

## SNLP – Statistical Natural Language Processing

### 1. SNLP - Motivationen

SNLP-Systeme sind

- Schnell und billig zu produzieren
- Erlauben schnelles „prototyping“
- **Robust**
  - Egal wie schlecht der Input ist, es gibt immer einen Output

### 1. SNLP - Motivationen

- SNLP-Systeme liefern gute Ergebnisse („real-world“ applications)
- Ambiguität von Sprache
- Wahrscheinlichkeitsstrategien wesentlicher Bestandteil menschlicher Kognition
- SNLP-Systeme werden dem „kreativen Charakter“ von Sprache gerecht

### 2. SNLP - Voraussetzungen

SNLP-Systeme bedienen sich der **Techniken maschinellen Lernens**

- Benötigen (annotierte) Textkorpora zu Trainings- und Testzwecken
- Z. B. Penn Treebank, Switchboard,...

### 2. SNLP - Korpora

Einige statistische „Spielereien“ im Textkorpus

– Zählen der häufigsten Wörter

Word	Freq.	Use
the	3332	determiner (article)
and	2972	conjunction
a	1775	determiner
to	1725	preposition, verbal infinitive marker
of	1440	preposition
was	1161	auxiliary verb
it	1027	(personal/expletive) pronoun
in	906	preposition
that	877	complementizer, demonstrative
he	877	(personal) pronoun
I	783	(personal) pronoun
his	772	(possessive) pronoun
you	686	(personal) pronoun
Tom	679	proper noun
with	642	preposition

Table 1.1 Common words in Tom Sawyer.

### 2. SNLP - Korpora

Einige statistische „Spielereien“ im Textkorpus

Word Frequency	Frequency of Frequency
1	3993
2	1292
3	664
4	410
5	243
6	199
7	172
8	131
9	82
10	91
11-50	540
51-100	99
> 100	102

Table 1.2 Frequency of frequencies of word types in Tom Sawyer.


## 2. SNLP - Korpora

Erkenntnisse:


- ungleiche Verteilung der Wort-"types"
- Einige wenige Wörter kommen sehr häufig vor
- 90% tauchen weniger als zehn mal auf, davon 12% weniger als drei mal
- => Problem für SNLP: verwendete Korpora müssen sehr groß sein

## 3. SNLP – Was ist das?

- Statistische Verfahren zunächst in der Spracherkennung eingesetzt => Ausdehnung auf andere NLP-Bereiche
- Grundlagen der SNLP: Wahrscheinlichkeitstheorie & Informationstheorie („noisy channel model“)



## 3. SNLP – Beispiel




## 3. SNLP – Beispiel

A simple grammar is shown in Figure 2 (adapted from Jurafsky and Martin (2009)).

A → β [p]			
S → NP VP	.80	Det → that	.05
S → Aux NP VP	.15	Det → the	.80
S → VP	.05	Det → a	.15
NP → Det Noun	.30	Noun → laptops	.50
NP → Proper-Noun	.35	Noun → desktops	.50
NP → Noun	.05	Verb → sell	.30
NP → Pronoun	.40	Verb → ship	.55
Nom → Noun	.75	Verb → repair	.15
Nom → Noun Noun	.20	Aux → can	.60
Nom → Proper-Noun Noun	.05	Aux → do	.40
VP → Verb	.55	Proper-Noun → Apple	.50
VP → Verb NP	.40	Proper-Noun → Sony	.50
VP → Verb NP NP	.05	Pronoun → you	.40
		Pronoun → I	.60

FIGURE 2 A very simple probabilistic grammar for English

## 3. SNLP – Beispiel



## 4.1 SNLP – Wie geht das?

### Modeling

- „Modeling is the general task of constructing machinery which mimics some task“
1. Struktur des Modells (z. B. Syntax-Modell => grammatikalische Regeln)
  2. Parametrisierung des Modells (Variablen, die bestimmte Wahrscheinlichkeiten tragen können)
  3. Instantiierung des Modells (d.h. Parameter bekommen Wahrscheinlichkeitswerte zugewiesen) => über Lernen/Schätzen

## 4.1 SNLP – Modeling

Problem bei Modeling:

- Overfitting (Modell ist zu speziell)
- Underfitting (Modell ist zu allgemein)

Zwei verschiedene Modelle:

- Generative vs. discriminative models

## 4.2 SNLP – Estimation/Learning

Parameter eines Modells müssen aufgrund von Trainingsdaten Werte zugewiesen bekommen.

Dabei ist zu beachten:

- **Bias** (Verzerrungen der Daten durch):
  - Bias by design (Occam 's razor)
  - Bias in design (maximum likelihood estimators, maximum entropy models)
- **Scalability**
  - Behandelt „trade-off“ zwischen Anzahl der Parameter und Computerressourcen

## 4.2 Estimation: Maximum likelihood (MLE)

- Bestimmung der Parameter des Modells so, dass die Wahrscheinlichkeit auf den Trainingsdaten am höchsten ist.
- einfache (inkorrekte) Bestimmung durch Zählen
  - z. B. bei „part-of-speech tagging“: (Wie oft bekommt ein Wort einen bestimmten „tag“ zugewiesen) / (Anzahl der verschiedenen möglichen „tags“ für dieses Wort)

## 4.2 Maximum likelihood - smoothing

- MLE is biased towards the training set => Tendenz zum „overfitting“
- Smoothing ist eine Technik, die Daten so zu verändern, dass die Performance der SNLP-Anwendung steigt

## 4.2 Estimation – Maximum Entropy (Maxent)

- Maß des Informationsgehaltes
- Kann z.B. genutzt werden, als Maß, wie viel Information in einer best. Grammatik steckt oder wie gut eine best. Grammatik eine Sprache abbildet,...
- „Maxent“ Modelle können Abhängigkeiten zwischen Parametern (Wörtern) modellieren.

MLE und Maxent Modelle sind in eine Art „Zusammenfassung“ der Trainingsdaten.

## 4.2 Estimation – Weitere Ansätze

- Kernel Methoden
- Ensemble Approaches

### 4.3 SNLP - Evaluation

Which method is best for a given task?

⇒ **Quantitative comparison between different approaches.**

Zwei Maße (e.g. text classification):

- **Precision:** number of correctly classified documents/number of classifications posited
- **Recall:** number of documents assigned a particular classification / number of documents in the testing set which actually belong to that class

### 4.3 SNLP - Evaluation

- training & testing set
- Upper bound upon performance: human performance
- Lower bound upon performance: chance

## 5. SNLP - Applications

- Part-of-Speech Tagging
- Statistical Parsing (shallow parsing)
- Text Classification
- Question answering (intelligent information retrieval)
- Machine Translation
- OCR/Speech Recognition
- Augmentive communication systems