


# Einführung in die Computerlinguistik

## Morphologie und Automaten II


WS 2006/2007

Manfred Pinkal

## Ein gerichteter Graph mit Kanteninschriften




## Ein Weg durchs Diagramm



klein eres|

## Ein alternativer Weg durchs Diagramm



klein er|es


## Das Problem

- Das Diagramm erlaubt typischerweise an einem Knoten/ einem Zustand mehrere Übergänge bei derselben Eingabe (deshalb „nicht-deterministisch“).
- Die zufällige Wahl einer Kante kann sich erst viel später als falsch herausstellen. Sie gibt keine Gewähr, dass tatsächlich alle möglichen Wege durch das Diagramm getestet wurden.
- Wir benötigen ein Verfahren, das uns die vollständige Suche garantiert.

## Ein Verfahren für die Pfadsuche: Die Idee

- Angenommen, wir befinden uns an einem Knoten  $k$  des Diagramms (dem „aktuellen Zustand“) und an einer Position im Eingabewort  $w$  (der „aktuellen Position“) – beides zusammen nennen wir die **aktuelle Konfiguration**.
- Wir testen, welche Kanten wir beschreiten können.
- Wir rücken nicht direkt im Automaten vor, sondern legen die alternativ möglichen Resultatkonfigurationen – Zustand und Position im Wort – in einer Liste noch zu erledigender Teilaufgaben, der **Agenda**, ab.
- Dann nehmen wir einen Eintrag von der Agenda. – Welchen?
- Wir betrachten die Agenda als Stapel („**Stack**“), legen neue Aufgaben oben auf die Agenda und nehmen einzelne Aufgaben ebenfalls von oben von der Agenda ("Last In – First Out").
- Wir führen die Aufgabe aus (d.h., rücken im Eingabewort auf die bezeichnete Stelle vor und gehen in den bezeichneten Zustand), testen mögliche nächste Schritte, legen die Resultate auf die Agenda usw. – bis wir die Eingabe erfolgreich abgearbeitet haben (akzeptieren!) oder die Agenda keine Aufgaben mehr enthält ist (zurückweisen!).


## Pfadsuche: Startkonfiguration: Startzustand und Eingabewort auf der Agenda



Eingabewort:

Agenda: 1 -- klein eres


## Pfadsuche: Nimm Aufgabe von der Agenda



Eingabewort: klein eres

Agenda: \_\_\_\_\_


## Pfadsuche: Generiere neue Aufgaben



Eingabewort: klein eres

Agenda: 2 -- klein eres  
2 -- klein eres


## Pfadsuche: Nimm Aufgabe von der Agenda



Eingabewort: klein eres

Agenda: 2 -- klein eres

## Pfadsuche: Generiere neue Aufgaben



3 -- klein eres


4 -- klein eres

2 -- klein eres

Eingabewort: klein eres

Agenda: 2 -- klein eres

## Pfadsuche: Nimm Aufgabe von der Agenda




4 -- klein eres

2 -- klein eres

Eingabewort: klein eres

Agenda: 2 -- klein eres

## Pfadsuche: Generiere neue Aufgaben



4 -- klein eres


4 -- klein eres

2 -- klein eres

Eingabewort: klein eres

Agenda:

## Pfadsuche: Nimm Aufgabe von der Agenda Keine neue Aufgabe!




4 -- klein eres

2 -- klein eres

Eingabewort: klein eres

Agenda:


## Pfadsuche: Nimm Aufgabe von der Agenda Keine neue Aufgabe!



Eingabewort: klein eres

Agenda: 2 -- klein eres

## Pfadsuche: Nimm Aufgabe von der Agenda Backtracking!




Eingabewort: klein eres

Agenda: \_\_\_\_\_




## Pfadsuche: Generiere Aufgaben



Eingabewort: klein eres

Agenda: 3 -- klein eres  
4 -- klein eres


## Pfadsuche: Nimm Aufgabe von der Agenda



Eingabewort: klein eres

Agenda: 4 -- klein eres


## Pfadsuche: Generiere Aufgabe



Eingabewort: klein eres

Agenda: 4 -- klein eres  
4 -- klein es

## Pfadsuche: Nimm Aufgabe von der Agenda: Eingabe abgearbeitet, Zielzustand: Akzeptiere!




Eingabewort: klein eres

Agenda: 4 -- klein es

## Anmerkung zum Pfadsuche-Algorithmus


- Der vorgestellte Pfadsuche-Algorithmus ist ein Beispiel für „Tiefensuche mit Backtracking“. Die Last In – First Out-Regel führt dazu, dass ein einmal gewählter Pfad so weit wie möglich weiter verfolgt wird. Wenn die Suche in eine Sackgasse gerät, werden systematisch die in der Agenda gespeicherten, noch nicht begangenen Verzweigungen ausprobiert.
- Der Algorithmus ist vollständig nur dann, wenn das Diagramm/der Automat keine Leerwort-Zyklen enthält (Schleifen, bei deren Durchlaufen das leere Wort abgearbeitet wird).
- Der Algorithmus ist ineffizient: Bei einem maximalen Verzweigungsfaktor  $n$  benötigt der Algorithmus zur vollständigen Abarbeitung eines Eingabewortes  $w$  im schlechtesten Fall  $n^{|w|}$  Schritte. Der **Zeitbedarf wächst exponentiell** mit der Wortlänge.
- Man kann die Situation verbessern, indem man
  - die Information im Diagramm geschickt anordnet
  - den Suchalgorithmus optimiert (z.B. durch Testen, ob eine neu generierte Konfiguration schon einmal vorgekommen ist)eine alternative Repräsentation wählt, die effizientere Verarbeitung erlaubt

## Ein deterministisches Diagramm



Beobachtung: Bestimmte Diagramme erfordern keine Suche, weil Übergänge bei gegebenem Zustand und Eingabesymbol eindeutig festgelegt sind.

## Saarbrücker Telefonnummern (international)



## Deterministische endliche Automaten

- Die beiden Diagramme unterscheiden sich von dem Adjektiv-Diagramm in einem wesentlichen Punkt: Für jeden Zustand/Knoten und jede Eingabe gibt es höchstens eine Kante, die beschriftet werden kann. Sie sind **deterministisch**.
- Die Definition des „deterministischen endlichen Automaten“ (DEA oder DFA, für „deterministic finite-state automaton“) führt einige weitere, weniger wesentliche, aber nützliche Beschränkungen gegenüber dem NEA ein.

## Deterministische und nicht-deterministische Automaten

- NEA erlaubt beliebige Worte (incl.  $\varepsilon$ ) als Kanteninschrift
- NEA erlaubt für einen Ausgangszustand und eine Eingabe mehrere oder gar keinen Zielzustand
- D.h.: NEA hat eine Übergangsrelation.
- DEA hat nur Einzelsymbole als Kanten-Inschriften, insbesondere sind Leerwort-Kanten nicht zulässig.
- DEA hat zu jedem Zustand und zu jedem Symbol genau eine wegführende Kante
- D.h.: DEA hat eine Übergangsfunktion.


## Definition: Deterministischer endlicher Automat

Ein deterministischer endlicher Automat ist ein Quintupel

$A = \langle K, \Sigma, \delta, s, F \rangle$ , wobei

- $K$  nicht-leere endliche Menge von Knoten (Zuständen)
- $\Sigma$  nicht-leeres Alphabet
- $s \in K$  Startzustand
- $F \subseteq K$  Menge von Endzuständen
- $\delta : K \times \Sigma \rightarrow K$  Übergangsfunktion

## Ein deterministisches Diagramm



Beobachtung: Bestimmte Diagramme erfordern keine Suche, weil Übergänge bei gegebenem Zustand und Eingabesymbol eindeutig festgelegt sind.

## Beispiel: Der DEA für Wortartmuster [1]

DEA  $A = \langle K, \Sigma, \delta, s, F \rangle$  mit

- $K = \{1, 2, 3, 4\}$
- $\Sigma = \{\text{ART}, \text{ADJA}, \text{NN}, \text{GPRT}\}$
- $s = 1$
- $F = \{3\}$
- $\delta$  definiert durch:
  - $\delta(1, \text{ART}) = 2$
  - $\delta(2, \text{ADJA}) = 2$
  - $\delta(2, \text{NN}) = 3$
  - $\delta(2, \text{GPRT}) = 4$
  - ... ..

## Beispiel [2]: Übergangstabelle für $\delta$


| $\delta$ : | ART | ADJA | NN | GPRT |
|------------|-----|------|----|------|
| 1          | 2   |      |    |      |
| 2          |     | 2    | 3  | 4    |
| 3          |     |      |    |      |
| 4          |     | 2    |    | 4    |

## Beispiel [3]: Übergangstabelle für $\delta$ , komplettiert

| $\delta$ : | ART | ADJA | NN | GPRT |
|------------|-----|------|----|------|
| 1          | 2   | 5    | 5  | 5    |
| 2          | 5   | 2    | 3  | 4    |
| 3          | 5   | 5    | 5  | 5    |
| 4          | 5   | 2    | 5  | 4    |
| 5          | 5   | 5    | 5  | 5    |

- Der Zustand eines DEA, aus dem es keine Möglichkeit gibt, in einen Endzustand zu gelangen, heißt „Senke“ oder engl. „trap state“: Falle.

## Das Zustandsdiagramm für Wortartmuster: Übergangsfunktion $\delta$ komplettiert



## Deterministische und nicht-deterministische Automaten [1]

- DEAs erlauben den Test von Eingabeketten in **linearer Zeit**: Jedes Wort der Länge  $n$  wird in genau  $n$  Schritten abgearbeitet.
- DEAs haben allerdings ein eingeschränkteres Beschreibungs-Inventar als NEAs.
- Frage: Ist deshalb die **Ausdrucksstärke** des DEA-Formalismus eingeschränkter als die von NEAs? Das heißt, gibt es Sprachen, die durch einen NEA, aber nicht durch einen DEA beschrieben werden?
- Die Antwort: **Nein**.



## Deterministische und nicht-deterministische Automaten [2]


- Jede Sprache, die von einem NEA akzeptiert wird, kann auch durch einen DEA beschrieben werden (und, trivialerweise, auch umgekehrt: ein DEA ist ein spezieller NEA). NEAs und DEAs besitzen die gleiche Ausdruckskraft, die Formalismen sind **beschreibungsäquivalent**.
- Das ist beweisbar. Noch wichtiger: Der Beweis ist **konstruktiv**, d.h.:
- Es gibt ein Konstruktionsverfahren, das es erlaubt, zu jedem NEA A einen DEA A' zu konstruieren, so dass  $L(A') = L(A)$ .

## Die NEA-DEA-Überführung

Der Algorithmus zur NEA-DEA-Überführung besteht aus drei Schritten:

1. Beseitigung von Mehrsymbol-Kanten
2. Beseitigung von  $\varepsilon$ -Kanten
3. Die „Potenz-Automaten“-Konstruktion

## Adjektivendungen: Zustandsdiagramm



## Schritt 1: Beseitigung von Mehrsymbolkanten

Gegeben sei der NEA  $A = \langle K, \Sigma, \Delta, s, F \rangle$ .

- Für alle Kanten  $\langle q, w, q' \rangle$  mit  $w = a_1 \dots a_n$ ,  $n > 1$ :


Entferne  $\langle q, w, q' \rangle$  aus  $\Delta$ .

- Erweitere  $K$  um neue Zustände  $q_1, \dots, q_{n-1}$ .

- Erweitere  $\Delta$  um neue Kanten

$\langle q, a_1, q_1 \rangle, \langle q_1, a_2, q_2 \rangle, \dots, \langle q_{n-1}, a_n, q' \rangle$


## Beispiel-Automat nach Schritt 1:




## Schritt 2: Beseitigung von $\epsilon$ -kanten

- Wir definieren zunächst als Hilfsbegriffe den „ $\epsilon$ -Vorbereich“  $V_\epsilon(p)$  und den „ $\epsilon$ -Nachbereich“  $N_\epsilon(p)$  von Zuständen:
  - $V_\epsilon(p) = \{q \mid p \text{ ist von } q \text{ aus ohne Abarbeiten eines Symbols erreichbar}\}$
  - $N_\epsilon(p) = \{q \mid q \text{ ist von } p \text{ aus ohne Abarbeiten eines Symbols erreichbar}\}$
- Anmerkung:  $V_\epsilon(p)$  und  $N_\epsilon(p)$  enthalten insbesondere  $p$  selbst.
- Für jede nicht-leere Kante  $\langle p, a, q \rangle \in \Delta$ : Erweitere  $\Delta$  um alle  $\langle p', a, q' \rangle$  mit  $p' \in V_\epsilon(p)$ ,  $q' \in N_\epsilon(q)$ .
- Entferne alle leeren Kanten aus  $\Delta$ .

## Schritt 2: Beseitigung von $\varepsilon$ -Kanten




## Schritt 2: Beseitigung von $\varepsilon$ -kanten





## Schritt 2: Beseitigung von $\epsilon$ -kanten: Resultat ist „buchstabierender Automat“




## Schritt 2: Beseitigung von $\epsilon$ -kanten

- Wir definieren zunächst als Hilfsbegriffe den „ $\epsilon$ -Vorbereich“  $V_\epsilon(p)$  und den „ $\epsilon$ -Nachbereich“  $N_\epsilon(p)$  von Zuständen:
  - $V_\epsilon(p) = \{q \mid p \text{ ist von } q \text{ aus ohne Abarbeiten eines Symbols erreichbar}\}$
  - $N_\epsilon(p) = \{q \mid q \text{ ist von } p \text{ aus ohne Abarbeiten eines Symbols erreichbar}\}$
- Anmerkung:  $V_\epsilon(p)$  und  $N_\epsilon(p)$  enthalten insbesondere  $p$  selbst.
- Für jede nicht-leere Kante  $\langle p, a, q \rangle \in \Delta$ : Erweitere  $\Delta$  um alle  $\langle p', a, q' \rangle$  mit  $p' \in V_\epsilon(p)$ ,  $q' \in N_\epsilon(q)$ .
- Entferne alle leeren Kanten aus  $\Delta$ .
- Wenn sich ein Endzustand im  $\epsilon$ -Nachbereich des Startzustandes  $s$  befindet, füge  $s$  zu den Endzuständen hinzu.

## Schritt 3: Potenzautomaten-Konstruktion, Vorüberlegung

- Wir haben einen Algorithmus zur Pfadsuche am Beispiel des unbearbeiteten Adjektivendungs-Diagramms kennengelernt: „**Tiefensuche mit Backtracking**“. Durch die Organisation der Agenda als Stapel/Stack („**last in – first out**“) wird eine Alternative so weit wie möglich verfolgt; bei endgültigem Scheitern wird das System zurückgesetzt.
- Durch die Organisation der Agenda als Warteschlange (queue), bei der die Aufgaben in der Reihenfolge ihrer Generierung abgearbeitet werden („**first in – first out**“), erhalten wir **Breitensuche**. Die alternativen Pfade werden (quasi) parallel verfolgt.


## Pfadsuche als Breitensuche



Eingabewort:

Agenda: 1 -- klein eres


## Pfadsuche als Breitensuche



Eingabewort: klein eres

Agenda: \_\_\_\_\_

## Pfadsuche als Breitensuche



Eingabewort: klein eres


Agenda: 4 -- klein eres

1a -- klein eres

3 -- klein eres




## Pfadsuche als Breitensuche



Eingabewort: klein eres

Agenda: 3 -- klein eres


## Pfadsuche als Breitensuche



Eingabewort: klein eres

Agenda: 1a -- klein eres


## Pfadsuche als Breitensuche



Eingabewort: klein eres

Agenda: 1a -- klein eres

## Pfadsuche als Breitensuche




Eingabewort: klein eres

Agenda: 4 -- klein eres  
2 -- klein eres  
4 -- klein eres


## Schritt 3: Potenzautomaten-Konstruktion, Vorüberlegung [2]

- Wir können „getaktete“ Breitensuche in einem buchstabierenden NEA so beschreiben:
  - Wir ermitteln alle Zustände, die durch die Abarbeitung des ersten Eingabesymbols vom Startzustand aus erreicht werden können.
  - Wir ermitteln alle Zustände, die durch die Abarbeitung des zweiten Eingabesymbols von einem Zustand dieser Zustandsmenge erreicht werden können, usf.
  - Wenn die Zustandsmenge, die wir auf diese Weise nach Abarbeiten des kompletten Wortes  $w$  enthalten, einen Endzustand des NEA enthält, wird  $w$  akzeptiert.

## Pfadsuche als Breitensuche




## Pfadsuche als Breitensuche




Eingabewort: klein eres

## Pfadsuche als Breitensuche




Eingabewort: klein eres

## Pfadsuche als Breitensuche




Eingabewort: klein eres

## Pfadsuche als Breitensuche



Eingabewort: klein eres\_

## Pfadsuche als Breitensuche



Eingabewort: klein er

## Schritt 3: Potenzautomaten-Konstruktion, Vorüberlegung [3]

- Wir können diese "getaktete Suche" selbst mit einem endlichen Automaten beschreiben:
  - Zustände des neuen Automaten lassen sich als Mengen von Zuständen des NEA beschreiben. Am Beispiel: Nach Abarbeiten des ersten Symbols „e“ befindet er sich in dem Zustand, dass es die Zustandsmenge des NEA  $\{1a, 2, 4\}$  als mögliche aktuelle Zustände erkannt hat.
  - Wenn die Eingabekette abgearbeitet ist, und der Automat sich in einem Zustand befindet, der einen Endzustand des NEA enthält, ist die Eingabe akzeptiert.
  - Die „möglichen Zustände“ des NEA, die sich durch ein bestimmtes Eingabe-Symbol erreichen lassen, sind eindeutig definiert. Der neue Automat ist also ein DEA.

### Schritt 3: Potenzautomaten-Konstruktion: Die Definition

Der Potenzautomat zum buchstabierenden NEA

$A = \langle K, \Sigma, \Delta, s, F \rangle$  ist der DEA  $A'$ :

$A' = \langle K', \Sigma, \delta, s', F' \rangle$  mit:

- $K' = \wp(K)$  (die Potenzmenge der Zustandsmenge des NEA)
- $s' = \{s\}$
- $\delta(p', a) = \{q \mid \text{es gibt } p \in p' \text{ und } \langle p, a, q \rangle \in \Delta\}$  für jedes  $p' \subseteq K, a \in \Sigma$
- $q' \in F'$  gdw.  $q' \cap F \neq \emptyset$

### Praktisches Vorgehen

Der Potenzautomat  $A'$  zu  $A = \langle K, \Sigma, \Delta, s, F \rangle$  hat  $2^{|K|}$  Zustände. In der Regel sind viele dieser Zustände unerreichbar (vom Startzustand  $\{s\}$  aus) und deshalb funktionslos.

Praktisches Konstruktionsverfahren:

Beginne mit  $\{s\}$ , berechne die Übergangsfunktion für  $\{s\}$ , für alle direkt von  $s$  erreichbaren Zustände usw., bis keine neuen erreichbaren Zustände hinzukommen.

## Beispiel: DEA für Adjektiv-Endungen


- Grundlage: der buchstabierende Automat  
 $A = \langle \{1, 1a, 1b, 2, 3, 4\}, \{e, m, n, r, s, t\}, \Delta, 1, \{1, 4\} \rangle$ ,  
 $\Delta$  wie im Diagramm Folie 42
- Potenzautomat ist  $A' = \langle K', \Sigma, \delta, s', F' \rangle$   
 mit  $K' = \wp(K)$   
 $s' = \{s\}$   
 $F' = \{q' \in K' \mid 1 \in q' \text{ oder } 4 \in q'\}$   
 $\delta$  s. Übergangstabelle nächste Folie

## DEA für Adjektiv-Endungen, Übergangstabelle


| $\delta$ :     | e              | m           | n           | r           | s           | t           |
|----------------|----------------|-------------|-------------|-------------|-------------|-------------|
| $\{1\}$        | $\{1a, 3, 4\}$ | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\{1b\}$    | $\emptyset$ |
| $\{1a, 3, 4\}$ | $\emptyset$    | $\{4\}$     | $\{4\}$     | $\{2, 4\}$  | $\{4\}$     | $\emptyset$ |
| $\{1b\}$       | $\emptyset$    | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\{2, 4\}$  |
| $\{2, 4\}$     | $\{3, 4\}$     | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\emptyset$ |
| $\{3, 4\}$     | $\emptyset$    | $\{4\}$     | $\{4\}$     | $\{4\}$     | $\{4\}$     | $\emptyset$ |
| $\{4\}$        | $\emptyset$    | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\emptyset$ |
| $\emptyset$    | $\emptyset$    | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\emptyset$ | $\emptyset$ |



## Das Diagramm




## Das Diagramm, vereinfacht



## Potenzautomatenkonstruktion, ein weiteres Beispiel

NEA  $A = \langle \{1,2,3\}, \{a,b\}, \Delta, 1, \{3\} \rangle$

$\Delta$  gegeben durch:



DEA

$A' = \langle \wp(\{1,2,3\}), \{a,b\}, \delta, \{1\}, F' \rangle$

$F' = \{\{3\}, \{1,3\}, \{2,3\}, \{1,2,3\}\}$

## Potenzautomatenkonstruktion, Beispiel 2: Die Übergangstabelle

| q           | $\delta(q, a)$ | $\delta(q, b)$ |
|-------------|----------------|----------------|
| $\{1\}$     | $\{1,2\}$      | $\{1\}$        |
| $\{2\}$     | $\emptyset$    | $\{3\}$        |
| $\{3\}$     | $\emptyset$    | $\emptyset$    |
| $\{1,2\}$   | $\{1,2\}$      | $\{1,3\}$      |
| $\{1,3\}$   | $\{1,2\}$      | $\{1\}$        |
| $\{2,3\}$   | $\emptyset$    | $\{3\}$        |
| $\{1,2,3\}$ | $\{1,2\}$      | $\{1,3\}$      |
| $\emptyset$ | $\emptyset$    | $\emptyset$    |


## Potenzautomatenkonstruktion, Beispiel 2: Die Übergangstabelle

| q            | $\delta(q, a)$ | $\delta(q, b)$ |
|--------------|----------------|----------------|
| <b>{1}</b>   | <b>{1,2}</b>   | <b>{1}</b>     |
| {2}          | $\emptyset$    | {3}            |
| {3}          | $\emptyset$    | $\emptyset$    |
| <b>{1,2}</b> | <b>{1,2}</b>   | <b>{1,3}</b>   |
| <b>{1,3}</b> | <b>{1,2}</b>   | <b>{1}</b>     |
| {2,3}        | $\emptyset$    | {3}            |
| {1,2,3}      | {1,2}          | {1,3}          |
| $\emptyset$  | $\emptyset$    | $\emptyset$    |

## Potenzautomatenkonstruktion, Beispiel 2: Das Zustandsdiagramm

Nur ein Teil der  
Zustände ist vom  
Startzustand aus  
erreichbar.

Die übrigen  
Zustände sind  
funktionslos.



## Morphologiesysteme

- Flexionsmorphologie: Lemmatisierung/Stemming
  - *veranstalt+et, Veranstaltung+en*
- Ableitungs-/Derivationsmorphologie
  - *Veranstalt+ung, un+glaubwürdig*
- Komposita-Zerlegung
  - *Fach+veranstaltung, glaub+würdig*

## Morphologiesysteme

- Flexionsmorphologie: Lemmatisierung/Stemming
- Ableitungs-/Derivationsmorphologie
- Komposita-Zerlegung

## Lemmatisierung/Stemming

- Rückführung flektierter Formen auf Stämme, erlaubt je nach morphologischer Struktur der Sprache Reduktion der Lexikongröße (Verhältnis Wortstämme/Lemmata : Wortformen) von 1:2 (Englisch), 1:5 (Deutsch), 1:200 und mehr (Türkisch, Finnisch).
- Ermittlung von grammatischen Merkmalen, die für die syntaktische Analyse nötig sind.
- Methode: Endliche Automaten + Flexionsklassen-Information im Lexikon + Regeln für vorhersagbare morphophonologische Prozesse
- Morphologische Analyse (und damit auch deren Umkehrung, die Wortformengenerierung) ist für das Stemming gelöst. Verbleibendes Problem für das Deutsche: Trennbare Präfixverben. Kommerzielle Systeme haben eine gute Abdeckung (bis ca. 98%). Abdeckungsprobleme sind meist auf Abdeckungsprobleme bei der Kompositazerlegung zurückzuführen.

## Wortbildungsmorphologie: Ableitung/Derivationsmorphologie

- Analyse liefert über den Wortstamm Information zur Ableitung der Bedeutung und über das Suffix Wortart- und Flexionsklasseninformation: **Vervielfältig+ung** bezeichnet den Vorgang des Vervielfältigens, ist feminines Substantiv und wird schwach flektiert.
- Zwei Probleme, die zusammenhängen:
  - viele Ableitungsprä- und -suffixe sind semiproduktiv
  - viele Ableitungen sind semantisch "nicht transparent": Sie haben eine konventionelle, lexikalisierte Bedeutung, die sich nicht aus den Bestandteilen erschließen lässt.
- Derivationsanalyse führt aus diesen Gründen zur **Übergenerierung**:
  - die *Lesung* bezeichnet den Akt des Vorlesens,
  - die *Vorlesung* aber nicht den Akt des Vorlesens,
  - die *Schreibung* nicht den Akt des Schreibens, und
  - die *Singung* ist ganz unmöglich

## Wortbildungsmorphologie: Ableitung/Derivationsmorphologie

- Die Analyse von Derivativen ist in Morphologiesysteme meist mehr oder weniger ausführlich mit integriert. Sie kann grundsätzlich mit endlichen Automaten realisiert werden.
- Wegen Semiproduktivität und fehlender semantischer Transparenz ist es sinnvoll, Wissen über Ableitungen im großen Umfang im Lexikon zu kodieren.

## Morphologiesysteme

- Lemmatisierung/Stemming
- Ableitungs-/Derivationsmorphologie
- Komposita-Zerlegung

## Kompositazerlegung

- Die Analyse von Komposita ist besonders in Sprachen wie dem Deutschen unerlässlich (potenziell beliebige Länge von Komposita und deshalb unbegrenzt großer Wortschatz).
- Rechtschreibprüfung ohne oder mit begrenzter Kompositabehandlung führt zu vielen korrekten, aber unerkannten Wörtern (MS Word bis vor einigen Jahren).
- Vollständigere Suche beim Informationszugriff (z.B. IR): Suche nach *Rentenversicherung* soll auch *Angestelltenrentenversicherung* finden.

## Kompositazerlegung: Probleme

- Fugenelemente:
  - sind keine Flexionssuffixe, vgl.: "*Absicht***s**" in Absichtserklärung
  - sind nicht vollständig aus der phonologischen/ orthografischen Umgebung vorhersagbar
  - gehören nicht zu der Information, die in Einträgen konventioneller Wörterbücher mit aufgeführt wird.
- Übergenerierung:
  - Beispiel zur Konversion alte-neue Rechtschreibung (falsch angewandte Drei-Konsonanten-Regel)
    - Hufeisenniere → Huf|ei|senn|niere

## Komposita-Zerlegung in Morphologiesystemen

- Gute Morphologien haben eine Kompositazerlegung mit guter Abdeckung und akzeptablem Übergenerierungsverhalten.
- Zur Vermeidung von Übergenerierung werden Blockierungslisten mit kurzen und seltenen Wörtern angelegt. Komposita, die diese Wörter enthalten, werden explizit im Lexikon aufgeführt.