Sprachtechnologie und Compiler

Prof. Dr.-Ing. Gregor Snelting
snelting@ipd.info.uni-karlsruhe.de

Institut für Programmstrukturen und Datenorganisation
Universität Karlsruhe (TH)

Wintersemester 2009/10

Folien teilweise basierend auf dem Skript von
Prof. em. Dr. Dr. h.c. Gerhard Goos

Kapitel 1

Einleitung

Organisatorisches

Vorlesung

- Die Veranstaltung ist prüfbar (bis zu 4 SWS)
- Homepage: `http://pp.info.uni-karlsruhe.de/lehre/WS200910/compiler`
- Kontakt: `snelting@ipd.info.uni-karlsruhe.de`

Übung

- Mittwochs 14 Uhr in HS -101
- wöchentliche Übungsblätter
- Homepage: `http://pp.info.uni-karlsruhe.de/lehre/WS200910/compiler/uebung`
- Kontakt: `sebastian.buchwald@kit.edu`

Organisatorisches - weiterführende Veranstaltungen (1/3)

Im Sommersemester bieten wir vertiefende Veranstaltungen an:

- Compilerpraktikum
  - Entwurf und vor allem Implementierung eines Compilers für (Mini-)Java in Kleingruppen
  - lexikalische, syntaktische und semantische Analyse, einfache Optimierungen, Codeerzeugung
  - 2 SWS in Prüfung anrechenbar
- Compiler II
  - Themen: Fortgeschrittene Programmanalysetechniken, Registerzuteilung, Cache-Optimierungen, Schleifentransformationen
  - 2 SWS

Organisatorisches - weiterführende Veranstaltungen (2/3)

Im Sommersemester bieten wir vertiefende Veranstaltungen an:

- Fortgeschrittene Objektorientierung
  - Theoretische Grundlagen, Implementierungstechniken, und aktuelle Entwicklungen im Bereich objektorientierter Programmiersprachen
- Semantik von Programmiersprachen
  - Einführung in die Semantik
  - Modellierung von Programmiersprachen innerhalb verschiedener Semantiken

Organisatorisches - weiterführende Veranstaltungen (3/3)

Im Sommersemester bieten wir vertiefende Veranstaltungen an:

- Seminar: Parallele Programmiersprachen
  - Übersicht aktueller Parallelsprachen
  - Techniken zur (automatischen) Parallelisierung
- Praktikum: Theorembeweiser und ihre Anwendungen
  - Umgang mit dem Theorembeweiser Isabelle/HOL
  - 2 SWS in Prüfung anrechenbar
- ...

Studien- und Diplomarbeiten

- Der Lehrstuhl bietet Studien- und Diplomarbeiten im Bereich Compiler Construction, Programmanalyse / Programmslicing, sowie maschinelle Verifikation an.
- Wir suchen Hiwis zur Mitarbeit im libFirm (`http://www.libfirm.org`) Projekt, einer modernen graphbasierten Compilerzwischensprache.

Kapitel 1: Einleitung

Warum Sprachtechnologie?

„Die Grenzen meiner Sprache sind die Grenzen meiner Welt“
(Wittgenstein, Tractatus)

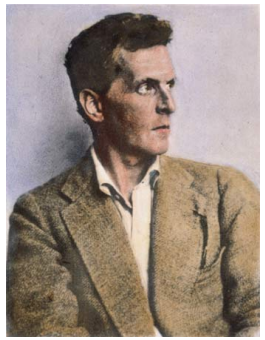

„Programmiersprachliche Konstrukte sind gefrorenes Wissen über gute Softwareentwicklung“
(G. Kahn)

„Some believed we lacked the programming language to describe your perfect world“
(Agent Smith, The Matrix)

Warum ist Sprachtechnologie interessant?

- Querschnittstechnologie mit breitem Anwendungsbereich in der Softwaretechnik
- ältestes Gebiet der praktischen Informatik $\longrightarrow$ sehr ausgereift
- Vorbild für erfolgreiche theoretische Fundierung praktischer Entwicklungen
- Musterbeispiel für Software Engineering bei mittelgroßen sequentiellen Software-Systemen
- hohe Korrektheit und Zuverlässigkeit

Warum ist Sprachtechnologie interessant?

- Programmiersprachen sind grundlegend für Weiterentwicklungen der Programmiermethodik
- Codegeneratoren sind grundlegend für Weiterentwicklung der Prozessor-/Software-Schnittstelle
- liefert Standardmethoden für Verarbeitung textueller Eingaben, sowie zur Generierung von Programmen aus Spezifikationen
- viele Anwendungen im Software Engineering: Textformatierung, Programmanalyse, Programmtransformationen, automatische Anwendung von Entwurfsmustern, Metaprogrammierung, Verarbeitung von XML, Refaktorisierung, Software-Sicherheitsanalyse, Metriken, ...

Anwendungsfelder

- Text $\longrightarrow$ Information
  - Textanalyse (Beispiel: LaTeX, Word, Konfigurationsdateien)
  - Programmanalyse (Beispiel: Software-Sanierung)
- Text $\longrightarrow$ Text
  - Quell-Quell-Transformation (Beispiel: Präprozessor, UML nach C)
- Programm $\longrightarrow$ Stackcode
  - Beispiel: Java Byte Code, .NET CLI
- Programm $\longrightarrow$ Maschinencode
  - Beispiel: Alle C-Übersetzer

Literatur - Lehrbücher

Andrew W. Appel, Jens Palsberg
Modern Compiler Implementation in Java
Cambridge University Press
ISBN: 052182060X

Alfred V. Aho, Monica S. Lam, Ravi Sethi
Compiler. Prinzipien, Techniken und Tools
PEARSON STUDIUM
ISBN: 3827370973

Weiterführende Literatur

Reinhard Wilhelm, Helmut Seidl
Übersetzerbau
Springer
ISBN: 9783540495963

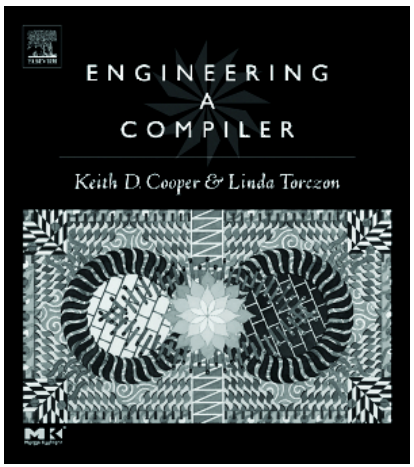

Keith Cooper, Linda Torczon
Engineering a Compiler
Morgan Kaufmann
ISBN: 978-1-55860-699-9

Weiterführende Literatur

Robert Morgan
Building an Optimizing Compiler
Digital Press
ISBN: 155558179X

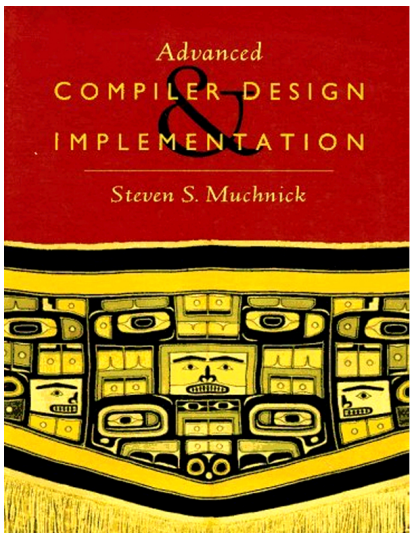

Steven Muchnick
Advanced Compiler Design and Implementation
Morgan Kaufmann
ISBN: 978-1-55860-320-2

Weiterführende Literatur

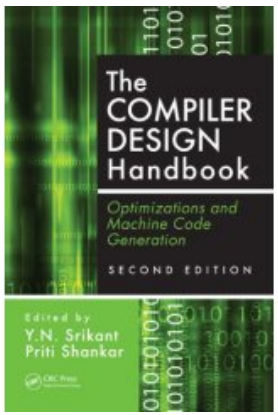

Y. N. Srikant, Priti Shankar
The Compiler Design Handbook: Optimizations and Machine Code Generation
CRC Press Inc
ISBN: 142004382X

Kapitel 1: Einleitung

Übersetzung einer Zuweisungsanweisung

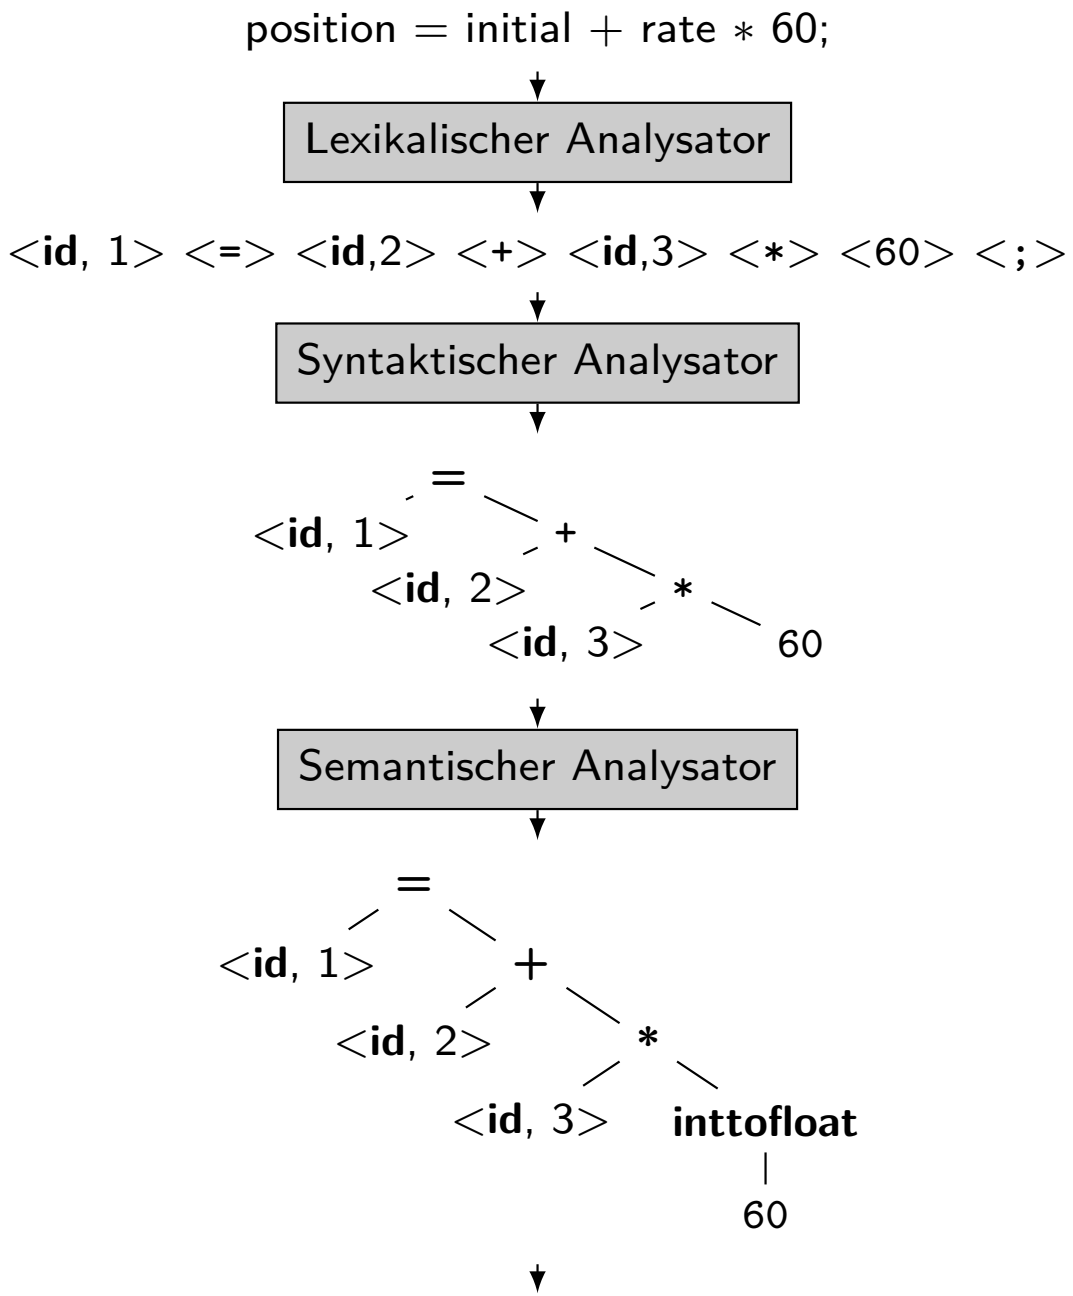

1	position	...
2	initial	...
3	rate	...
	⋮	

Stringtabelle

Übersetzung einer Zuweisungsanweisung

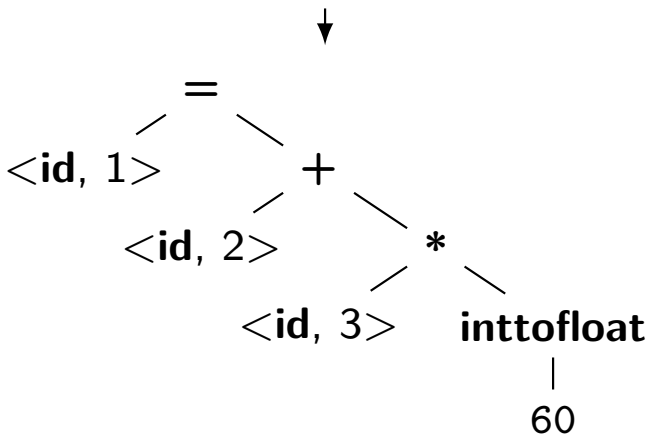

Zwischencodegenerator

```
t1  = inttofloat(60)
t2  = id3 * t1
t3  = id2 + t2
id1 = t3
```

Codeoptimierer

```
t1  = id3 * 60.0
id1 = id2 + t1
```

```
t1  = id3 * 60.0
id1 = id2 + t1
```

Codegenerator

```
LDF   R2, id3
MULF  R2, R2, #60.0
LDF   R1, id2
ADDF  R1, R1, R2
STF   id1, R1
```

Kapitel 1: Einleitung

Übersetzen

Übersetzen

Text aus *Quell*sprache in *Ziel*sprache übertragen unter Erhaltung der Bedeutung (bedeutungsäquivalent, semantikerhaltend)

- Quell-/Zielsprache können identisch sein
- Ziel kann maschinen-interpretierbare Sprache sein.
- Bei Programmiersprachen: Semantik durch Ausführung - Interpretation - des Quell-/Zieltexts gegeben

Zielkriterien

- Korrektheit
- Minimaler Betriebsmittelaufwand zur Laufzeit (Rechenzeit, Speicher, Energie)
- Kompatibilität mit anderen Übersetzern
  - gleicher Sprachumfang akzeptiert
  - Interaktion mit Programmen
    - anderer Sprachen
    - anderer Übersetzer
    - auf anderen Rechnern
    - dynamische Verknüpfung
- Übersetzungsgeschwindigkeit
- *Diese Ziele widersprechen sich teilweise!*

Bedeutung (Semantik) von Programmtexten

definiert durch Komposition:

- Programmtext hat Struktur (Syntax)
- Bedeutung den Strukturelementen zugeordnet
- Gesamtbedeutung durch Komposition der syntaktischen Elemente

Strukturelemente imperativer Sprachen

- Datentypen, Objekte (Variable, benannte Konstante, Literale) und Operationen
- ablaufsteuernde Elemente
- statische Strukturelemente (definieren Gültigkeitsbereiche)

also:

- Programmtext hat keine Bedeutung als Text
- Bedeutung erst nach Identifikation der Strukturelemente erfaßbar

Spezifikation von Übersetzungen

Naive Idee: Aufzählung

- Gib zu jedem Quellprogramm ein (oder mehrere) Zielprogramme an
- Aber: Quellsprachen erlauben i.A. abzählbar unendlich viele Elemente (Programme)

deshalb intensionale Definition

- Kompositionalität der Sprachen nutzen: syntaxorientierte Übersetzung
- Sprachelemente definieren Bedeutung
- Übersetzungsdefinition für alle Sprachelemente definiert
- Übersetzung unter Nutzung der Kompositionalität

Anforderungsanalyse bei Übersetzern

- Festlegung der Quellsprache (Norm, Erweiterungen, Einschränkungen, . . .)
- Festlegung des Niveaus der Interpretation und der Zielsprache:
  - abstrakte Maschine definieren
  - Abgrenzung Hardware/Laufzeitsystem
  - Entwurf Laufzeitsystem
- Systemeinbettung: andere Übersetzer, andere Sprachen, BS-Anschluß, ... berücksichtigen
- formales Modell der Semantik zur genauen Definition von „Korrektheit“ der Bedeutungsäquivalenz (wird leider meist unterlassen)

Abstrakte Maschinen

gegeben durch Typen, Objekte und Operationen, Ablaufsteuerung

- Sprache definiert eine abstrakte Maschine
  - Objekte bestimmen die Speicherelemente
  - Operationen und Ablaufsteuerung die Befehle

Beispiele: virtuelle Java-Maschine, .NET CLR

- Interpretation: Ausführung des Programms auf der Ebene der abstrakten Maschine
- Umkehrung: Jede abstrakte Maschine definiert Sprache

Ebenen der Interpretation bzw. Übersetzung

- Reiner Interpretierer
- Vorübersetzung
- Laufzeitübersetzer
- Vollständige Übersetzung
- Makrosprachen

Reiner Interpretierer

- liest Quelltext jeder Anweisung bei jeder Ausführung und interpretiert sie
- billig, wenn nur einmal ausgeführt
- sinnvoll bei Kommandosprachen

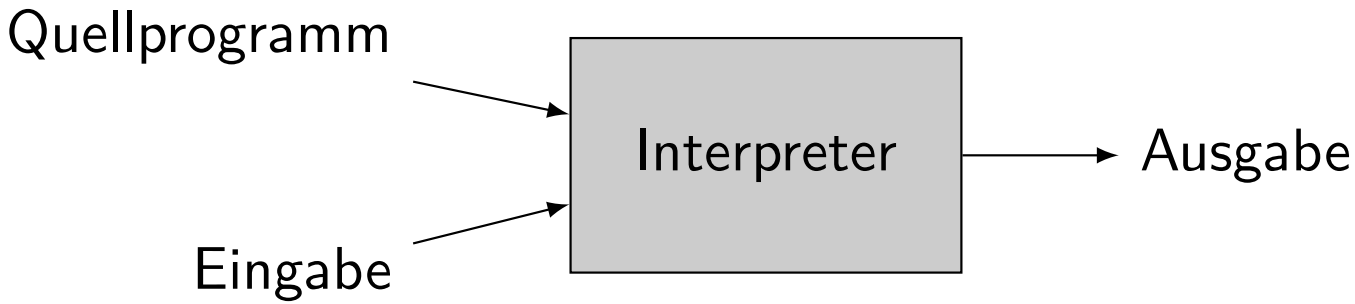

Interpretation nach Vorübersetzung

- Analyse der Quelle und Transformation in eine für den Interpretierer günstigere Form, z.B. durch
  - Zuordnung Bezeichnergebrauch - Vereinbarung
  - Transformation in Postfixform
- nicht unbedingt Maschinenniveau
- Beispiel: Java-Bytecode, Smalltalk-Bytecode, Pascal P-Code

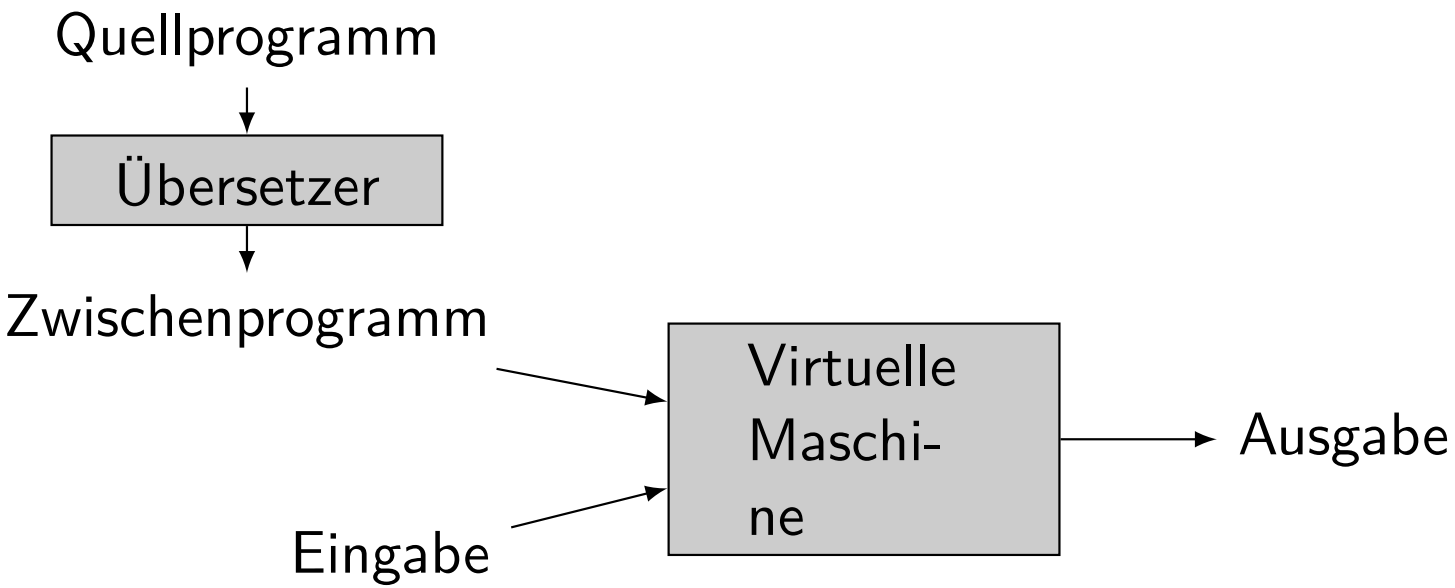

Vollständige Übersetzung

- Übersetzung in Maschinencode, z.B. x86, SPARC
- Code zur Nutzung des Laufzeitsystems
- Auch (maschinennahe) Zielsprache definiert eine abstrakte Maschine. Interpretierer definiert durch:
  - die Hardware der Zielmaschine
  - Betriebssystem
  - Laufzeitsystem (E/A-Unterprogramme, Speicherverwaltung, -bereinigung, ...)

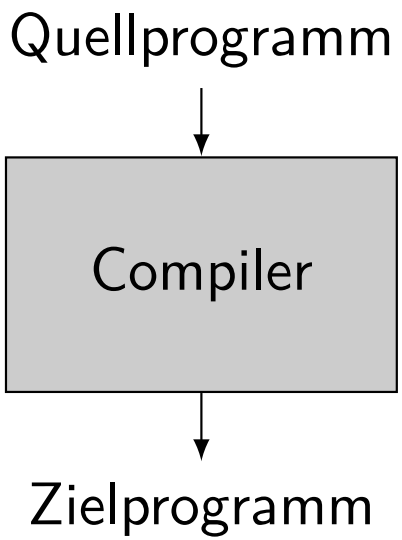

Laufzeitübersetzer (JIT-Compiler)

- Übersetzung während Programmausführung[1]
- Auszuführender Code wird übersetzt und eingesetzt
  - schneller als reine Interpretation
  - Speichergewinn: Quelle kompakter als Zielprogramm
  - langsamer als vollständige Übersetzung, da nur lokaler Kontext benutzt (es ist auch Besseres denkbar, aber schwierig)
  - gut im Test (nur kleiner Teil des Codes ausgeführt)
  - kann dynamisch ermittelte Laufzeiteigenschaften berücksichtigen (dynamische Optimierung)
- Übersetzung mit Substitution
- Beispiel: .NET, das sich wegen nicht direkt greifbarer Typinformation nicht für Interpretation eignet

[1] Laufzeitübersetzung erfunden 1974, CMU

Makrosprachen

- Zielsprache identisch mit (Ausschnitt der) Quellsprache
- Makros werden nach vorgegebenen Vorschriften ersetzt
- Beispiele: Textformatierung, Textverarbeitung, Vorverarbeitung (Präprozessor) von C, C++, C#

Kapitel 1: Einleitung

Fließbandarchitektur eines Übersetzer

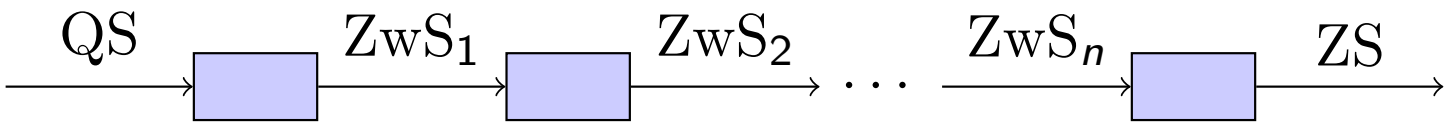

QS: Quellsprache ZwS_i: Zwischensprache i ZS: Zielsprache
Die Fließbandarchitektur wurde auf Grund von Speicherbeschränkungen eingeführt (pragmatische Entscheidung), nicht auf Grund einer mathematischen Notwendigkeit.

Ein Sprachverarbeitungssystem

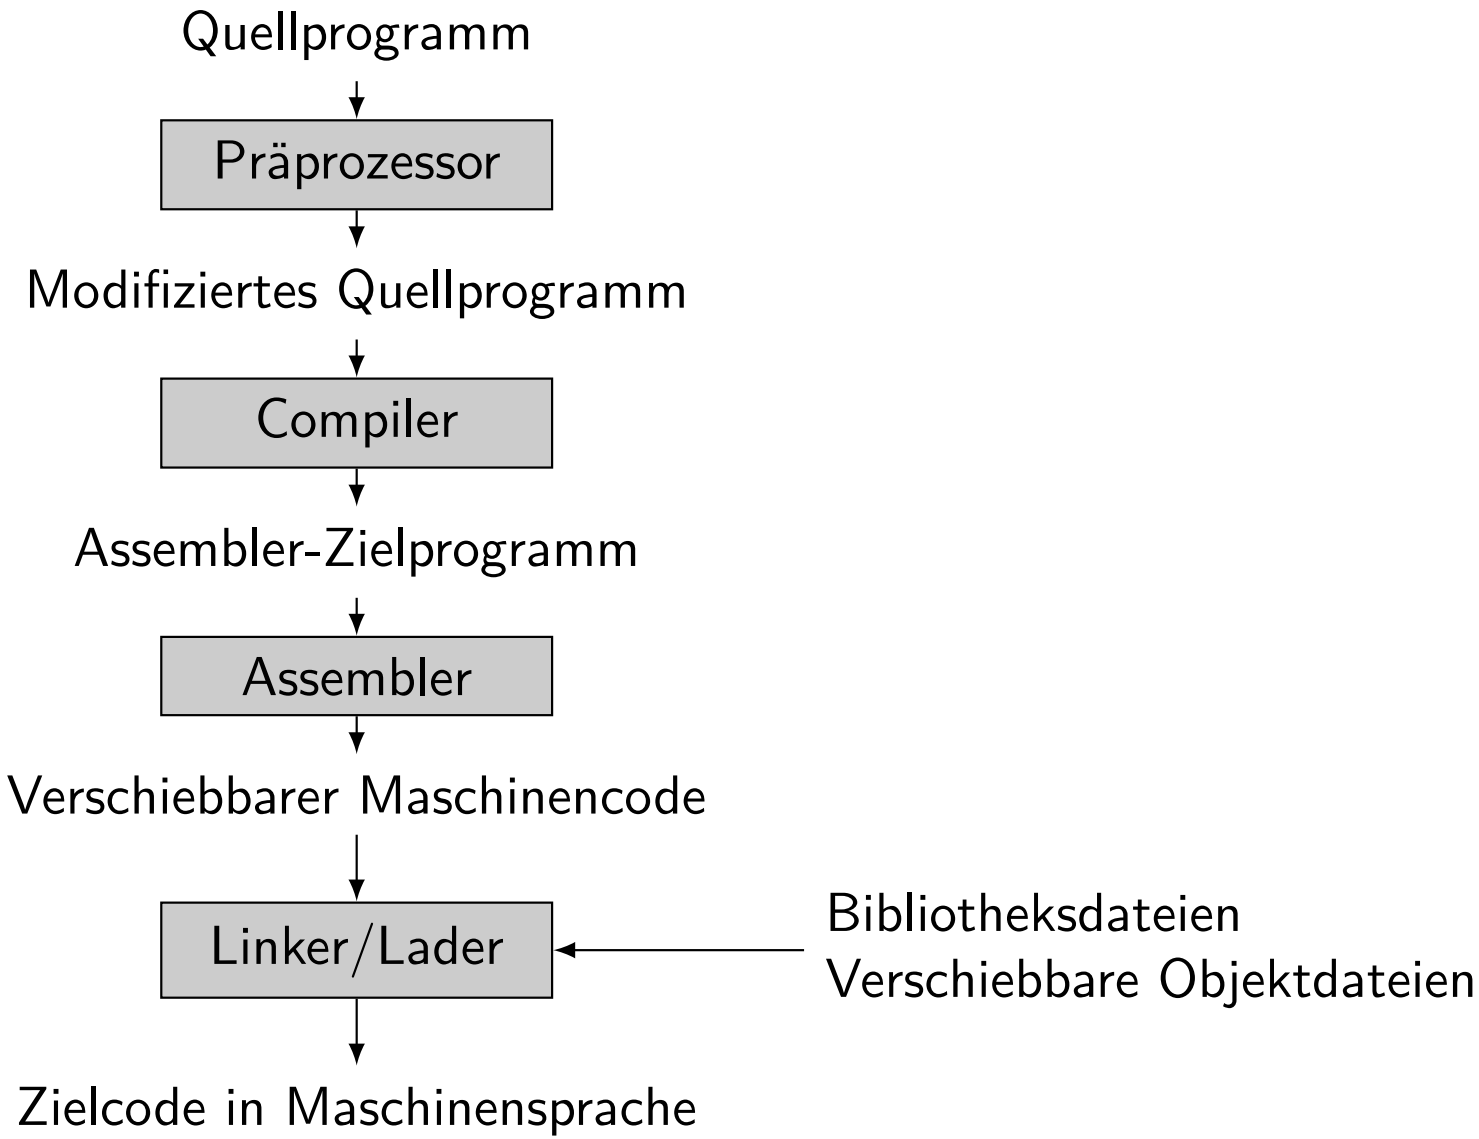

Komponenten eines Übersetzers

Analyse	lexikalische Analyse	Lesen, Tokens (Symbole) erkennen
	syntaktische Analyse	Strukturbaum erzeugen
	semantische Analyse	Namens-, Typ-, Operatoranalyse, Konsistenzprüfung
Abbildung	Transformation	Daten abbilden, Operationen abbilden
	globale Optimierung	Konstantenfaltung, gemeinsame Teilausdrücke erkennen, globale Zusammenhänge erkennen und nutzen, Programmreorganisation
Codierung	Codeerzeugung	Ausführungsreihenfolge bestimmen, Befehlsauswahl, Registerzuteilung, Nachoptimierung
	Assemblieren und Binden	interne und externe Addressen auflösen, Befehle, Addressen, Daten codieren

Analysephase

- Aufgaben:
  - Feststellung der bedeutungstragenden Elemente
  - Zuordnung statischer Bedeutung
  - Konsistenzprüfung
- Linguistik: Syntax umfasst gesamte Analysephase
  - Problem: Nicht mit kontextfreier Grammatik (also effizient) parsbar; deshalb Aufteilung
- Schritte:
  - Symbolentschlüsselung
  - Syntaktische Analyse (Parsen)
  - Semantische Analyse
  - noch keine Übersetzung! nur Analyse

Lexikalische Analyse

- zerlegt Quellprogramm (Text) in Sequenz bedeutungstragender Einheiten (Tokenstrom)
- beseitigt überflüssige Zeichen(folgen) wie
  - Kommentare,
  - Leerzeichen, Tabulatoren usw.
- Abgetrennt von Parser, dadurch
  - reguläre Automaten möglich
  - Geschwindigkeit höher

Syntaktische Analyse

- Syntaktische Analyse
- liefert abstrakten Syntax(-baum) des Programms
- aus softwaretechnischen Gründen deterministische kontextfreie Grammatik als Spezifikation

Abstrakter Syntaxbaum (AST)

Beispiel:

while (r>=n) {
r=r−n;
q=q+1
}

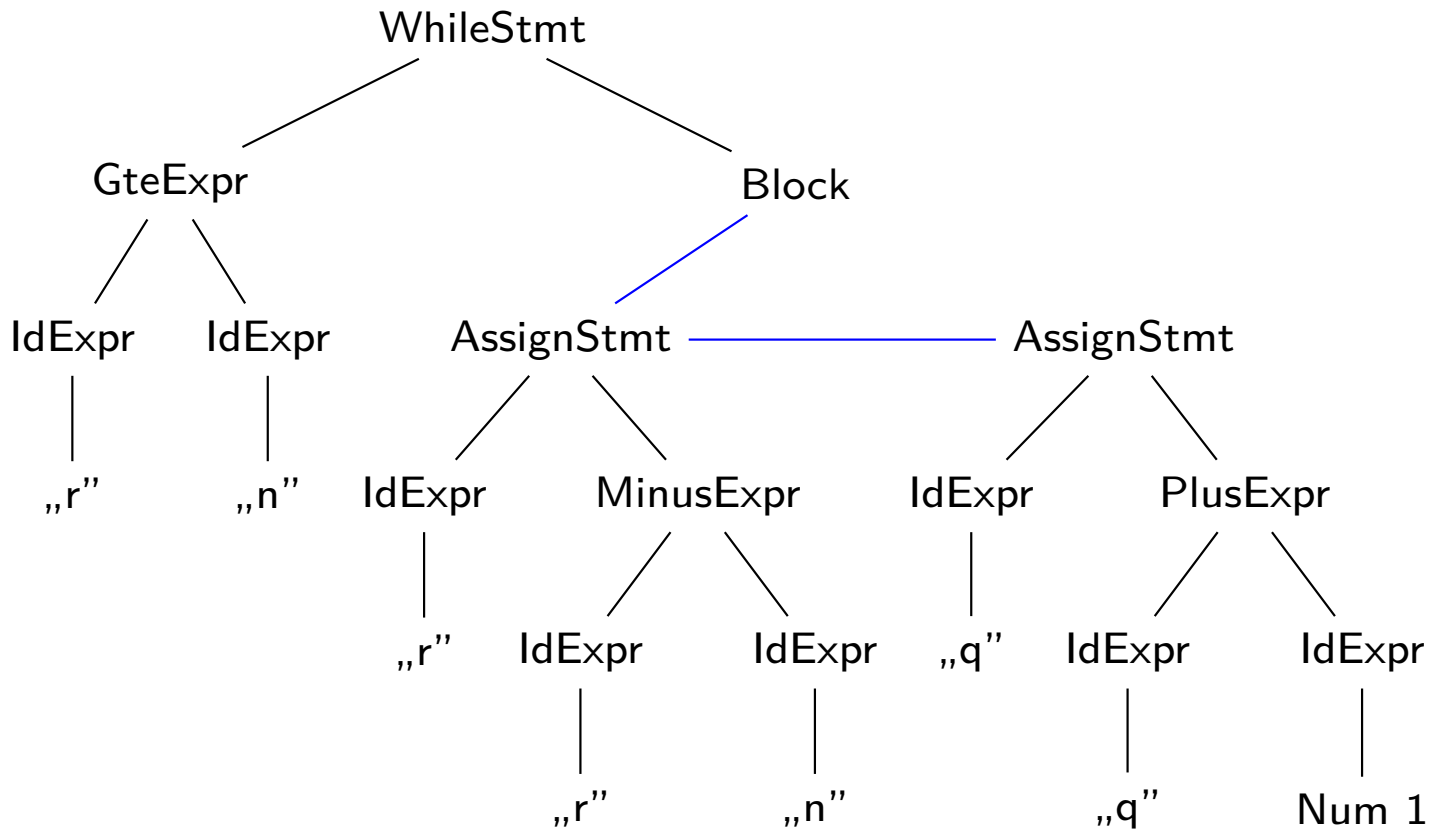

Semantische Analyse

- Analyse des Strukturbaums
  - notwendig, da Programmiersprachen kontextsensitiv
  - Bedeutung von Bezeichnern
- Namens- und Typanalyse
  - ist eng verschränkt
- Konsistenzprüfungen
  - sind Einschränkungen der Programmiersprache
  - Beispiel: Statische negative Array-Grenzen
- Bedeutungsbindung (soweit möglich)
  - Operatoridentifikation
  - Zuordnung von Namensverwendungen zu ihren Definitionen

Transformationsphase

- Transformation
  - eigentliche Übersetzung
  - Speicherlayout der Objekte auf der Zielmaschine
  - Übersetzung der Operationen
  - Übersetzung der Ablaufsteuerung
  - Noch kein Zielcode generiert
- Optimierung
  - genauer: optimierende Transformationen (mit Korrektheitsnachweis)
  - „interessantester Teil" heutiger Übersetzerforschung

Codegenerierung

- Codegenerierung
  - wählt Befehle aus (Codeselektion)
  - bestimmt die Ausführungsreihenfolge
  - bestimmt konkrete Repräsentation
    - im Speicher
    - in Registern
- Nachoptimierung
- dann Assemblieren und Binden

40 „State of the Art" Optimierungen

- Address Optimization
- Alias Analysis (by address)
- Alias Analysis (by type)
- Alias Analysis (const qualified)
- Array Bounds Optimization
- Bitfield Optimization
- Block Merging
- Branch Elimination
- Constant Folding
- Constant Propagation
- Cross Jumping
- CSE Elimination
- Dead Code Elimination
- Expression Simplification
- Forward Store
- Function Inlining
- Garbage Collection Optimisation
- Hoisting
- If Optimisation
- Induction Variable Elimination
- Instruction Combining
- Integer Divide Optimization
- Integer Modulus Optimization
- Integer Multiply Optimization
- Loop Collapsing
- Loop Fusion
- Loop Unrolling
- Narrowing
- New Expression Optimization
- Pointer Optimization
- printf Optimization
- Quick Optimization
- Register Allocation
- SPEC-Specific Optimization
- Static Declarations
- Strength Reduction
- String Optimization
- Synchronized Function Optimization
- Tail Recursion
- Try/Catch Block Optimization
- Unswitching
- Value Range Optimization
- Virtual Function Optimization
- Volatile Conformance

UNCOL

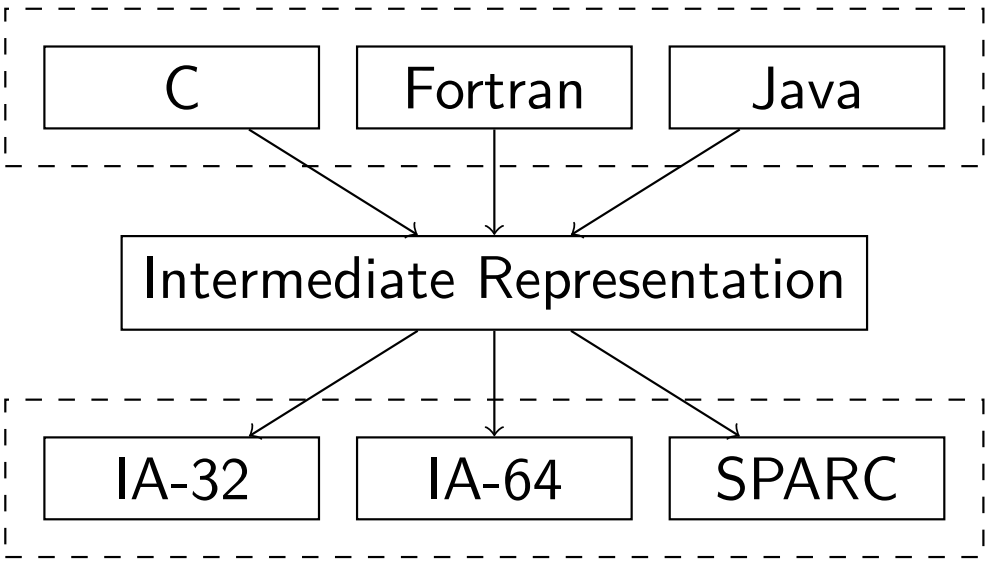

- Idee von T. B. Steel, Jr. 1961
- UNCOL: UNiversal Computer Oriented Language.
- Niemals direkt implementiert

- Beste heutige Annäherung an UNCOL: .NET CLI/CLR
- Argumente
  - Ablaufsteuerung in allen Sprachen fast gleich
  - Anzahl der Basistypen gering und ähnlich
  - OO-Eigenschaften durch Verbunde simulierbar

Modulare Struktur von Compilern

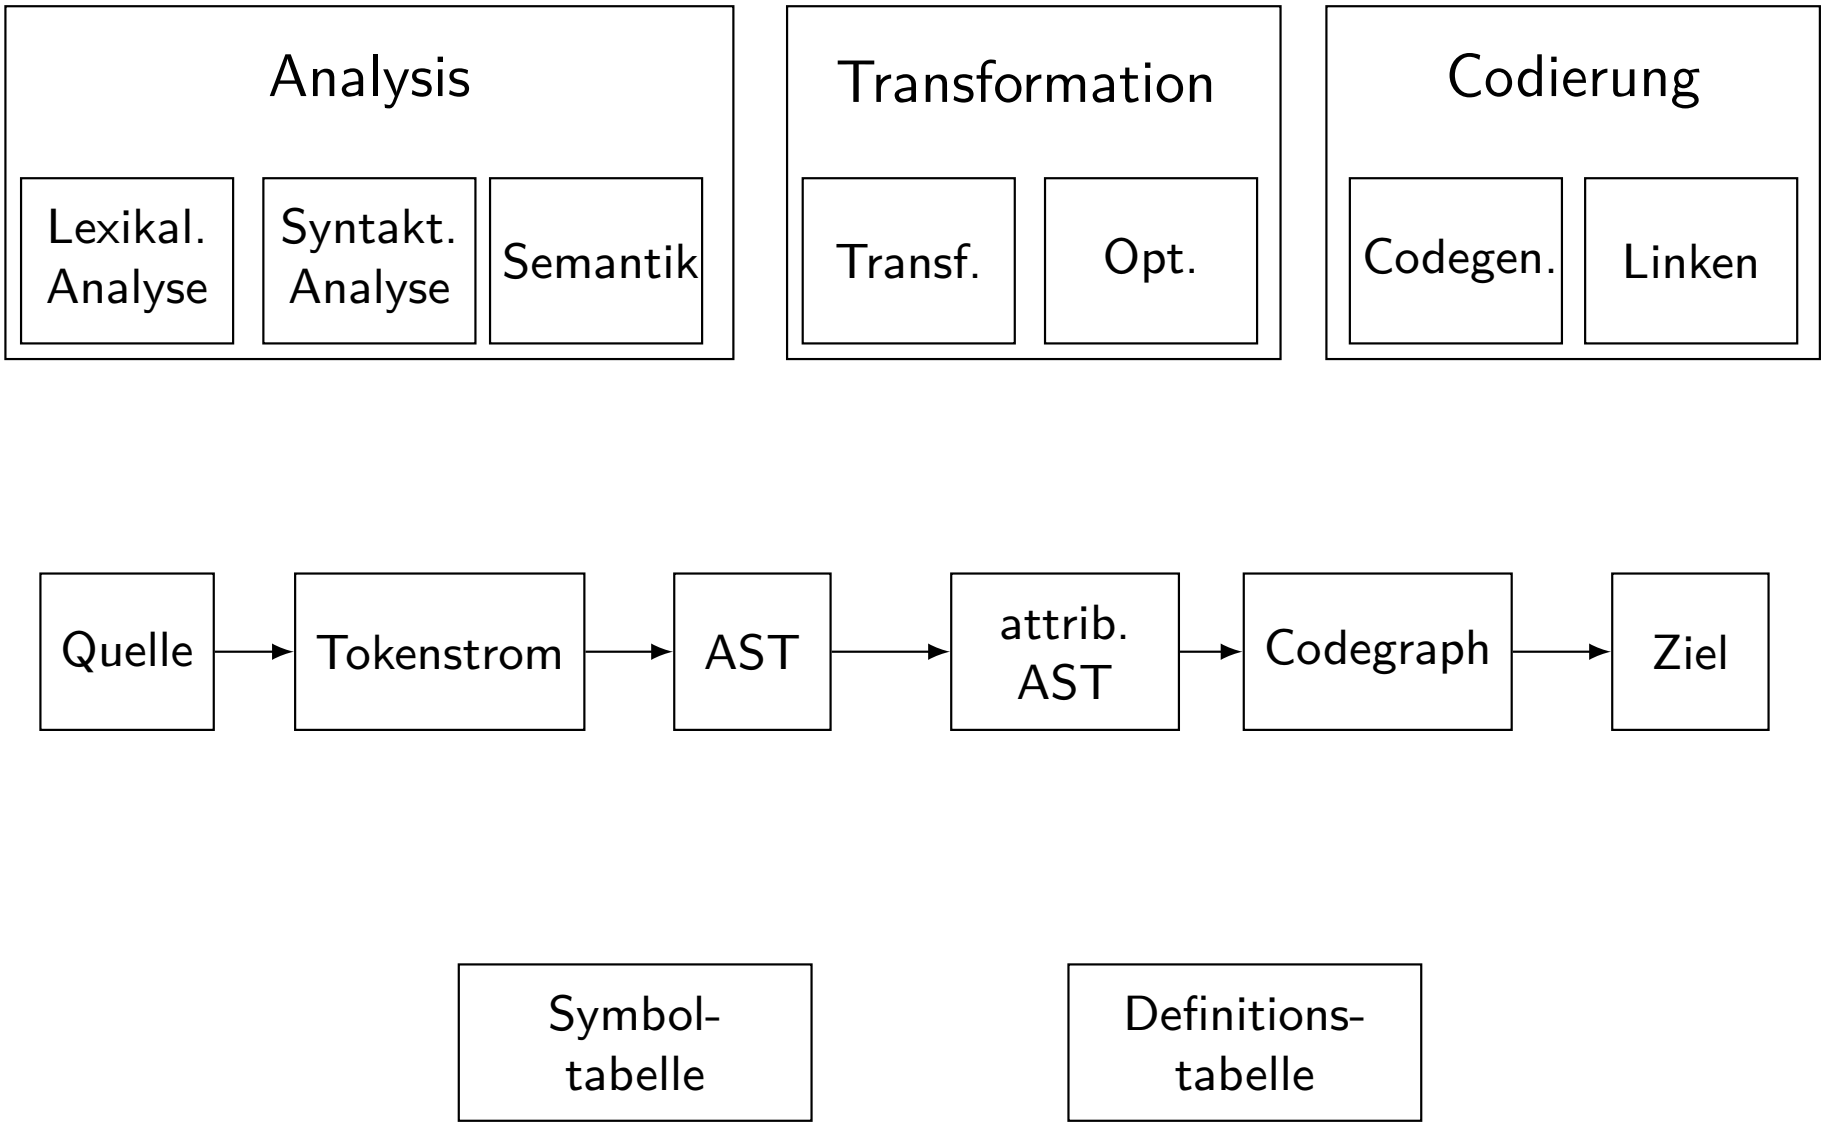

Datenstrukturen

- Tokenstrom
- (Attributierter) Syntaxbaum (AST)
- Codegraph
- Zielprogramm
- Stringtabelle
- Symboltabelle

Tokenstrom

Token:
bedeutungstragende Einheit im Programm Paar aus syntaktischem Schlüssel und Merkmal (Value)

Tokenstrom:
Darstellung des Quellprogramms als Folge von Tokens

- Schnittstelle: Lexer und Parser
- Vorsicht: Tokenstrom begrifflich notwendig, aber Implementierung noch offen! (gilt auch für die weiteren Datenstrukturen)

Attributierter Syntaxbaum

- Syntaxbaum:
  - Schachtelung der bedeutungstragenden Einheiten
  - kann kompositional Semantik zugeordnet werden
- Abstrakte Syntax:
  - Syntax stark vereinfacht und durch Struktur wiedergegeben
  - z.B. fallen Schlüsselworte wie while und Klammerungen weg
- Attribute:
  - Ergebnisse von semantischer Analyse
  - z.B. Typen, Namen, (konstante) Werte, Definitionsstellen, usw.
- Schnittstelle zwischen Syntaxanalyse, semantische Analyse, Transformationsphase

Stringtabelle

- Zuordnung Bezeichner, Literalkonstanten (evtl. andere Symbole) zur übersetzerinternen Codierung
- Aufbau während Symbolentschlüsselung, dann unverändert im Übersetzungslauf

Symboltabelle

- Datenbank des Übersetzers
- Tabelle aller Definitionen (Vereinbarungen):
  - enthält Informationen zu jedem Bezeichner (z.B. Typ, Speicherlayout,...)
  - Auflösung von Blockstrukturen, Überladung, Namenskonflikten
- oft ist die Stringtabelle in die Symboltabelle integriert

Codegraph

- Darstellung des Programms mit Datenobjekten und Operationen der Zielmaschine
- Befehle für Operationen noch nicht ausgewählt (Art des Registerzugriffs, Adressierungsmodi, usw. noch offen)
- Keine Register- und Speichereinschränkungen
- Schnittstelle:
  - Transformationsphase und Codegenerierung
  - Eingabe und Ergebnis vieler Optimierungen

Zielprogramm

- Ausgabe der Codeselektion: symbolisch codiert
- Assemblierer: verschlüsselt binär, löst symbolische Adressen auf, soweit intern bekannt
- Binder: löst externe Symbole auf
- Ergebnis: Objektprogramm ohne symbolische Adressen (aber eventuell relativ adressiert)

Java Byte Code (Assembler fur die JVM)

```
; Purpose: Print out "Hello World!"

.class public examples/HelloWorld
.super java/lang/Object
.method public <init>()V
aload_0                                                    ; 0x2a
invokespecial java/lang/Object/<init>()                    ; 0xb7 0x00 0x16
return                                                     ; 0xb1
.end method
.method public static main([Ljava/lang/String;)V
.limit stack 2
; push System.out onto the stack
getstatic java/lang/System/out Ljava/io/PrintStream;       ; 0xb2 0x00 0x02
; push a string onto the stack
ldc "Hello World!"                                         ; 0x12 0x15
; call the PrintStream.println() method.
invokevirtual java/io/PrintStream/println(Ljava/lang/String;)V ; 0x0d 0x00 0x0c
return                                                     ; 0xb1
.end method
```