

Anwendungen der Computerlinguistik

4. Übersicht der Themen

Pius ten Hacken

Block 1

Freitag 14-18

1. Einführung

2. NLU-Modell

Praktische
Arbeit

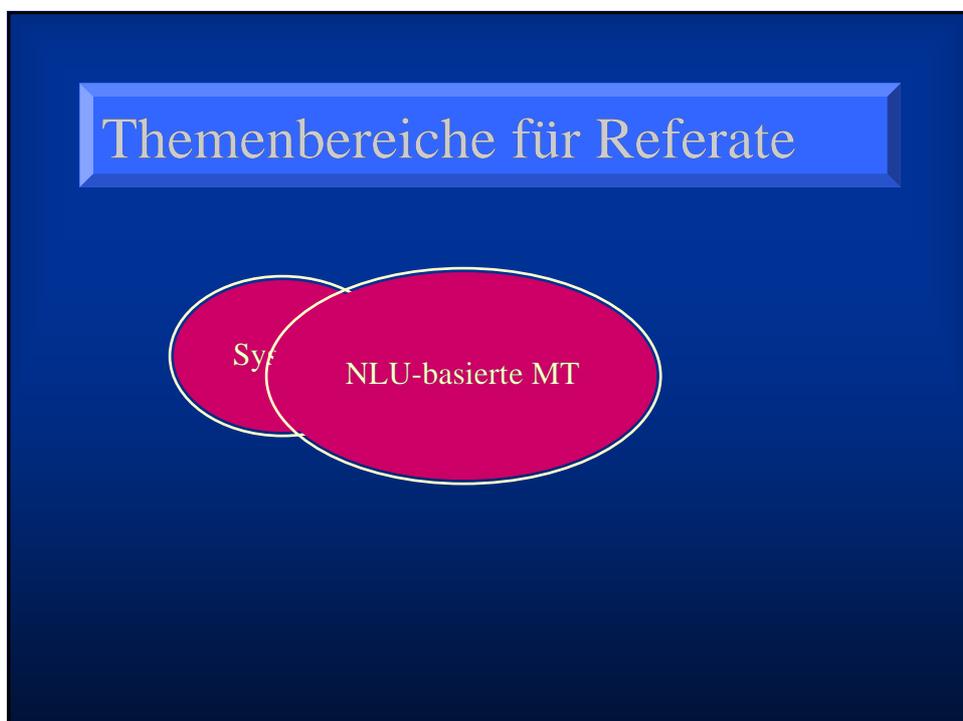
Samstag 9-12

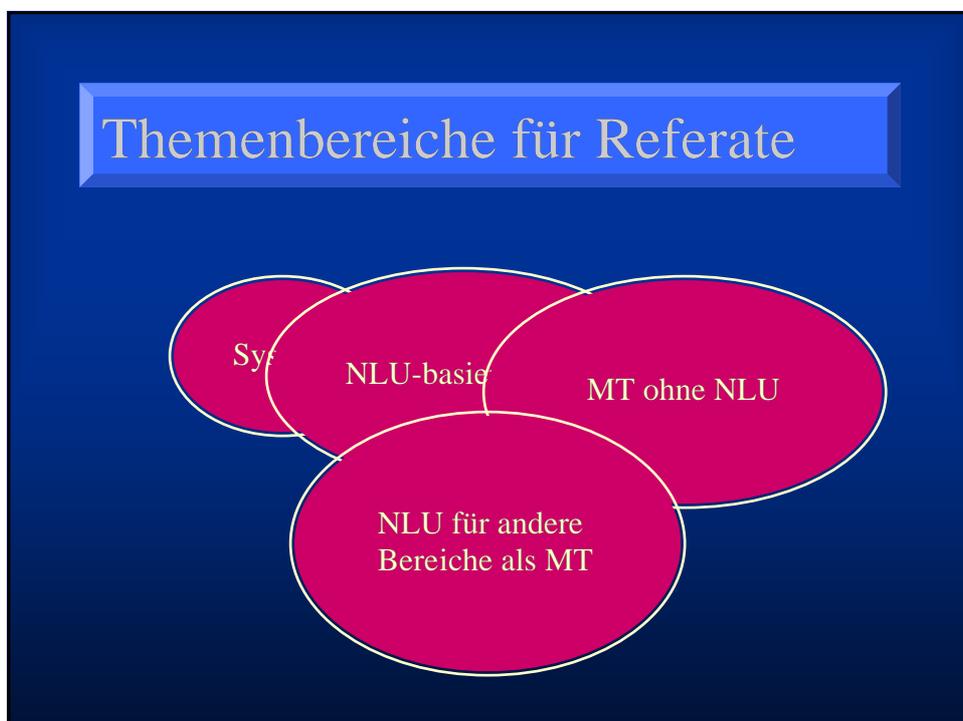
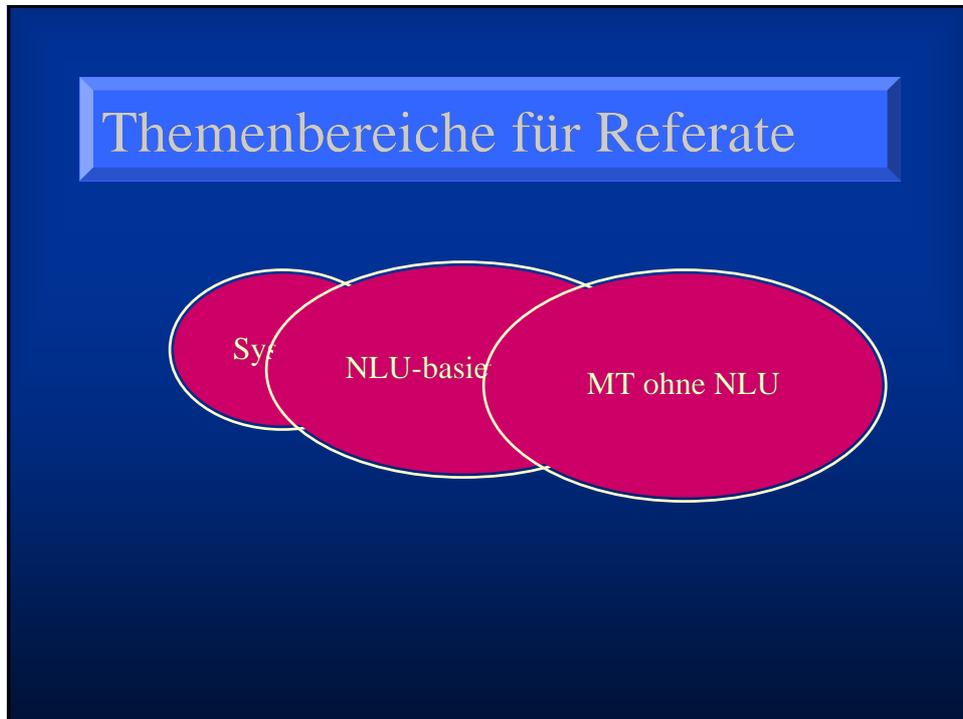
3. MT

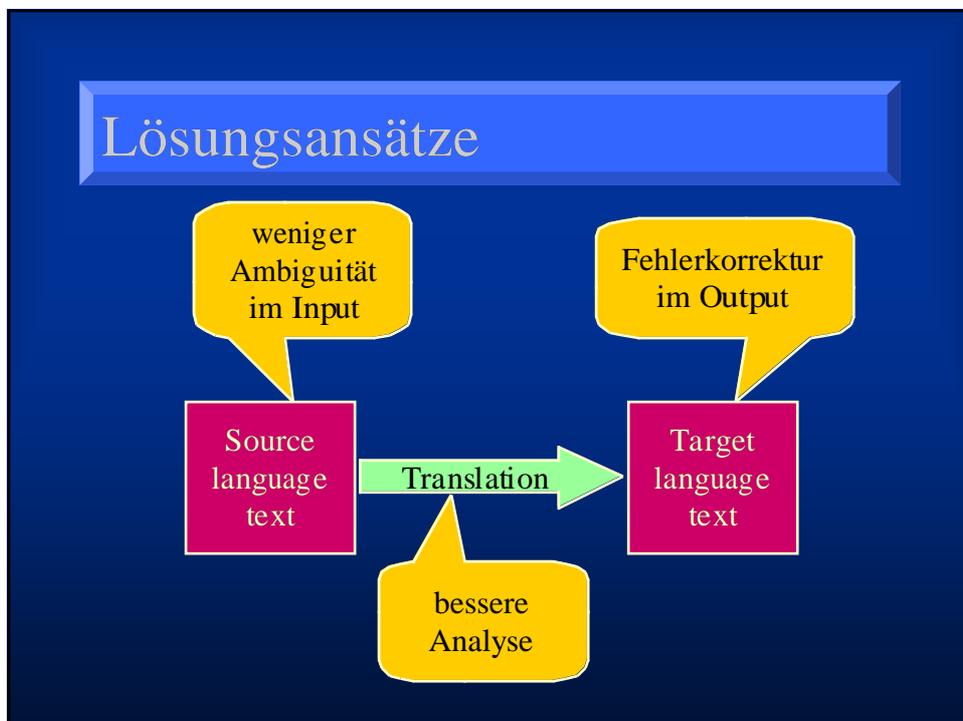
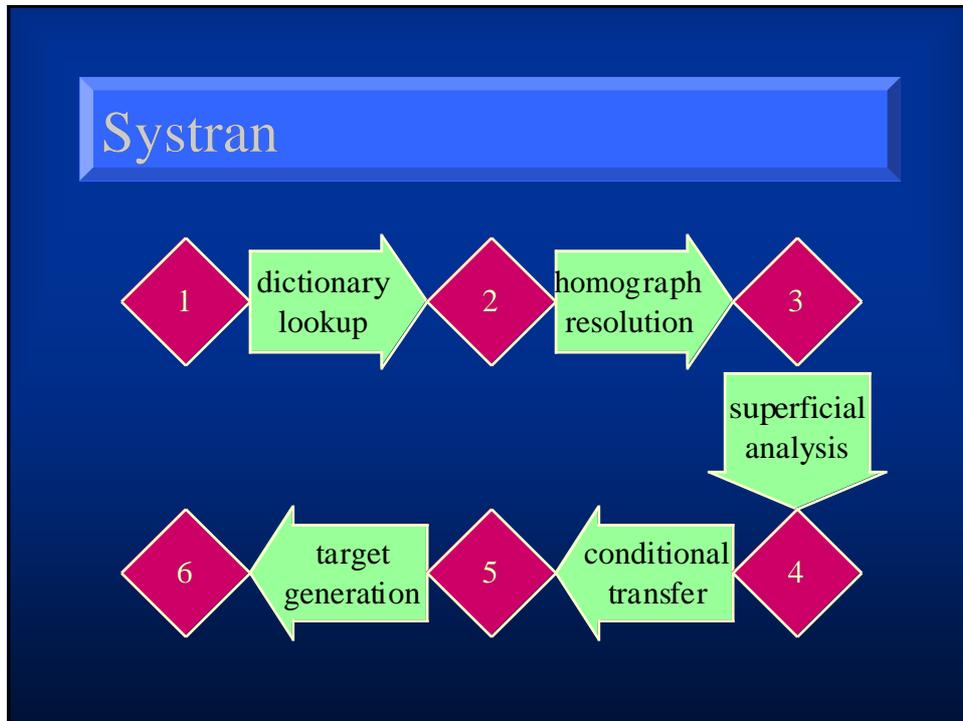
Diskussion

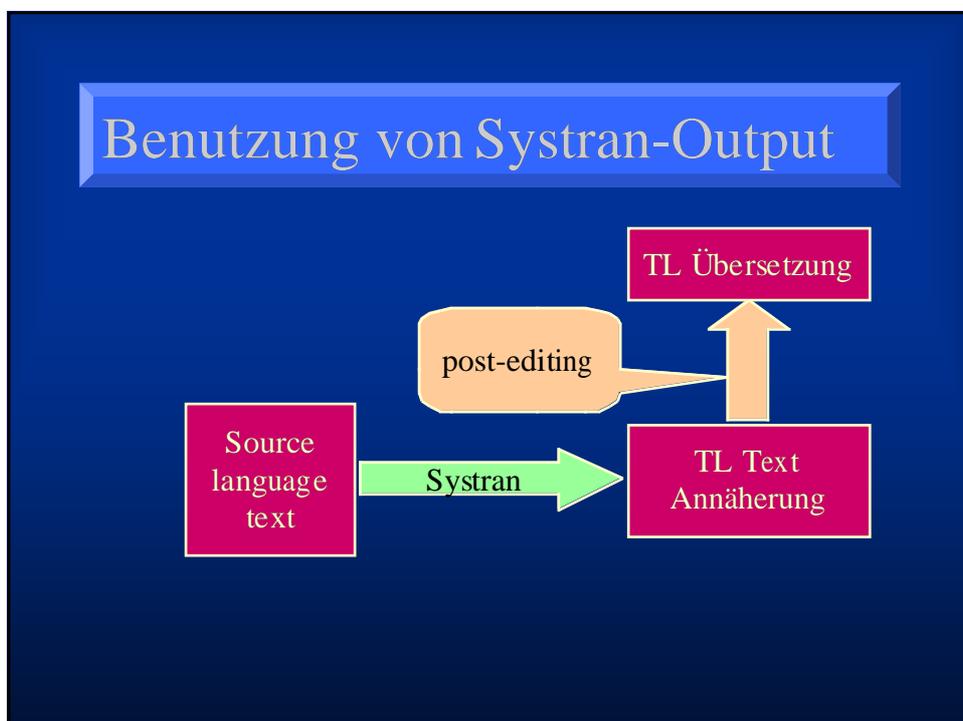
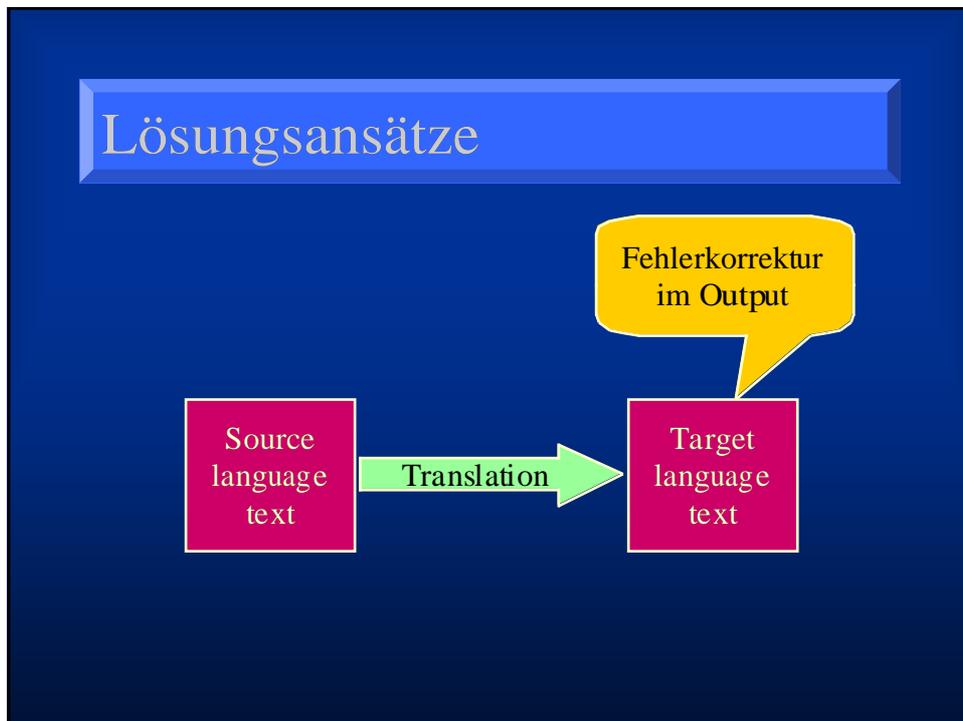
Samstag 14-17

4. Themen





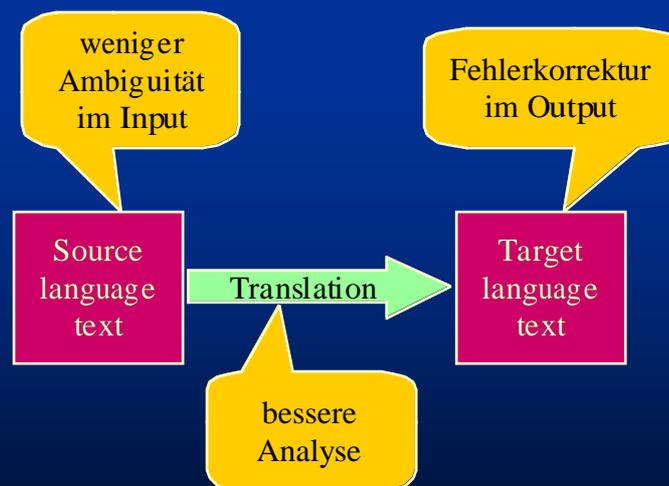


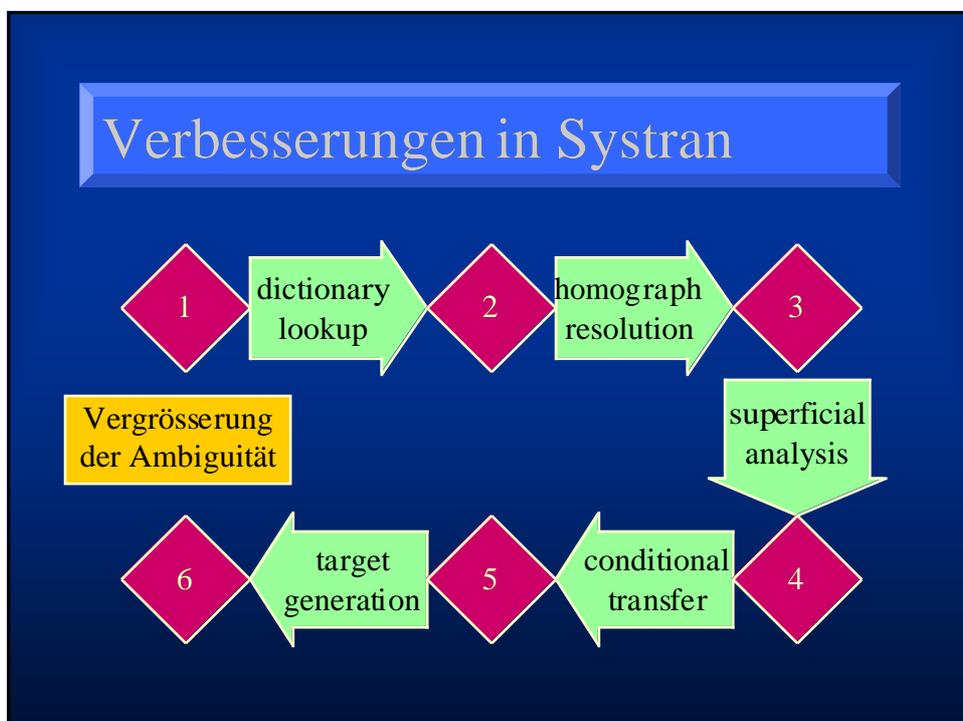
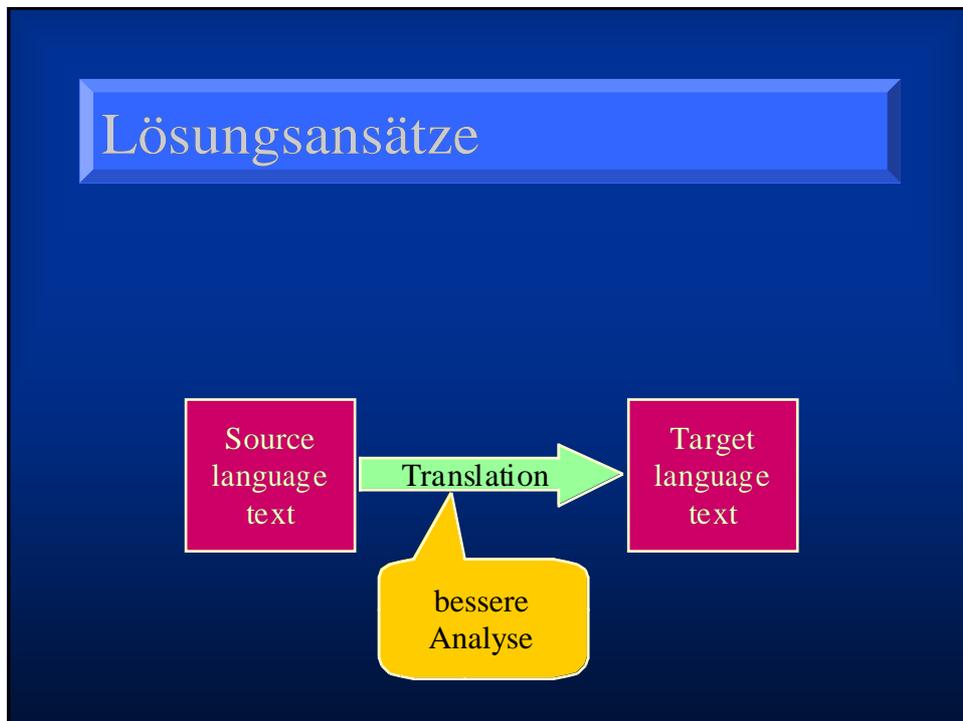


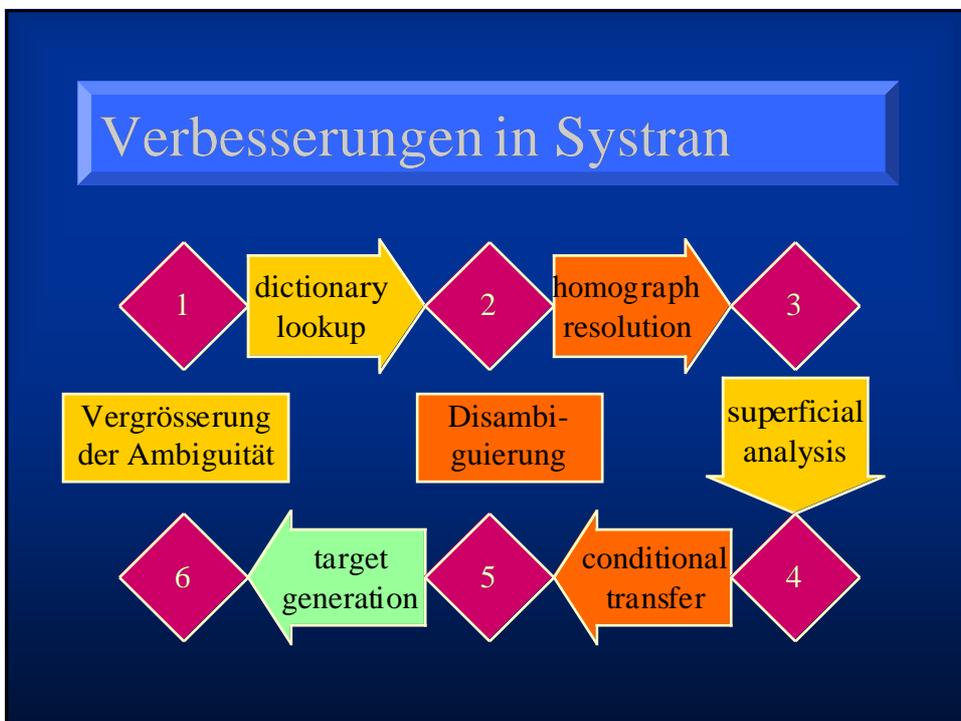
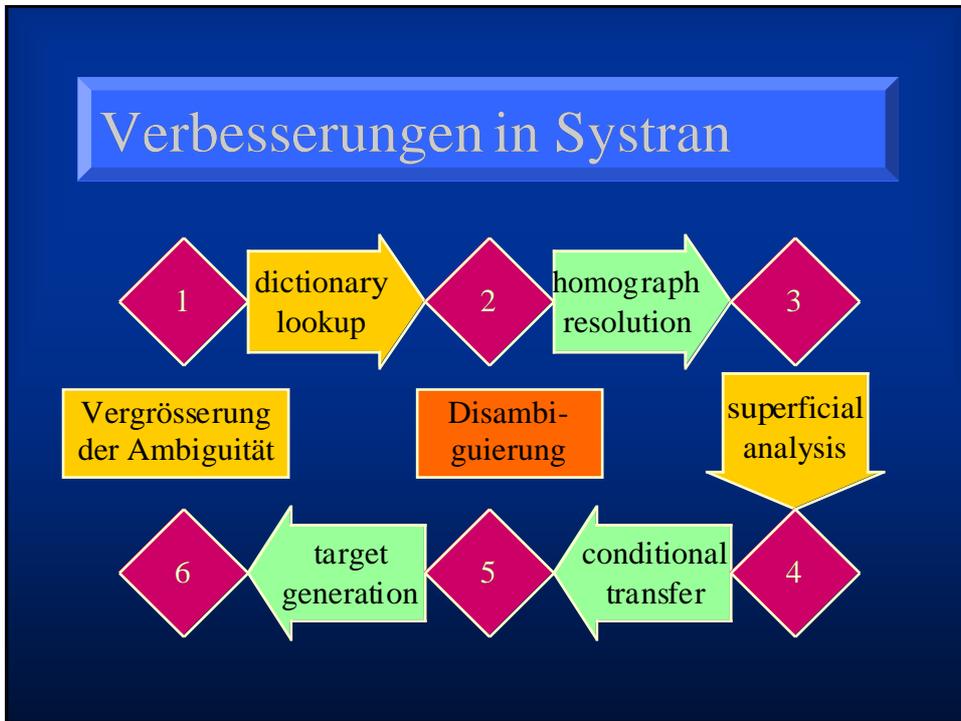
Post-editing

- übliche Praxis in der professionellen Übersetzung
- effizientes Post-Editing von MT Output erfordert:
 - andere Herangehensweise (minimalistisch statt perfektionistisch)
 - Unterstützung durch editing software

Lösungsansätze







Reduktion der Ambiguität

- Lösung der Ambiguität innerhalb der Systran-Architektur:
 - mehr oder bessere Kontexte für homograph resolution
 - mehr oder bessere Kontexte für conditional semantics, Präpositionen, lexical routines
- Vermeidung der Ambiguität:
 - weniger Homonyme im Lexikon
 - weniger Strukturen in der Analyse

Ambiguität und Kenntnisse

- Je mehr wir über den Input wissen, desto mehr können wir die Ambiguität einschränken.
- Wissensquellen:
 - allgemeine Eigenschaften der Sprache
 - Generalisierungen über den spezifischen Input, den wir erwarten können
 - Manipulierung des Inputs

Generalisierungen

Le succès de cette méthode est évident.



The success of this method is obvious.

succès:

- a. success
- b. bestseller
- hit
- c. conquest

méthode:

- a. method
- approach
- b. manual
- tutor
- primer

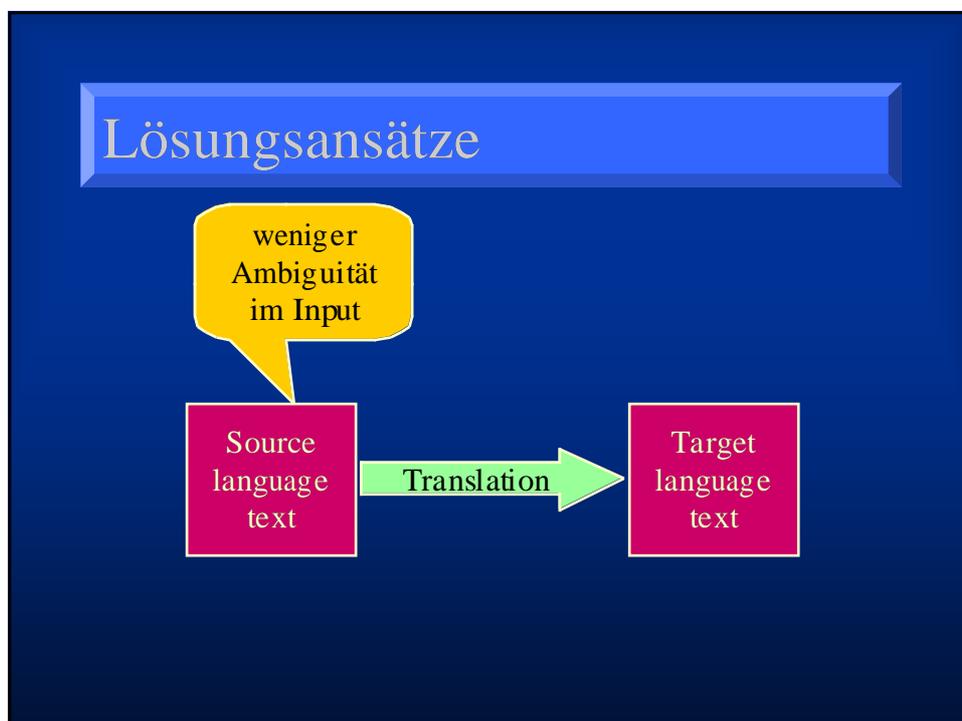
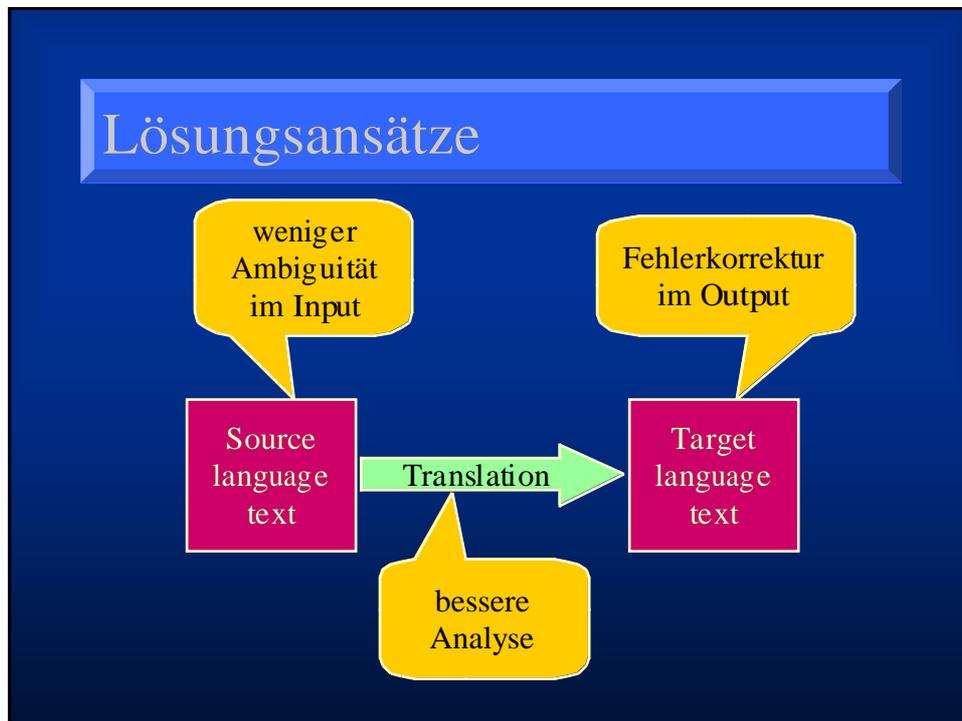
évident:

- obvious
- evident
- self-evident

Customization

- Entfernung von irrelevanten Bedeutungen im Lexikon
- Generalisierungen für die verbleibenden Bedeutungen
- Fehleranalyse im Post-Editing



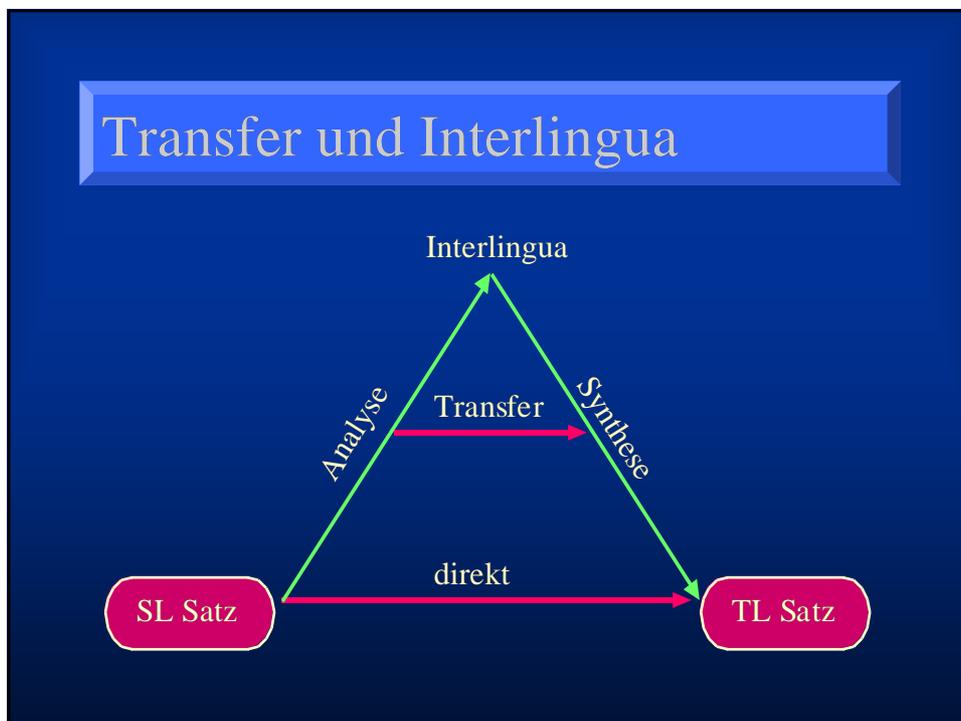
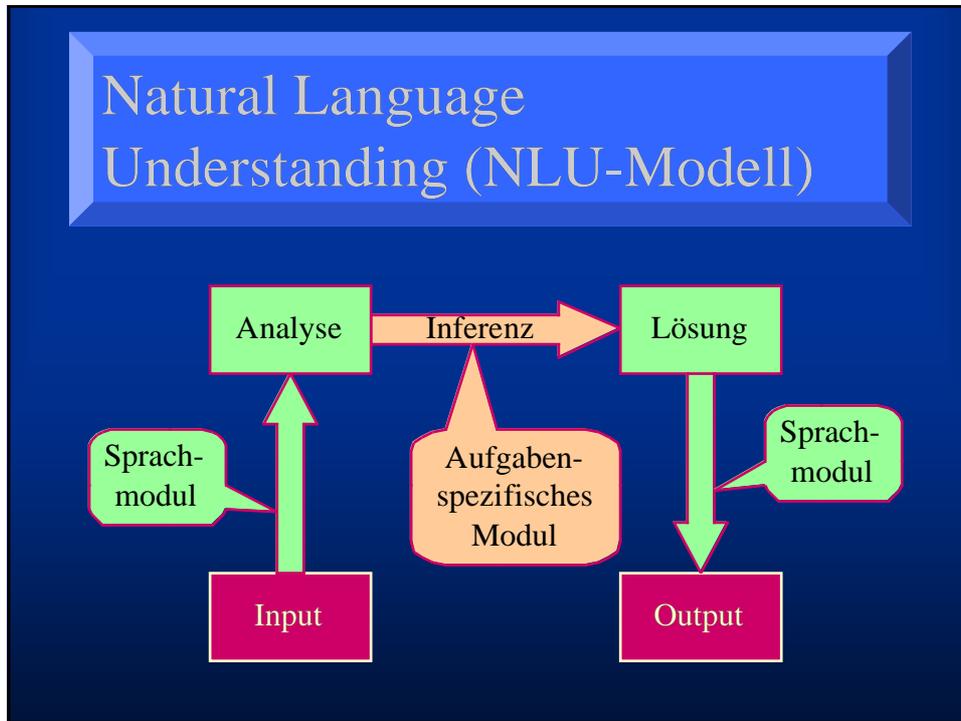


Controlled language

- selbst-erstellte Texte
- beschränkte Domäne
- genügende Textmenge
- Ausschluss von Ambiguität im Input
- Probleme:
 - genügend Ausdrucksmöglichkeiten
 - Unterstützung bei der Einhaltung der Einschränkungen

Themenbereiche für Referate





Eurotra

- Transfersystem
- neun Sprachen, dezentrale Entwicklung
- Minimierung des Transfers durch Angleichung der IS
- linguistisch informierte Analyse
 - eklektische Behandlung der Theorie
 - keine absolute Vereinheitlichung des Analyseprozesses

Rosetta

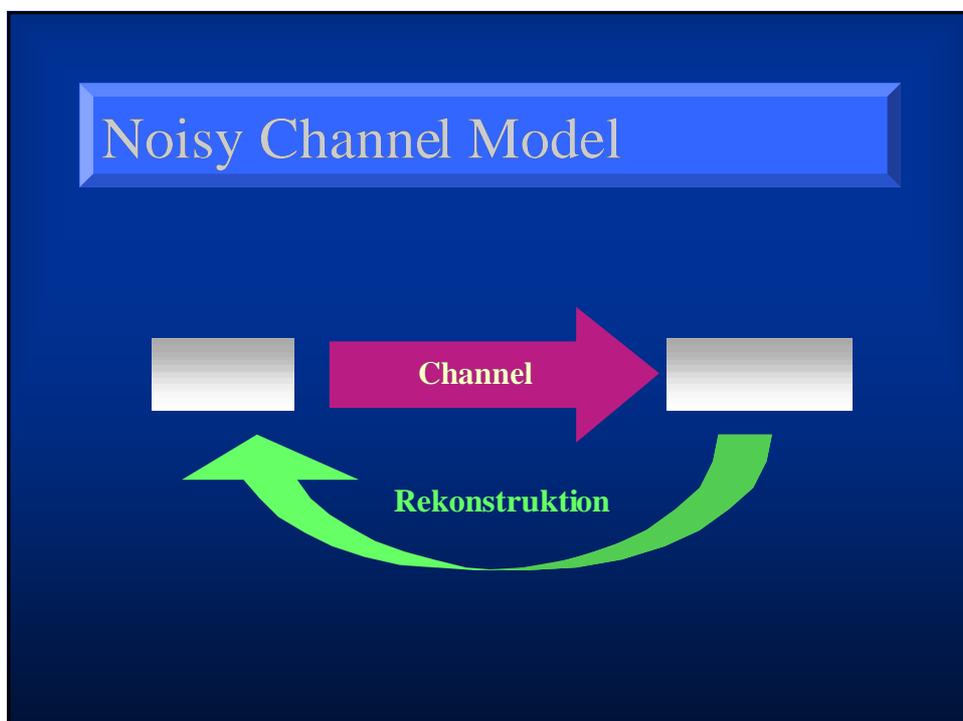
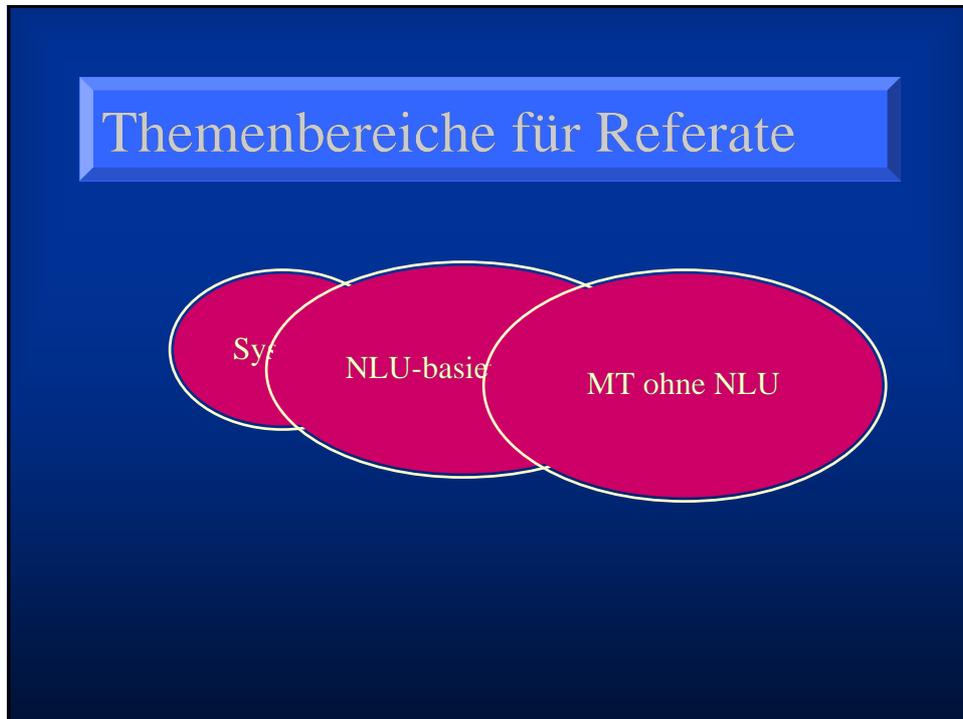
- Interlingua-System
- drei Sprachen, zentrale Entwicklung
- Gesamtarchitektur basiert auf Logik:
 - Kompositionalität
 - “Menge der möglichen Übersetzungen”
- eklektische Einpassung von Analysen einzelner Phänomene

Unitran

- Transfersystem
- one-woman project
- Linguistisch basierte Analyse
 - Syntax gemäss Chomsky
 - Semantik gemäss Jackendoff
- Klassifikation und Lösung von Divergenzen in der Übersetzung

Knowledge-Based MT

- Interlingua-Ansatz
- Künstliche Intelligenz als Basis
- Sprachtheorie als Hilfsmittel
- Repräsentation einer Domäne mit sprachunabhängigen Konzepten

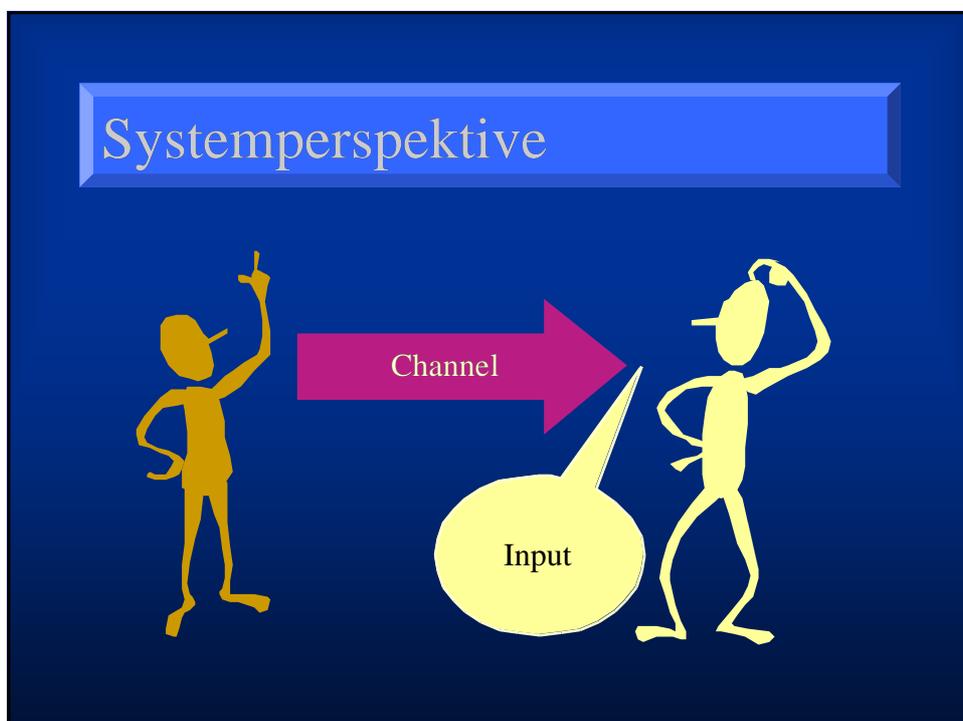
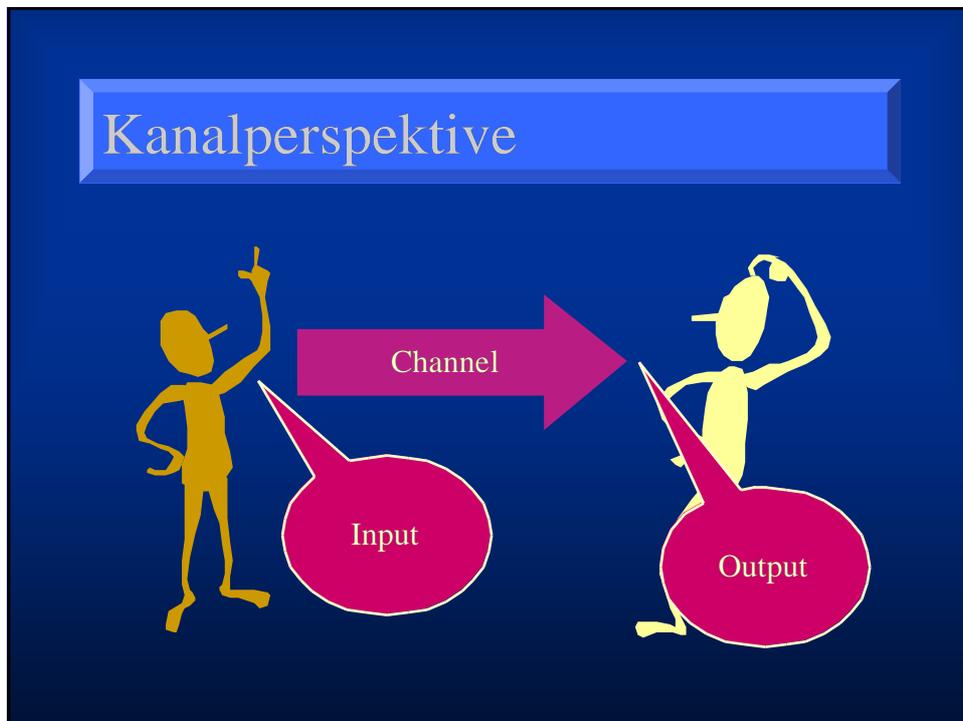


Information Theory

- Claude Shannon,
– Bell Laboratories, 1948
- Information als Problem für Engineering
- Rekonstruktion auf der Basis von probabilistischen Verfahren

Form und Bedeutung

- “Frequently the messages have *meaning*; that is they refer to or are correlated according to some system with certain physical or conceptual entities.
- These semantic aspects of communication are irrelevant to the engineering problem.” [Shannon (1948)]



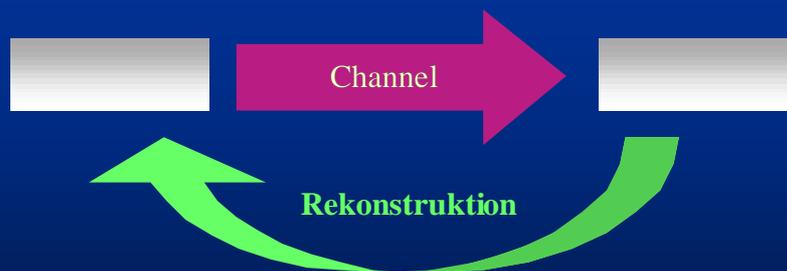
Rekonstruktion

- Der Output des Kanals wird bestimmt von:
 - Eigenschaften des Inputs
 - Eigenschaften des Kanals

Tagging im Noisy Channel Model



MT im Noisy Channel Model



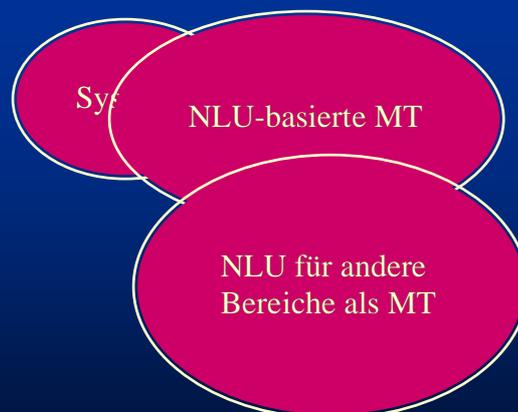
Schritte in der Entwicklung

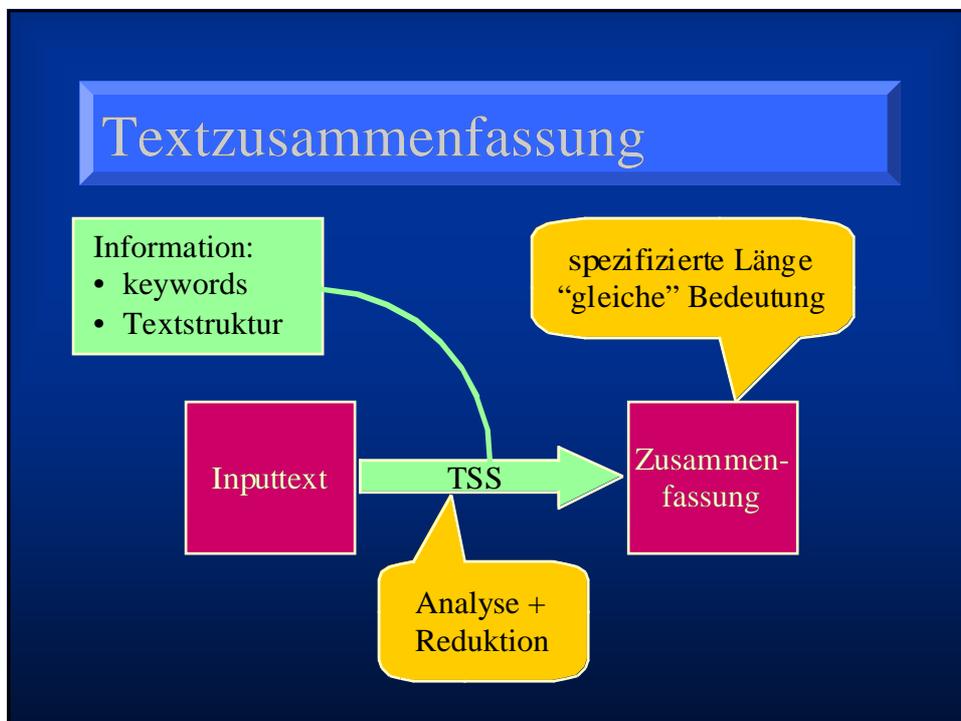
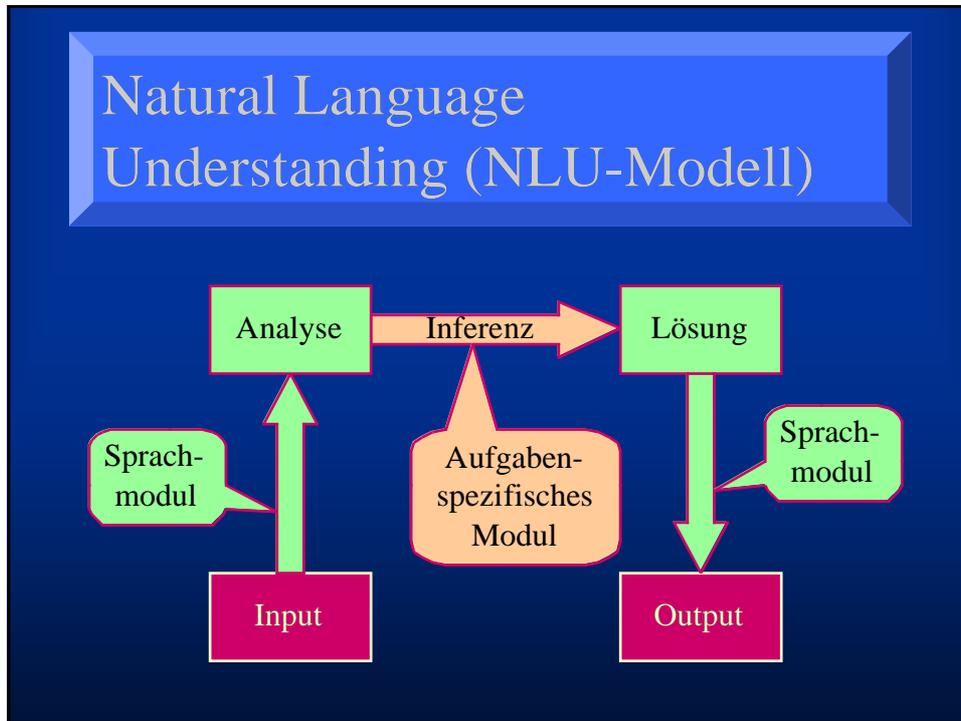
- Corpussammlung
- Alignment
- Evaluation der Corpora
 - Korrespondenz der Wörter aus SL mit TL
 - Abfolge der Wörter in der TL
- Maximierungsalgorithmus

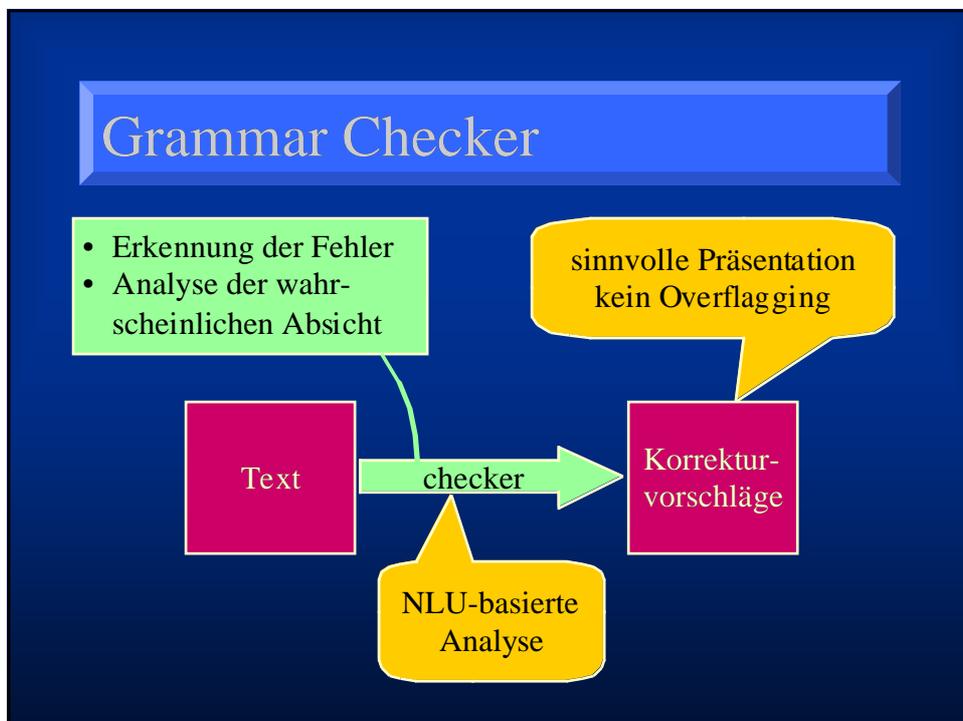
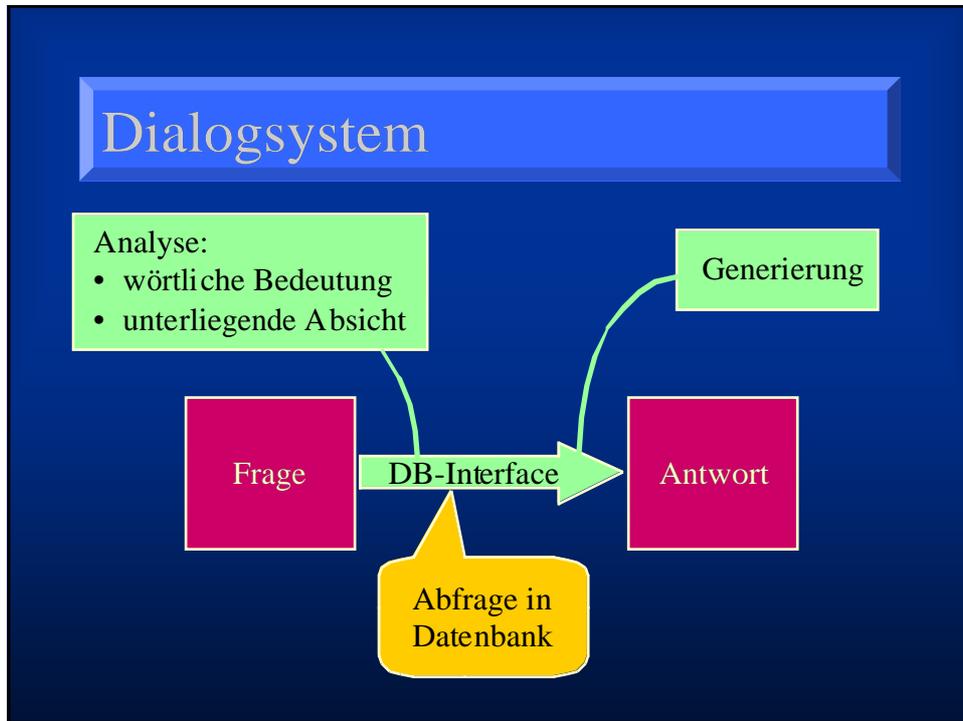
Example-Based MT

- Alternative zur Anwendung von Bayes's Theorem
- Datenbank von Beispielen mit korrekten Übersetzungen
- Algorithmus zur Erkennung der richtigen Beispiele

Themenbereiche für Referate







Übersicht der Themen

- Controlled Language
- Eurotra
- Rosetta
- Unitran
- KBMT
- Statistisches MT
- EBMT
- Text Summarization
- Dialogsysteme
- Grammar Checkers

Block 1

