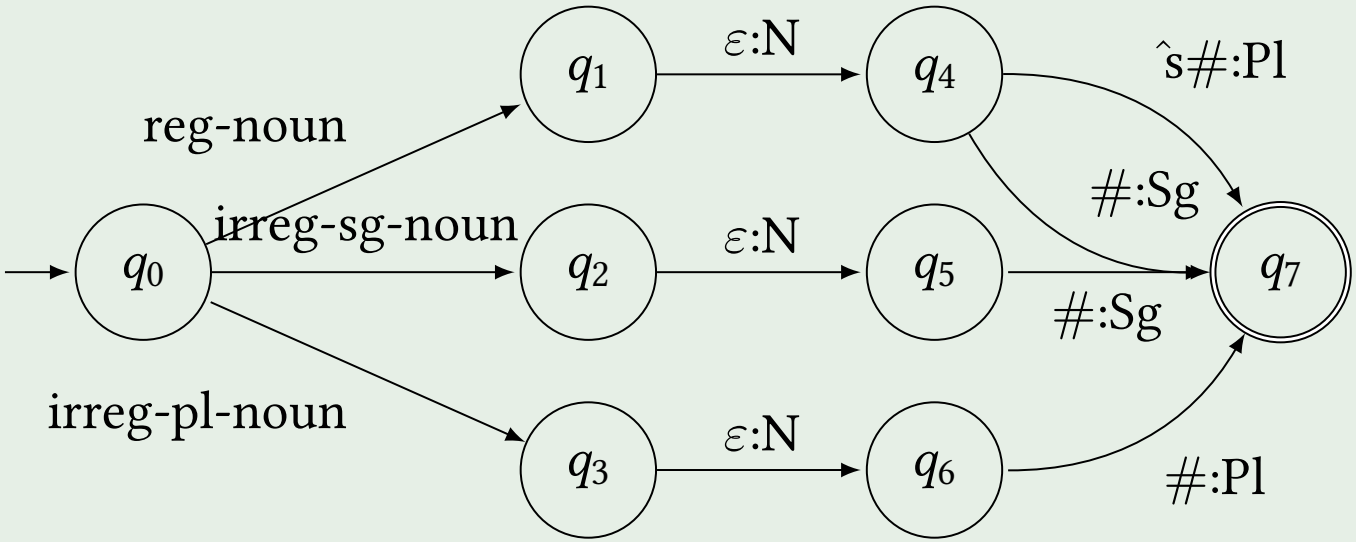

Für die Platzhalter reg-noun, irreg-sg-noun und irreg-pl-noun müssen noch entsprechende Nomen eingesetzt werden. Außerdem müssen wir dafür sorgen, dass bei einem unregelmäßigen Plural der richtige Stamm ausgegeben wird.

Finite State Transducer (10)

FST for *fox, goose, cat*

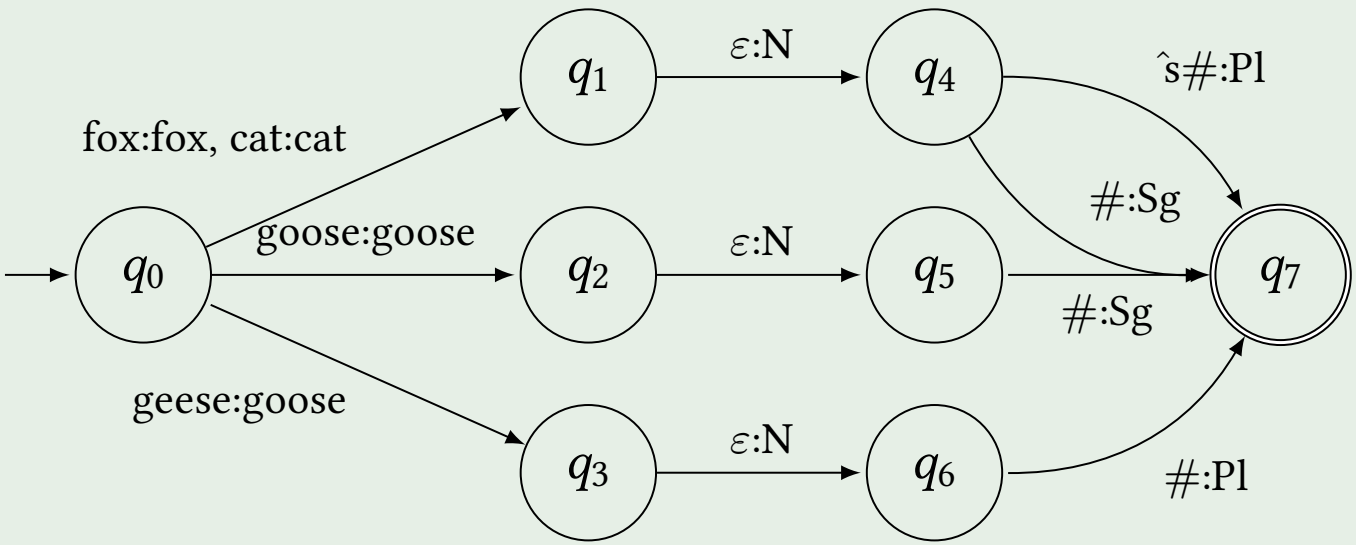

Finite State Transducer (10)

FST for *fox, goose, cat*

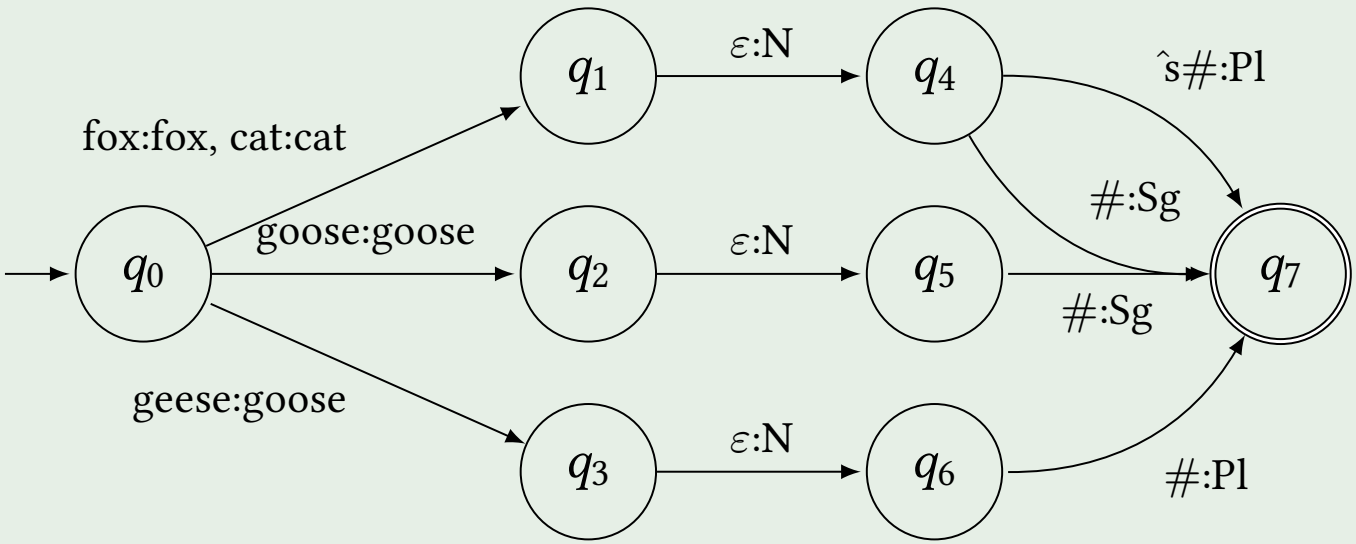

Außerdem benötigen wir orthographische Regeln der folgenden Art:
e-insertion: “e” hinzufügen nach einem -s, -z, -x, -ch, -sh und vor -s

Finite State Transducer (11)

Wir haben also drei Ebenen:

Lex. Ebene:	…	f	o	x	N	Pl		…
Zwischenebene:	…	f	o	x	^	s	#	…
Oberfläche:	…	f	o	x	e	s		

- Orthographische Regeln können ebenfalls als FSTs realisiert werden.
- Der Lexikalische FST und die FST für orthographische Regeln werden hintereinandergeschaltet (*cascaded transducers*)

Finite State Transducer (12)

FST für e-insertion

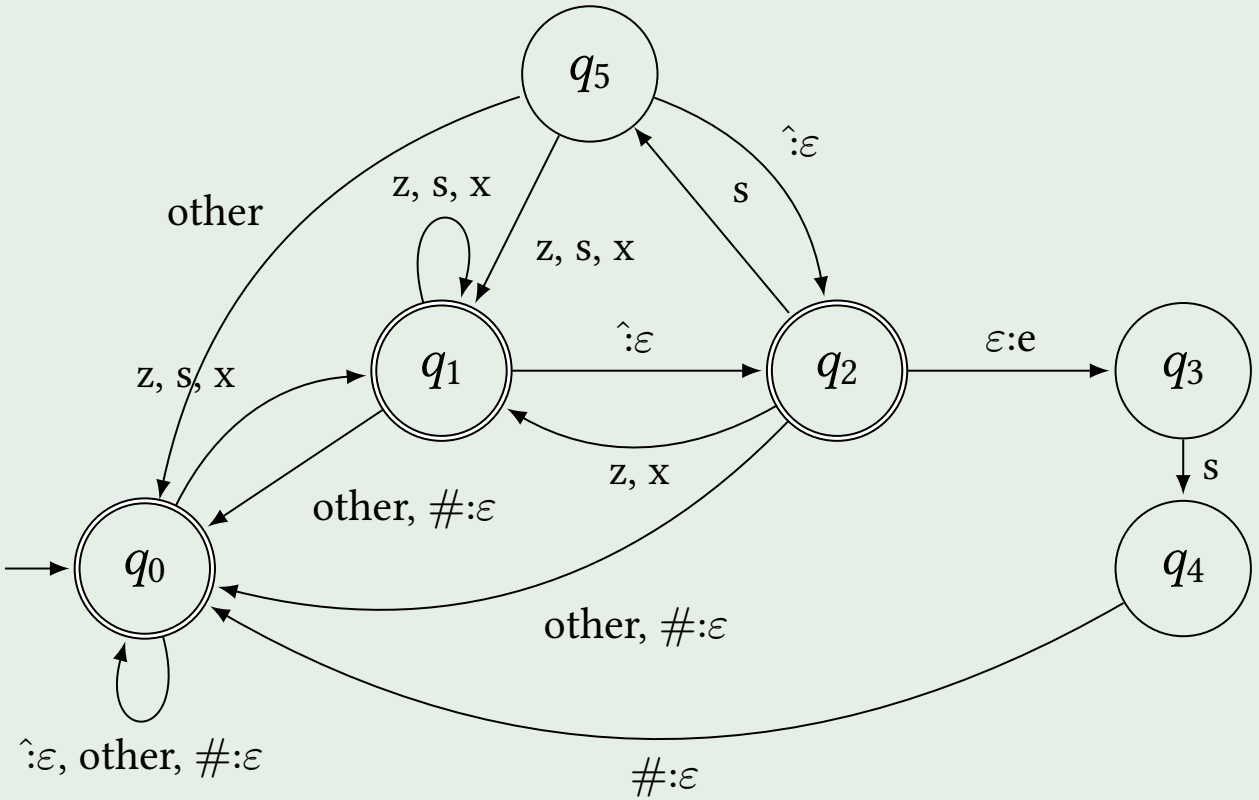

(ein einzelnes a steht hier für das Paar $a : a$, z.B. “z” für “z:z”. ”other” bezeichnet alles außer z,s,x,ˆ, #.)