

Syntax-basierte maschinelle Übersetzung mit Baumübersetzern

Andreas Maletti

Leipzig — 28. April 2015

Maschinelle Übersetzung

Original

Übersetzung (GOOGLE TRANSLATE)

- ▶ The addressees of this paper are students and students will be in the audience are.

Maschinelle Übersetzung

Original

- ▶ Die Adressaten dieses Vortrags sind Studierende und im Publikum werden sich Studierende befinden.

Übersetzung (GOOGLE TRANSLATE)

- ▶ The addressees of this paper are students and students will be in the audience are.

Maschinelle Übersetzung

Original

- ▶ Die Adressaten dieses Vortrags sind Studierende und im Publikum werden sich Studierende befinden.

Übersetzung (GOOGLE TRANSLATE)

- ▶ The addressees of this paper are students and students will be in the audience are.
- ▶ To scientific lecture, a public discussion follows on.

Maschinelle Übersetzung

Original


- ▶ Die Adressaten dieses Vortrags sind Studierende und im Publikum werden sich Studierende befinden.
- ▶ An den wissenschaftlichen Vortrag schließt sich eine öffentliche Diskussion an.

Übersetzung (GOOGLE TRANSLATE)

- ▶ The addressees of this paper are students and students will be in the audience are.
- ▶ To scientific lecture, a public discussion follows on.


Maschinelle Übersetzung

Dreieck von VAUQUOIS:



Maschinelle Übersetzung

Dreieck von VAUQUOIS:



Übersetzungsmodell: "string-to-tree"

Maschinelle Übersetzung

Trainingsdaten

- ▶ paralleler Korpus
- ▶ Wortbeziehungen
- ▶ Syntaxbäume der deutschen Sätze (Zielsprache)

Maschinelle Übersetzung

Trainingsdaten

- ▶ paralleler Korpus
- ▶ Wortbeziehungen
- ▶ Syntaxbäume der deutschen Sätze (Zielsprache)

Paralleler Korpus

Linguistische Ressource mit Beispielübersetzungen
(auf Satzebene)

Maschinelle Übersetzung

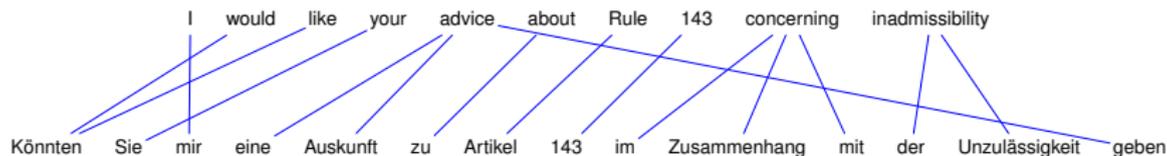
paralleler Korpus, Wortbeziehungen, Syntaxbaum

I would like your advice about Rule 143 concerning inadmissibility

Könnten Sie mir eine Auskunft zu Artikel 143 im Zusammenhang mit der Unzulässigkeit geben

Maschinelle Übersetzung

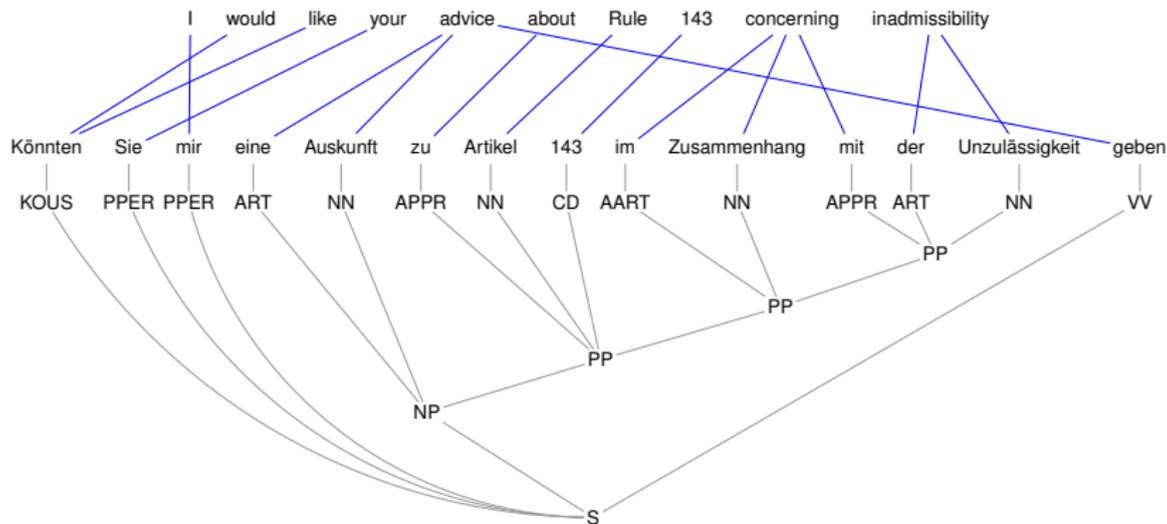
paralleler Korpus, **Wortbeziehungen**, Syntaxbaum



per GIZA++ [OCH, NEY, 2003]

Maschinelle Übersetzung

paralleler Korpus, Wortbeziehungen, **Syntaxbaum**



per BERKELEY-Parser [PETROV et al., 2006]

Baumübersetzer

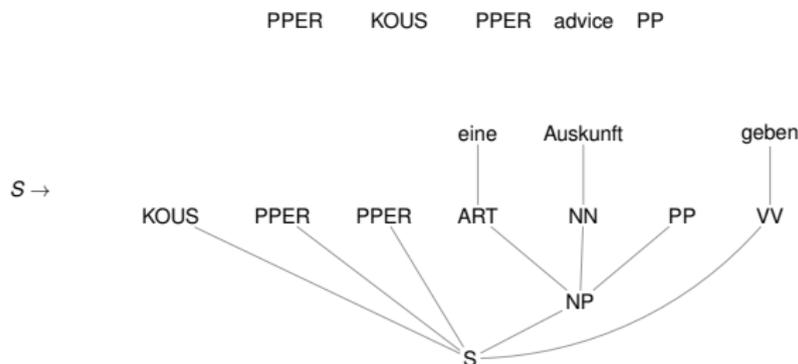
Erweiterter absteigender Baumübersetzer (STSG)

- ▶ Variante von [M., GRAEHL, HOPKINS, KNIGHT, 2009]
- ▶ Regeln der Gestalt $NT \rightarrow (r, r_1)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte Regelseite r_1 einer regulären Baumgrammatik

Baumübersetzer

Erweiterter absteigender Baumübersetzer (STSG)

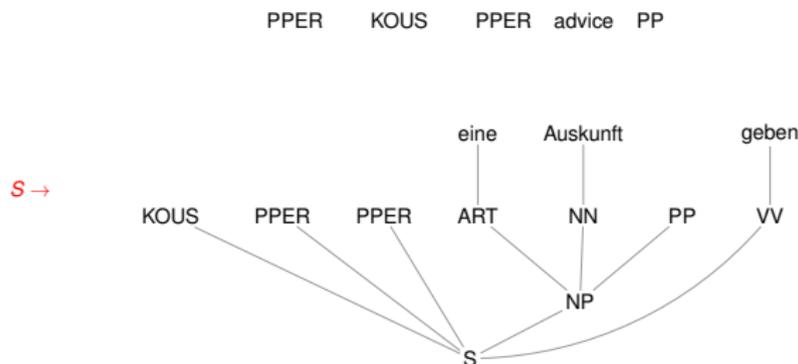
- ▶ Variante von [M., GRAEHL, HOPKINS, KNIGHT, 2009]
- ▶ Regeln der Gestalt $NT \rightarrow (r, r_1)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte Regelseite r_1 einer regulären Baumgrammatik



Baumübersetzer

Erweiterter absteigender Baumübersetzer (STSG)

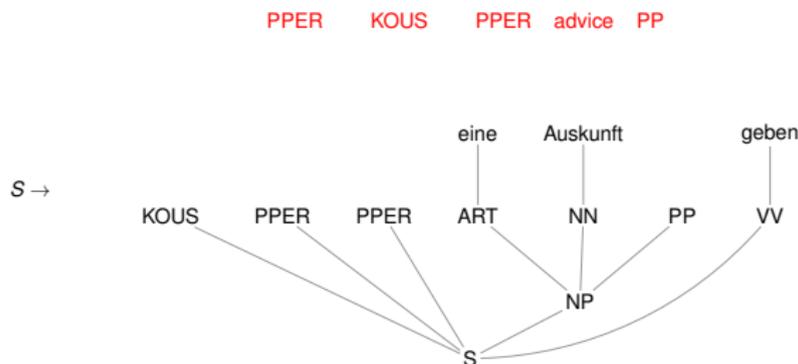
- ▶ Variante von [M., GRAEHL, HOPKINS, KNIGHT, 2009]
- ▶ Regeln der Gestalt $NT \rightarrow (r, r_1)$
 - ▶ **Nichtterminal NT**
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte Regelseite r_1 einer regulären Baumgrammatik



Baumübersetzer

Erweiterter absteigender Baumübersetzer (STSG)

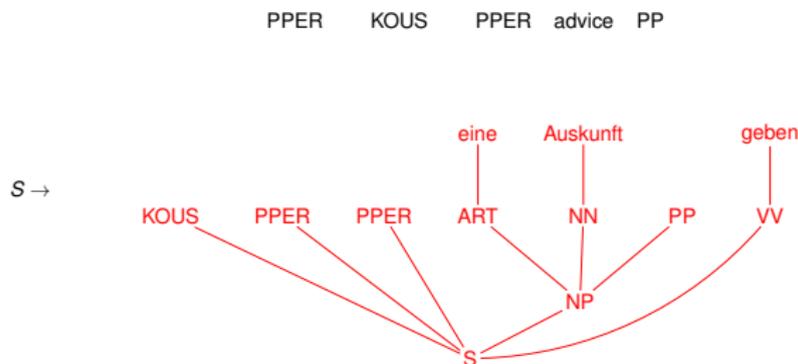
- ▶ Variante von [M., GRAEHL, HOPKINS, KNIGHT, 2009]
- ▶ Regeln der Gestalt $NT \rightarrow (r, r_1)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte Regelseite r_1 einer regulären Baumgrammatik



Baumübersetzer

Erweiterter absteigender Baumübersetzer (STSG)

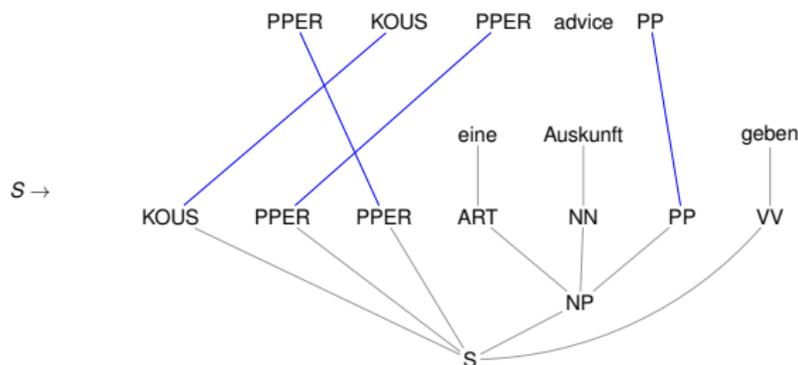
- ▶ Variante von [M., GRAEHL, HOPKINS, KNIGHT, 2009]
- ▶ Regeln der Gestalt $NT \rightarrow (r, r_1)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte Regelseite r_1 einer regulären Baumgrammatik



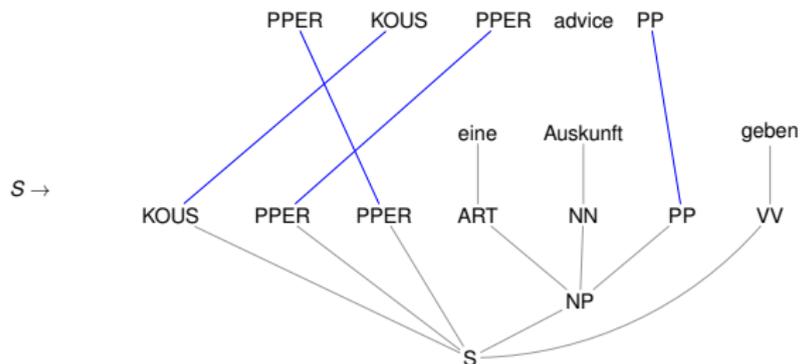
Baumübersetzer

Erweiterter absteigender Baumübersetzer (STSG)

- ▶ Variante von [M., GRAEHL, HOPKINS, KNIGHT, 2009]
- ▶ Regeln der Gestalt $NT \rightarrow (r, r_1)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte Regelseite r_1 einer regulären Baumgrammatik
- ▶ (bijektive) Synchronisation der Nichtterminale



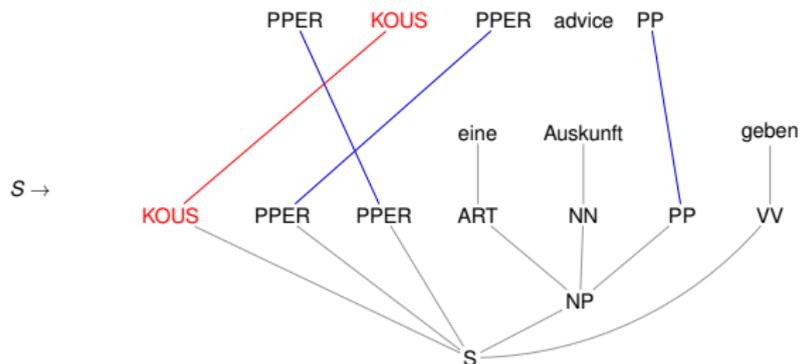
Baumübersetzer



Regelanwendung

1. Auswahl synchroner Nichtterminale

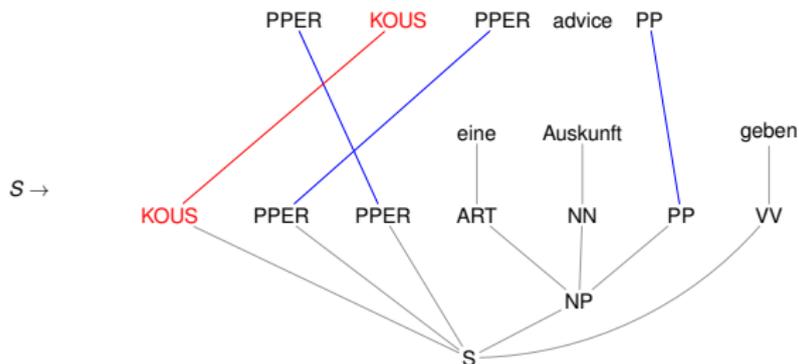
Baumübersetzer



Regelanwendung

1. Auswahl synchroner Nichtterminale

Baumübersetzer



Regelanwendung

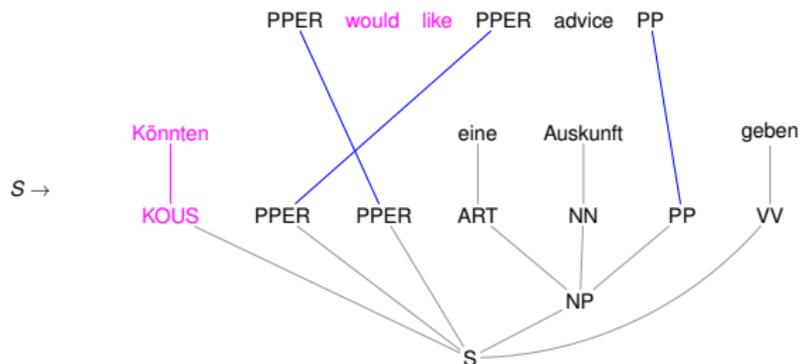
1. Auswahl synchroner Nichtterminale
2. **Auswahl einer passenden Regel**

would like

KOUS →


Könnten
|
KOUS

Baumübersetzer

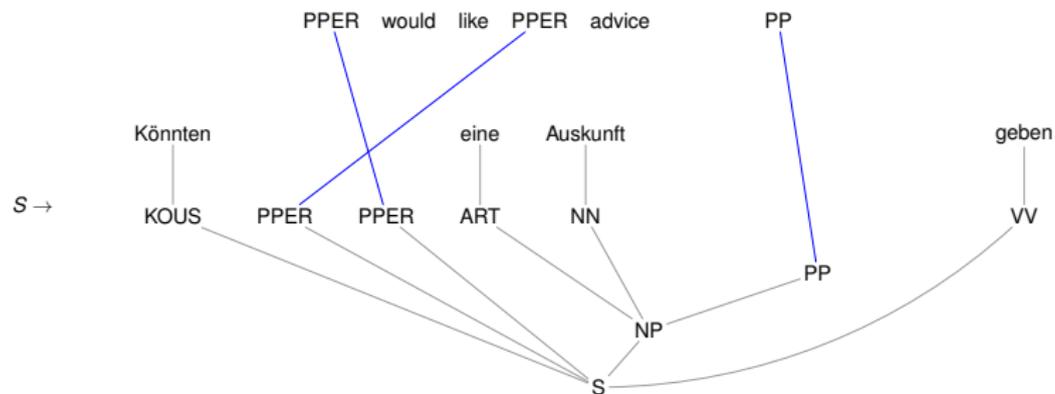


Regelanwendung

1. Auswahl synchroner Nichtterminale
2. Auswahl einer passenden Regel
3. Ersetzung auf beiden Seiten



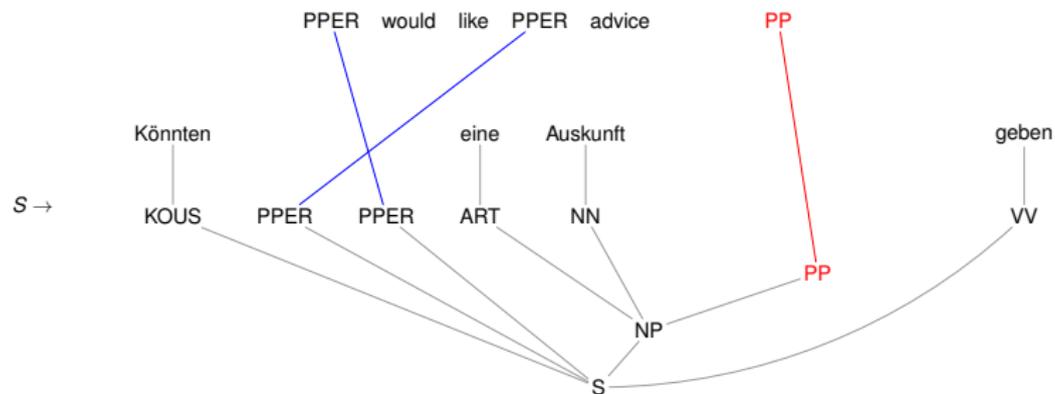
Baumübersetzer



Regelanwendung

1. Nichtterminal-Auswahl


Baumübersetzer



Regelanwendung


1. Nichtterminal-Auswahl

Baumübersetzer

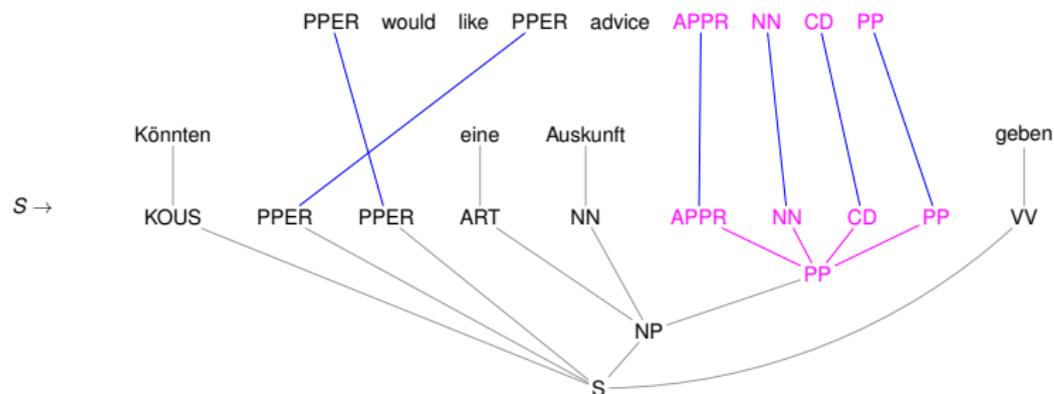


Regelanwendung

1. Nichtterminal-Auswahl
2. passende Regel

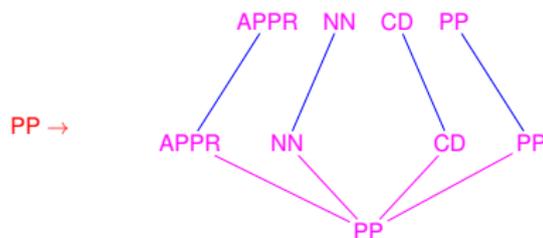


Baumübersetzer



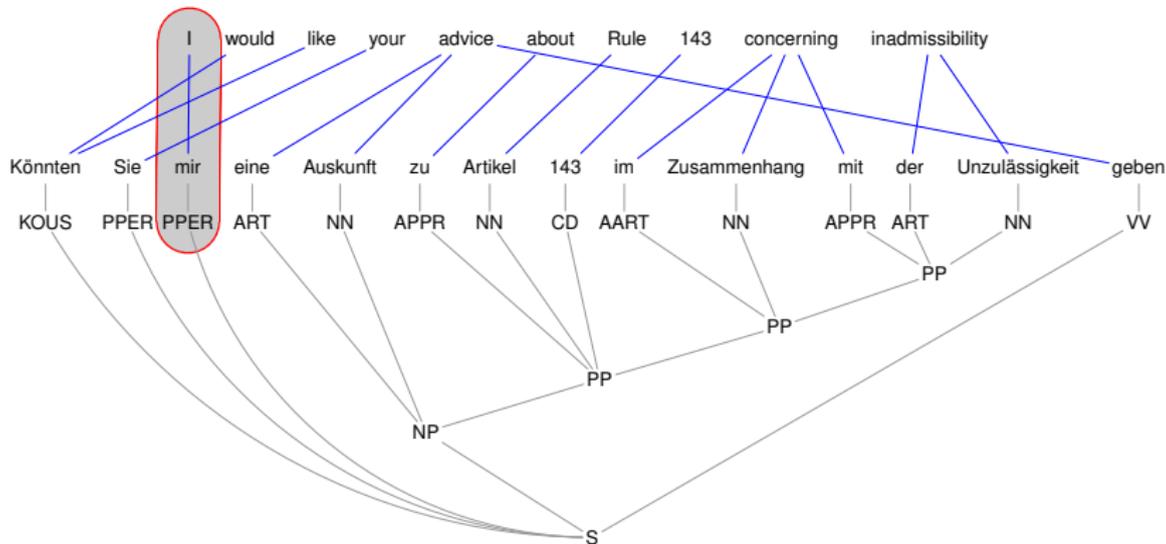
Regelanwendung

1. Nichtterminal-Auswahl
2. passende Regel
3. **Ersetzung**



Regelextraktion

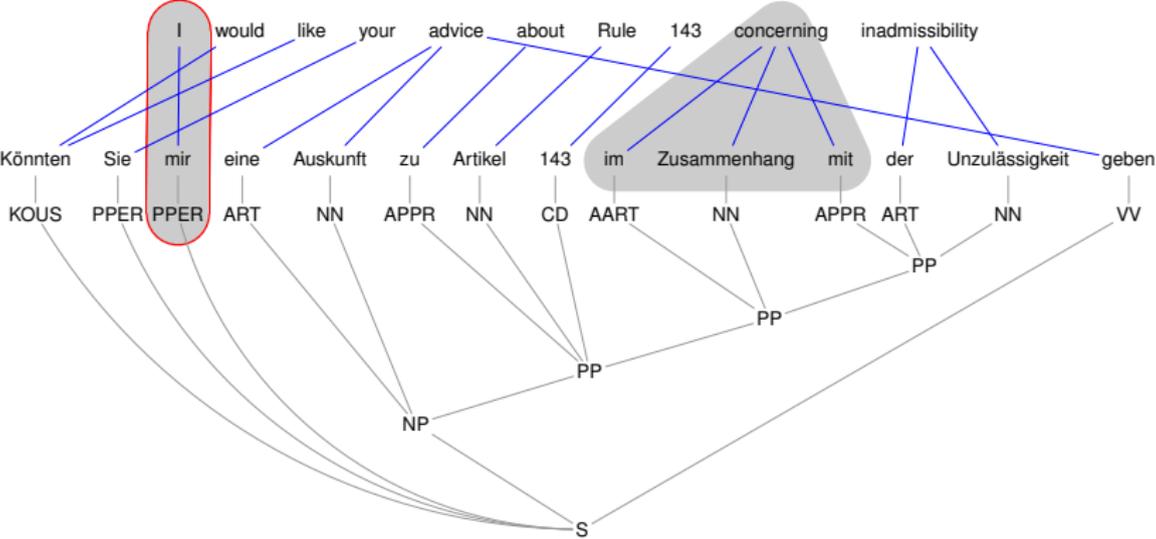
nach [GALLEY, HOPKINS, KNIGHT, MARCU, 2004]



extrahierbare Regeln rot umrandet

Regelextraktion


nach [GALLEY, HOPKINS, KNIGHT, MARCU, 2004]



extrahierbare Regeln rot umrandet

Regelextraktion

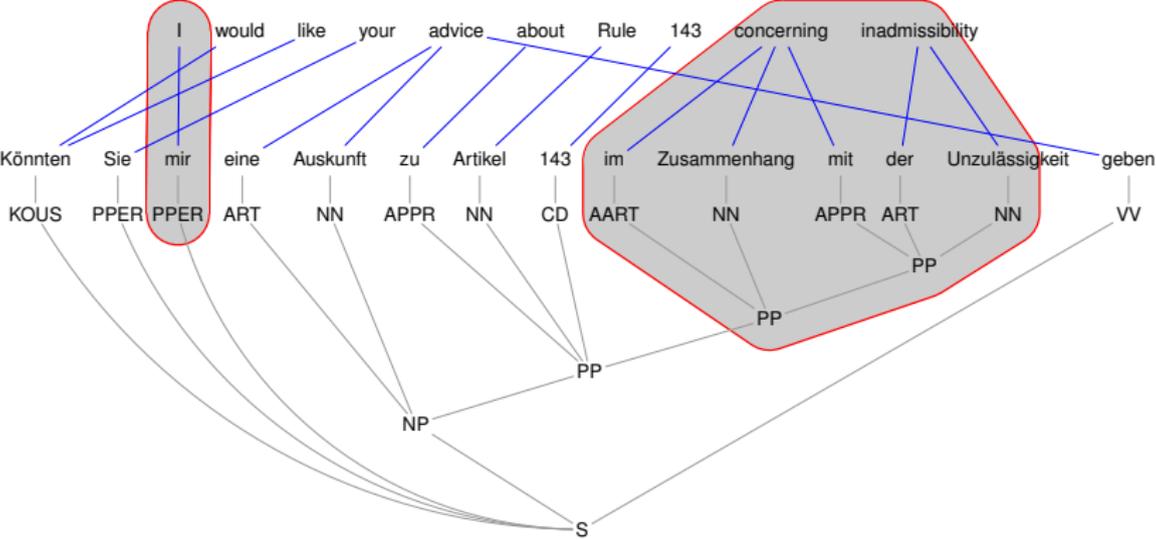
nach [GALLEY, HOPKINS, KNIGHT, MARCU, 2004]



extrahierbare Regeln rot umrandet

Regelextraktion


nach [GALLEY, HOPKINS, KNIGHT, MARCU, 2004]



extrahierbare Regeln rot umrandet

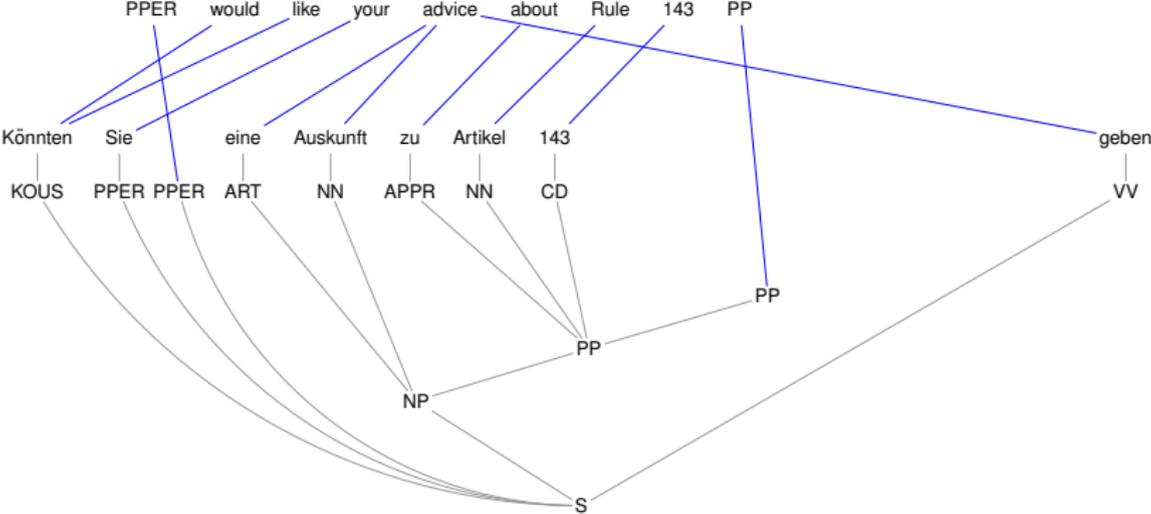
Regelextraktion

Ausschneiden der extrahierbaren Regeln:



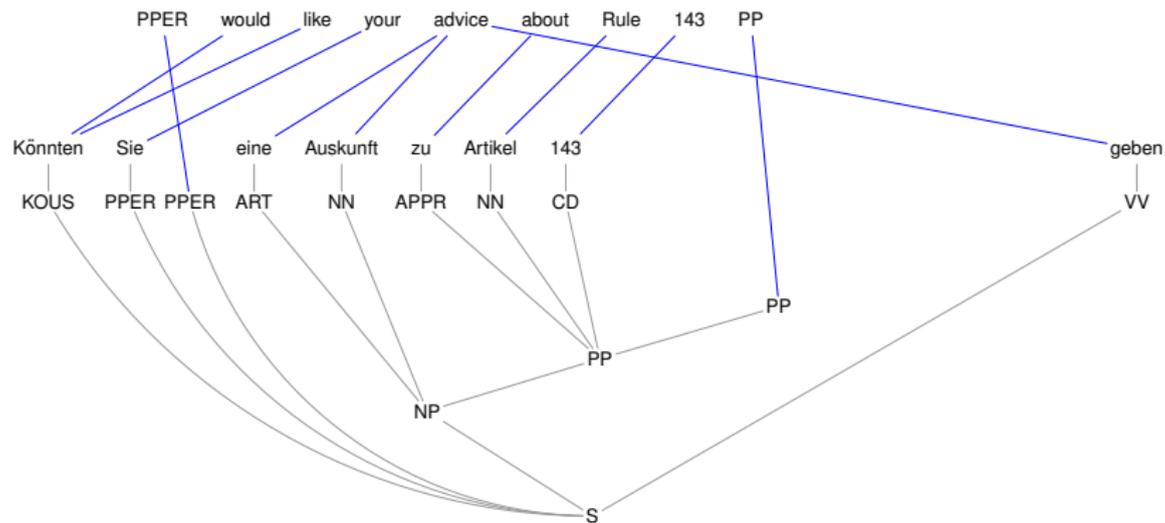
Regelextraktion

Ausschneiden der extrahierbaren Regeln:




Regelextraktion

Erneute Regelextraktion:




Regelextraktion

Erneute Regelextraktion:



Regelextraktion

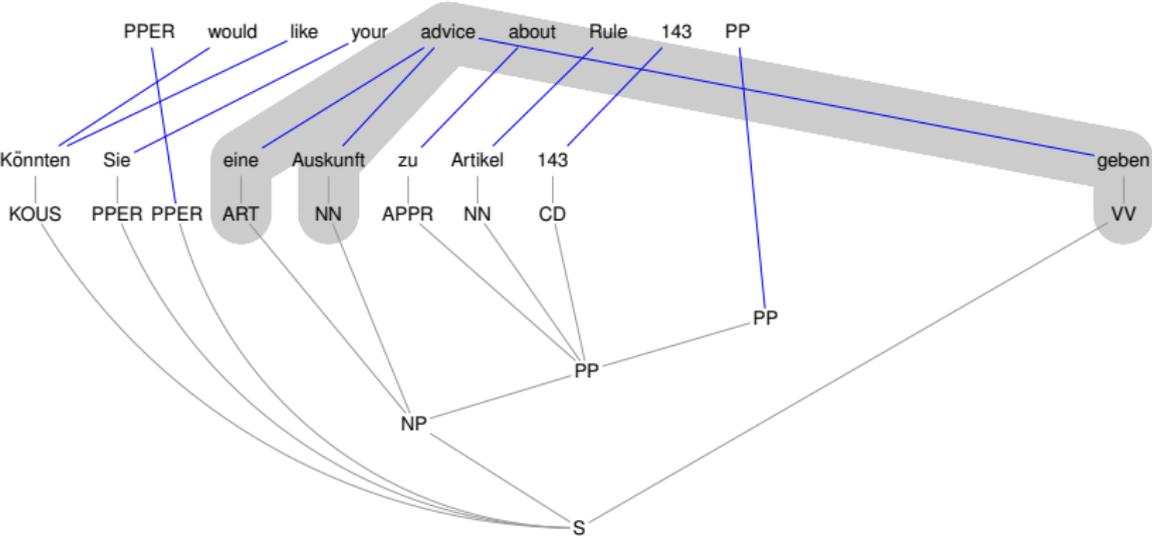
Erneute Regelextraktion:



extrahierbare Regeln rot umrandet

Regelextraktion

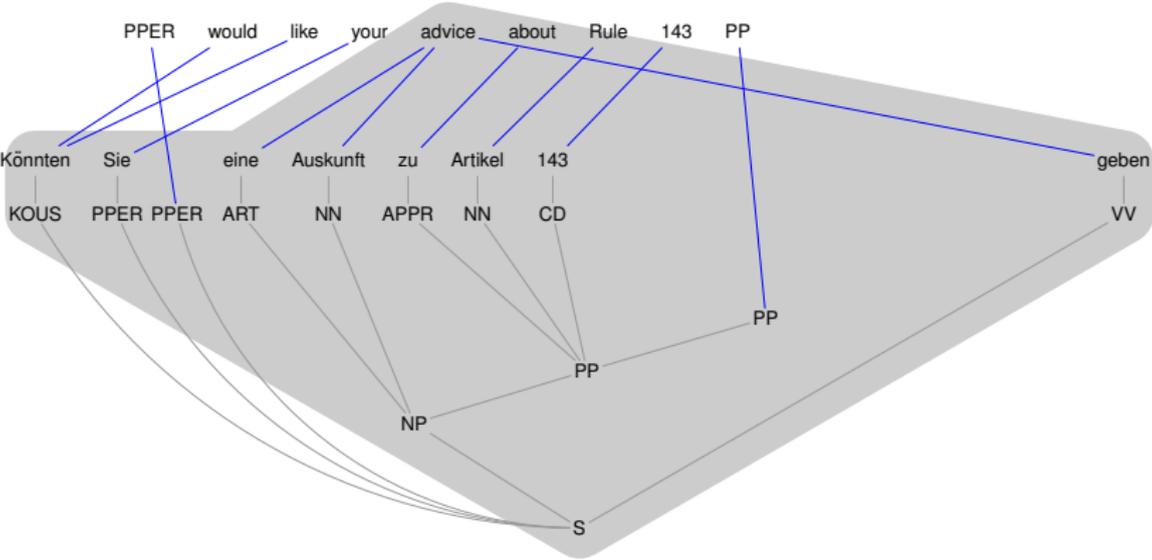
Erneute Regelextraktion:



extrahierbare Regeln rot umrandet

Regelextraktion


Erneute Regelextraktion:



extrahierbare Regeln rot umrandet

Regelextraktion

Erneute Regelextraktion:



extrahierbare Regeln rot umrandet

Baumübersetzer

Vorteile

- ▶ sehr einfach
- ▶ implementiert in MOSES [KOEHN et al., 2007]
- ▶ “kontext-frei”

Baumübersetzer


Vorteile

- ▶ sehr einfach
- ▶ implementiert in MOSES [KOEHN et al., 2007]
- ▶ “kontext-frei”

Nachteile

- ▶ Probleme mit Diskontinuitäten
- ▶ Komposition und Binarisierung problematisch [M. et al., 2009] und [ZHANG et al., 2006]
- ▶ “kontext-frei”

Regelextraktion



- ▶ sehr spezielle Regel
- ▶ jede Regel für "advice" liefert Satzstruktur
- ▶ (Syntax hinderlich)

Baumübersetzer

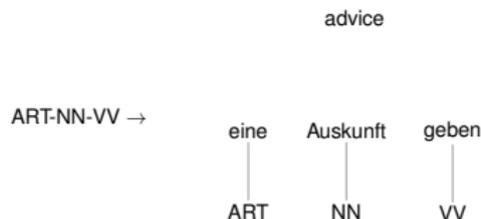
Mehrfach-Baumübersetzer (MBOT)

- ▶ Variante von [M., 2010]
- ▶ Regeln der Gestalt $NT \rightarrow (r, \langle r_1, \dots, r_n \rangle)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte **Regelseiten** r_1, \dots, r_n einer regulären Baumgr.

Baumübersetzer

Mehrfach-Baumübersetzer (MBOT)

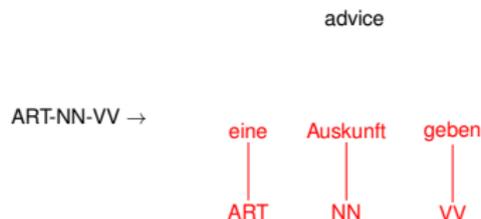
- ▶ Variante von [M., 2010]
- ▶ Regeln der Gestalt $NT \rightarrow (r, \langle r_1, \dots, r_n \rangle)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte **Regelseiten** r_1, \dots, r_n einer regulären Baumgr.



Baumübersetzer

Mehrfach-Baumübersetzer (MBOT)

- ▶ Variante von [M., 2010]
- ▶ Regeln der Gestalt $NT \rightarrow (r, \langle r_1, \dots, r_n \rangle)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte **Regelseiten** r_1, \dots, r_n einer regulären Baumgr.




Baumübersetzer

Mehrfach-Baumübersetzer (MBOT)

- ▶ Variante von [M., 2010]
- ▶ Regeln der Gestalt $NT \rightarrow (r, \langle r_1, \dots, r_n \rangle)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte **Regelseiten** r_1, \dots, r_n einer regulären Baumgr.


ART-NN-VV about Rule 143 PP



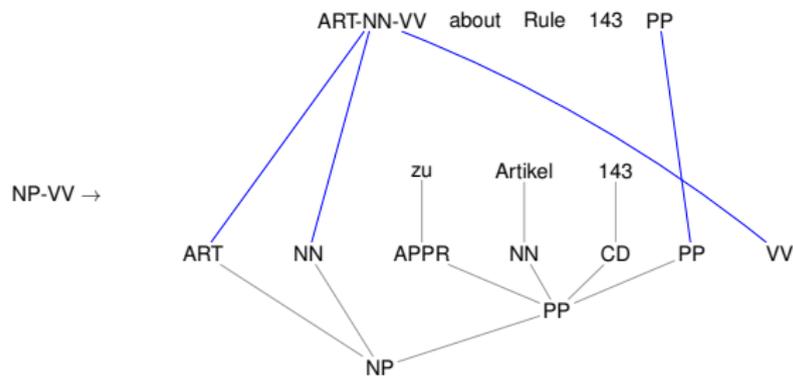
Baumübersetzer

Mehrfach-Baumübersetzer (MBOT)

- ▶ Variante von [M., 2010]
- ▶ Regeln der Gestalt $NT \rightarrow (r, \langle r_1, \dots, r_n \rangle)$
 - ▶ Nichtterminal NT
 - ▶ rechte Regelseite r einer kontextfreien Grammatik
 - ▶ rechte **Regelseiten** r_1, \dots, r_n einer regulären Baumgr.
- ▶ (surjektive) Synchronisation der Nichtterminale



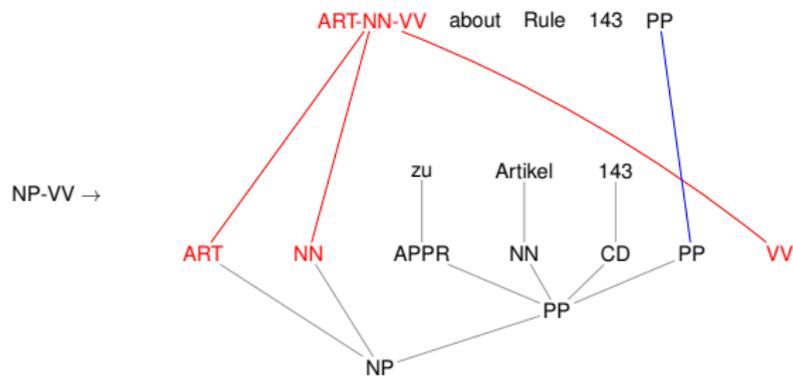
Baumübersetzer



Regelanwendung

1. Nichtterminalauswahl

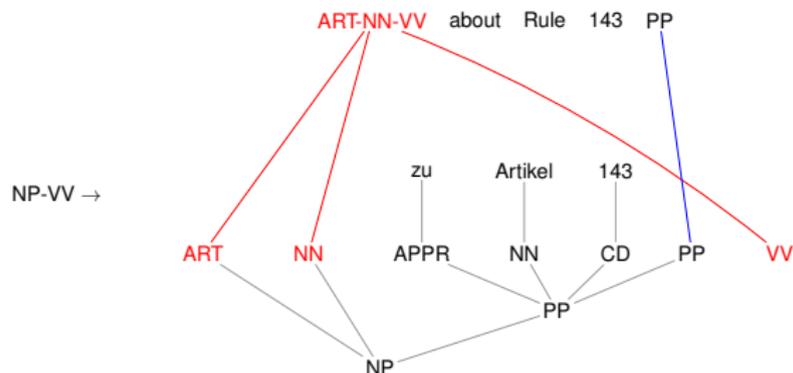
Baumübersetzer



Regelanwendung

1. Nichtterminalauswahl

Baumübersetzer



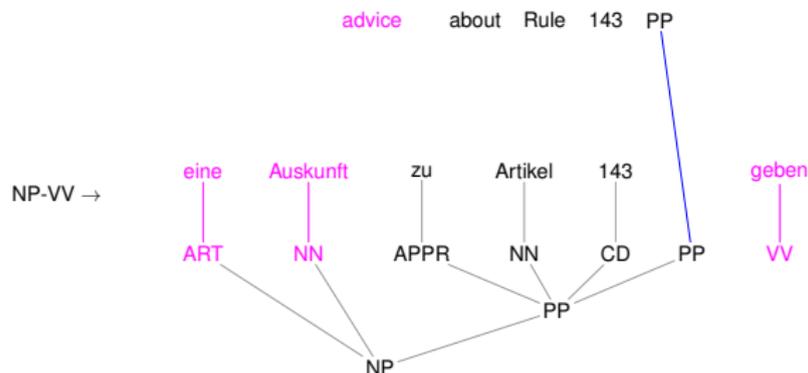
Regelanwendung

1. Nichtterminalauswahl
2. **passende Regel**

ART-NN-VV →

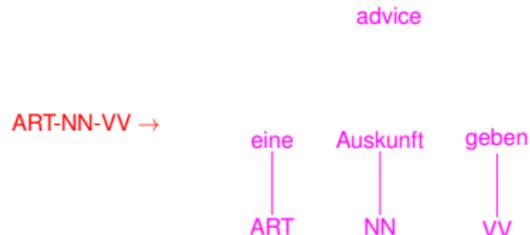


Baumübersetzer




Regelanwendung

1. Nichtterminalauswahl
2. passende Regel
3. **Ersetzung**



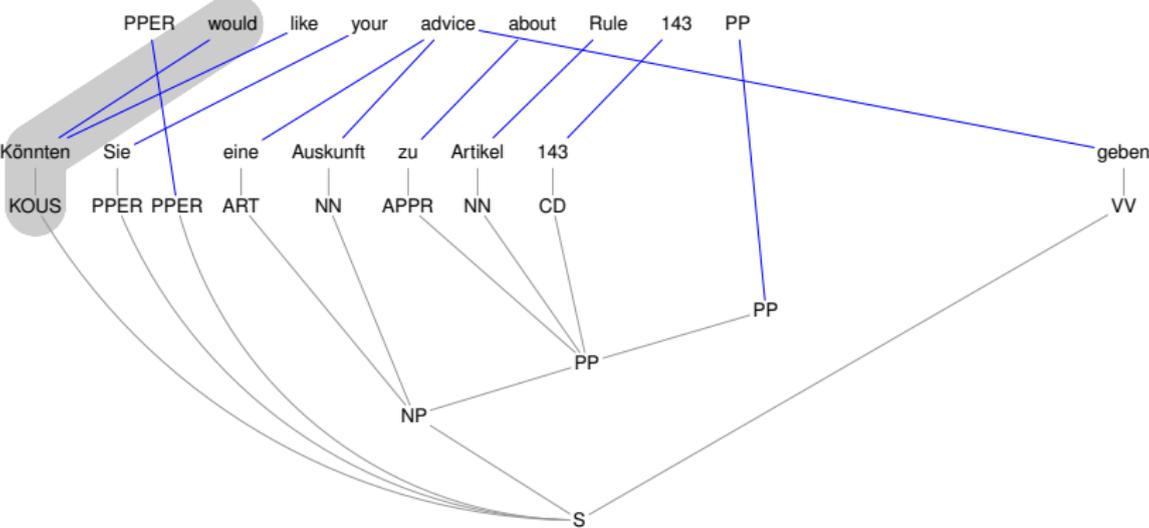
Regelextraktion

nach [M., 2011]



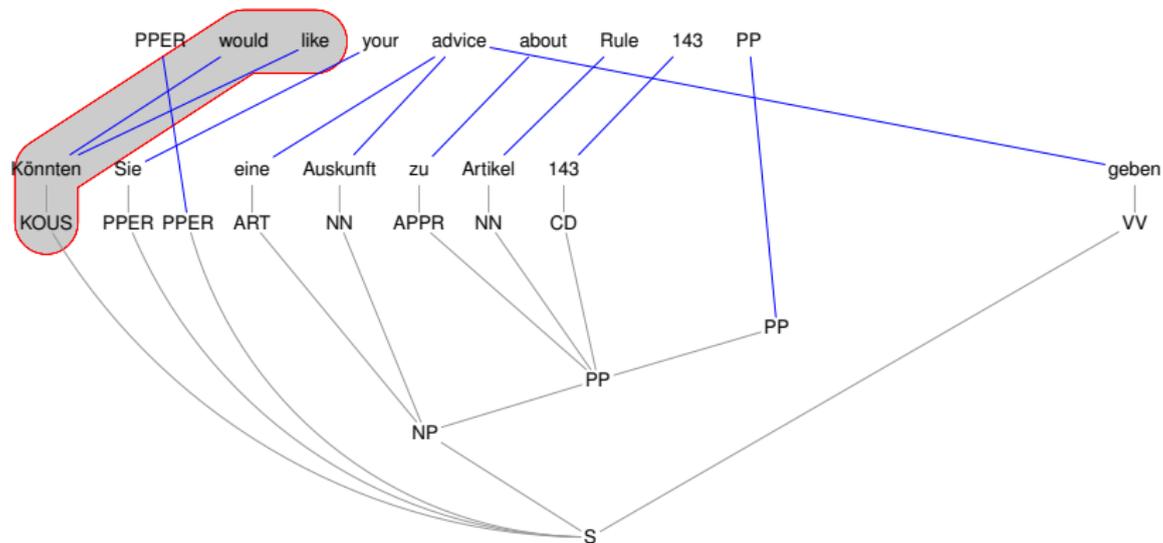
Regelextraktion

nach [M., 2011]



Regelextraktion


nach [M., 2011]



extrahierbare Regeln rot umrandet

Regelextraktion

nach [M., 2011]



extrahierbare Regeln rot umrandet

Baumübersetzer

Vorteile

- ▶ komplizierte Diskontinuitäten
- ▶ auch in MOSES [BRAUNE et al., 2013]
- ▶ binarisierbar, komponierbar

Baumübersetzer


Vorteile

- ▶ komplizierte Diskontinuitäten
- ▶ auch in MOSES [BRAUNE et al., 2013]
- ▶ binarisierbar, komponierbar

Nachteile

- ▶ Ausgabe nicht regulär (als Baumsprache)
- ▶ nicht symmetrisch (Eingabe kontext-frei; Ausgabe nicht)

Diskontinuitäten



Bewertung

Übersetzung	System	BLEU
Englisch → Deutsch	STSG	15.22
	MBOT	15.90
	phrasenbasiert	16.73
	hierarchisch	16.95
	GHKM	17.10
Englisch → Arabisch	STSG	48.32
	MBOT	49.10
	phrasenbasiert	50.27
	hierarchisch	51.71
	GHKM	46.66
Englisch → Chinesisch	STSG	17.69
	MBOT	18.35
	phrasenbasiert	18.09
	hierarchisch	18.49
	GHKM	18.12

aus [SEEMANN, BRAUNE, M., 2015]

Aktuelle Forschung

Dekodierung

- ▶ Eingabeseite kontextfreie Grammatik
- ▶ erweiterter CYK-Algorithmus für Übersetzung
(Parse des Eingabesatzes; Übersetzung entsteht)

Aktuelle Forschung

Dekodierung

- ▶ Eingabeseite kontextfreie Grammatik
- ▶ erweiterter CYK-Algorithmus für Übersetzung
(Parse des Eingabesatzes; Übersetzung entsteht)

Beobachtungen

- ▶ phrasenbasierte System machen keine Suchfehler
[CHANG, COLLINS, 2011]

Aktuelle Forschung

Dekodierung

- ▶ Eingabeseite kontextfreie Grammatik
- ▶ erweiterter CYK-Algorithmus für Übersetzung
(Parse des Eingabesatzes; Übersetzung entsteht)

Beobachtungen

- ▶ phrasenbasierte System machen keine Suchfehler
[CHANG, COLLINS, 2011]
- ▶ STSG und MBOT sehr wohl
 - ▶ Heuristiken (??? BLEU)
 - ▶ exakte Dekodierung mit Syntaxwald (+2–3 BLEU)

Aktuelle Forschung

Regelextraktion

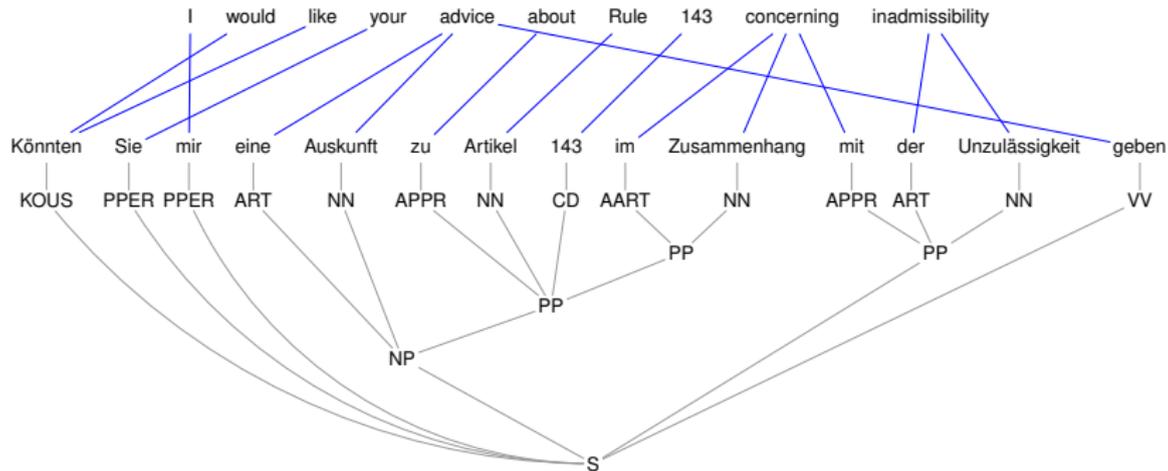
- ▶ zu viele extrahierbare Regeln
 - ▶ welche Einschränkungen? [SEEMANN, BRAUNE, M., 2015]
 - ▶ effizientere Darstellung (evtl. symbolisch)

Aktuelle Forschung

Regelextraktion

- ▶ zu viele extrahierbare Regeln
 - ▶ welche Einschränkungen? [SEEMANN, BRAUNE, M., 2015]
 - ▶ effizientere Darstellung (evtl. symbolisch)
- ▶ nur bester Syntaxbaum
 - ▶ Regelextraktionen mit Syntaxwald (ambitioniert)

Aktuelle Forschung



Aktuelle Forschung

Regelextraktion

- ▶ zu viele extrahierbare Regeln
 - ▶ welche Einschränkungen? [SEEMANN, BRAUNE, M., 2015]
 - ▶ effizientere Darstellung (evtl. symbolisch)
- ▶ nur bester Syntaxbaum
 - ▶ Regelextraktionen mit Syntaxwald (ambitioniert)

Übersetzungsmodelle

- ▶ nur wortbasierte Systeme für Wortbeziehungen
 - ▶ effiziente Einschränkungen moderner Systeme
 - ▶ unüberwachtes Lernen

Aktuelle Forschung

Regelextraktion

- ▶ zu viele extrahierbare Regeln
 - ▶ welche Einschränkungen? [SEEMANN, BRAUNE, M., 2015]
 - ▶ effizientere Darstellung (evtl. symbolisch)
- ▶ nur bester Syntaxbaum
 - ▶ Regelextraktionen mit Syntaxwald (ambitioniert)

Übersetzungsmodelle

- ▶ nur wortbasierte Systeme für Wortbeziehungen
 - ▶ effiziente Einschränkungen moderner Systeme
 - ▶ unüberwachtes Lernen
- ▶ Modelle für semantik-basierte Übersetzung
 - ▶ graph-basierte Modelle

Aktuelle Forschung

Übersetzungsmodelle

- ▶ **Ausdrucksstärke**
 - ▶ von STSG-Kompositionen (mit FÜLÖP, ENGELFRIET)
 - ▶ von Teilklassen von MBOT
 - ▶ von kombinatorischen Kategorialgrammatiken (mit KUHLMANN)

Aktuelle Forschung

Übersetzungsmodelle

- ▶ Ausdrucksstärke
 - ▶ von STSG-Kompositionen (mit FÜLÖP, ENGELFRIET)
 - ▶ von Teilklassen von MBOT
 - ▶ von kombinatorischen Kategorialegrammatiken (mit KUHLMANN)

Minimierung

- ▶ klassisch
- ▶ basierend auf Simulationen und Bisimulationen
- ▶ basierend auf Beinahe-Äquivalenz

Literatur

Auswahl



CHIANG: *Hierarchical Phrase-Based Translation*
Comput. Linguist. 33, 2007



GALLEY, HOPKINS, KNIGHT, MARCU
What's in a Translation Rule? Proc. NAACL, 2004



KOEHN: *Statistical Machine Translation*
Cambridge University Press, 2010



OCH, NEY: *The Alignment Template Approach to Statistical Machine Translation.* Comput. Linguist. 30, 2004