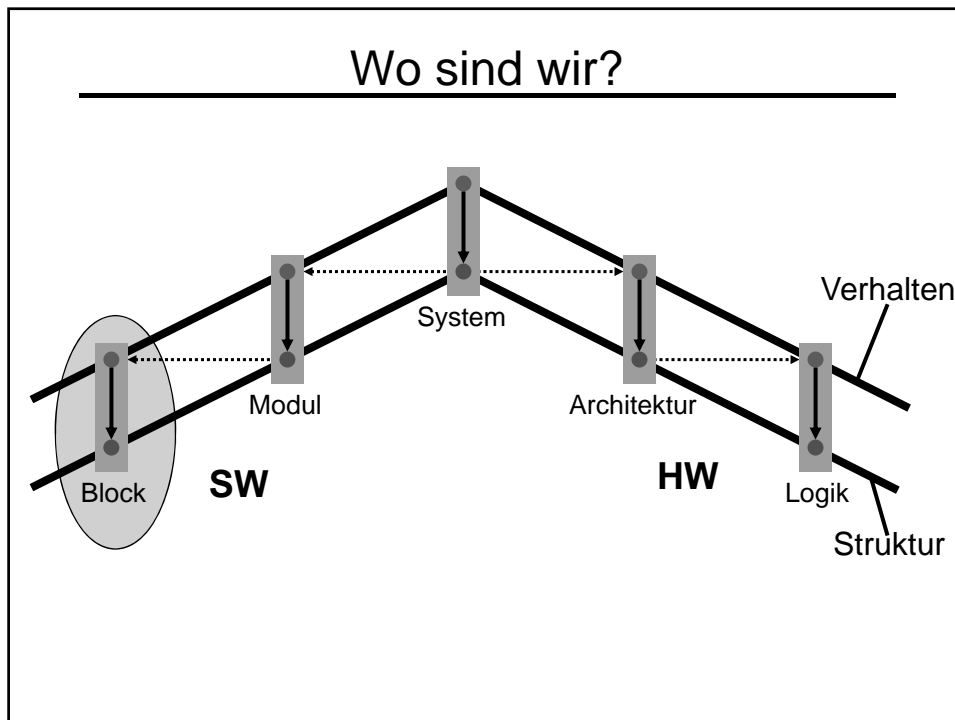


# Compiler und Codegenerierung

Hw-Sw-Co-Design

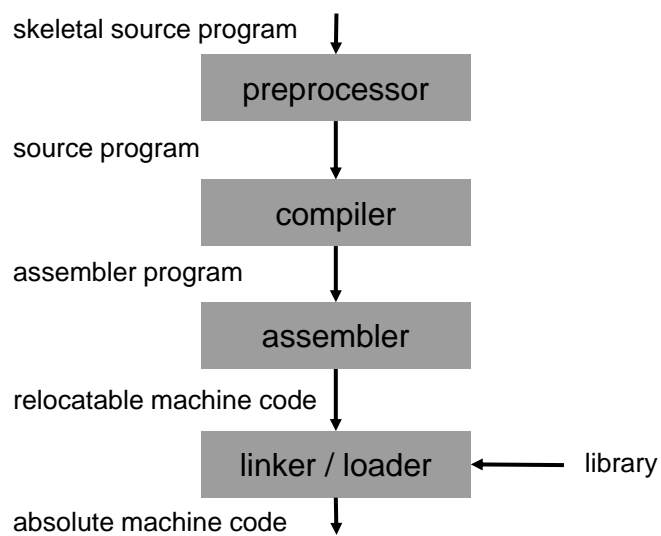


## Compiler und Codegenerierung

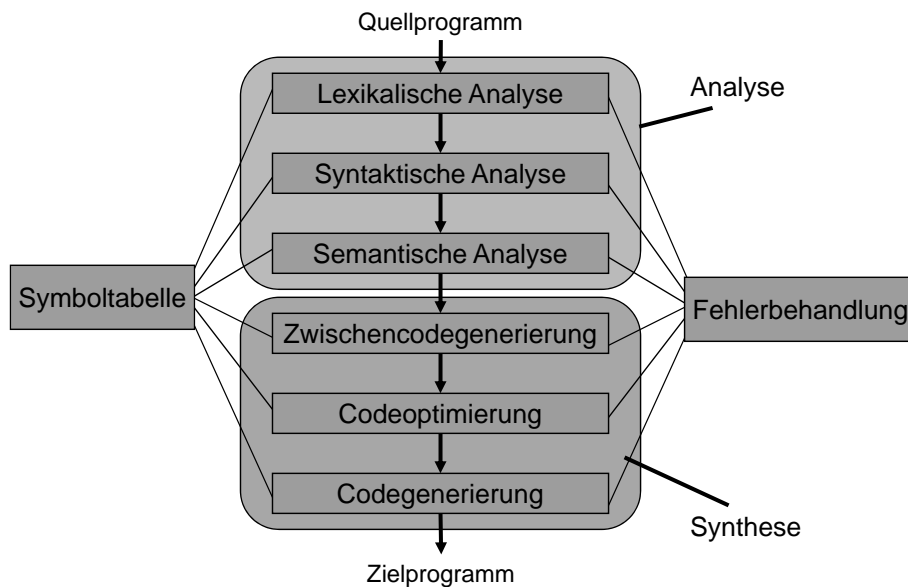
### ➤ Compiler - Aufbau

- Codegenerierung
- Codeoptimierung
- Codegenerierung für Spezialprozessoren
- Retargetable Compiler

## Übersetzungsprozess



## Phasen eines Compilers



## Analyse

### ➤ lexikalische Analyse

- Quellprogramm scannen und in Symbole zerlegen
- reguläre Ausdrücke: Erkennung durch endliche Automaten

### ➤ syntaktische Analyse

- Symbolfolgen parsen und daraus Sätze bilden
- Sätze werden durch eine kontextfreie Grammatik beschrieben

$Z \rightarrow \text{Bezeichner} := A$


$A \rightarrow A + A \mid A * A \mid \text{Bezeichner} \mid \text{Zahl}$

### ➤ semantische Analyse

- sicherstellen, dass die Teile sinnvoll zusammenpassen  
Bsp.: Typumwandlungen


## Beispiel (1)

Quellprogramm ..... **lexikalische Analyse**



## Beispiel (2)

**syntaktische Analyse** ..... **semantische Analyse**



## Beispiel (3)

### Zwischengenerierung

```
tmp1 := IntToReal(60)
tmp2 := id3*tmp1
tmp3 := id2+tmp2
id1 := tmp3
```

### Codeoptimierung

```
tmp1 := id3 * 60.0
id1 := id2 + tmp1
```

### Codegenerierung

```
MOVF id3, R2
MULF #60.0, R2
MOVF id2, R1
ADDF R2, R1
MOVF R1, id1
```

## Synthese


- **Zwischengenerierung**
  - maschinenunabhängig → retargeting einfacher
  - soll leicht erzeugbar sein
  - soll leicht ins Zielprogramm übersetzbar sein
- **Optimierung**
  - GP-Prozessoren: schneller Code, schnelle Übersetzung
  - Spezialprozessoren: schneller Code, kurzer Code, wenig Speicherbedarf
  - Zwischengenerierung und Zielcode optimierbar
- **Codegenerierung**

## Syntaxbaum und DAG

$a := b*(c-d) + e*(c-d)$

Syntaxbaum

DAG (directed acyclic graph)



## 3-Adress-Code (1)

### ➤ 3-Adress-Befehle

- maximal 3 Adressen (2 Operanden, 1 Resultat)
- maximal 2 Operatoren

#### Zuweisungen

```
x := y op z  
x := op y  
x := y
```

```
x := y[i]  
x[i] := y
```

```
x := &y  
y := *x  
*x := y
```

#### Kontrollflussbefehle


```
goto L  
if x relop y goto L
```

#### Unterprogramme

```
param x  
call p,n  
return y
```

## 3-Adress-Code (2)

### ➤ Generierung von 3-Adress-Code



```
t1 := c - d
t2 := e * t1
t3 := b * t1
t4 := t2 + t3
a := t4
```

## 3-Adress-Code (3)

### ➤ Vorteile

- Auflösung langer arithmetischer Ausdrücke und geschachtelter Schleifen
- temporäre Namen erlauben einfache Umordnung von Befehlen
- bereits gültiger Ablaufplan

### ➤ Definition: Ein 3-Adress-Befehl

$$x := y \text{ op } z$$

definiert  $x$  und

verwendet  $y$  und  $z$

## Grundblöcke (1)

---

- **Definition:** Ein Grundblock (basic block) ist eine Folge von fortlaufenden Anweisungen, in die der Kontrollfluss am Anfang eintritt, und die er am Ende verlässt ohne dass er dazwischen anhält oder - außer am Ende - verzweigt.

```
t1 := c - d
t2 := e * t1
t3 := b * t1
t4 := t2 + t3
if t4 < 10 goto L
```

## Grundblöcke (2)

---

- Sequenz von 3-Adress-Befehlen →  
Menge von Grundblöcken:

1. Bestimmung der Blockanfänge

**Blockanfänge sind**

- **der erste Befehl**
- **Ziele von bedingten oder unbedingten Sprüngen**
- **Befehle, die direkt auf bedingte oder unbedingte Sprünge folgen**

2. Bestimmung der Grundblöcke

- **zu jedem Blockanfang gehört ein Grundblock**
- **der Grundblock besteht aus dem Anfang selbst und geht bis zum (exklusive) nächsten Blockanfang oder bis zum Programmende**




## Kontrollflussgraphen

### ➤ entarteter Kontrollflussgraph (CFG)

- die Knoten stellen ganze Grundblöcke dar

```
i := 0
t2 := 0
L t2 := t2 + i
  i := i + 1
  if i < 10 goto L
x := t2
```



## DAG eines Grundblocks

### ➤ Definition: Ein DAG eines Grundblocks ist ein gerichteter azyklischer Graph mit folgender Knotenmarkierung:

- Blätter werden mit einem Variablen/Konstantennamen markiert. Variablen mit Initialwerten bekommen den Index 0.
- Innere Knoten werden mit einem Operatorsymbol markiert. Aus dem Operator kann man bestimmen, ob der Wert oder die Adresse der Variablen verwendet wird.
- Optional kann ein Knoten mit einer Sequenz von Variablennamen markiert werden. Dann wird allen Variablen der berechnete Wert zugewiesen.

## Beispiel (1)

### C Programm

```
int i, prod, a[20], b[20];
...
prod = 0;
i = 0;
do {
    prod = prod + a[i]*b[i];
    i++;
} while (i < 20);
```

### 3-Adress Code


```
(1) prod := 0
(2) i := 0
(3) t1 := 4 * i
(4) t2 := a[t1]
(5) t3 := 4 * i
(6) t4 := b[t3]
(7) t5 := t2 * t4
(8) t6 := prod + t5
(9) prod := t6
(10) t7 := i + 1
(11) i := t7
(12) if i < 20 goto (3)
```

## Beispiel (2)

### Grundblöcke

(1)	prod := 0	B1
(2)	i := 0	
(3)	t1 := 4 * i	B2
(4)	t2 := a[t1]	
(5)	t3 := 4 * i	
(6)	t4 := b[t3]	
(7)	t5 := t2 * t4	
(8)	t6 := prod + t5	
(9)	prod := t6	
(10)	t7 := i + 1	
(11)	i := t7	
(12)	if i < 20 goto (3)	

### Kontrollflussgraph




## Beispiel (3)

Grundblock B2

```
t1 := 4 * i
t2 := a[t1]
t3 := 4 * i
t4 := b[t3]
t5 := t2 * t4
t6 := prod + t5
prod := t6
t7 := i + 1
i := t7
if i < 20 goto (3)
```

DAG für B2



## Compiler und Codegenerierung

- Compiler - Aufbau
- Codegenerierung
- Codeoptimierung
- Codegenerierung für Spezialprozessoren
- Retargetable Compiler

## Codegenerierung

---

### ➤ Anforderungen

- korrekter Code
- effizienter Code
- effiziente Generierung

### ➤ Codegenerierung = Softwaresynthese

- Allokation: meist schon gegeben
- Bindung:
  - Registervergabe, Registerzuweisung
  - Befehlsauswahl
- Ablaufplanung
  - Instruktionsreihenfolge

## Registerbindung

---

### ➤ Ziel: effiziente Nutzung der Register

- Befehle mit Registeroperanden sind i.allg. kürzer und schneller ausführbar als Befehle mit Speicheroperanden

### ➤ Registervergabe, Registerzuweisung

- bestimme für jeden Punkt im Programm die Menge der Variablen, die in Registern gehalten werden sollen
- weise diesen Variablen bestimmte Register zu
- das Finden einer optimalen Zuweisung ist ein NP-vollständiges Problem
- zusätzlich gibt es Vorgaben für die Verwendung von Registern durch Prozessorarchitektur, Compiler, Betriebssystem

## Befehlsauswahl

### ➤ Codemuster für jeden 3-Adress Befehl

$x := y + z$	}	MOV $y, R0$
		ADD $z, R0$
$u := x - w$	}	MOV $R0, x$
		MOV $x, R0$
		SUB $w, R0$
		MOV $R0, u$


### ➤ Probleme

- oft ineffizienter Code generiert → Codeoptimierung
- es kann viele passende Zielinstruktionen geben
- manche Instruktionen nur mit bestimmten Registern möglich
- Ausnutzung von speziellen Prozesseigenschaften  
Bsp.: autoinkrement / dekrement Adressierung

## Ablaufplanung (1)

### ➤ Ziel: effiziente Ausführungsreihenfolge

- möglichst kurz und möglichst wenige Register



## Ablaufplanung (2)

```
t2 := c + d
t3 := e - t2
t1 := a + b
t4 := t1 - t3
```

```
MOV c, R0
ADD d, R0
MOV e, R1
SUB R0, R1
MOV a, R0
ADD b, R0
SUB R1, R0
MOV R0, t4
```

```
t1 := a + b
t2 := c + d
t3 := e - t2
t4 := t1 - t3
```

```
MOV a, R0
ADD b, R0
MOV c, R1
ADD d, R1
MOV R0, t1
MOV e, R0
SUB R1, R0
MOV t1, R1
SUB R0, R1
MOV R1, t4
```

## Maschinenmodell

- $n$  Register  $R0 \dots R_{n-1}$
- Byte-adressierbar, 4 Byte bilden ein Wort
- Instruktionsformat

**op source, destination**

- Bsp.: MOV R0, a  
ADD R1, R0
- jede Instruktion hat Kosten von 1
- Adressen von Speicheroperanden befinden sich in den folgenden Instruktionsworten

## Adressierungsarten

mode	form	address	added cost
absolute	M	M	1
register	R	R	0
indexed	c(R)	c + contents(R)	1
indirect register	*R	contents(R)	0
indirect indexed	*c(R)	contents(c+contents(R))	1
immediate	#c	c	1

## Lebenszeit von Variablen

- **Definition:** Ein Name in einem Grundblock ist aktiv an einem bestimmten Punkt, wenn sein Wert nach diesem Punkt noch verwendet wird (möglicherweise in einem anderen Grundblock).
- **Bestimmung der Lebenszeit**
  1. gehe zum Ende des Grundblocks und notiere, welche Namen am Ausgang aktiv sein müssen
  2. gehe rückwärts zum Blockanfang; für jeden Befehl  
(I)  $x := y \text{ op } z$ 
    - binde die Informationen über  $x$ ,  $y$ ,  $z$  an (I)
    - setze  $x$  auf nicht-aktiv und keine-nächste-Verwendung
    - setze  $y$ ,  $z$  auf aktiv und nächste-Verwendung auf (I)

## Einfacher Codegenerator (1)

---

- aktuelle Stelle einer Variablen  $t$ 
  - Register oder Speicher; wenn  $t$  sowohl in einem Register als auch im Speicher steht, bevorzuge das Register
  
- für jeden 3-Adress-Befehl  $x := y \text{ op } z$ 
  1. bestimme durch  $getreg(x)$  die Stelle  $L$ , wo das Ergebnis  $x$  abgelegt werden soll
  
  2. bestimme  $y'$ , die aktuelle Stelle von  $y$ ; falls  $y'$  nicht  $L$  ist, generiere **MOV  $y'$ ,  $L$**
  
  3. bestimme  $z'$ , die aktuelle Stelle von  $z$ , und generiere **op  $z'$ ,  $L$**

## Einfacher Codegenerator (2)

---

- $L = getreg(x)$  für den Befehl  $x := y \text{ op } z$ 
  1. wenn  $y$  in einem Register  $R$  ist, das sonst keine Variablen hält und  $y$  keine nächste Verwendung hat: return( $R$ )
  
  2. wenn ein leeres Register  $R$  existiert: return( $R$ )
  
  3. wenn  $x$  eine nächste Verwendung hat oder **op** ein Operator ist, der ein Register benötigt (z.Bsp. indirekte Adressierung), finde ein belegtes Register  $R$ , speichere das Register (**MOV  $R$ ,  $M$** ) und return( $R$ )
  
  4. wenn  $x$  nicht mehr im Grundblock benutzt wird oder kein passendes Register gefunden wurde: return( $M_x$ )