Compiler

Proseminar „C-Programmierung - Grundlagen und Konzepte”

Torsten Zühlke

9zuehlke@informatik.uni-hamburg.de

3. Juni 2011

Gliederung

Gliederung

Definition

Compiler[1]

Ein Compiler (auch Übersetzer oder Kompilierer genannt) ist ein Computerprogramm, das eine in einer Quellsprache geschriebene Eingabe in eine semantisch äquivalente Ausgabe einer Zielsprache umwandelt.

Grundsätze[2]

The compiler must preserve the meaning of the program being compiled.

The compiler must improve the input program in some discernible way.

Beispiele

- `tpic` überführt `pic`-Grafiken in LaTeX
- `gcc` überführt Quellcode diverser Hochsprachen in Maschinencode

[1] Frei nach: Compiler. `http://de.wikipedia.org/wiki/Compiler` 2011-05-24

[2] Cooper & Torczon: Engineering a Compiler. Morgan Kaufmann 2003

Motivation

Vorteile von Compilern

- Programmierung in Hochsprache möglich
- Programmierung für mehrere Plattformen einfacher

$\Rightarrow$ Schnellere Softwareentwicklung

- Erkennt Fehler
- Erzeugt bessere Programme

$\Rightarrow$ Zuverlässigere Software

Gliederung

Die Compilerphasen

Analyse- und Synthesephase

Compiler arbeiten üblicherweise in 2 Phasen, die weiter unterteilt sind.

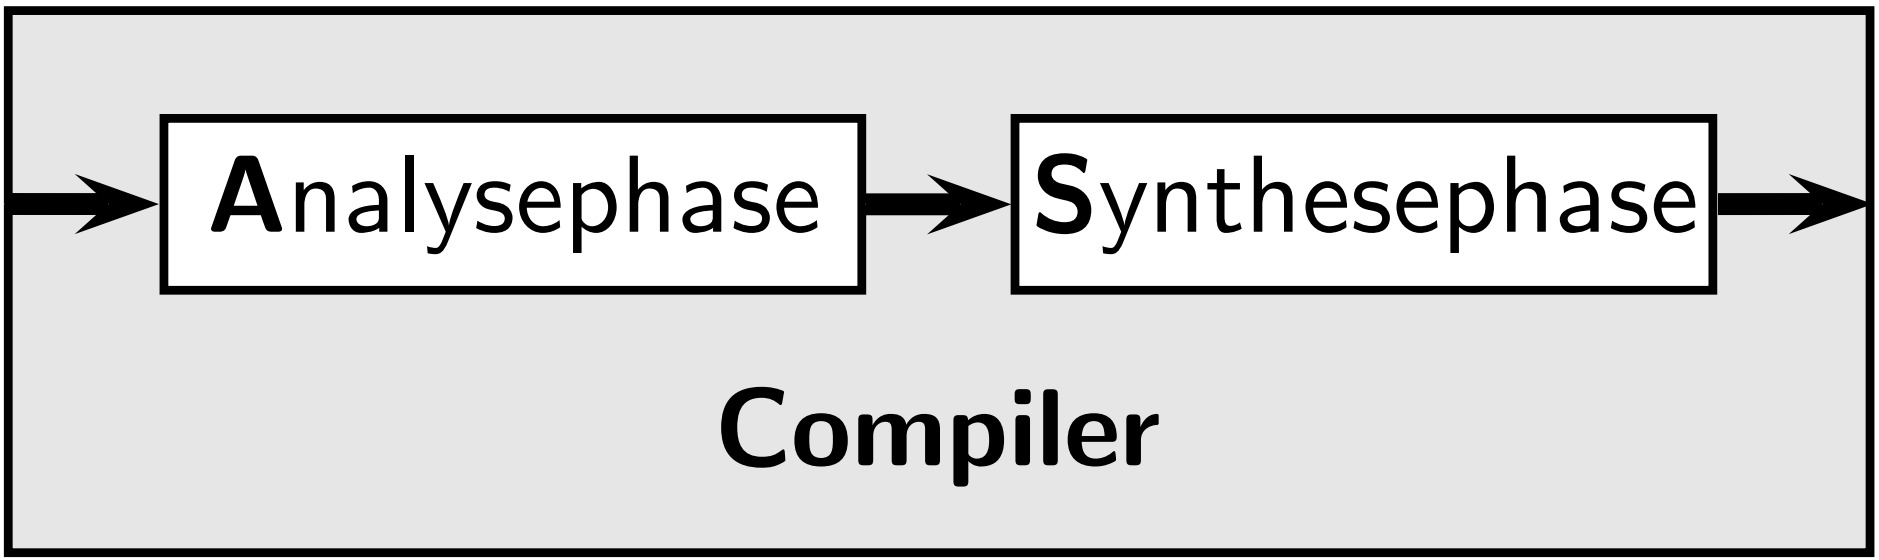

- Die Analysephase prüft auf Korrektheit
- Die Synthesephase erzeugt und optimiert Maschinencode

Gliederung

Die Analysephase (Frontend)

Analyseschritte

Die Analysephase ist aufgeteilt in

- Lexikalische Analyse
- Syntaktische Analyse
- Semantische Analyse

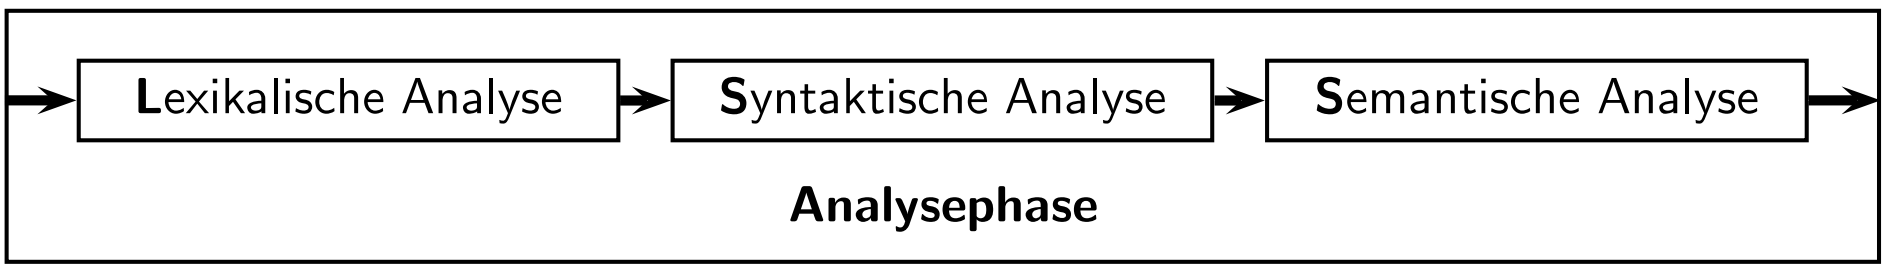

Die Lexikalische Analyse

Aufgabe

Bei der Lexikalischen Analyse wird der Quellcode in Tokens umgewandelt.

Token

Token (engl.): Terminalsymbol $\Leftrightarrow$ zusammengehörende Grundeinheit

Mögliche Tokens

- Schlüsselwörter
  if, for, while, switch, return, ...
- Bezeichner
- Typen
  int, float, double, char, ...
- Konstanten
  Ganzzahlen, Fließkommazahlen, Zeichen, Zeichenketten
- Operatoren

Veranschaulichung I

C-Code

```
 1 int main(int argc, char *argv[])
 2 {
 3   int *pointer, value;
 4   value = 0;
 5   pointer = &value;
 6
 7   for(int i = 0; i < 5; i++){
 8     value += i;
 9     printf("%d\n", *pointer);
10   }
11
12   return *pointer;
13 }
```

Veranschaulichung II

Tokens

<Typ, int>, <"main">,<"(">, <Typ, int>, <"argc">, <",">,
<Typ, char>, <Op, "*">, <"argv">, <Op, []>, <")">, <"{">
<Typ, int>, <Op, "*">, <"pointer">, <"Value">, <";">
<"value">, <Op, "=">, <Ganzzahl, 0>, <";">
<"pointer">, <Op, "=">, <Op, "&">, <"value">, <";">
<Schl.wort, "for">, <"(,">
<Typ, int>, <"i">, <Op, =>, <Ganzzahl, 0>, <";">
<"i">, <Op, <>, <Ganzzahl, 5>, <";">
<"i">, <Op, ++>, <")">, <"{">
<"value">, <Op, +=>, <"i">, <";">
<"printf">, <"(">,<String, "%d\n">, <",">,
<Op, *>, <"pointer">, <")">, <";">, <"}">
<Schl.wort, "return">, <Op, *>, <pointer>, <";">, <"}">

Die Syntaktische Analyse

Aufgaben

- Prüfung der Eingabe auf syntaktische Korrektheit
- Erstellen eines Syntaxbaums

Vergleich der Eingabe mit einer Definition der Eingabesprache.

Hierfür muss eine formale Definition der Eingabesprache vorliegen.

Exkurs - Sprachen & Grammatiken I

Formale Sprache

Eien Formale Sprache L ist eine Menge von erlaubten Wörtern.
z.B. $L = \{w \mid w \text{ ist C-Programm}\}$

Formale Grammatik

Mathematisches Konstrukt zur Beschreibung formaler Sprachen.
Nichtterminale werden mittels Produktionsregeln zu Terminalen abgeleitet.
Terminale sind (Teil-)Wörter.

Chomsky-Hierarchie

Die Chomsky-Hierarchie klassifiziert Grammatiken nach Produktionsregeln:

- Typ 0 Unbeschränkte Grammatik
- Typ 1 Kontextsensitive Grammatik
- Typ 2 Kontextfreie Grammatik
- Typ 3 Reguläre Grammatik

Exkurs - Sprachen & Grammatiken II

Erweiterte Backus-Naur-Form (EBNF)

Metasprache, die kontextfreie Grammatiken mittels ihrer Regeln darstellt.

- Menschenlesbar
- Maschinenlesbar

EBNF-Beispiel[1]

```
ZifferAußerNull = "1" | "2" | "3" | "4" | "5"
                | "6" | "7" | "8" | "9" ;
Ziffer          = "0" | ZifferAußerNull ;
NatuerlicheZahl = ZifferAußerNull { Ziffer } ;
GanzeZahl       = "0" | [ "-" ] NatuerlicheZahl ;
```

[1] Erweiterte Backus-Naur-Form.
http://de.wikipedia.org/wiki/Erweiterte_Backus-Naur-Form 2011-05-26

C-Grammatik I

C-Syntax (Auszug, vereinfacht)[1]

```
translation_unit    = function_definition;
function_definition = type_specifier IDENTIFIER declaration_list
                      compound_statement;
type_specifier      = VOID | INT | CHAR;
declaration_list    = declaration | declaration_list declaration;
declaration         = type_specifier init_declarator_list;
init_declarator_list= init_declarator
                    | init_declarator_list ',' init_declarator;
init_declarator     = declarator | declarator = inititializer;
declarator          = ['*'] IDENTIFIER;
initializer         = ['&'] IDENTIFIER | CONSTANT;
compound_statement  = '{' statement_list '}'
                    | '{' declaration_list statement_list '}';
```

[1] ANSI C Grammar(Yacc). http://www.lysator.liu.se/c/ANSI-C-grammar-y.html 2011-05-26

C-Grammatik II

C-Codebeispiel

```c
int main(int argc, char *argv[])
{
  int *pointer, value;
  value = 0;
  pointer = &value;

  for(int i = 0; i < 5; i++){
    value += i;
    printf("%d\n", *pointer);
  }

  return *pointer;
}
```

Semantische Analyse I

Semantische Analyse

Der Compiler sammelt Informationen über Programmdetails:

- Eigenschaften benutzter Werte/Typen
- Art der Bereitstellung und Initialisierung von Werten
- Vorhaltezeit für Werte
- Art der Speicherfreigabe
- Überladene Funktionen
- Zulässigkeit von Zuweisungen

Semantische Analyse II

Deklaration

Informationen über Variablen werden gewonnen aus

- Deklarationen
- Kontext der Nutzung

Vorwärtsdeklaration

Deklaration eines Bezeichners steht im Quellcode nach der ersten Nutzung.
Auflösen von Vorwärtsdeklarationen:
$\Rightarrow$ Semantische Analyse mehrfach ausführen

Gliederung

Die Synthesephase (Backend)

Syntheseschritte

Die Synthesephase ist aufgeteilt in

- Zwischencodeerzeugung
- Programmoptimierung
- Codeerzeugung

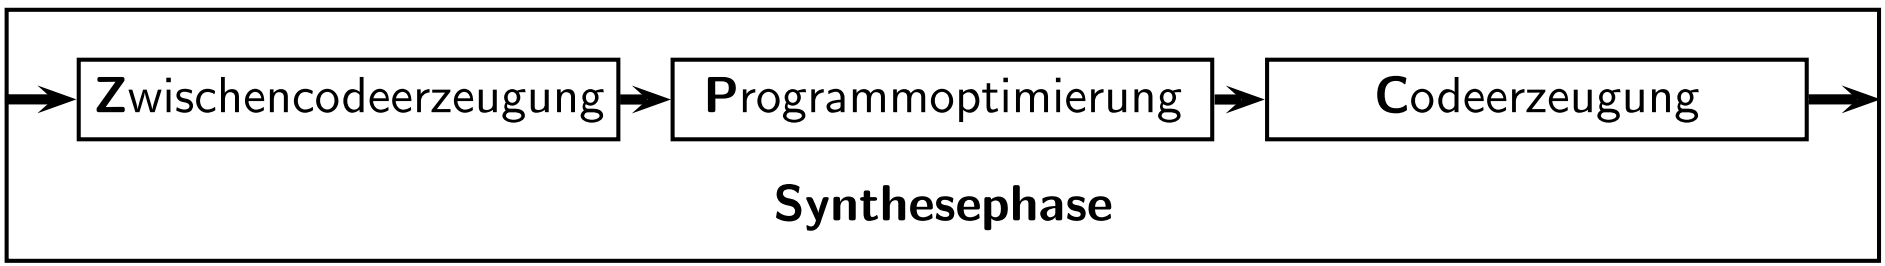

Die Zwischencodeerzeugung I

Aufgabe

Die Eingabe wird in eine systemnahen Zwischencode übersetzt.
Dieser Zwischencode hat folgende Eigenschaften:

- Verwendet Prozessorbefehle
- Verwendet Speicher unbegrenzter Größe
- Kann unbegrenzt viele Register adressieren

Die Zwischencodeerzeugung II

ILOC[1]

$$w \leftarrow x \times 2 \times y \times z$$

`loadAI`	$r_{arp}, @w$	$\Rightarrow r_w$	// load w
`loadI`	2	$\Rightarrow r_2$	// constant 2 into r_2
`loadAI`	$r_{arp}, @x$	$\Rightarrow r_x$	// load x
`loadAI`	$r_{arp}, @y$	$\Rightarrow r_y$	// load y
`loadAI`	$r_{arp}, @z$	$\Rightarrow r_z$	// load z
`mult`	r_w, r_2	$\Rightarrow r_w$	// $r_w \leftarrow w \times 2$
`mult`	r_w, r_x	$\Rightarrow r_w$	// $r_w \leftarrow (w \times 2) \times x$
`mult`	r_w, r_y	$\Rightarrow r_w$	// $r_w \leftarrow (w \times 2 \times x) \times y$
`mult`	r_w, r_z	$\Rightarrow r_w$	// $r_w \leftarrow (w \times 2 \times x \times y) \times z$
`storeAI`	r_w	$\Rightarrow r_{arp}, 0$	// write r_w back to w

[1] Cooper & Torczon: Engineering a Compiler. Morgan Kaufmann 2003

Optimierung

Optimierung

Bei der Optimierung wird der Quellcode in Bezug auf seinen Ressourcenbedarf verbessert.
Minimierung von z.B.

- Speicherzugriffe
- Speicherbedarf
- Befehlszahl
- Wartezeiten

Optimierungen

Einige mögliche Optimierungen

- Schleifen abwickeln
- Toten Code elimineren
- Neuordnung von Befehlen
- Statische Formelauswertung
- Erkennung von Konstanten
- Einfügen von Unterprogrammen
- Verwendung schnellerer Anweisungen
- Paging verhindern

Optimierungsprobleme

It (the compiler) will almost always fail to produce optimal code.[1]

Optimierung vs. Optimierung

Eine Optimierung einer Eigenschaft kann negative Auswirkungen auf andere Eigenschaften haben.

Speicherzugriffe $\Leftrightarrow$ Befehlszahl
Speicherzugriffe $\Leftrightarrow$ Speicherbedarf

[1] Cooper & Torczon: Engineering a Compiler. Morgan Kaufmann 2003

Die Codeerzeugung

Aufgabe

Entscheidung über die Zuweisung von Registern und Speicherstellen

Abhängig von:

- Art und Zahl der Register
- Verwendung der Variablen
- Inkonsistenzen bei der Nutzung von Registern

Veranschaulichung I

C-Codebeispiel

```c
int main(int argc, char *argv[])
{
  int *pointer, value;
  value = 0;
  pointer = &value;

  for(int i = 0; i < 5; i++){
    value += i;
    printf("%d\n", *pointer);
  }

  return *pointer;
}
```

Veranschaulichung II

Ausgabe bei Ausführung des Programms

```
0
1
3
6
10
```

Rückgabe: 10

Veranschaulichung III

Assemblercode (Initialisierung)

```
main:
.LFB0:
   pushq  %rbp                    //Stackframe setzen
   movq   %rsp,      %rbp         // I
   subq   $32,       %rsp         // I
   movl   $0,        -20(%rbp)    //value = 0
   leaq   -20(%rbp), %rax         //pointer = &value
   movq   %rax,      -16(%rbp)    //pointer auf Stack Speichern
   movl   $0,        -4(%rbp)     //i = 0 (for)
   jmp   .L2                      // -> Schleifenbedingung
```

Veranschaulichung IV

Assemblercode (Schleifenrumpf)

```
.L3:                                    //Schleifenrumpf
   movl   -20(%rbp), %eax               //value laden
   addl   -4(%rbp),  %eax               //value += i
   movl   %eax,      -20(%rbp)          //value zurückspeichern
   movq   -16(%rbp), %rax               //printf("%d\n", *pointer)
   movl   (%rax),    %eax               // I
   movl   %eax,      %esi               // I
   movl   $.LC0,     %edi               // I
   movl   $0,        %eax               // I
   call   printf                        // I
   addl   $1,        -4(%rbp)           // i++
```

Veranschaulichung V

Assemblercode (Schleifenbedingung & Ende)

```
.L2:                                    //Schleifenbedingung
   cmpl   $4,          -4(%rbp)         //i < 5 (for)
   jle    .L3                           // -> Schleifenrumpf
   movq   -16(%rbp), %rax               //return *pointer
   movl   (%rax),    %eax               // I
   leave                                //Stack aufräumen
   ret                                  //Funktion verlassen
```

Veranschaulichung VI

Assemblercode (Optimiert)

```
main:
.LFB0:
   subq   $8,        %rsp       //Stackframe setzen
   xorl   %esi,      %esi       //printf("0\n")
   movl   $.LC0,     %edi       // I
   xorl   %eax,      %eax       // I
   call   printf                // I
   movl   $1,        %esi       //printf("1\n")
   movl   $.LC0,     %edi       // I
   xorl   %eax,      %eax       // I
   call   printf                // I

                                 ...
```

Veranschaulichung VII

Assemblercode (Optimiert)

```
                                        ...

    movl    $10,        %esi        //printf("10\n")
    movl    $.LC0,      %edi        // I
    xorl    %eax,       %eax        // I
    call    printf                  // I
    movl    $10,        %eax        //return 10
    addq    $8,         %rsp        //Stack aufräumen
    ret                             //Funktion verlassen
```

Überblick

Compilerphasen

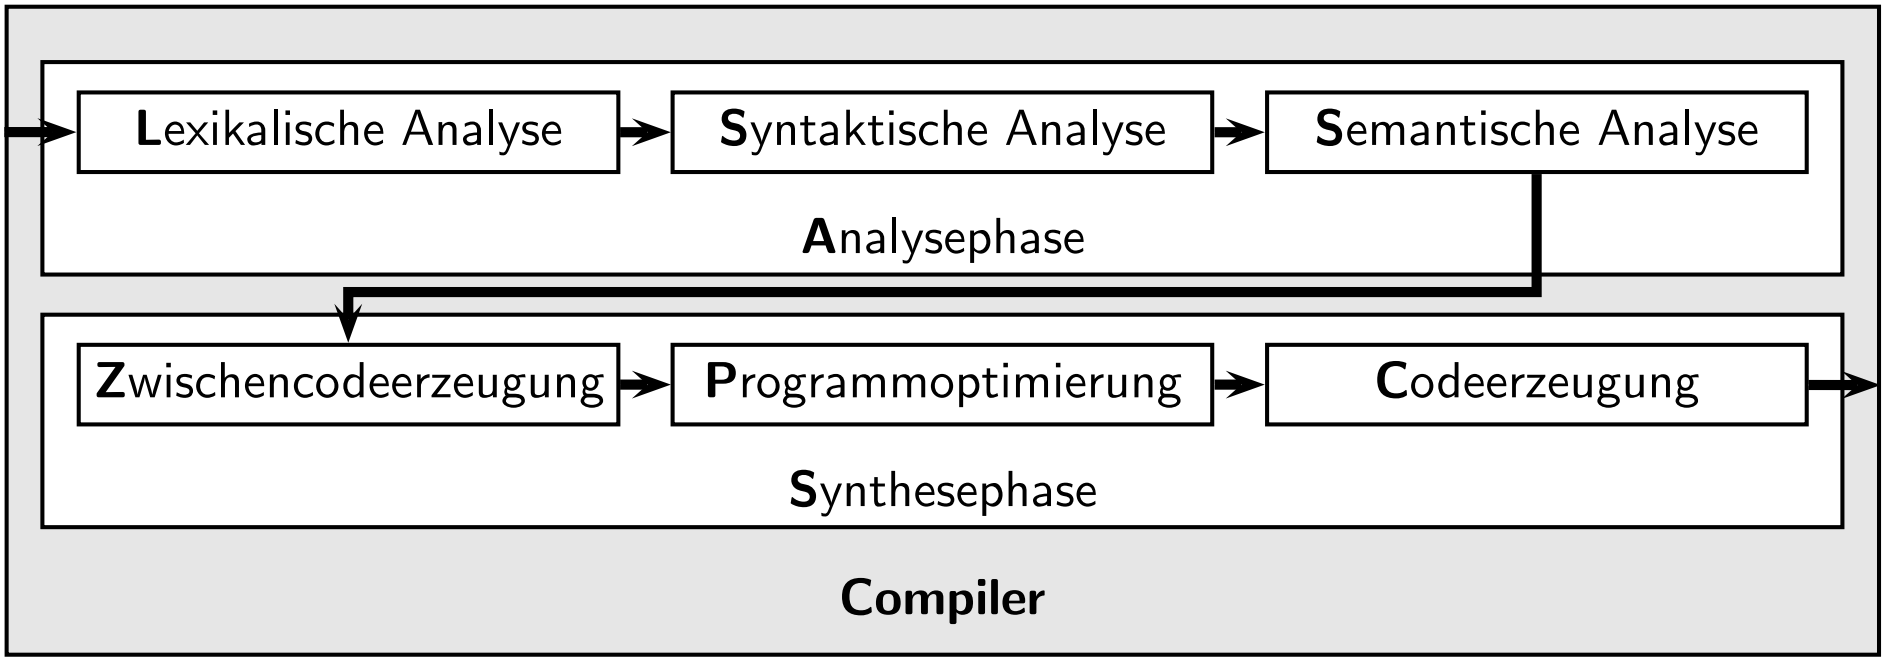

Alternative Implementation

Compilerphasen

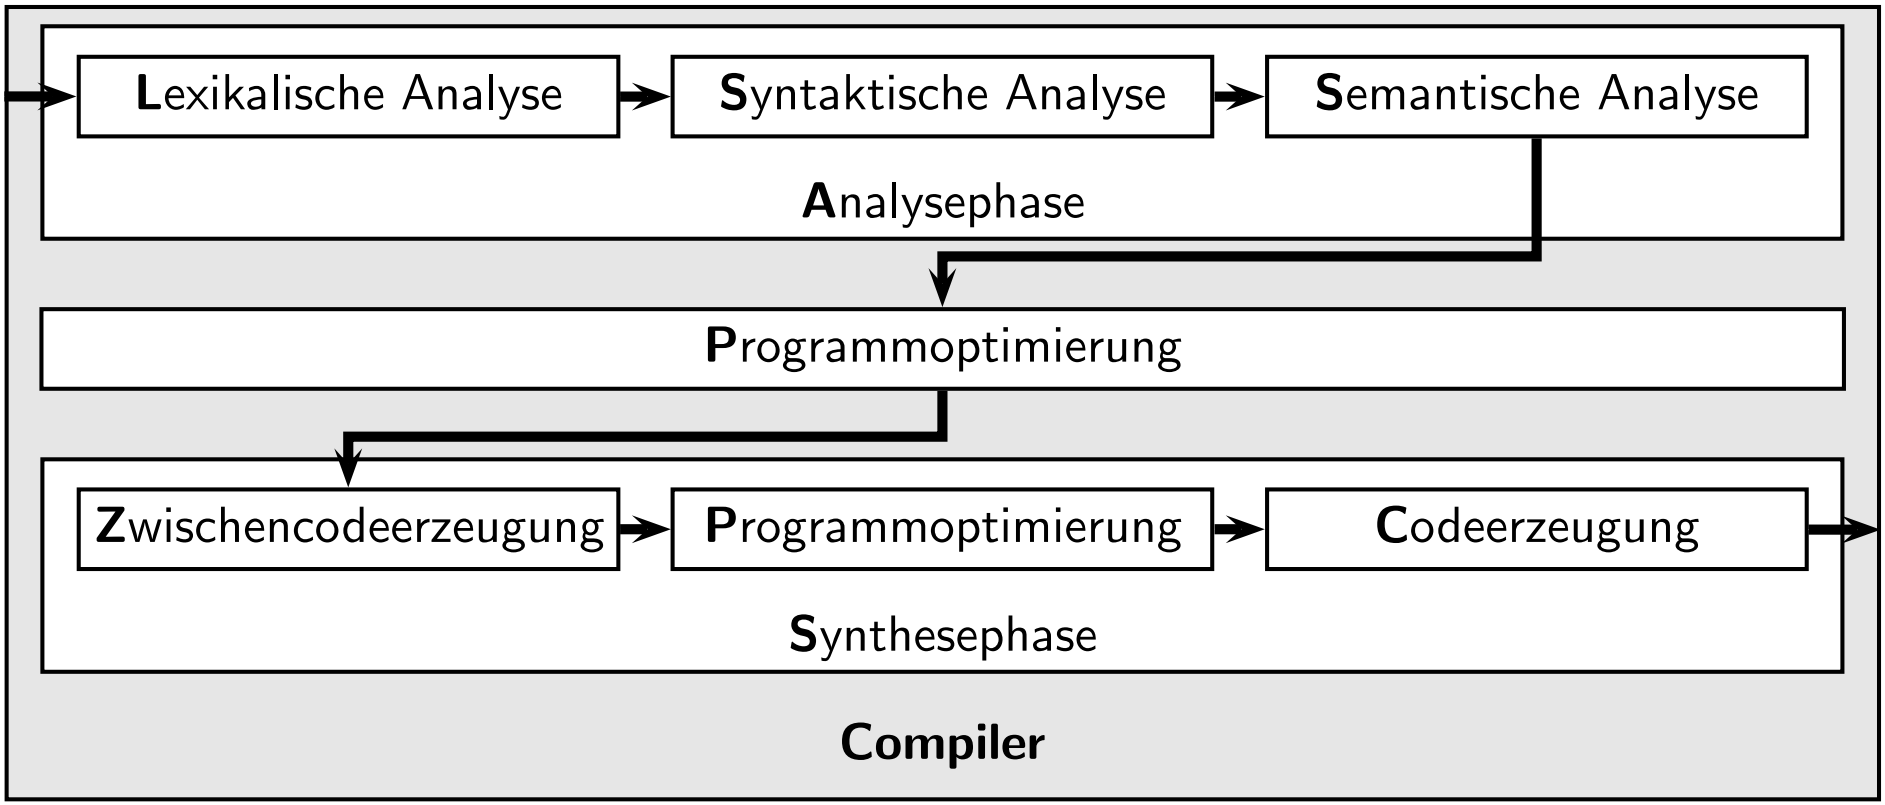

Gliederung

Compilerformen I

Compilerformen

Es gibt verschiedene Compilerformen:

- Compiler
  Ausführung und Kompilation unabhängig
- Interpreter
  Quellcode wird zur Ausführungszeit interpretiert
- Compreter
  Vorher erzeugter Zwischencode wird zur Ausführungszeit interpretiert
- Just-in-time-compiler (JIT-Compiler)
  Quellcode wird direkt vor der Ausführung kompiliert
  Teilweise wird unabhängig von der Ausführung Zwischencode erstellt

Compilerformen II

Gegenüberstellung

	Analysephase			Synthesephase		
	Lex. A	Syn. A	Sem. A	Zw.Code	Opt.	Code
Compiler	X	X	X	X	X	X
Compreter	X	X	X	X	X	I
Interpreter	I	I	(I)	-	-	I
JIT-Compiler	X / J	X / J	X / J	X / J	X / J	J

X: im Voraus, I: interpretiert, J: bedarfsorientiert (just in time),
(): implementationsabhängig

Compilertypen

Native Compiler

Erzeugt Programmcode für die Plattform auf der er selbst läuft

Cross-Compiler

Erzeugt Programmcode für eine andere Plattform

Transcompiler (Transpiler)

Übersetzt aus einer Hochsprache in eine andere

Compilervarianten

Single-pass-Compiler

Erzeugt den Zielcode in einem Compilerdurchlauf

Multi-pass-Compiler

Erzeugt den Zielcode in mehreren Schritten

Zusammenfassung

1. Grundlagen

   Definition, Motivation

2. 2-Phasen-Modell
   - Allgemeines
   - Analysephase

     Lexikalische -, Syntaktische -, Semantische Analyse

     Tokens, Sprachen, Grammatiken, Chomsky-Hierarchie, EBNF
   - Synthesephase

     Zwischencodeerzeugung, Optimierung, Codeerzeugung

     ILOC

   Alternative Implementation mit 3 Phasen

3. Compilertypen

   Compiler, Interpreter, Compreter, Just-in-Time-Compiler

   Native Compiler, Cross-Compiler, Transcompiler

   Single-Pass-Compiler, Multi-Pass-Compiler

Anhang: Sprachen & Grammatiken I

Alphabete & Formale Sprachen

- Ein Alphabet Σ ist eine endliche Symbolmenge
- Eine Formale Sprache L ist eine Menge von Wörtern

Sprechweise

L ist Sprache über Σ:
Alle Wörter aus L bestehen nur aus Symbolen aus Σ.

Beispiel

$\Sigma = \{0, 1\}$
$L = \left\{(ab)^+ \mid a, b \in \Sigma, a \neq b\right\}$
$L = \{01, 10, 0101, 1010, 010101, 101010, ...\}$

Anhang: Sprachen & Grammatiken II

Formale Grammatik

Eine formale Grammatik G ist ein mathematisches Konstrukt zur Beschreibung und Erzeugung formaler Sprachen mittels Produktionsregeln.

- Σ, einem endlichen Alphabet aus Terminalsymbolen
- N, einem endlichen Alphabet von Nichtterminalsymbolen
- P, einer endlichen Menge von Produktionsregeln
  - Jede Regel ist eine Relation $A \rightarrow w$ mit $A, w \in (\Sigma \cup N)^*$
  - A enthält mindestens ein Nichtterminalsymbol
- $S \in N$, einem Startsymbol

Formale Grammatik

Mit Formalen Grammatiken können Formale Sprachen beschrieben und erzeugt werden.

Anhang: Sprachen & Grammatiken III

Beispiel

Sei G folgenden Formale Grammatik: $G = (\Sigma, N, P, S)$
$\Sigma = \{0, 1\}$
$N = \{A, B, S\}$
P sei die Menge folgender Regeln:

Alternative 1

$$\begin{array}{rcl} S & \rightarrow & A \mid B \\ A & \rightarrow & 0B1 \mid 01 \\ B & \rightarrow & 1A0 \mid 10 \end{array}$$

Alternative 2

$$\begin{array}{rcl} S & \rightarrow & 0A1 \mid 1A0 \mid 01 \mid 10 \\ 0A1 & \rightarrow & 01A01 \mid 0101 \\ 1A0 & \rightarrow & 10A10 \mid 1010 \end{array}$$

L sei die aus G erzeugte Sprache:
$L = \{01, 10, 0101, 1010, 010101, 101010, ...\}$

Anhang: Sprachen & Grammatiken IV

Chomsky-Hierarchie

Die Chomsky-Hierarchie klassifiziert Grammatiken nach Produktionsregeln:

- Typ 0 Unbeschränkte Grammatik
- Typ 1 Kontextsensitive Grammatik
  Produktionsregeln haben die Form $\alpha A \beta \rightarrow \alpha \gamma \beta$
- Typ 2 Kontextfreie Grammatik
  Produktionsregeln haben die Form $A \rightarrow \alpha$
- Typ 3 Reguläre Grammatik
  Produktionsregeln haben die Form $A \rightarrow \epsilon$ oder
  $A \rightarrow aB$ (rechtsregulär) bzw. $A \rightarrow Ba$ (linksregulär)

A, B: Nichtterminal, a: Terminal
α, β, γ: Wörter aus Terminalen und Nichtterminalen, γ ist nicht leer
ϵ: leeres Wort

Anhang: Sprachen & Grammatiken V

Erweiterte Backus-Naur-Form (EBNF)

Die EBNF stellt kontextfreie (Typ-2-)Grammatiken mittels ihrer Produktionsregeln dar.

EBNF-Beispiel[1]

```
ZifferAußerNull = "1" | "2" | "3" | "4" | "5"
                | "6" | "7" | "8" | "9" ;
Ziffer          = "0" | ZifferAußerNull ;
NatuerlicheZahl = ZifferAußerNull { Ziffer } ;
GanzeZahl       = "0" | [ "-" ] NatuerlicheZahl ;
```

[1] Erweiterte Backus-Naur-Form. http://de.wikipedia.org/wiki/Erweiterte_Backus-Naur-Form 2011-05-26

Quellen I

- ANSI C Grammar(Yacc).
  `http://www.lysator.liu.se/c/ANSI-C-grammar-y.html`.
  2011-05-26.
- Compiler.
  `http://de.wikipedia.org/wiki/Compiler`.
  2011-05-24.
- Erweiterte Backus-Naur-Form.
  `http://de.wikipedia.org/wiki/Erweiterte_Backus-Naur-Form`.

  2011-05-26.
- Formal grammar.
  `http://en.wikipedia.org/wiki/Formal_grammar`.
  2011-05-26.

Quellen II

- Formale Grammatik.
  `http://de.wikipedia.org/wiki/Formale_Grammatik`.
  2011-05-24.
- Formale Sprache.
  `http://de.wikipedia.org/wiki/Formale_Sprache`.
  2011-05-24.
- GNU compiler collection.
  `http://en.wikipedia.org/wiki/GNU_Compiler_Collection`.
  2011-05-24.
- Keith Cooper and Linda Torczon.
  Engineering a Compiler: International Student Edition.
  Morgan Kaufmann, I.S.ed edition, 12 2003.

Quellen III


Christoph Habel and Matthias Jantzen.
FGI-1: Formale Grundlagen der Informatik.
Universität Hamburg, SoSe 2010.