

# Vortrag SWP Gruppe 3

## Translation Memories für automatische Patentübersetzung

Sabrina Mänz  
Thomas Wangler

Institut für Computerlinguistik

22.07.2013

# Inhaltsübersicht

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

**1** Aufgabenstellung

2 Arbeitsschritte

3 Evaluierung

4 Ergebnisse

5 Resumee

6 Quellen

# Erinnerung Aufgabenstellung

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- Aus PatTR-Korpus SMT-System lernen
- Fuzzy Matches finden (TM)
- Bei geeignetem FMS merkliche Verbesserung gegenüber SMT-Baseline

Source	<i>The second paragraph of Article 21 is deleted .</i>
String Edit	
TM Source	<i>The second paragraph of Article 5 is deleted .</i>
Word Alignment	
TM Target	<i>À l' article 5 , le texte du deuxième alinéa est supprimé .</i>
XML Frame	<i>&lt;À l' article&gt; 21 &lt;, le texte du deuxième alinéa est supprimé .&gt;</i>

- Aufteilung anhand Metadaten (Filereader)
- **Testdaten:** Jahr 2000 - 2115 Sätze
- **Devsets:** 1996, 1998, 2002, 2004 - 2.037.564 Sätze
- **Trainingsset:** 5.271.065 Sätze
  
- patr.claims insgesamt: 8.346.862 Sätze
  
- 1.036.118 Sätze erfüllen >100 Kriterium

# Inhaltsübersicht

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

**Arbeitsschritte**

Evaluierung

Ergebnisse

Resumee

Quellen

1 Aufgabenstellung

**2 Arbeitsschritte**

3 Evaluierung

4 Ergebnisse

5 Resumee

6 Quellen

# Vorbereitung des Korpus

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- Entfernung von langen Sätzen: `training/clean-corpus-n.perl`
- tokenisieren: `tokenizer/tokenizer.perl`
- compound-splitter: `generic/compound-splitter.perl`
- lowercasen: `tokenizer/lowercase.perl`
- Satzgrenzen einfügen: `irstlm/bin/add-start-end.sh`  
Bsp.: `<s>a device according to claim 8 characterised in that on the mounting or rear side the further disc-like cover ( 67 ) has a receiving opening ( 73 ) for receiveing the fixing element ( 68 ) which is in the form of a screw . </s >`
- Vorformatieren für Hadoop und CreateXML  
Bsp.: `1|||<s>a device according to claim 8 [...] </s >`

# Baseline Model

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- Build language Model: `irstlm/bin/build-lm.sh`
- Compile LM: `irstlm/bin/compile-lm`
- Build binarised LM: `mosesdecoder/bin/build_binary`
- Trainieren des Modells: `training/train-model.perl`
- `moses.ini`

**Translating:** vorrichtung nach anspruch 5 , dadurch gekennzeichnet , daß die weitere scheibenartige abdeckung ( 67 ) geringeren durchmessers auf der frontseite ( 64 ) [...]

**BEST TRANSLATION:** a device according to claim 5 , characterised in that the further disc-like cover ( 67 ) [...]

# Testset I

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- Hadoop liefert Fuzzy Matches  
1001 3573116 0.85  
1009 4666468 0.714
- Keys aus hadoop-output-File extrahieren
- createFMString ausführen
- CreateXML ausführen
- Aufruf mosesdecoder: `/mosesdecoder/bin/moses -xml-input exclusive -f ./moses.ini <xmlfile > translation.xml`
- Englischsprachiges Corpus liefert Modellübersetzung
- Evaluation

# Beispiel CreateXML

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

**source:** `<s >verwendung nach anspruch 1 , worin die verbindung an ein polymer gebunden ist . </s >`

**tmSource:** `<s >verwendung nach anspruch 12 , wobei die verbindung freisetzbar an ein polymer gebunden ist . </s >`

**tmTarget:** `<s >the use according to claim 12 , wherein the compound is releasably bound to a polymer . </s >`

**alignments:** 0-0 1-2 2-3 2-4 3-5 4-6 5-7 6-8 7-9 8-10 14-11 9-12  
13-13 10-14 11-15 12-16 15-17 16-18

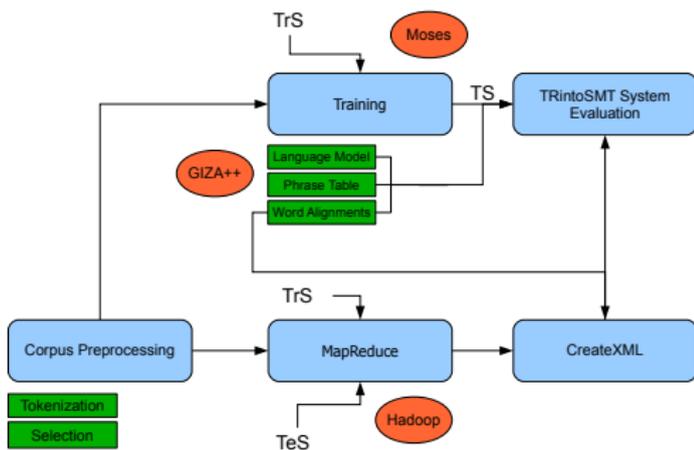
**xml:** `<xml translation="use according to claim" >x </xml >1`

`<xml translation="," >x </xml >worin`

`<xml translation="the compound to a polymer bound is ." >  
x </xml >`

# Implementierung

## ■ kurze DEMO



# Inhaltsübersicht

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

**Evaluierung**

Ergebnisse

Resumee

Quellen

1 Aufgabenstellung

2 Arbeitsschritte

**3 Evaluierung**

4 Ergebnisse

5 Resumee

6 Quellen

- Rahmenbedingungen / Evaluierungstechnik:  
Vergleich von Sätzen, für die FM gefunden
- Vergleich von Ergebnissen von  
Baseline-SMT-Übersetzung vs. Korpus-Übersetzung und  
TMSystem-Übersetzung vs. Korpus-Übersetzung
- Evaluation:  
multi-bleu.perl -lc translation.modell < translation.xml  
multi-bleu.perl -lc translation.modell < translation.noxml

# Inhaltsübersicht

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

1 Aufgabenstellung

2 Arbeitsschritte

3 Evaluierung

**4 Ergebnisse**

5 Resumee

6 Quellen

# Gefundene FM

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- 312 Sätze aus Testset bei  $FMS \geq 0,7$  (15%)
- 1416 aus Testset bei  $FMS \geq 0,5$  (67%)

zur Erinnerung:

**source:** `<s >verwendung nach anspruch 1 , worin die  
verbindung an ein polymer gebunden ist . </s >`

**tmSource:** `<s >verwendung nach anspruch 12 , wobei die  
verbindung freisetzbar an ein polymer gebunden ist . </s >`

# Auswertung I

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- Übersetzung **ohne xml**

BLEU = 56.51

(BP=0.972, ratio=0.973, hyp\_ len=6500, ref\_ len=6683)

- Übersetzung **mit xml**

BLEU = 44.96

(BP=0.953, ratio=0.955, hyp\_ len=6379, ref\_ len=6683)

# Auswertung II

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

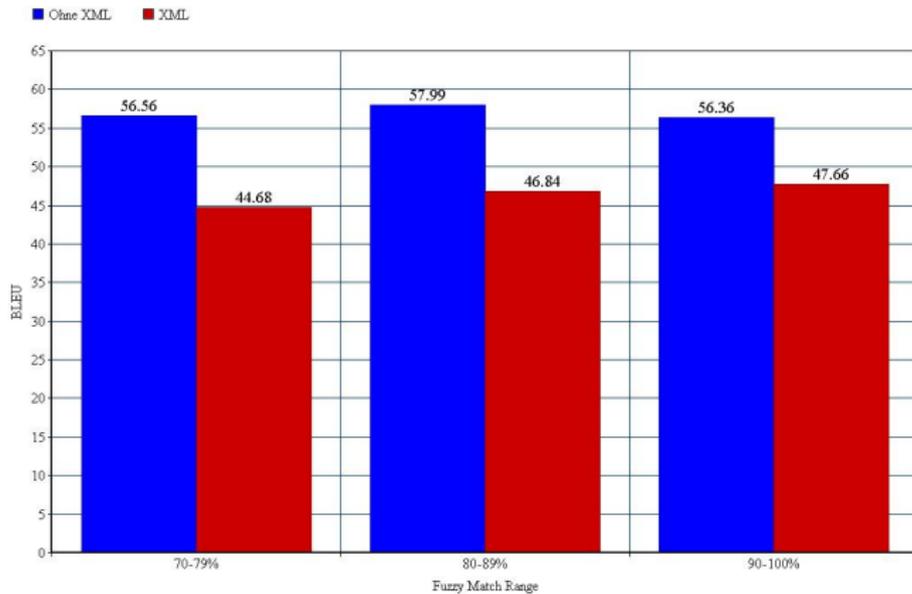
Evaluierung

Ergebnisse

Resümee

Quellen

Evaluations-Ergebnisse



# Auswertung zweites Set

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resümee

Quellen

- Korpusdaten (in Anlehnung an Acquis-Korpus, Koehn et al.):
  - Trainingsset: 1.165.867 Sätze
  - Testset: 4.107 Sätze
  - 63 FuzzyMatches (FMS  $\geq 0,7$ )
- Übersetzung **ohne xml**  
BLEU = 53.81  
(BP=0.998, ratio=0.998, hyp\_len=1258, ref\_len=1261)
- Übersetzung **mit xml**  
BLEU = 41.86  
(BP=0.963, ratio=0.964, hyp\_len=1215, ref\_len=1261)

# Auswertung Product - Koehn et al.

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resümee

Quellen

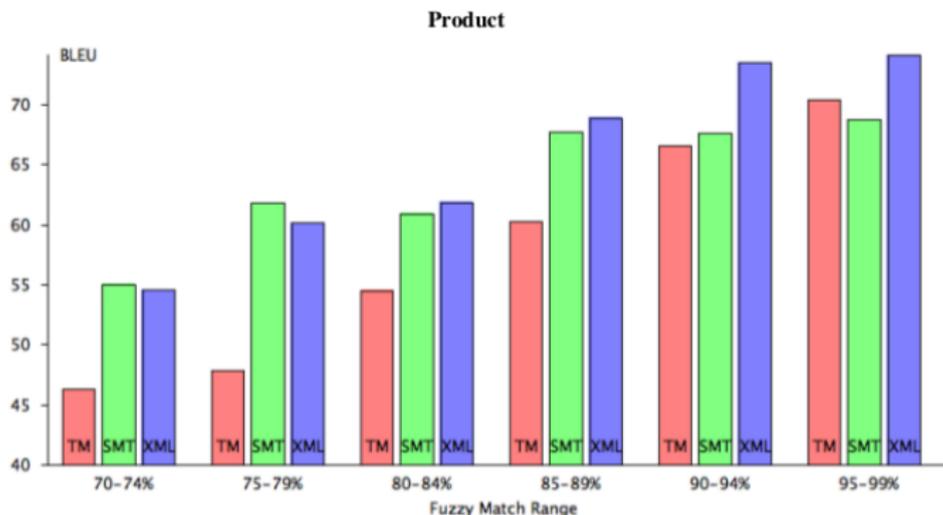


Figure 4: **Basic Results:** BLEU scores for different fuzzy match ranges. Our XML method performs best for sentence which have fuzzy matches of at least 80%, SMT is best below this threshold.

# Mögliche Gründe

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- Satzlänge im Testset (19.1 vs. 12 Wörter)
- Größe des Trainingssets
  - als Hauptgrund ausgeschlossen
- Paper: 83.461 Sätze (Product) vs. Projekt: 5.271.065 Sätze
- Struktur der xml-Konstruktion
- **Sprachpaar**: Englisch-Französisch vs. Deutsch-Englisch

# Inhaltsübersicht

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

**Resumee**

Quellen

1 Aufgabenstellung

2 Arbeitsschritte

3 Evaluierung

4 Ergebnisse

**5 Resumee**

6 Quellen

# Herausforderungen I

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- Projekt zu zweit
- Lauffähige Tools
- Moses-Parameter
- Dokumentation Hadoop

# Herausforderungen II

## ■ Implementierung des Pseudocodes

```
function construct-xml:  
  1: xml = ""  
  2: included = false  
  3: startt = -1  
  4: for all target positions  $t \in [0; |t|$  [do  
  5:   if !included AND matched-target( $t$ ) then  
  6:     startt = -1  
  7:     included = true  
  8:   else if included AND (!matched-target( $t$ ) OR  
     insertion[ $t$ ]) then  
  9:     if startt  $\geq$  0 then  
 10:      xml += "<xml translation=""  
 11:      xml += t[startt, t]  
 12:      xml += "> x </xml>"  
 13:     end if  
 14:     included = false  
 15:   end if  
 16:   xml += insertion[ $t$ ]  
 17: end for  
 18: return xml
```

# Gelungenes und Gelerntes

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

- Teamarbeit, google.code
- Technische Hürden überwunden
- Hadoop
- Notwendigkeit von Unittesting
- Dokumentation
- Devsets möglichst klein halten, Testen vor Verwendung
- Arbeiten mit großen Datenmengen kostet Zeit
- Zeitpläne helfen zur Orientierung
- Projekt läuft

- Optimierung wünschenswert
- Anwendung auf Gesamt-Patrr-Corpus
- Vergleich der verschiedenen Bereiche des Corpus -  
Unterschiede in der Nützlichkeit?
- Beide Richtungen übersetzen
- Anderer Ansatz für xmlConstruction
- z.B. Ordnen der tmTarget nach der source - Problem  
deletions

# Inhaltsübersicht

Vortrag SWP  
Gruppe 3

Sabrina Mänz  
Thomas  
Wangler

Aufgabenstellung

Arbeitsschritte

Evaluierung

Ergebnisse

Resumee

Quellen

1 Aufgabenstellung

2 Arbeitsschritte

3 Evaluierung

4 Ergebnisse

5 Resumee

**6 Quellen**

- Philipp Koehn, Jean Senellart, 2011:  
Convergence of Translation Memory and Statistical Machine Translation, AMTA Workshop on MT Research and the Translation Industry.
  
- <http://www.statmt.org/moses/?n=Moses.Baseline>