


# Ausgewählte Kapitel aus dem Übersetzerbau



Prof. G. Goos

Sebastian Hack, Rubino Geiß

Universität Karlsruhe

Adenauerring 20a, Raum 201, 233, 236

Tel. 608-4760, -7399, -8352

[{ggoos,hack,rubino}@ipd.info.uni-karlsruhe.de](mailto:{ggoos,hack,rubino}@ipd.info.uni-karlsruhe.de)

[www.info.uni-karlsruhe.de](http://www.info.uni-karlsruhe.de)

# Voraussetzung / Lernziele

- Voraussetzungen: Vorlesung Übersetzerbau
  - Zwischendarstellungen: SSA
  - Registerzuteilung
  - Grundkenntnisse in Programmiersprachen
- Lernziele:
  - Übersetzerverifikation
  - Optimierung & Codeerzeugung bei Darstellungen in SSA-Form
  - Methoden der klassischen Codeoptimierung
  - Optimierung für Parallele Programme

# Vorlesungsplan

Einführung (1)

Verifikation (1)

Datenflussanalyse (2-5)

- Einführung
- Analysen und Fragestellungen
- Algorithmen

Zwischensprachen mit SSA-Eigenschaft (5)

- Speicherdarstellung
- Chi-Terme
- Lowering / Codegenerierung
- Registerzuteilung
- Nachoptimierung

Cache-Optimierungen (10)

- Fortschrittliche Methoden der Registerzuteilung
- Befehlsanordnung

Parallele Sprachen, Parallelisierung, Threads (12)



# Inhalt - Einführung

## Einführung

- Motivation
- Vorlesungsplan
- Literatur
- Internetseiten - Software


- **Bitte um aktive Teilnahme**

Ohne Anregung / Kritik kann die Vorlesung nicht „rund“ werden!

Also bitte Kontakt zu den Herrn Goos, Hack oder Geiss nicht scheuen;  
wie bekannt gibt es nur blöde Antworten, aber keine  
blöden Fragen :)

DANKE

# Literatur - Hauptwerke I



Andrew W. Appel:

Modern Compiler Implementation in Java

558 Seiten (12. März 1998)

Cambridge University Press; ISBN: 0521583888


Robert Morgan:

Building an Optimizing Compiler


300 Seiten (August 1997)

Butterworth-Heinemann; ISBN: 155558179X

# Literatur - Hauptwerke II



Michael Joseph Wolfe, u.a.:  
High Performance Compilers for Parallel Computing  
570 Seiten (August 2000)  
Addison-Wesley Pub Co; ISBN: 0805327304



Steve Muchnick:  
Advanced Compiler Design and Implementation  
888 Seiten (30. September 1997)  
Morgan Kaufmann; ISBN: 1558603204

# Literatur - Hauptwerke III

H.P. Zima (Editor):  
Parallel Computation  
First International ACPC Conference  
Proceedings (LNCS 591)  
Springer Verlag; ASIN: 0387554378

Cliff Click and Keith D. Cooper:  
Combining Analyses, Combining Optimizations  
ACM Transactions on Programming Languages and Systems  
Bd. 17, No. 2, Seiten 181-196, 1995; ISSN: 0164-0925  
[www.acm.org/pubs/toc/Abstracts/0164-0925/201061.html](http://www.acm.org/pubs/toc/Abstracts/0164-0925/201061.html)

# Literatur - Hauptwerke IV

Flemming Nielson, Hanne Riis Nielson, Chris Hankin:  
Principles of Program Analysis  
Springer Verlag 1999.  
Corrected 2nd printing, 2005.  
<http://www2.imm.dtu.dk/~riis/PPA/ppa.html>



# Weitere Literatur I

R. W. Gray, Vince P. Heuring, S. P. Levi, A. M. Sloane, William M. Waite:  
Eli: A Complete, Flexible Compiler Construction System  
Comm. ACM, 1992, Bd. 35, No. 2, Seiten 121-131

G. J. Chaitin, M. A. Auslander, A. K. Chandra, J. Cocke, M. E. Hopkins, P. W. Markstein:  
Register Allocation via Coloring  
Journal of Computer Languages, 1981, Bd. 6, Seiten 45-57

Martin Trapp:  
Optimierung Objekt-orientierter Programme  
Universität Karlsruhe, Dez. 1999, Doktorarbeit

Markus Armbruster, Christian von Roques:  
Entwurf und Implementierung eines Sather-K Übersetzers  
Fakultät für Informatik, Universität Karlsruhe, Dez. 1996, Diplomarbeit

# Weitere Literatur II

Sabine Glesner, Gerhard Goos, Wolf Zimmermann:  
Verifix: Konstruktion und Architektur verifizierender Übersetzer  
(Verifix: Construction and Architecture of Verifying Compilers)  
it - Information Technology, 2004

Sebastian Hack, Daniel Grund, Gerhard Goos:  
Register allocation for programs in SSA-form  
Compiler Construction 2006, Springer, March 2006.  
[http://dx.doi.org/10.1007/11688839\\_20](http://dx.doi.org/10.1007/11688839_20)

# Fundstellen für Übersetzerbaukästen im Netz

Übersichtsseiten zu Übersetzern und Übersetzerbaukästen:

- <http://www.compilerconnection.com/>
- <http://www.compilers.net/index.htm>
- <http://compilers.iecc.com/tools.html>
- <http://wwwold.first.gmd.de/cogent/catalog/>
- <http://www.idiom.com/free-compilers/>

Eine Archivseite der Newgroup „comp.compilers“ mit Zusatzinfos

- <http://compilers.iecc.com/> (comp.compilers archiv)

# Software

Cocktail ein Übersetzerbaukasten:

- <http://wwwold.first.gmd.de/cocktail/>

ELI ein Übersetzerbaukasten mit Betonung des Erstellungsprozess:

- <http://eli-project.sf.net>

SUIF ein Übersetzerbaukasten mit besonderem Augenmerk auf Optimierungen:

- <http://suif.stanford.edu/>
- <http://suif.stanford.edu/suif/suif2/index.html> (neuere Version)
- <http://www.eecs.harvard.edu/hube/research/machsuiif.html> (Machine SUIF)

Trimaran ein System zur Simulierung von Hardware für experimentelle Zwecke (insbesondere Parallelität auf Instruktionsebene)

- <http://www.trimaran.org/>

Open Research Compiler ORC (Intel beteiligt)

- "<http://ipf-orc.sourceforge.net/>"

Firm (auf Anfrage bei uns) implementiert SSA

PAG (Program Analyzer Generator), Uni Saarbrücken

# Verifikation einer Übersetzung

---

## Übersicht

- Korrektheit
- Spezifikation und Implementierung
- Kompositionalität
- Programmprüfung
- Zusammenfassung

# Definition Quell-/Zielsprache

- Jede Korrektheitsaussage setzt eine präzise Definition der betrachteten Gegenstände, hier der beteiligten Sprachen voraus
- Quellsprache gegeben durch
  - Grammatik
  - Regeln der statischen Semantik
  - formale Spezifikation der dynamischen Semantik
- Zielsprache (Maschinensprache) gegeben durch
  - Maschinenbeschreibung (Wortgrößen, Speicher, Register, ...)
  - formale Spezifikation der Maschinenbefehle
  - beides findet man in Hardware-Beschreibungen der Prozessoren

# Definition formaler Semantik

- Algebraische Spezifikationen,
- denotationelle Semantik: Programm definiert Abbildungen,
- natürliche Semantik
- ...
- operationelle Semantik:
  - abstrakte Zustandsmaschinen (abstract state machines, ASM):  
Programm definiert Zustandsübergänge
  - ...

Für unsere Zwecke nur operationelle Beschreibungen brauchbar:

- sonst keine Semantik für endlos laufende Programme
- Beschreibung der Quell- und Zielsprache mit dem gleichen Verfahren

# abstrakte Zustandsmaschinen

ASMs verallgemeinern endliche Zustandsmaschinen, d.h. endl. Automaten

- jeder Zustand  $q_t$  ist eine Algebra mit Wertemenge und Operationen
- durch einen Zustandsübergang  $q_t \rightarrow q_{t+1}$  werden die Ergebnisse von Funktionsaufrufen verändert
- $q_{t+1}$  unterscheidet sich von  $q_t$  nur durch diese veränderten Funktionsergebnisse
- die Veränderungen können unter Bedingung stehen usw.

Beispiel: (ct bezeichnet den „Befehlszähler“ current-task, nullstellige Fkt.)

```
if ct = while then  
  if value(ct,condition) = true then ct := truetask(ct)  
  else ct := falsetask(ct)  
  endif  
endif
```



# Zustände

Sequentielles Programm durchläuft Zustände

$q_0 q_1 q_2 \dots$

- Zustand  $q_t$  besteht aus Objekten, die zum Zeitpunkt  $t$  existieren:  $q_t = (q_t^0, q_t^1, \dots, q_t^n)$
- Operation entspricht Übergang  $q_t \rightarrow q_{t+1}$
- Zustandsmenge  $Q$  die während Programmlauf existieren kann: Zustandsraum eines Programms (abhängig von Programm & Eingaben)

# Beobachtbare Zustände

beobachtbar:

- Anfangs- und Endzustand
- Ein- und Ausgaben
- Im beobachtbaren Zustand  $q$  nur bestimmte Objekte  $q$  beobachtbar:  $q$  Teilfolge von  $q_t = (q_t^0, q_t^1, \dots, q_t^n)$
- Berechnung nicht beobachtbarer Objekte unerheblich, wenn sie terminiert
- Zwischenzustände unerheblich, wenn es nicht unendlich viele sind

# Korrekte Übersetzung

- Betrachte nur beobachtbare Zustände:
  - deterministische Programme: Folge beobachtbarer Zustände
  - indeterministische Programme: azyklischer Graph beobachtbarer Zustände,  
Programmausführung entspricht Pfad vom Anfangs- zum Endzustand im Graph
  - parallele oder konkurrente Programme: azyklischer Graph beobachtbarer Zustände  
Programmausführung wählt einen azyklischen Teilgraphen aus (hier nicht näher betrachtet)

# Azyklischer Zustandsgraph

Indeterministisches


Programm:

```
do
  [] true -> x:=1
  [] true -> x:=0
od
```

Korrekte Ausführung auch:


```
do true -> x:=1 od
```

Bei nichtdeterministischer Programmausführung darf sich der Übersetzer einen gültigen Pfad aussuchen.



# Korrekte Übersetzung I

- Quellprogramm  $\pi$
- Zielprogramm  $\pi'$
- Bisimulation:  
Bei gleicher Eingabe gleiche beobachtbare Objekte in beobachtbarer Zustandsfolge  
(Relation  $\rho$  zwischen beobachtbaren Zuständen)



# Korrekte Übersetzung

## präzise Definition

$\pi'$  ist korrekte Übersetzung von  $\pi$ , wenn für alle zulässigen Eingaben eine der folgenden Aussagen gilt:

- Zu jeder Folge beobachtbarer Zustände  $q_0', q_1', \dots, q_k'$  von  $\pi'$  die regulär terminiert, gibt es eine terminierende Zustandsfolge  $q_0, q_1, \dots, q_k$  von  $\pi$  mit  
mit  
 $q_i \rho q_i'$  für  $0 \leq i \leq k$ ;
- Zu jeder nicht-terminierenden Folge beobachtbarer Zustände  $q_0', q_1', \dots$  von  $\pi'$  gibt es eine Zustandsfolge  $q_0, q_1, \dots$  von  $\pi$  mit  $q_i \rho q_i'$  für alle  $i$ ;
- Zu jeder Folge beobachtbarer Zustände  $q_0', q_1', \dots, q_{k+1}'$  von  $\pi'$ , die mit einer Fehlermeldung wegen Verletzung von Betriebsmittelbeschränkungen terminiert, gibt es eine Zustandsfolge  $q_0, q_1, \dots, q_k, \dots$  von  $\pi$  mit  $q_i \rho q_i'$  für  $0 \leq i \leq k$ ;


regulär: endliche viele Schritte ohne Fehlermeldung

$\rho$ : korrespondierende beobachtbare Zustandsvariable haben gleichen Wert

# Spezifikation und Implementierung

Korrektheitsbeweis in zwei Schritten:

- Ist die Spezifikation korrekt? Kommutiert das Diagramm



- Ist die Implementierung von f korrekt?

# Kompositionalität

Sowohl die Spezifikationstreue als auch die Implementierung werden nicht in einem Schritt betrachtet

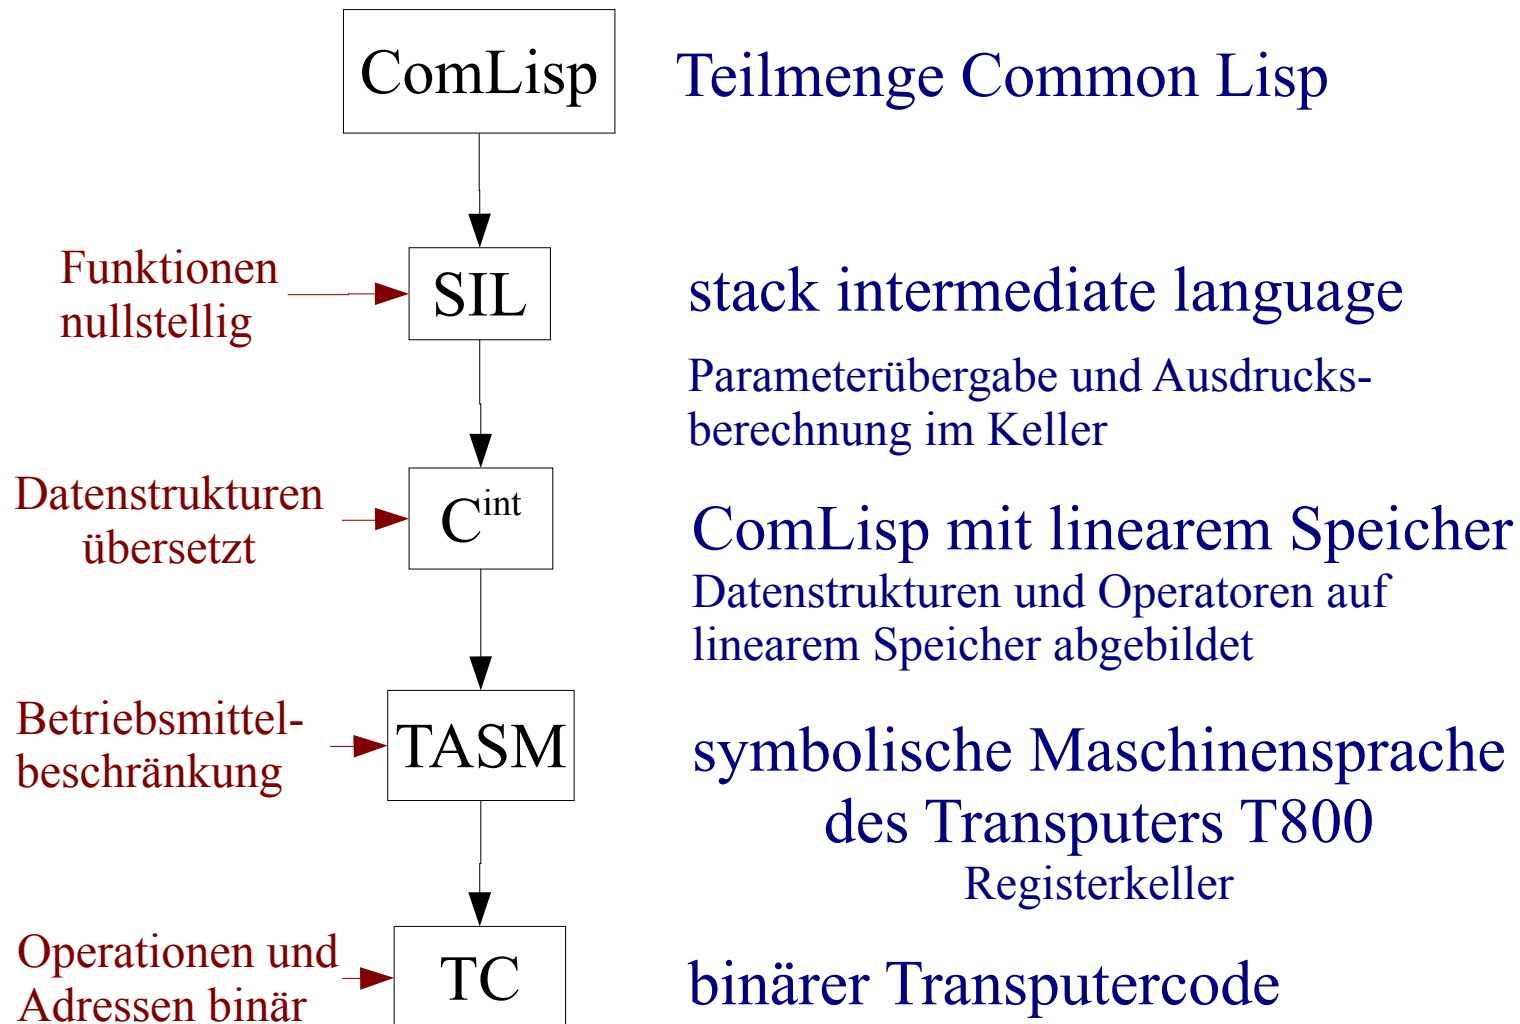
- horizontale Kompositionalität:
  - Semantik der Quellsprache entsprechend Syntaxbaum aus Semantik der Sprachelemente zusammengesetzt
  - analog: Semantik des Zielprogramms aus Abfolge der Befehle
- vertikale Kompositionalität:
  - Übersetzung nicht in einem Schritt, sondern mit zwischengeschalteten Zwischensprachen

Horizontale Kompositionalität folgt aus den Sprachdefinitionen.

Anwendbarkeit vertikaler Kompositionalität muß man (durch Bisimulation) beweisen.



# Vertikale Kompositionalität im Verifix-Projekt



# Implementierungskorrektheit

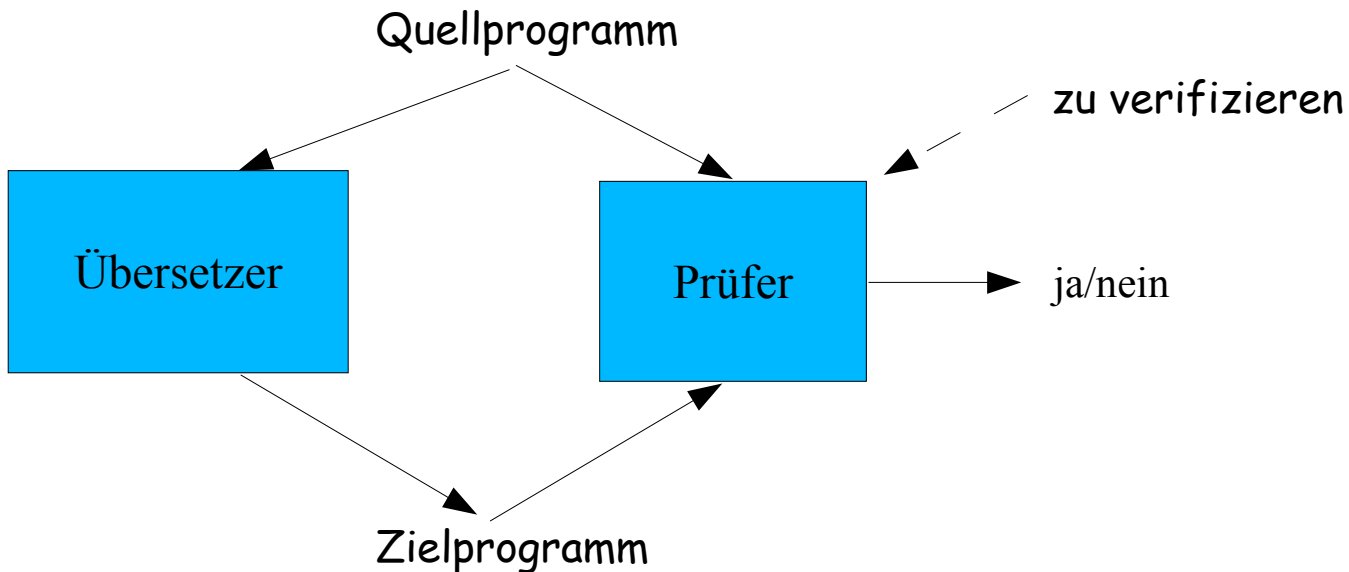
Nachweis durch korrekte Konstruktion

- schließt Verwendung von *Generatoren* aus  
(oder die *Generatoren* müßten verifiziert werden)
- Schwierigkeiten bei nicht-verfeinernden  
Optimierungstransformationen

also besser: *Generatoren* auf theoretischer Grundlage verwenden,  
Implementierungskorrektheit auf andere Weise

# Programmprüfung

Statt die Implementierung zu prüfen, prüfe nur das Ergebnis!



Methode von Blum&Kannan  
„Programs that check their work“  
auf Übersetzer angewandt von  
Gaul & Goerigk

Prüfer garantiert  
partielle Korrektheit,  
aber: für jedes Programm  
einzeln prüfen


# Programmprüfung II

Prüfung auch für Teilschritte geeignet, z.B.:

Prüfereingabe: kf. Grammatik  $G$ , Quellprogramm  $\pi$ , Syntaxbaum  $B$

Prüferaufgabe: prüfe, daß der Baum  $B$  das Wort  $\pi$  korrekt wiedergibt,

- beginnend an der Baumwurzel, prüfe rekursiv, daß es eine passende Produktion  $p$  in  $G$  gibt
- Ausgabe „ja“, wenn Syntaxbaum  $B$  korrekte Ableitung für  $\pi$  bzgl.  $G$

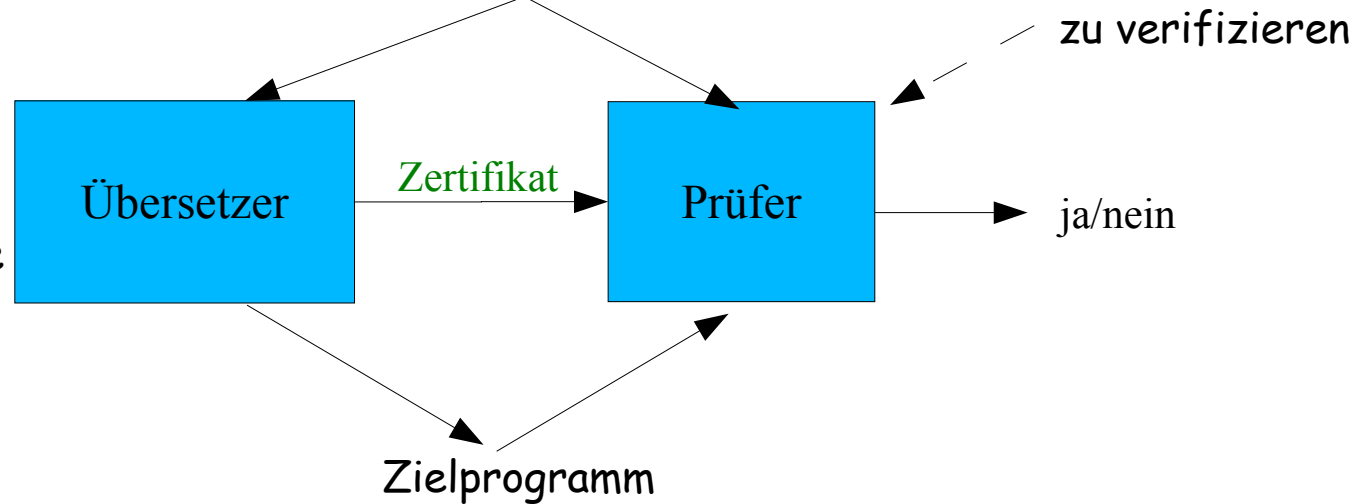



geeignet für alle  
Aufgaben der  
Analysephase

# Programmprüfung III mit Zertifikaten

Erweiterung bei NP-Problemen und Problemen mit mehreren Lösungen  
Quellprogramm

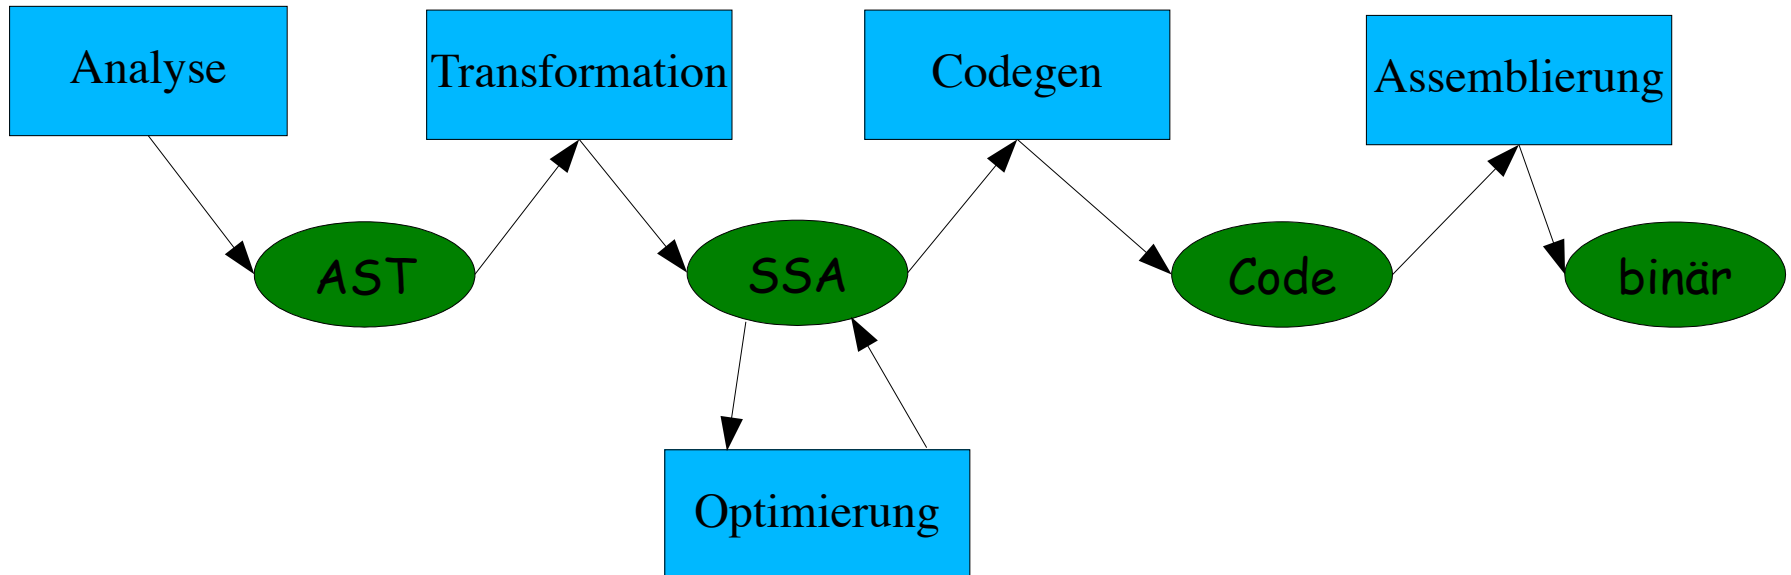
Bei NP-Problemen  
polynomiell viele  
Entscheidungsschritte



Weitergabe der Entscheidungsschritte als Zertifikat  
kann die Anzahl der „ja“-Antworten höchstens  
verkleinern

# Aufgaben in der Synthesephase

- Korrektheit der SSA-Erzeugung (setzt formale Semantik für SSA voraus)
- Korrektheit der Optimierungen auf SSA-Form
- Korrektheit der Registerzuteilung
- Korrektheit der Codeerzeugung
- Korrektheit der Nachoptimierungen (Befehlsanordnung, usw.)
- Korrektheit der Assemblierung



# Zusammenfassung

## Gegenwärtiger Stand (Anfang 2006)

- Verifikationsprinzipien bekannt (direkter Beweis, Programmprüfung)
- Verfahren für einzelne Teilsprachen und Teilschritte durchgeführt
  - Comlisp, IS, Java-Ausschnitt, Sather-Ausschnitt
- maschinelle Verifikation mit Theorembeweiser noch in Arbeit (Glesner)
- noch keine vollständige Verifikation eines realistischen Übersetzers für eine realistische Sprache

## Vergleich mit anderen Arbeiten:

- proof-carrying code (Necula) prüft Typsicherheit, nicht Korrektheit
- Optimierungsverifikation (Necula) prüft Teile der Korrektheit des gcc ohne Rückgriff auf Implementierungseigenschaften
- viele frühere Arbeiten