Grundlagen des Übersetzerbaus

WS 2014/15

Organisatorisches (1/2)

Bedeutung einiger Folienmarkierungen

- Im Folientitel, z.B.

  Organisatorisches (1/2) — *Erste von zwei Folien zum Thema „Organisatorisches“*

  Organisatorisches (1a/2) — *Zusätzliche Folie zu Folie „Organisatorisches (1/2)“*

- Auf der Folie

  Symbole — *Begriffsdefinition/Begriffsklärung*

   — *(meist ausgeblendete) Folie mit nützlichen Zusatz-Informationen; Bezug zur „Quell-Folie“ über den jeweiligen Folientitel*

  Methoden ☛ — *Begriff der im Folgenden (ggf. auf nachfolgender Folie) näher erläutert wird*

  klassifizieren — *Hyperlink zu Folie, die weitere Informationen zum markierten Begriff enthält*

   — *Hyperlink zu Folie, die weitere Informationen zum nebenstehenden Thema enthält*

Organisatorisches (2/2)

Hauptsächliche Hintergrund-Literatur

- R. Wilhelm, D. Maurer: Übersetzerbau. 2. Aufl. Springer 1997
- A, Aho, S Lam, R. Sethi, J. Ullman: Compiler. 2. Aufl. Pearson Studium 2008
- R. Wilhelm, H. Seidl: Übersetzerbau – Virtuelle Maschinen. Springer 2007

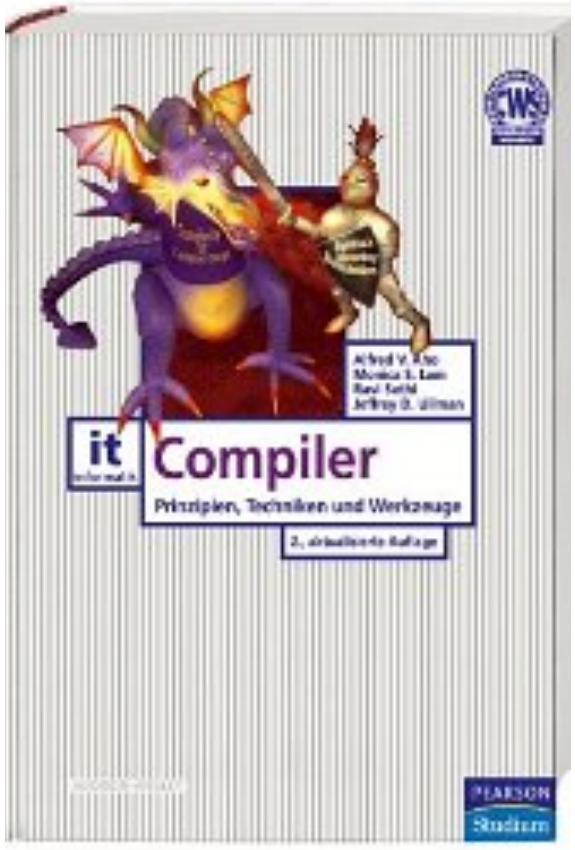

Grundlagen des Übersetzerbaus

Themen

- Grundprinzipien der Sprachübersetzung
- Schwerpunkt: Übersetzung **imperativer** Programmiersprachen

Inhalt (insgesamt)

- Einführung und Motivation
- Kern des Übersetzungsprozesses
- Lexikalische Analyse
- Syntaktische Analyse
- Semantische Analyse
- Codeerzeugung für reale Maschinen

Fortsetzung (im nächsten Semester): Übersetzung anderer Sprachparadigmn

- Funktional
- Logisch
- Objektorientiert

Einführung und Motivation

Inhalt

- Motivation und Begriffsbildungen
- Konzeptionelle Übersetzerteilaufgaben
- Reale Übersetzerstrukturen

Lernziele

- Die Bedeutung des Übersetzerbaus erklären können
- Den zentralen Begriff „Übersetzer“ und damit verwandte Begriffe und ihre jeweiligen Zusammenhänge beschreiben können
- Die prinzipiellen Arbeitsschritte eines Übersetzers wiedergeben können, sowie beschreiben können, wie diese in realen Übersetzern umgesetzt werden

Motivation (1/4)

Prinzipielle Bedeutung des Übersetzerbaus

- Ohne höhere Programmiersprachen und Übersetzer keine „vernünftige“ Kommunikation zwischen Mensch und Rechner

Gilt sinngemäß auch für alternative Kommunikationsformen (z.B. Spracheingabe)

Beispiel: ggt-Algorithmus (in Turbo Pascal)

```
PROGRAM ggt;
var i, j, temp: integer;
BEGIN
   i := 15;   j := 21;
   WHILE (i <> 0) DO
   BEGIN
      IF (i < j) THEN
      BEGIN
         temp := i;
         i := j;
         j := temp;
      END;
          i := i - j;
   END;
   Write ('Größter gemeinsamer Teiler ist ', j);
END.
```

Motivation (2/4)

Beispiel (Forts.)**: ggt-Algorithmus** (in ausführbarem Code, Ausschnitt)

```
00000000:  4D 5A 70 00 06 00 0E 00 06 00 25 04 25 F1 E3 00  ‖  MZp.......%.%ñã.
00000010:  00 40 00 00 20 00 00 00 1C 00 00 00 23 00 00 00  ‖  .@.. .......#...
00000020:  2D 00 00 00 79 00 00 00 E7 00 00 00 EE 00 00 00  ‖  -...y...ç...î...
00000030:  E6 00 00 00 D6 00 00 00 01 00 0A 00 1B 01 0A 00  ‖  æ...Ö...........
00000040:  10 03 0A 00 61 07 0A 00 7C 07 0A 00 C6 07 0A 00  ‖  ....a...|...Æ...
00000050:  A6 07 0A 00 00 00 00 00 00 00 00 00 00 00 00 00  ‖  ¦...............
00000060:  1F 47 72 F6 DF 74 65 72 20 67 65 6D 65 69 6E 73  ‖  .Größter gemeins
00000070:  61 6D 65 72 20 54 65 69 6C 65 72 20 69 73 74 20  ‖  amer Teiler ist
00000080:  DC 00 00 0A 00 55 EB D5 31 2B DC 2D 02 0A 00 C3  ‖  Ü....UëÕ1+Ü-...Ã
00000090:  06 52 00 A4 00 C3 06 54 00 A7 00 E2 3E 52 00 00  ‖  .R.¤.Ã.T.§.â>R..
000000A0:  74 27 ED 52 00 3B 06 54 00 7D 12 ED 52 00 FA 56  ‖  t'íR.;.T.}.íR.úV
000000B0:  00 ED 54 00 FA 52 00 ED 56 00 FA 54 00 ED 52 00  ‖  .íT.úR.íV.úT.íR.
000000C0:  2B 06 54 00 FA 52 00 D9 CA 2B 58 01 1E 57 2B 00  ‖  +.T.úR.ÙÊ+X..W+.
000000D0:  00 0E 57 31 2B 50 DC 70 06 0A 00 ED 54 00 D6 52  ‖  ..W1+PÜp...íT.ÖR
000000E0:  50 31 2B 50 DC B0 06 0A 00 DC A6 05 0A 00 DC E6  ‖  P1+PÜ°...Ü¦...Üæ
000000F0:  02 0A 00 5D 31 2B DC 16 01 0A 00 00 00 00 00 00  ‖  ...]1+Ü.........
00000100:  A6 F8 00 C4 2B EE 06 38 00 33 DD DE DE 08 DE E1  ‖  ¦ø.Ä+î.8.3ÝÞÞ.Þá
00000110:  00 EF 2D 05 13 00 A6 04 CB DE EE CA 03 2D FA 0A  ‖  .ï-...¦.ËÞîÊ.-ú.
00000120:  00 FA 0C 00 03 06 04 00 FA 0E 00 FA 18 00 FA 1C  ‖  .ú......ú..ú..ú.
00000130:  00 FA 24 00 C4 06 38 00 26 ED 02 00 FA 20 00 C3  ‖  .ú$.Ä.8.&í..ú .Ã
00000140:  06 2A 00 CD 00 EE 0E 2C 00 2B 58 02 A5 39 02 A6  ‖  .*.Í.î.,.+X.¥9.¦
00000150:  13 00 C9 B3 2E BC A6 35 2D 21 EB 1D EE 45 02 E2  ‖  ..É³.¼¦5-!ë.îE.â
00000160:  C3 04 D4 B4 1E 0E 1F A6 0C 01 A9 00 25 2D 21 A6  ‖  Ã.Ô´...¦..©.%-!¦
00000170:  13 01 A9 23 25 2D 21 A6 A6 00 A9 24 25 2D 21 A6  ‖  ..©#%-!¦¦.©$%-!¦
00000180:  04 01 A9 3F 25 2D 21 1F A9 58 00 1E 50 1E 50 A9  ‖  ..©?%-!.©X..P.P©
00000190:  63 02 0E 50 0E DE 4E 02 0E DE 2B 02 A9 58 01 1E  ‖  c..P.ÞN..Þ+.©X..
000001A0:  50 1E 50 A9 63 02 0E 50 0E DE 3A 02 0E DE A6 02  ‖  P.P©c..P.Þ:..Þ¦.
000001B0:  2D 33 2B A3 5B C7 FE A4 53 D8 A3 59 C7 D5 AD C7  ‖  -3+£[Çþ¤SØ£YÇÕ-Ç
000001C0:  B2 AD 74 0E 40 C7 A4 AD 53 D8 A3 59 C7 D5 AD 74  ‖  ²-t.@Ç¤-SØ£YÇÕ-t
000001D0:  01 40 F3 4C 00 2B 33 2B 2D 02 00 B9 E2 2D 06 58  ‖  .@óL.+3+-..¹â-.X
000001E0:  E2 FE 1F FC C3 FB 00 C7 B3 39 73 03 2B A0 A0 57  ‖  âþ.üÃû.Ç³9s.+  W
000001F0:  A6 54 2D 21 EF FD C7 4E 16 01 58 5B 59 5A 5E 5F  ‖  ¦T-!ïýÇN..X[YZ^_
00000200:  5D 1F 07 A4 A9 F0 00 E2 2D 06 D9 03 A9 2B 00 59  ‖  ]..¤©ð.â-.Ù.©+.Y
00000210:  5B D9 07 A9 A0 00 33 2B 33 A6 A6 F8 00 C4 2B B9  ‖  [Ù.© .3+3¦¦ø.Ä+¹
00000220:  FA 32 00 EF 2D 0B 2B 74 3D ED 10 00 0B 2B 74 2F  ‖  ú2.ï-.+t=í...+t/
00000230:  C4 2B 26 ED 10 00 0B 2B 74 1B 2B 2B 77 17 B8 CF  ‖  Ä+&í...+t.++w.¸Ï
00000240:  3D 00 10 73 10 A6 10 00 B8 D4 03 2D 72 07 26 3B  ‖  =..s.¦..¸Ô.-r.&;
00000250:  06 08 00 72 06 26 ED B6 00 D9 D0 EF 2B EE 2B 2B  ‖  ...r.&í¶.ÙÐï+î++
00000260:  1E 38 00 E2 D9 10 EB 0E 34 00 EB 1E 36 00 2D 1E  ‖  .8.âÙ.ë.4.ë.6.-.
00000270:  2E 00 FE 2B 0B 2B 74 13 33 2B FA 2E 00 FA 30 00  ‖  ..þ+.+t.3+ú..ú0.
```

Motivation (3/4)

Beispiel (Forts.): ggt-Algorithmus (in Assembler)

```
......
+0000063D.) 55              PUSH     BP
+0000063E.) 8B EC           MOV      BP,SP
+00000640.) C4 5E 06        LES      BX,SS:[BP+06]
+00000643.) B8 BB 05        MOV      AX,05BB
+00000646.) 33 D2           XOR      DX,DX
+00000648.) E8 EE FE        Relative NEAR CALL [CS:-0112] ; LOCAL LABEL AT +00000539
+0000064B.) 75 0A           SHORT    JNE  [+0A]            ; LOCAL LABEL AT +00000657
+0000064D.) 26              ES:
+0000064E.) 83 7F 1A 00     CMP      DS:[BX+1A],00
+00000652.) 74 03           SHORT    JE   [+03]           ; LOCAL LABEL AT +00000657
+00000654.) E8 70 00        Relative NEAR CALL [CS:+0070]  ;LOCAL SUBROUTINE +000006C7
+00000657.) 5D              POP      BP
+00000658.) CA 04 00        FAR      RET 0004
+0000065B.) AC              LODSB
+0000065C.) 3C 0D           CMP      AL,0D
+0000065E.) 74 0C           SHORT    JE   [+0C]           ; LOCAL LABEL AT +0000066C
+00000660.) 3C 1A           CMP      AL,1A
+00000662.) 74 11           SHORT    JE   [+11]           ; LOCAL LABEL AT +00000675
+00000664.) 3B F3           CMP      SI,BX
+00000666.) 75 F3           SHORT    JNE  [-0D]           ; LOCAL LABEL AT +0000065B
+00000668.) B8 BB 05        MOV      AX,05BB
+0000066B.) C3              NEAR     RET
+0000066C.) 3B F3           CMP      SI,BX
+0000066E.) 74 09           SHORT    JE   [+09]           ; LOCAL LABEL AT +00000679
+00000670.) AC              LODSB
+00000671.) 3C 0A           CMP      AL,0A
+00000673.) 74 01           SHORT    JE   [+01]           ; LOCAL LABEL AT +00000676
+00000675.) 4E              DEC      SI
+00000676.) 33 C0           XOR      AX,AX
+00000678.) C3              NEAR     RET
+00000679.) B8 D0 05        MOV      AX,05D0
.....
```

Motivation (4/4)

Warum ist Übersetzerbau (auch heute noch) wichtig?

- Etablierte, ausgereifte Teildisziplin der Informatik („Grundlagenwissen“)
- Breiter Anwendungsbereich für Übersetzerbau-Knowhow
  (z.B. Bau von Software-Werkzeugen)
- Paradebeispiel für erfolgreiches Software Engineering
  - Nahezu vollständige, *theoretische Durchdringung* des Problembereichs und potenzieller Lösungsmöglichkeiten
  - Für jede der Teilaufgaben (eines Übersetzers)
    - problemadäquate Beschreibungsmittel
      Formalisierung der Problemstellung
    - Werkzeuge zur automatischen Umsetzung der Beschreibungen in Programme
      Generierung von Programmen aus Formalisierungen
  - Konsequente *Strukturierung* (modularer Aufbau von Übersetzern entsprechend Teilaufgaben)

Aufwand 1957: 18 PJ
(für 1. FORTRAN-Compiler)
Aufwand heute: ≤ 1 PJ
(für vergleichbaren Compiler)

Einführung: Übersetzer

Begriffsbildungen (vorläufig)

- **Übersetzer**: Programm zur (semantiktreuen) Umsetzung
  (höhere) Programmiersprache ➔ Maschinensprache, d.h. Abbildung $Ü_L$: L → M

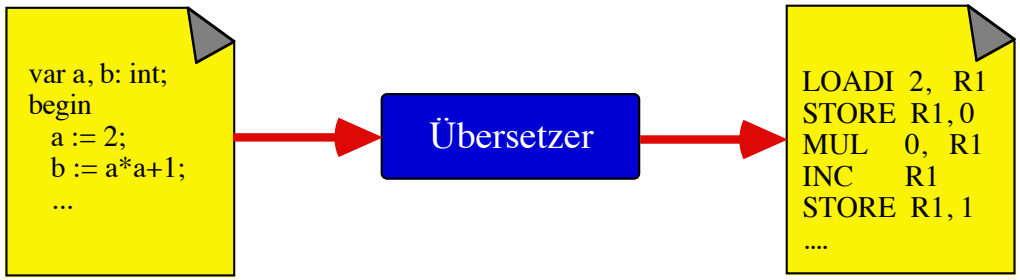

  - Imperativ: „zustandsorientiert“; Variablen + Anweisungen als wesentliche Konzepte entspricht Speicherzellen und deren Veränderung
  - Objektorientiert: „zustandsorientiert“; Objekte + Botschaften als wesentliche Konzepte
  - Funktional: „wertorientiert“ (nur Ausdrücke); üblicher Ausführungsmechanismus: **Reduktion**
  - Logisch: operationelle Sicht der Prädikatenlogik; Ausführungsmechanismus: **Resolution**
  - Spezielle Sprachen (z.B. Hardwarebeschreibung, Graphik- und Textverarbeitung)

Ersetzung von Ausdrücken durch Werte

Formel A *folgt aus Menge von Formeln* P ⇔ P ∪ {¬ A} *ist widerspruchsvoll*

- **Übersetzerbau**: Formalismen, Methoden, Werkzeuge zur systematischen Erstellung von Übersetzern

Interpreter und Übersetzer

Basis für Korrektheitsüberlegungen

Universeller Interpreter: $I_u: S \times L \times D^* \rightarrow D^* \cup \{error\}$

Beispiel
f(x, y) = x + y
f‘(y) = 1+ y
f‘(y) = f(1, y)

Partielle Auswertung: $I_L = I_u(b_L)$

Beispiel
$f(x, y) = x^4 + x^2 + y$
$f‘(x) = x^2$,
$f“(x, y) = x^2 + x + y$
$f(x, y) = f‘ \circ f“ = f“(f‘(x), y)$

Funktionsaufspaltung: $I_u = Ü_u \circ I_m$

Sprachspezifischer Interpreter: $I_L: L \times D^* \rightarrow D^* \cup \{error\}$
Korrektheit: $I_L(p_L, e) = I_u(b_L, p_L, e)$

Universeller Übersetzer: $Ü_u: S \times L \rightarrow M$
Maschinen-Interpreter: $I_M: M \times D^* \rightarrow D^* \cup \{error\}$
Korrektheit: $I_M(Ü_u(b_L, p_L), e) = I_u(b_L, p_L, e)$

Currying: $Ü_u \cong ÜG_L$

$A \times B \rightarrow C \cong A \rightarrow (B \rightarrow C)$

Übersetzer-Generator: $ÜG_L: S \rightarrow (L \rightarrow M)$
Korrektheit: $ÜG_L(b_L)(p_L) = Ü_u(b_L, p_L)$

Auswertung

Sprachspezifischer Übersetzer: $Ü_L: L \rightarrow M$
Korrektheit: $Ü_L(p_L) = ÜG_L(b_L)(p_L)$

Insgesamt: $I_M(Ü_L(p_L), e) = I_u(b_L, p_L, e)$

Interpreter

Übersetzer

S	*Menge von Sprachdefinitionen*
L	Menge der *„Quellsprachen“-Programme*
M	Menge der *„Zielsprachen“-Programme*
$b_L \in S$	*Beschreibung von* L
$b_M \in S$	*Beschreibung von* M
$p_L \in L$	*Quellsprachenprogramm*
$p_M \in M$	*Maschinenprogramm*
D	*Datenbereich*
$e \in D^*$	*Eingabe*
error	*Sonderelement*

Struktur von Übersetzern (1/2)

Bisher vereinfacht

- Übersetzer = Abbildung: $Ü_L$: L → M

d.h. $p_L \in L$ *als gültiges Programm, d.h. als syntaktisch und kontext-korrekt vorausgesetzt*

Tatsächlich

- Eingabe: Folge von Zeichen über Eingabezeichenvorrat V
  (von der festgestellt werden muss, ob sie ein „gültiges“ Programm der Programmiersprache ist)
- Ausgabe: Folge von Zeichen über einem Ausgabezeichenvorrat W
  (die ggf. in bestimmter Weise in der Maschinensprache formatiert sein muss)

Übersetzer

- Komplexe Funktion Ü: V* → W*
- Bewältigung der Komplexität: Strukturierung durch Funktionsaufspaltung
  $Ü = Ü_E \circ Ü_L \circ Ü_A$ mit $Ü_E$: V* → L und $Ü_A$: M → W*
  - Geringere Komplexität der Teilfunktionen
  - Individuelle Behandlung der Teilfunktionen

Struktur von Übersetzern (2/2)

Übersetzer als Bestandteil eines sprachverarbeitenden Systems

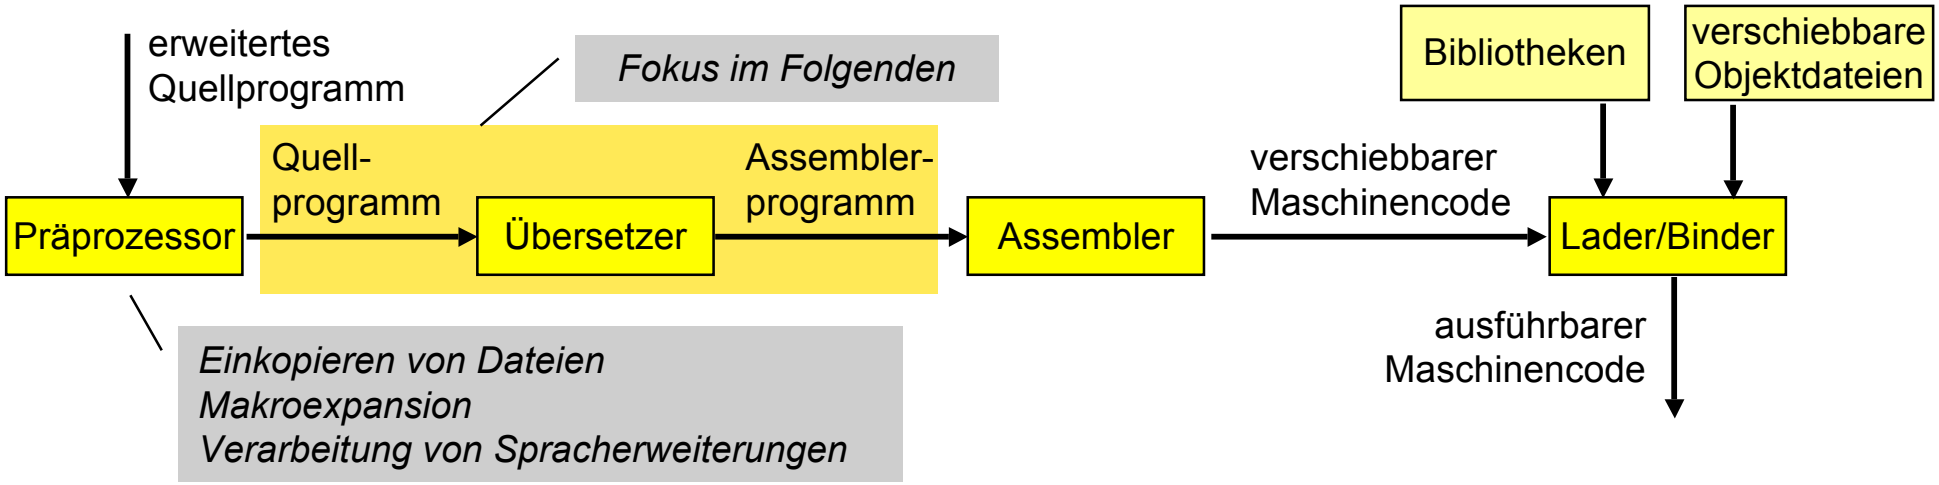

Grobstruktur eines Übersetzers

Darstellung des Programms in „Zwischensprache“

Übersetzer = Analyse + Synthese

Reduktion des Quellsprachenprogramms auf seine semantische „Substanz“

Darstellung der semantischen „Substanz“ in anderer Form (Maschinenprogramm)

„frontend“ „backend“

Konzeptionelle Übersetzerteilaufgaben

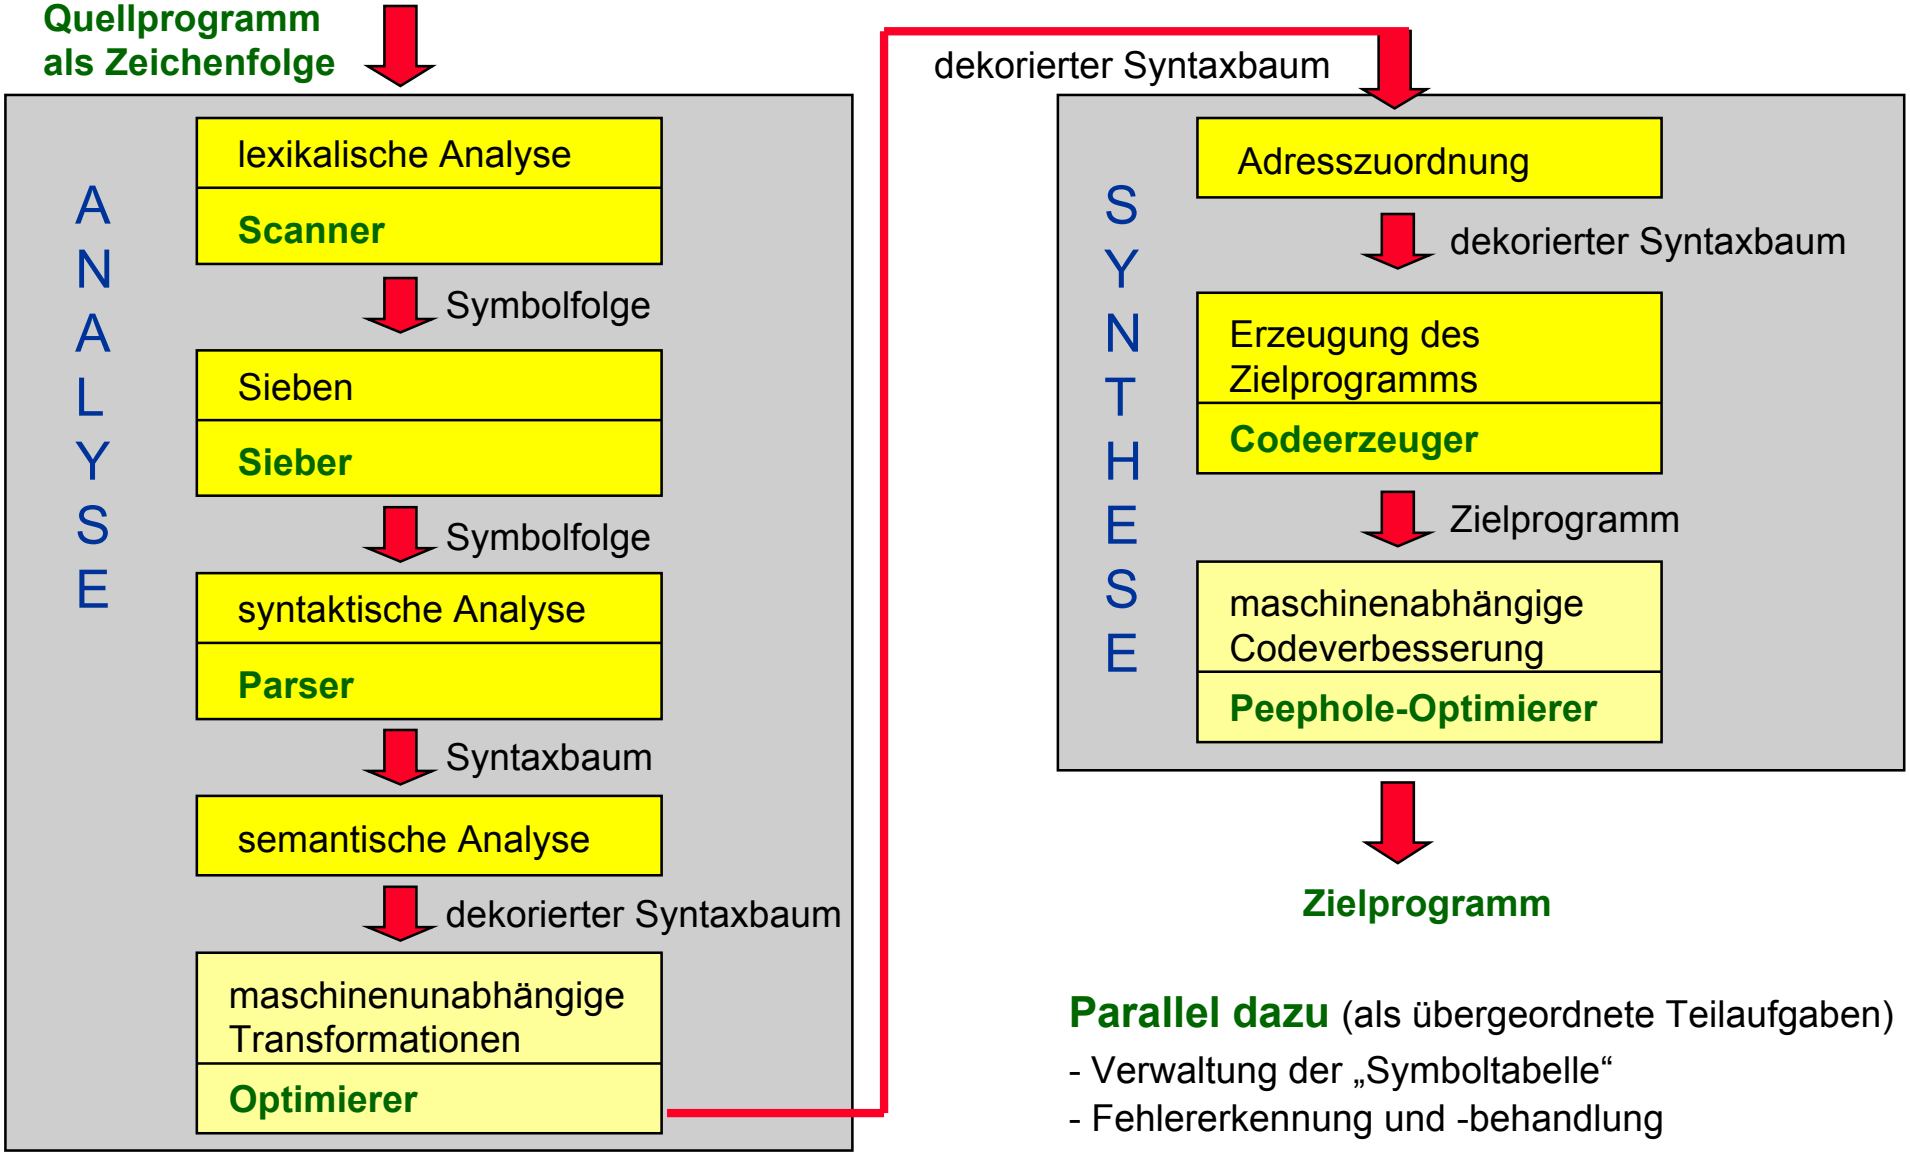

Parallel dazu (als übergeordnete Teilaufgaben)

- Verwaltung der „Symboltabelle“
- Fehlererkennung und -behandlung

Lexikalische Analyse

Scanner-Aufgaben

- Quellprogramm als Zeichenfolge lesen

Beachte: Symbol ≠ Zeichen

- Zeichenfolge in lexikalische Einheiten („Symbole“) zerlegen, z.B.
  - Bezeichner (id)
  - Zahldenotationen (int)
  - Separatoren (z.B. Zwischenraum, neue Zeile)
  - Sonderzeichen(-Kombinationen) (com, col, sem, bec, mul, add)

Sieber-Aufgaben

- Besondere Symbole erkennen (und „verarbeiten“), z.B.
  - Übersetzer-Direktiven, Schlüsselwörter
  - Überflüssige Symbole (z.B. Kommentare, Folgen von Leerzeichen)
- Symbole bestimmter Symbolklassen (z.B. id) eindeutig codieren + durch Code ersetzen

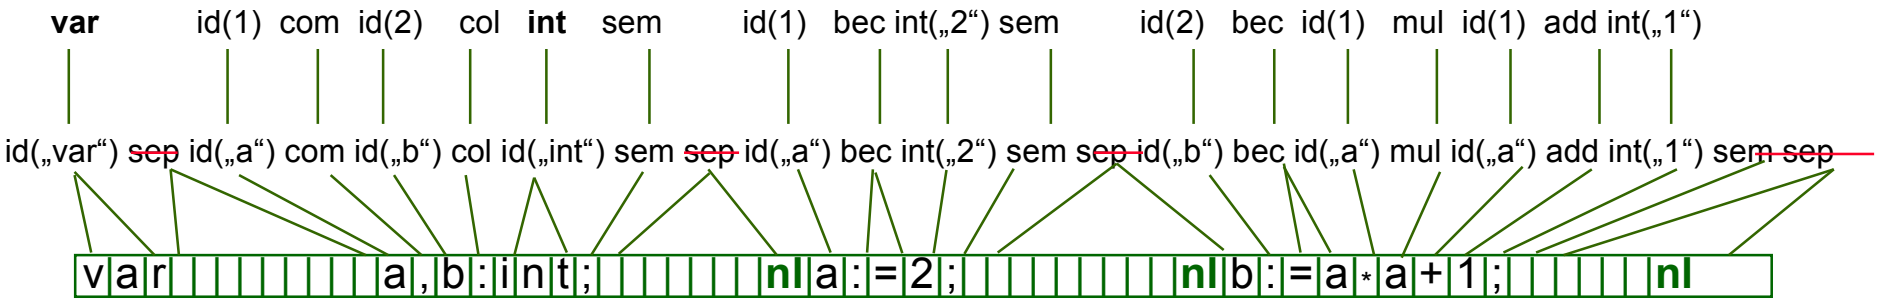

Parser-Aufgaben

- *Struktur* des Programms (entsprechend Grammatik) ermitteln
- Gegebenenfalls Fehler erkennen, lokalisieren und diagnostizieren

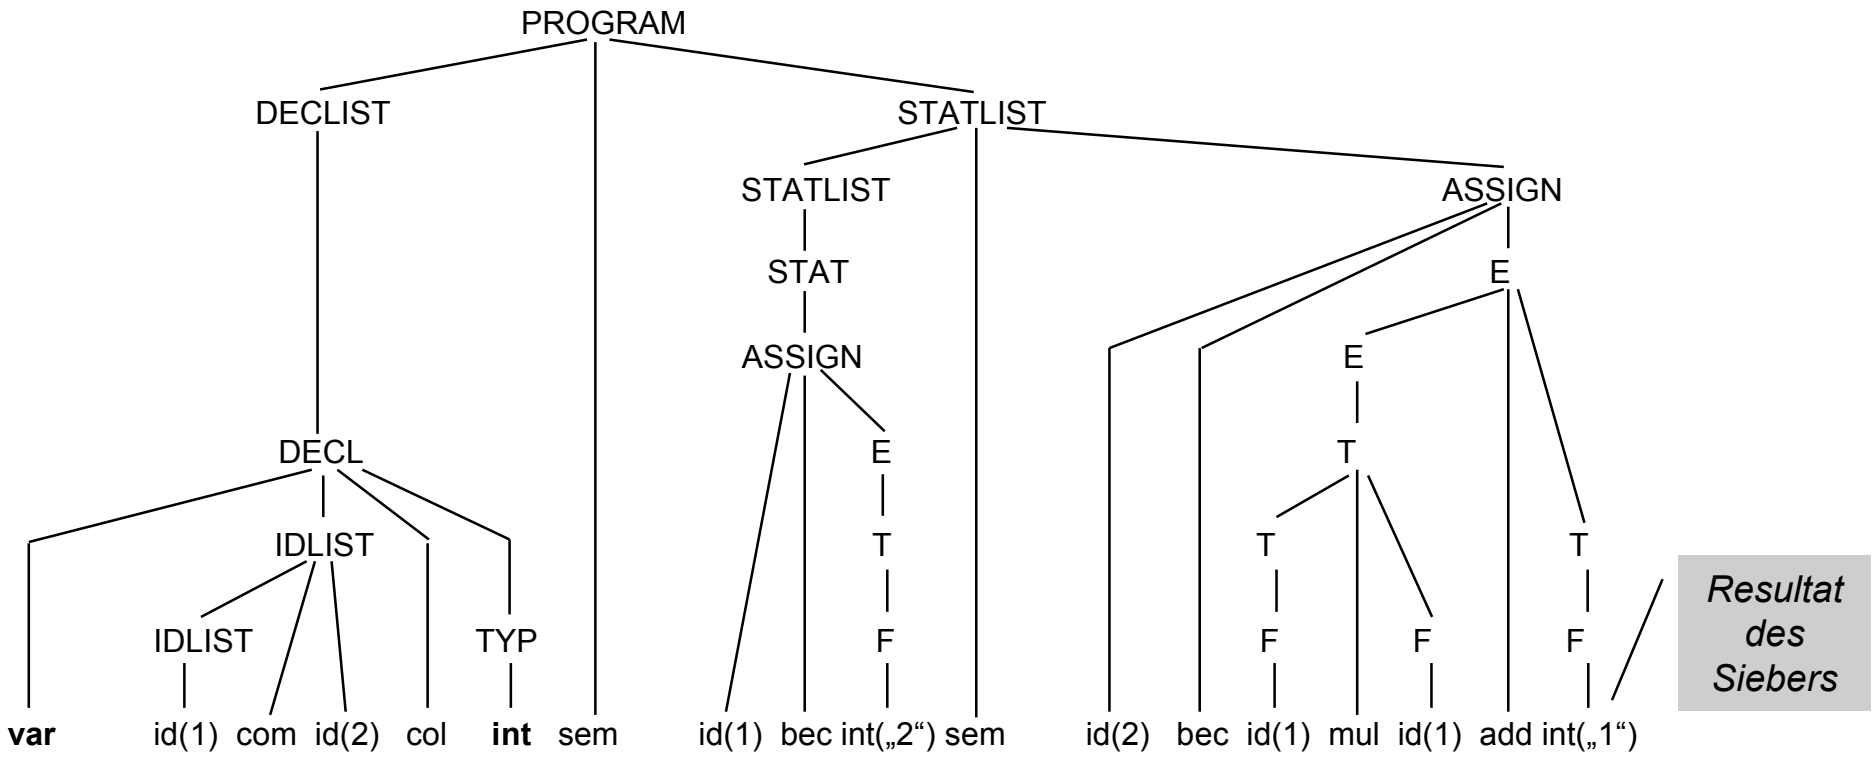

Semantische Analyse

Aufgabe

- Ermittlung von *statischen semantischen Eigenschaften* ☛
  (= Eigenschaften, die über kontextfreie Eigenschaften hinausgehen, aber statisch bestimmt werden können, z.B. *Typisierung* ☛ und *Typkorrektheit* ☛)

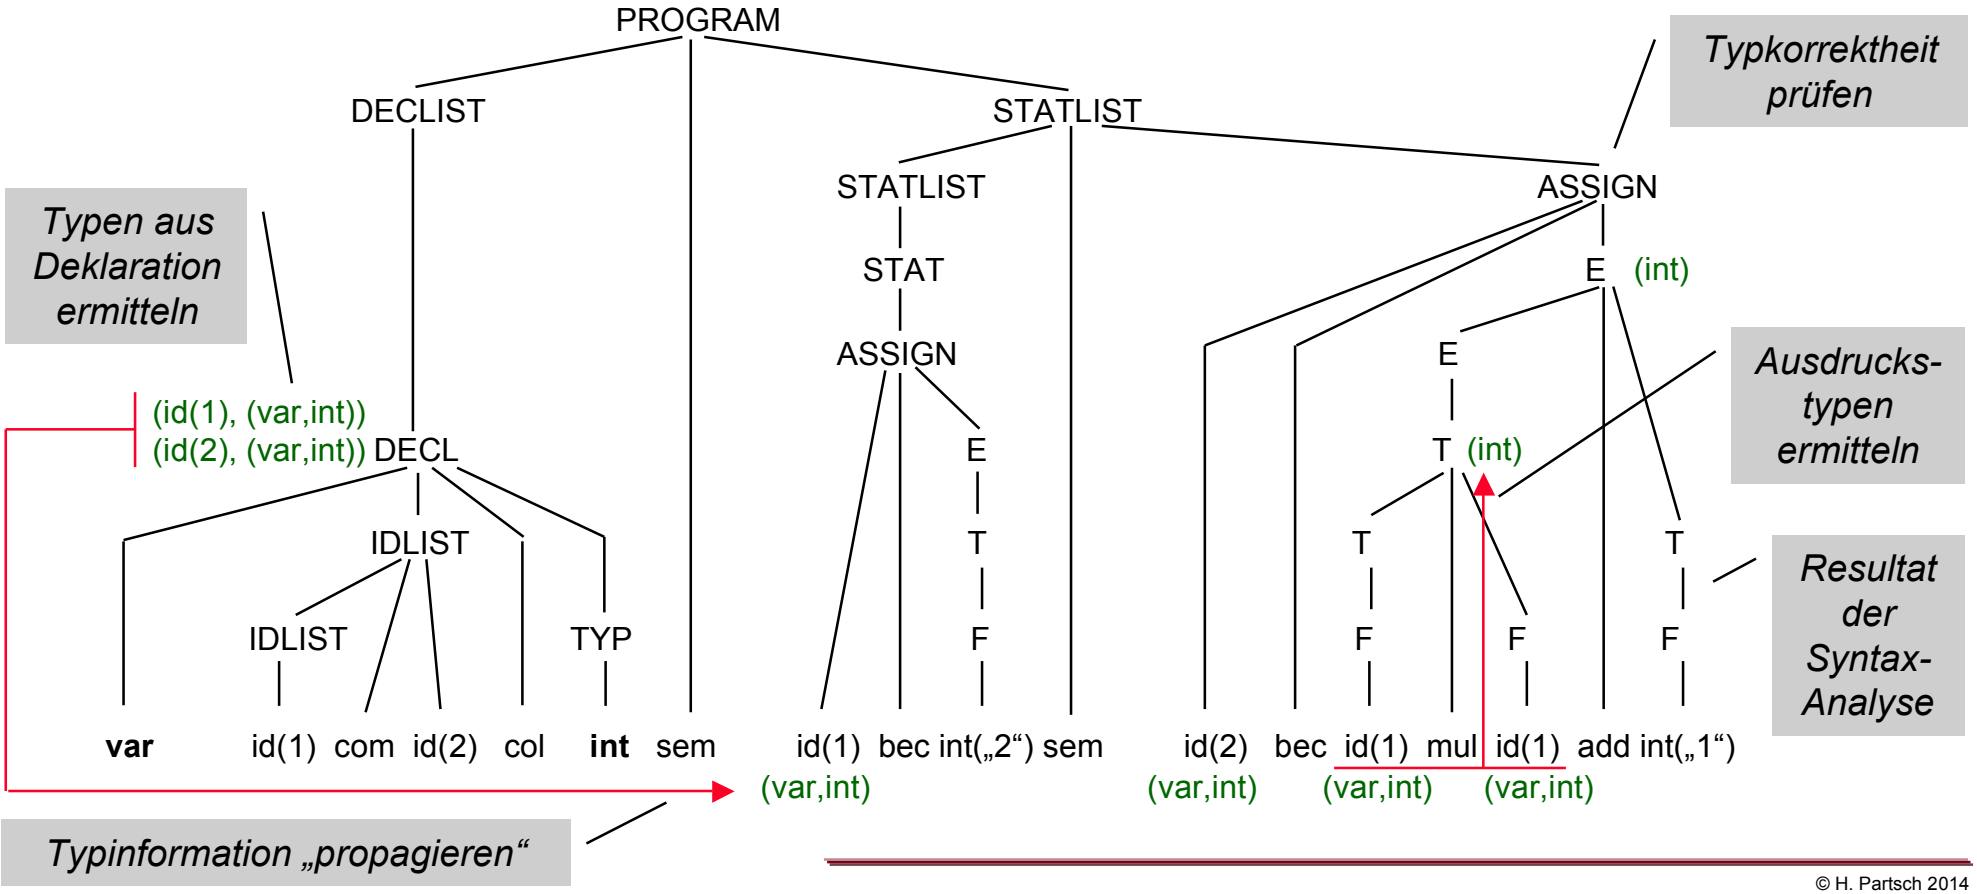

Maschinenunabhängige Optimierung

Optimierer-Aufgaben

- Weitere statische Analysen (durch *Datenflussanalyse* oder *abstrakte Interpretation*) hinsichtlich eventueller Laufzeitfehler (z.B. Verwendung uninitialisierter Variablen)
- Effizienzsteigernde *Programmtransformationen* ☛, z.B.
  - Konstantenpropagation
  - Konstantenfalten
  - Herausziehen schleifeninvarianter Berechnungen
  - Elimination von redundanten Berechnungen und „totem Code“

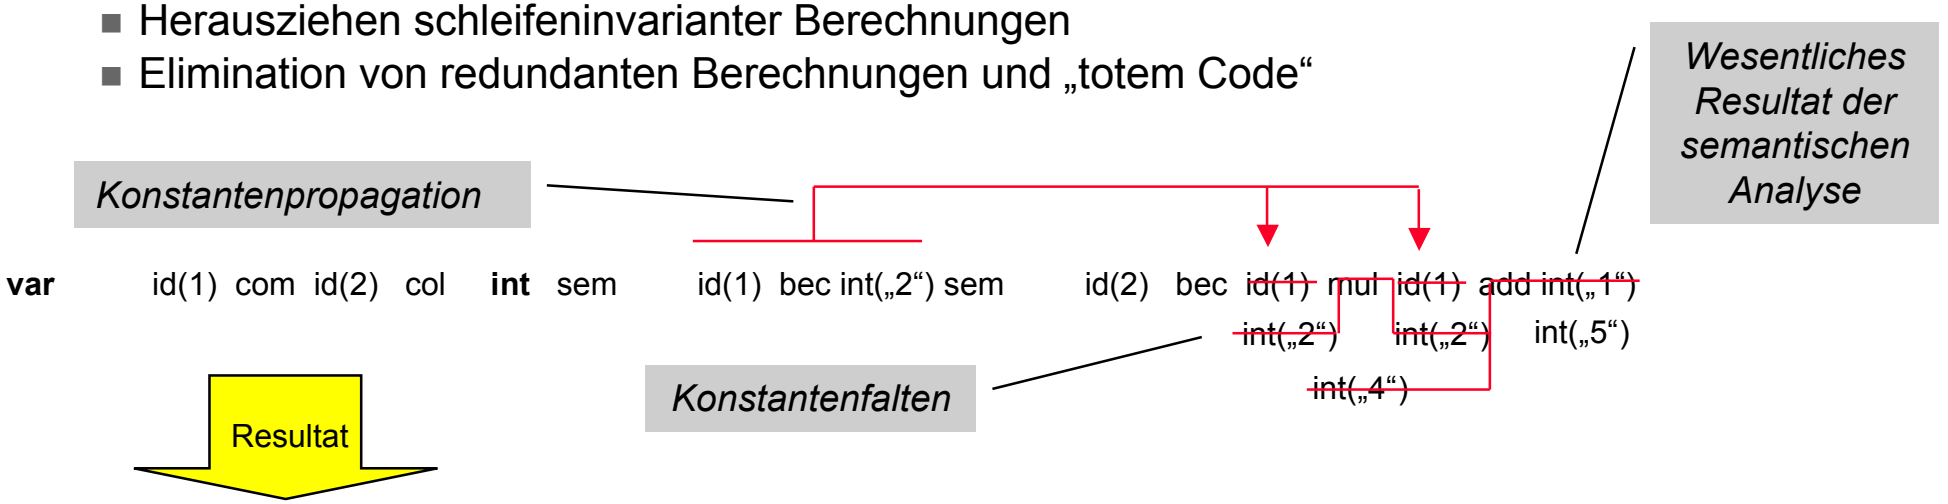

Adresszuordnung

Aufgabe

- Zuordnung von Variablen elementarer Typen zu Speichereinheiten (Relativadressen) unter Verwendung von Eigenschaften der Zielmaschine (z.B. Wort-, Adresslänge, Befehlsvorrat)

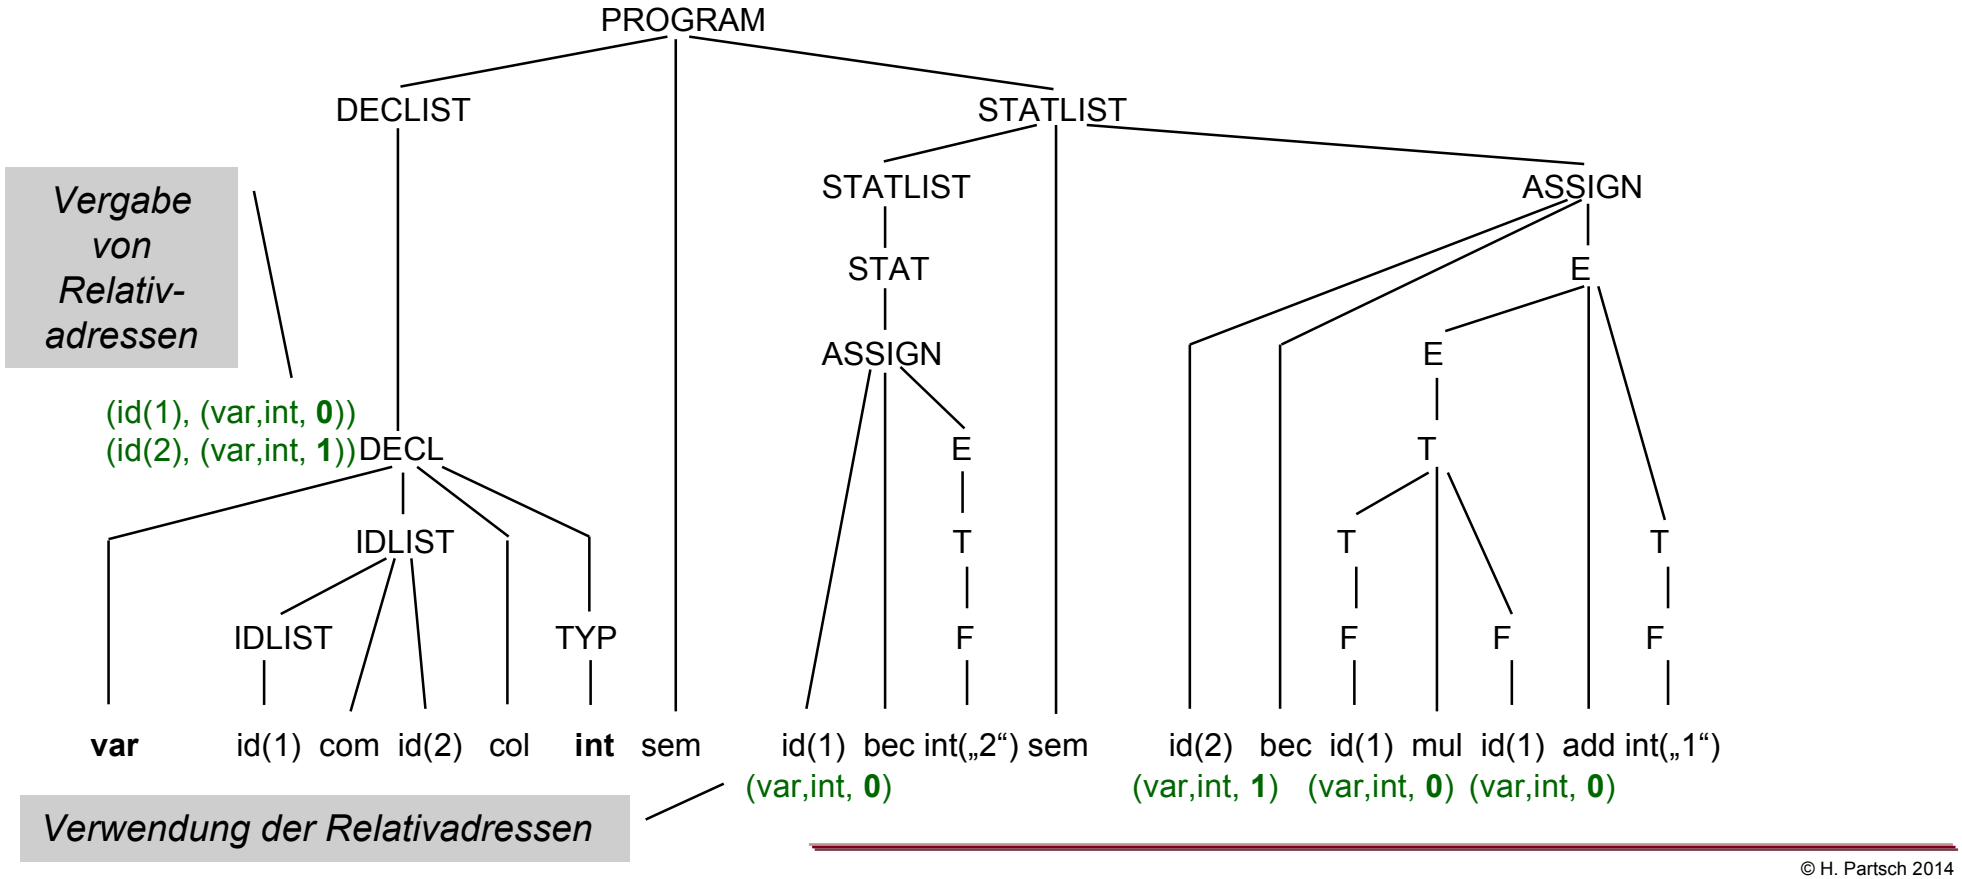

Erzeugung des Zielprogramms

Codeerzeuger-Aufgaben

- Generierung der Befehle des Zielprogramms
- *Registerzuteilung* ☛ (Kriterium: Effizienz + Ökonomie)
- *Codeselektion* ☛ (Auswahl „guter“ Befehlsfolgen)

Resultat der Adressvergabe

var id(1) com id(2) col **int** sem id(1) bec int(„2“) sem id(2) bec id(1) mul id(1) add int(„1“)

(var,int, **0**) (var,int, **1**) (var,int, **0**) (var,int, **0**)

```
LOADI   2, R1
STORE   R1, 0

LOAD    0, R1
MUL     0, R1

ADDI    1, R1

STORE   R1, 1
```

Maschinenbefehle

LOAD	*adr*, *reg*	lade Inhalt von Zelle mit Adresse *adr* in Register *reg*
STORE	*reg*, *adr*	speichere Inhalt von Register *reg* in Zelle *adr*
LOADI	*int*, *reg*	lade Konstante *int* in Register *reg*
ADDI	*int*, *reg*	addiere Konstante *int* zum Inhalt von Register *reg*
MUL	*adr*, *reg*	multipliziere Inhalt von Register *reg* mit Inhalt von Zelle mit Adresse *adr*

Maschinenabhängige Codeverbesserung

Maschinenabhängige Codeverbesserung („Peephole-Optimierung“)

- *Maschinenabhängige* Codeverbesserung braucht nur *lokale Information*
- Maschinenunabhängige Codeverbesserung verwendet meist *globale Information*

Wichtigste Aufgaben

- Überflüssige Befehle eliminieren
- Allgemeine Befehle durch effizientere ersetzen

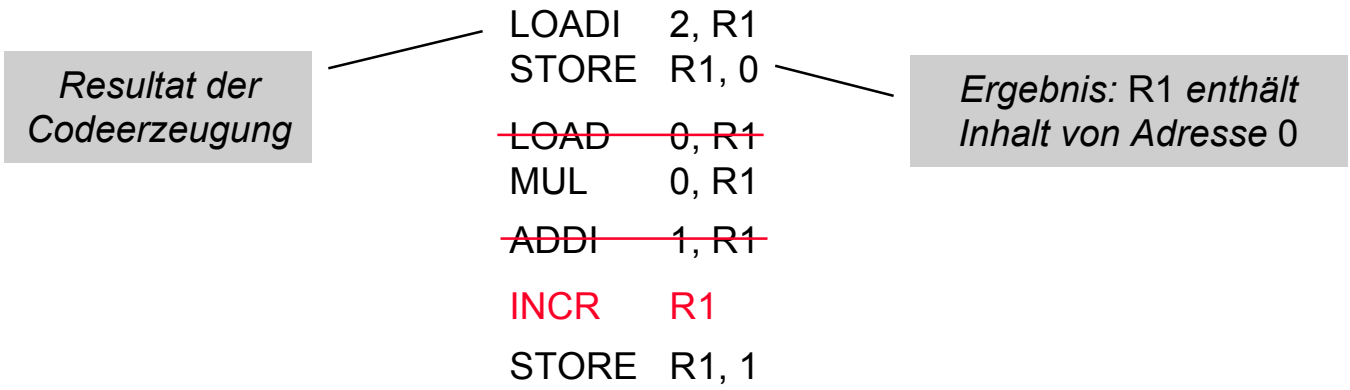

Reale Übersetzerstrukturen

Eigenschaften der konzeptionellen Struktur

- Gliederung des Übersetzungsprozesses in eine *Folge von Teilprozessen*
- *Zwischendarstellungen* durch Mechanismen aus der Theorie der formalen Sprachen
- *Aufteilung der Teilprozesse* basiert auf
  - Pragmatischen Überlegungen
  - Korrespondenzen zwischen Beschreibungsmechanismen und Automatenmodellen

In realen Übersetzern

- *Zusammenlegen von Teilaufgaben* (z.B. Scanner + Sieber)
- *„verschränkte" Arbeitsweise* (z.B. Parser ruft Scanner + semantische Routinen auf)
- Vorteil: Aufbau und Speicherung von Zwischenformen kann entfallen

Unterscheidung von Übersetzern nach ihrer (realen) Struktur

- **Einpass-Übersetzer** (nur ein Durchlauf durch das Quellprogramm)
  alle Teilaufgaben durch Unterprogramme zum Parser erledigt (z.B. Pascal-Übersetzer)
- **Mehrpass-Übersetzer** (z.B. Algol 68- oder Ada-Übersetzer)
  pro Pass eine oder mehrere Teilaufgaben (verbunden über Zwischenformen)

Generierung von Übersetzerbestandteilen

Formale Spezifikation und Generierung

- (einige) Übersetzerteilaufgaben sind *Erkennungsprobleme* für gewisse Typen von Grammatiken und können durch entsprechende Automaten erledigt werden
  - Grammatiken sind die formale Spezifikation
  - Automaten sind (aus der Spezifikation) automatisch erzeugbar („Übersetzergenerierung“)

Übersetzerteilaufgaben	Spezifikationsmechanismen	Automatentyp
lexikalische Analyse	reguläre Ausdrücke	determ. endl. Automaten
syntaktische Analyse	kontextfreie Grammatiken	determ. Kellerautomaten
semantische Analyse	Attributgrammatiken	
effizienzsteigernde Transformationen	Baum-zu-Baum-Transformationen	endliche Baumtransduktoren
Codeselektion in der Codeerzeugung	reguläre Baumgrammatiken	endliche Baumautomaten