

Sprachsynthese: Textnormalisierung

Uwe Reichel (Änderungen von F. Schiel 2016)
Institut für Phonetik und Sprachverarbeitung
Ludwig-Maximilians-Universität München
reichelu|schiel@phonetik.uni-muenchen.de

20. Oktober 2022

Inhalt

*Textnormalisierung =
Vorverarbeitung des Text-Inputs in 'aussprechbare' Wortketten*

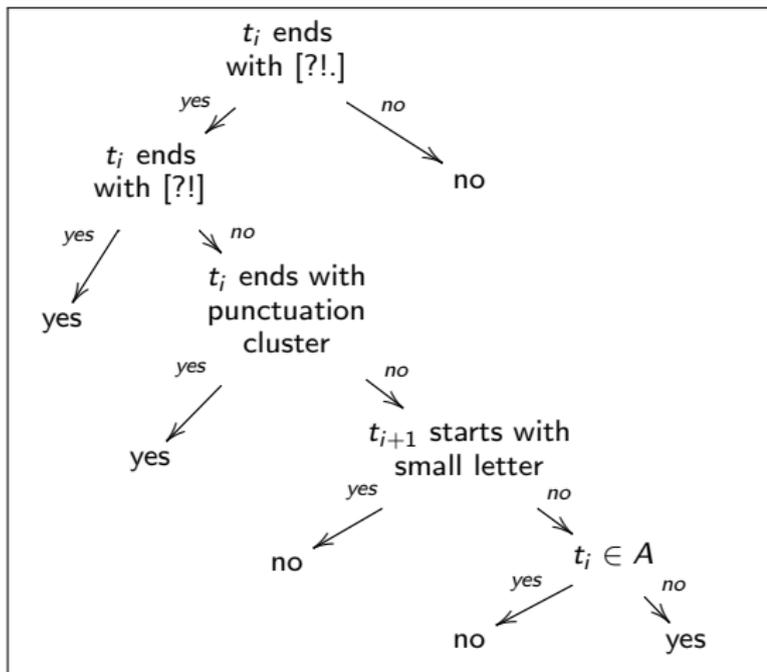
- Satzsegmentierung
- Tokenisierung
- Wortnormalisierung, Finite-State-Methoden
- Ausgabe

Satzsegmentierung

- **Disambiguierung des Punkts:**
Satzgrenze, Abkürzung, Ordnungszahl, Datum, '...'
- **hierbei hilfreich:**
 - Kleinschreibung nach '.' → keine Satzgrenze
 - Abkürzungs-Mustererkennung: Abk. enden auf '.', treten sonst nicht ohne '.' auf und
 - sind einbuchstabig oder
 - enthalten einen weiteren '.' oder
 - enthalten keinen Vokal oder
 - die Buchstabenfolge widerspricht der Silbenphonotaktik (*rcal.*)

Technik:

For each word t_i in sentence:
decide if sentence ends after t_i



Technik: Entscheidungsbaum Satzende nach Wort t_i ?; $A = \{\text{Abkürzung, Titel}\}$.

Tokenisierung

- Zerlegung eines Satzes in **Tokens**
- *Token*: durch Leerzeichen begrenzte Zeichenfolge + Abtrennung von Satzzeichen
- Vorverarbeitung:
 - z.B. Trennung inhomogener Zeichenfolgen
 - *5cm* → *5 cm*
- Beispiel: *'Der Bolzen war 10cm lang - oder 12cm?'* →
[Der] [Bolzen] [war] [10] [cm] [lang] [-] [oder] [12] [cm] [?]

Wortnormalisierung

- **Wortnormalisierung:** Nicht-Standard-Wörter → (aussprechbare) Standard-Wörter
Beispiele: 'USA' → '[u] [es] [a]', '3-4' → 'drei bis vier'
- **1. Expansion von Zahlen:**
 - römisch → arabisch durch Berechnung
 - arabisch → Wort mit Hilfe eines **Finite-State-Transducers**
 - kontextabhängig: Realisierung ziffernweise, als Bruchzahl, Datum, Jahreszahl, Uhrzeit, oder Telefonnummer
 - durchsuche Wortumgebung auf **Schlüsselphrasen:** *Nummer, Uhr, im Jahre, nach Christus, anrufen, wählen, ...*
 - kontextabhängig: Flexion von Ordinalzahlen (*der 10. Mai, am 10. Mai*) kontextabhängig
 - Problem römische Zahlen: *Johannes X, Kapitel X, Mister X*

Wortnormalisierung: Finite-State-Methoden

Technik: Finite-State-Methoden

- Verfahren zum
Analysieren (Parsen): Endlicher Automat (DFA)
Transformieren: Finite-State-Transducer (FST)
- **Definitionen**
 - **Alphabet** Σ : endliche Menge von Zeichen
 - **'Wort'** w : Verkettung von Zeichen aus Σ
 Σ^* : Menge aller 'Wörter' über Alphabet Σ
 - **Sprache** L über Σ : Teilmenge von Σ^* ,
d.h. Menge von 'Wörtern'

Wortnormalisierung: Finite-State-Methoden

Technik: Endlicher Automat (DFA)

- **Entscheidungsproblem:** entscheide, ob 'Wort' $w \in L$
- **Endlicher Automat:** $\mathcal{A} = (Q, \Sigma, q_0, F, \Delta)$
 - Q : endliche Zustandsmenge
 - Σ : endliches Eingabe-Alphabet
 - $q_0 \in Q$: Startzustand
 - $F \subseteq Q$: Menge von Finalzuständen
 - $\Delta : Q \times \Sigma \rightarrow Q$: Übergangsrelation; $\Delta(q_x, s) = q_y$
("vom Zustand q_x gelangt man durch Einlesen des Zeichens s in Zustand q_y ")
- Sprache $L(\mathcal{A})$: Menge aller von \mathcal{A} akzeptierten 'Wörter'

Wortnormalisierung: Finite-State-Methoden

- 'Wort' w ist Element von $L(\mathcal{A})$, wenn in \mathcal{A} nach Einlesen des letzten Zeichens von w ein Finalzustand erreicht werden kann
- **deterministischer** endlicher Automat DFA: Δ ist für jedes Zustand-Eingabesymbol-Paar eindeutig

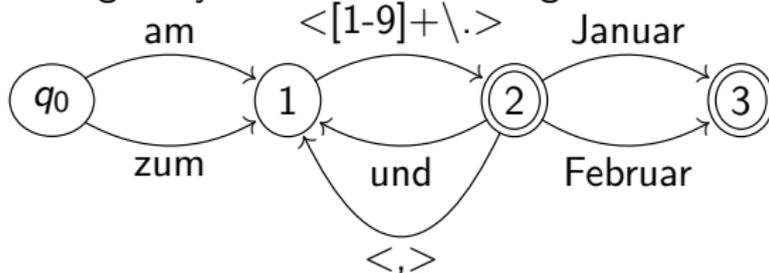


Abbildung: DFA-Ausschnitt für Sprache "Dativ". Menge von 'Wörtern' (hier: Tokensequenzen), für die Ordnungszahlen im Dativ *-ten* stehen müssen. q_0 : Startzustand, 2, 3: Finalzustände

Wortnormalisierung: Finite-State-Methoden

Technik: Finite State Transducer (FST)

- Übersetzung einer Zeichenkette in eine andere
- **Finite State Transducer** $\mathcal{T} = (\Sigma_1, \Sigma_2, Q, q_0, F, \Delta)$
 - Σ_1 : Eingabealphabet
 - Σ_2 : Ausgabealphabet
 - Q : endliche Zustandsmenge
 - $q_0 \in Q$: Startzustand
 - $F \subseteq Q$: Finalzustände
 - $\Delta : Q \times \Sigma_1 \times \Sigma_2 \rightarrow Q$: Übergangsrelation mit Ersetzung;
 $\Delta(q_x, i : o) = q_y$ ("Vom Zustand q_x gelangt man durch Einlesen des Eingabezeichens i in Zustand q_y . Dabei wird i durch das Ausgabezeichen o ersetzt.")

Wortnormalisierung: Finite-State-Methoden

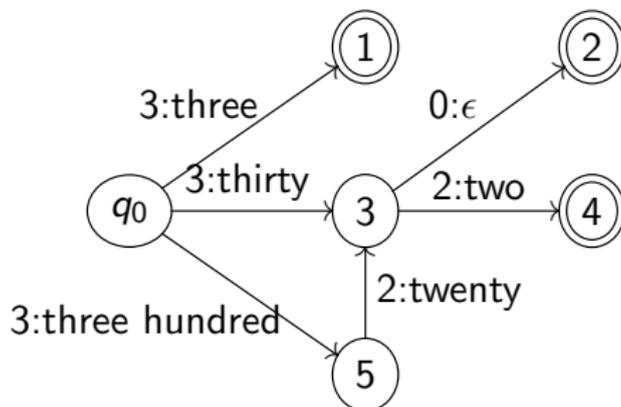


Abbildung: FST-Ausschnitt zur Umwandlung von Zahlen. Beispiel: 320
→ *three hundred twenty*.

Wortnormalisierung

- **2. Erkennung und Aussprache von Akronymen:**

- +/– ausbuchstabiert: *UNO* vs. *USA*
- Expansion auch von Wortteilen (*CD-ROM*)

- **3. Abkürzungen:** Lexikon zur Expansion nötig

- **4. Hybrid-Wörter:** *B-2-Bomber*, *80er*, *§20(B)*, und

- **5. Multi-Wörter:** URL's, Mailadressen, und

- **6. Nicht-Buchstaben:** *4-5* → *minus*, *bis*?

Technik: Heuristische Behandlung 4.-6.:

- Zerlegung an Zeichendiskontinuitäten
(*B-2-Bomber* → *B*, *-*, *2*, *-*, *Bomber*)

- *Finite-State-Transducer* zur Normalisierung der einzelnen Teile

z.B. Autos.

```
<SENTENCE>  
  
  <TOKEN >  
  
    <STRING>z.</STRING>  
    <NRM>zum</NRM>  
  
  </TOKEN >  
  <TOKEN >  
  
    <STRING>B.</STRING>  
    <NRM>Beispiel</NRM>  
  
  </TOKEN >  
  <TOKEN >  
  
    <STRING>Autos</STRING>  
    <NRM>Autos</NRM>  
  
  </TOKEN >  
  <TOKEN >  
  
    <STRING>.</STRING>  
    <NRM>.</NRM>  
  
  </TOKEN >  
</SENTENCE>
```

Beispielverarbeitung

BAS webservice

<https://clarin.phonetik.uni-muenchen.de/BASWebServices/>
G2P (Reichel, Kisler, 2014): *Files 2_textnormalisierung_G2P.txt*,
FelixBurghardt2.txt

Optionen: lng=deu-DE, oform=tab|tcf, textnorm=yes