

Prinzipien von Programmiersprachen Vorlesung Wintersemester 2007, 2008, 2009

Johannes Waldmann, HTWK Leipzig

4. Februar 2010

1 Einleitung

Inhalt

(aus Sebesta: Concepts of Programming Languages)

- (3) Beschreibung von Syntax und Semantik
- (5) Namen, Bindungen, Sichtbarkeiten
- (6) Datentypen
- (7) Ausdrücke und Zuweisungen, (8) Anweisungen und Ablaufsteuerung, (9) Unterprogramme
- (11) Abstrakte Datentypen, (12) Objektorientierung
- (13) Nebenläufigkeit, (14) Ausnahmenbehandlung
- (15) Funktionale Programmierung, eingebettete domainspezifische Sprachen

Organisation

- Vorlesung
 - mittwochs 13:45–15:15, u : Li 207, g: G 121
- Übungen (alle Z 423)
 - Do (u) 13:45 + Fr (g) 11:15
 - Fr (u) 11:15 + Fr (g) 9:30

– Mi (u) 15:30 + Fr (g) 13:45

Übungsgruppe wählen: <https://autotool.imn.htwk-leipzig.de/cgi-bin/Super.cgi>

Literatur

- <http://www.imn.htwk-leipzig.de/~waldmann/edu/ws09/pps/folien/pps/>
- Robert W. Sebesta: Concepts of Programming Languages, Addison-Wesley 2004
siehe auch <ftp://ftp.aw.com/cseng/authors/sebesta/concepts7e>

Übungen

1. Anwendungsgebiete von Programmiersprachen, wesentliche Vertreter
zu Skriptsprachen: finde die Anzahl der "*.java"-Dateien unter \$HOME/workspace,
die den Bezeichner String enthalten. (Benutze eine Pipe aus drei Unix-Kommandos.)

Lösungen:

```
find workspace/ -name "*.java" | xargs grep -l String | wc -l  
find workspace/ -name "*.java" -exec grep -l String {} \; | wc -l
```

2. Maschinenmodelle (Bsp: Register, Turing, Stack, Funktion)

funktionales Programmieren in Haskell (siehe <http://www.haskell.org/>)

```
bash  
export PATH=/home/waldmann/built/bin:$PATH  
ghci  
:set +t  
length $ takeWhile (== '0') $ reverse $ show $ product [ 1 .. 100 ]
```

Kellermaschine in PostScript.

```
42 42 scale 7 9 translate .07 setlinewidth .5 setgray/c{arc clip fill  
setgray}def 1 0 0 42 1 0 c 0 1 1{0 3 3 90 270 arc 0 0 6 0 -3 3 90 270  
arcn 270 90 c -2 2 4{-6 moveto 0 12 rlineto}for -5 2 5{-3 exch moveto  
9 0 rlineto}for stroke 0 0 3 1 1 0 c 180 rotate initclip}for showpage
```

Mit gv oder kghostview ansehen (Options: watch file). Mit Editor Quelltext ändern.
Finden Sie den Autor dieses Programms!

(Lösung: John Tromp, siehe auch <http://www.iwriteiam.nl/SigProgPS.html>)

Ausführungsarten

Anweisungen der Quellsprache werden in Anweisungen der Zielsprache übersetzt.
(Bsp: Quelle: C, Ziel: Prozessor)

- interpretieren: jeden einzelnen Befehl: erst übersetzen, dann ausführen.
Bsp: Skriptsprachen
- compilieren: erst gesamtes Programm übersetzen, dann Resultat ausführen
Bsp: C, Fortran
- Mischformen: nach Zwischensprache compilieren, diese dann interpretieren.
Bsp: Pascal (P-Code), Java (Bytecode), C# (CIL)

Struktur eines Übersetzers

- (Quelltext, Folge von Zeichen)
- lexikalische Analyse (→ Folge von Token)
- syntaktische Analyse (→ Baum)
- semantische Analyse (→ annotierter Baum)
- Zwischencode-Erzeugung (→ Befehlsfolge)
- Code-Erzeugung (→ Befehlsfolge in Zielsprache)
- Zielmaschine (Ausführung)

Übung: Beispiele für Übersetzer

Java:

```
javac Foo.java # erzeugt Bytecode (Foo.class)
java Foo      # führt Bytecode aus (JVM)
```

Einzelheiten der Übersetzung:

```
javap -c Foo # druckt Bytecode
```

C:

```
gcc -c bar.c # erzeugt Objekt (Maschinen)code (bar.o)
gcc -o bar bar.o # linkt (lädt) Objektcode (Resultat: bar)
./bar # führt gelinktes Programm aus
```

Einzelheiten:

```
gcc -S bar.c # erzeugt Assemblercode (bar.s)
```

Aufgaben:

- geschachtelte arithmetische Ausdrücke in Java und C: vergleiche Bytecode mit Assemblercode
- vergleiche Assemblercode für Intel und Sparc (einloggen auf goliath, dann gcc wie oben)

gcc für Java (gcj):

```
gcj -c Foo.java # erzeugt Objektcode  
gcj -o Foo Foo.o --main=Foo # linken, wie oben
```

- Assemblercode ansehen, vergleichen

```
gcj -S Foo.java # erzeugt Assemblercode (Foo.s)
```

- Kompatibilität des Bytecodes ausprobieren zwischen Sun-Java und GCJ (beide Richtungen)

```
gcj -C Foo.java # erzeugt Class-File (Foo.class)
```

2 Syntax von Programmiersprachen

Daten-Repräsentation im Compiler

- Jede Compiler-Phase arbeitet auf geeigneter Repräsentation ihre Eingabedaten.
- Die semantischen Operationen benötigen das Programm als Baum (das ist auch die Form, die der Programmierer im Kopf hat).
- In den Knoten des Baums stehen Token,
- jedes Token hat einen Typ und einen Inhalt (eine Zeichenkette).

Token-Typen

Token-Typen sind üblicherweise

- reservierte Wörter (if, while, class, ...)
- Bezeichner (foo, bar, ...)
- Literale für ganze Zahlen, Gleitkommazahlen, Strings, Zeichen
- Trennzeichen (Komma, Semikolon)
- Klammern (runde: paren(these)s, eckige: brackets, geschweifte: braces) (jeweils auf und zu)
- Operatoren (=, +, &&, ...)

Formale Sprachen

- ein *Alphabet* ist eine Menge von Zeichen,
- ein *Wort* ist eine Folge von Zeichen,
- eine *formale Sprache* ist eine Menge von Wörtern.

Beispiele

- Alphabet $\Sigma = \{a, b\}$,
- Wort $w = ababaaab$,
- Sprache $L =$ die Menge aller Wörter über Σ gerader Länge.

Formale Sprachen: Chomsky-Hierarchie

- (Typ 0) aufzählbare Sprachen (beliebige Grammatiken, Turingmaschinen)
- (Typ 1) kontextsensitive Sprachen (monotone Grammatiken, linear beschränkte Automaten)
- (Typ 2) kontextfreie Sprachen (kontextfreie Grammatiken, Kellerautomaten)
- (Typ 3) reguläre Sprachen (rechtslineare Grammatiken, reguläre Ausdrücke, endliche Automaten)

Tokenklassen sind meist reguläre Sprachen.

Programmiersprachen werden kontextfrei beschrieben (mit Zusatzbedingungen).

Grammatiken

Grammatik G besteht aus:

- Terminal-Alphabet Σ
(üblich: Kleibuchst., Ziffern)
- Variablen-Alphabet V
(üblich: Großbuchstaben)
- Startsymbol $S \in V$
- Regelmenge
(Wort-Ersetzungs-System)

$$R \subseteq (\Sigma \cup V)^* \times (\Sigma \cup V)^*$$

von G erzeugte Sprache: $L(G) = \{w \mid S \rightarrow^* w \wedge w \in \Sigma^*\}$. r

Grammatik

```
{ terminale
  = mkSet "abc"
, variablen
  = mkSet "SA"
, start = 'S'
, regeln = mkSet
  [ ("S", "abc")
  , ("ab", "aabbA")
  , ("Ab", "bA")
  , ("Ac", "cc")
  ]
```

Wort-Ersetzungs-Systeme

Berechnungs-Modell (Markov-Algorithmen)

- Zustand (Speicherinhalt): Zeichenfolge (Wort)
- Schritt: Ersetzung eines Teilwortes

Regelmenge $R \subseteq \Sigma^* \times \Sigma^*$

Regel-Anwendung: $u \rightarrow_R v \iff \exists x, z \in \Sigma^*, (l, r) \in R : u = x \cdot l \cdot z \wedge x \cdot r \cdot z = v$.

Beispiel: Bubble-Sort: $\{ba \rightarrow ab, ca \rightarrow ac, cb \rightarrow bc\}$

Beispiel: Potenzieren: $ab \rightarrow bba$

Aufgaben: gibt es unendlich lange Rechnungen für: $R_1 = \{1000 \rightarrow 0001110\}$, $R_2 = \{aabb \rightarrow bbaaaa\}$?

Typ-3-Grammatiken

(= rechtslineare Grammatiken)

jede Regel hat die Form

- Variable \rightarrow Terminal Variable
- Variable \rightarrow Terminal
- Variable $\rightarrow \epsilon$

(vgl. lineares Gleichungssystem)

Beispiele

- $G_1 = (\{a, b\}, \{S, T\}, S, \{S \rightarrow \epsilon, S \rightarrow aT, T \rightarrow bS\})$
- $G_2 = (\{a, b\}, \{S, T\}, S, \{S \rightarrow \epsilon, S \rightarrow aS, S \rightarrow bT, T \rightarrow aT, T \rightarrow bS\})$

Sätze über Reguläre Sprachen

Für jede Sprache L sind die folgenden Aussagen äquivalent:

- es gibt einen regulären Ausdruck X mit $L = L(X)$,
- es gibt eine Typ-3-Grammatik G mit $L = L(G)$,
- es gibt einen endlichen Automaten A mit $L = L(A)$.

Wenn L_1, L_2 reguläre Sprachen sind, dann sind die folgenden Sprachen auch regulär:

- Mengenoperationen $L_1 \cup L_2, L_1 \cap L_2, L_1 \setminus L_2$
- Verkettung $L_1 \cdot L_2 = \{w_1 \cdot w_2 \mid w_1 \in L_1, w_2 \in L_2\}$
- Stern $L_1^* = \bigcup_{k \geq 0} L_1^k$

Reguläre Sprachen/Ausdrücke

Die Menge $E(\Sigma)$ der *regulären Ausdrücke* über einem Alphabet (Buchstabenmenge) Σ ist die kleinste Menge E , für die gilt:

- für jeden Buchstaben $x \in \Sigma : x \in E$
(autotool: Ziffern oder Kleinbuchstaben)
- das leere Wort $\epsilon \in E$ (autotool: Eps)
- die leere Menge $\emptyset \in E$ (autotool: Empty)
- wenn $A, B \in E$, dann
 - (Verkettung) $A \cdot B \in E$ (autotool: * oder weglassen)
 - (Vereinigung) $A + B \in E$ (autotool: +)
 - (Stern, Hülle) $A^* \in E$ (autotool: ^*)

Jeder solche Ausdruck beschreibt eine *reguläre Sprache*.

Beispiele/Aufgaben zu regulären Ausdrücken

Wir fixieren das Alphabet $\Sigma = \{a, b\}$.

- alle Wörter, die mit a beginnen und mit b enden: $a\Sigma^*b$.
- alle Wörter, die wenigstens drei a enthalten $\Sigma^*a\Sigma^*a\Sigma^*a\Sigma^*$
- alle Wörter mit gerade vielen a und beliebig vielen b ?
- Alle Wörter, die ein aa oder ein bb enthalten: $\Sigma^*(aa \cup bb)\Sigma^*$
- (Wie lautet das Komplement dieser Sprache?)

Übungen Reg. Ausdr.

- Tokenklassendef. für einige Programmiersprachen (welche Tokenklassen? welche reg. Ausdrücke? wie im Sprachstandard ausgedrückt?)
- String-Konstanten (Umgehen von Sonderzeichen)
- Kommentare
- Notation für reg. Ausdr. in gängigen Werkzeugen

Kontextfreie Sprachen

Def (Wdhlg): G ist kontextfrei (Typ-2), falls $\forall(l, r) \in R(G) : l \in V$.
geeignet zur Beschreibung von Sprachen mit hierarchischer Struktur.

```
Anweisung -> Bezeichner = Ausdruck
| if Ausdruck then Anweisung else Anweisung
Ausdruck -> Bezeichner | Literal
| Ausdruck Operator Ausdruck
```

Bsp: korrekt geklammerte Ausdrücke: $G = (\{a, b\}, \{S\}, S, \{S \rightarrow aSbS, S \rightarrow \epsilon\})$.

Bsp: Palindrome: $G = (\{a, b\}, \{S\}, S, \{S \rightarrow aSa, S \rightarrow bSb, S \rightarrow \epsilon\})$.

Bsp: alle Wörter w über $\Sigma = \{a, b\}$ mit $|w|_a = |w|_b$

(erweiterte) Backus-Naur-Form

- Noam Chomsky: Struktur natürlicher Sprachen (1956)
- John Backus, Peter Naur: Definition der Syntax von Algol (1958)

Backus-Naur-Form (BNF) \approx kontextfreie Grammatik

```
<assignment> -> <variable> = <expression>
<number> -> <digit> <number> | <digit>
```

Erweiterte BNF

- Wiederholungen (Stern, Plus) $\langle \text{digit} \rangle^+$
- Auslassungen

```
if <expr> then <stmt> [ else <stmt> ]
```

kann in BNF übersetzt werden

Ableitungsbäume für CF-Sprachen

Def: ein geordneter Baum T mit Markierung $m : T \rightarrow \Sigma \cup \{\epsilon\} \cup V$ ist Ableitungsbaum für eine CF-Grammatik G , wenn:

- für jeden inneren Knoten k von T gilt $m(k) \in V$
- für jedes Blatt b von T gilt $m(b) \in \Sigma \cup \{\epsilon\}$
- für die Wurzel w von T gilt $m(w) = S(G)$ (Startsymbol)
- für jeden inneren Knoten k von T mit Kindern k_1, k_2, \dots, k_n gilt $(m(k), m(k_1)m(k_2) \dots m(k_n)) \in R(G)$ (d. h. jedes $m(k_i) \in V \cup \Sigma$)
- für jeden inneren Knoten k von T mit einzigem Kind $k_1 = \epsilon$ gilt $(m(k), \epsilon) \in R(G)$.

Ableitungsbäume (II)

Def: der *Rand* eines geordneten, markierten Baumes (T, m) ist die Folge aller Blatt-Markierungen (von links nach rechts).

Beachte: die Blatt-Markierungen sind $\in \{\epsilon\} \cup \Sigma$, d. h. Terminalwörter der Länge 0 oder 1.

Für Blätter: $\text{rand}(b) = m(b)$, für innere Knoten: $\text{rand}(k) = \text{rand}(k_1) \text{rand}(k_2) \dots \text{rand}(k_n)$

Satz: $w \in L(G) \iff$ existiert Ableitungsbaum (T, m) für G mit $\text{rand}(T, m) = w$.

Eindeutigkeit

Def: G heißt *eindeutig*, falls $\forall w \in L(G)$ genau ein Ableitungsbaum (T, m) existiert.

Bsp: ist $\{S \rightarrow aSb \mid SS \mid \epsilon\}$ eindeutig?

(beachte: mehrere Ableitungen $S \rightarrow_R^* w$ sind erlaubt, und wg. Kontextfreiheit auch gar nicht zu vermeiden.)

Die naheliegende Grammatik für arith. Ausdr.

$\text{expr} \rightarrow \text{number} \mid \text{expr} + \text{expr} \mid \text{expr} * \text{expr}$

ist mehrdeutig (aus zwei Gründen!)

Auswege:

- Transformation zu eindeutiger Grammatik (benutzt zusätzliche Variablen)
- Operator-Assoziativitäten und -Präzedenzen

Assoziativität

$$(3 + 2) + 4 \stackrel{?}{=} 3 + 2 + 4 \stackrel{?}{=} 3 + (2 + 4)$$

$$(3 - 2) - 4 \stackrel{?}{=} 3 - 2 - 4 \stackrel{?}{=} 3 - (2 - 4)$$

$$(3 * *2) * *4 \stackrel{?}{=} 3 * *2 * *4 \stackrel{?}{=} 3 * *(2 * *4)$$

- Grammatik-Regeln
- Plus ist nicht assoziativ (für Gleitkommazahlen)
- links oder rechts?

Präzedenzen

$$(3 + 2) * 4 \stackrel{?}{=} 3 + 2 * 4 \stackrel{?}{=} 3 + (2 * 4)$$

- Grammatik-Regeln
- Verhältnis von plus zu minus, mal zu durch?

Übungen

- Lexik und Syntax von Java: http://java.sun.com/docs/books/jls/third_edition/html/j3TOC.html

- richtig oder falsch?

```
int x = /* foo /* // /** bar */ 42;
```

- “Wadler’s law of language design”
- reguläre Ausdrücke
- kontextfreie Grammatiken
- eindeutige Grammatiken für arithmetische Ausdrücke

3 Semantik von Programmiersprachen

Statische und dynamische Semantik

Semantik = Bedeutung

- statisch (kann zur Übersetzungszeit geprüft werden)

Beispiele:

- Typ-Korrektheit von Ausdrücken,
- Bedeutung (Bindung) von Bezeichnern

Hilfsmittel: Attributgrammatiken

- dynamisch (beschreibt Ausführung des Programms)
operational, axiomatisch, denotational

Attributgrammatiken (I)

- Attribut: Annotation an Knoten des Syntaxbaums.

$A : \text{Knotenmenge} \rightarrow \text{Attributwerte}$ (Bsp: \mathbb{N})

- Attributgrammatik besteht aus:

- kontextfreier Grammatik G (Bsp: $\{S \rightarrow e \mid mSS\}$)

- für jeden Knotentyp (Terminal + Regel)

eine Menge von erlaubten Attribut-Tupeln $(A(X_0), A(X_1), \dots, A(X_n))$

für Knoten X_0 mit Kindern $[X_1, \dots, X_n]$

$S \rightarrow mSS, A(X_0) + A(X_3) = A(X_2); S \rightarrow e, A(X_0) = A(X_1);$ Terminale:
 $A(e) = 1, A(m) = 0$

Attributgrammatiken (II)

ein Ableitungsbaum mit Annotationen ist *korrekt bezüglich einer Attributgrammatik*, wenn

- zur zugrundeliegenden CF-Grammatik paßt
- in jedem Knoten das Attribut-Tupel (von Knoten und Kindern) zur erlaubten Tupelmenge gehört

Plan:

- Baum beschreibt Syntax, Attribute beschreiben Semantik

Ursprung: Donald Knuth: Semantics of Context-Free Languages, (Math. Systems Theory 2, 1968)

technische Schwierigkeit: Attributwerte effizient bestimmen. (beachte: (zirkuläre) Abhängigkeiten)

Arten von Attributen

- synthetisiert:
hängt nur von Attributwerten in Kindknoten ab

- ererbt (inherited)
hängt nur von Attributwerten in Elternknoten und (linken) Geschwisterknoten ab

Wenn Abhängigkeiten bekannt sind, kann man Attributwerte durch Werkzeuge bestimmen lassen.

Attributgrammatiken–Beispiele

- Auswertung arithmetischer Ausdrücke (dynamisch)
- Bestimmung des abstrakten Syntaxbaumes
- Typprüfung (statisch)
- Kompilation (für Kellermaschine) (statisch)

Konkrete und abstrakte Syntax

- konkreter Syntaxbaum = der Ableitungsbaum
- abstrakter Syntaxbaum = wesentliche Teile des konkreten Baumes

unwesentlich sind z. B. die Knoten, die zu Hilfsvariablen der Grammatik gehören.
abstrakter Syntaxbaum kann als synthetisiertes Attribut konstruiert werden.

```
E -> E + P ; E.abs = new Plus(E.abs, P.abs)
E -> P      ; E.abs = P.abs
```

Regeln zur Typprüfung

... bei geschachtelten Funktionsaufrufen

- Funktion f hat Typ $A \rightarrow B$
- Ausdruck X hat Typ A
- dann hat Ausdruck $f(X)$ den Typ B

Beispiel

```
String x = "foo"; String y = "bar";
Boolean.toString(x.length() < y.length());
```

(Curry-Howard-Isomorphie)

Ausdrücke → Kellermaschine

Beispiel:

$3 * x + 1 \Rightarrow$ push 3, push x, mal, push 1, plus

- Code für Konstante/Variable c : push c ;
- Code für Ausdruck x op y : code (x) ; code (y) ; op;
- Ausführung eines Operators:
holt beide Argumente vom Stack, schiebt Resultat auf Stack

Der erzeugte Code ist synthetisiertes Attribut!

Beispiele: Java-Bytecode (javac, javap), CIL (gmcs, monodis)

Äbungen (Stackmaschine)

Schreiben Sie eine Java-Methode, deren Kompilation genau diesen Bytecode erzeugt:

a)

```
public static int h(int, int);
```

Code:

```
0: iconst_3
1: iload_0
2: iadd
3: iload_1
4: iconst_4
5: isub
6: imul
7: ireturn
```

b)

```
public static int g(int, int);
```

Code:

```
0: iload_0
1: istore_2
2: iload_1
3: ifle           17
6: iload_2
7: iload_0
8: imul
```

```
9: istore_2
10: iload_1
11: iconst_1
12: isub
13: istore_1
14: goto      2
17: iload_2
18: ireturn
```

Dynamische Semantik

- operational:
beschreibt Wirkung von Anweisungen durch Änderung des Programmzustandes
- denotational:
ordnet jedem (Teil-)Programm einen Wert zu, Bsp: eine Funktion (höherer Ordnung).
Beweis von Programmeigenschaften durch Term-Umformungen
- axiomatisch (Bsp: wp-Kalkül):
enthält Schlußregeln, um Aussagen über Programme zu beweisen

Bsp: Operationale Semantik Schleife

`while (B) A`

wird übersetzt in Sprungbefehle

`if (B) ...`

(vervollständige!)

Aufgabe: übersetze `for (A; B; C) D` in `while`!

Denotationale Semantik

Beispiele

- jedes (nebenwirkungsfreie) *Unterprogramm* ist eine Funktion von Argument nach Resultat
- jede *Anweisung* ist eine Funktion von Speicherzustand nach Speicherzustand

Vorteile denotationaler Semantik:

- Bedeutung eines Programmes = mathematisches Objekt
- durch Term beschreiben, durch äquivalente Umformungen verarbeiten (equational reasoning)

Vorteil deklarativer Programmierung:

Programmiersprache *ist* Beschreibungssprache

Beispiel Denotationale Semantik

```
monoton :: Ord a => [a] -> Bool
monoton (x:y:zs) = x <= y && monotone (y:zs)
monoton _ = True
```

```
merge :: Ord a => [a] -> [a] -> [a]
merge [] ys = ys ; merge xs [] = xs
merge (x:xs) (y:ys) =
    if x <= y then x : merge ... ...
    else ...
```

Behauptung: $\text{monoton } xs \ \&\& \ \text{monoton } ys$
 $\Rightarrow \text{monoton } (\text{merge } xs \ ys)$

Beweis d. Induktion
über $\text{length } xs + \text{length } ys$

Beispiel: Semantik von Unterprogr.

Welche Funktion ist das:

```
f (x) = if x > 52
        then x - 11
        else f (f (x + 12))
```

Axiomatische Semantik

Notation für Aussagen über Programmezustände:

$\{ V \} A \{ N \}$

- für jeden Zustand s , in dem Vorbedingung V gilt:
- wenn A (Anweisung) ausgeführt wird,
- gilt im erreichten Zustand t die Nachbedingung N

Beispiel:

$\{ x \geq 5 \} y := x + 3 \{ y \geq 7 \}$

Gültigkeit solcher Aussagen kann man

- beweisen (mit Hoare-Kalkül)
- prüfen (testen)

Eiffel

Bertrand Meyer, <http://www.eiffel.com/>

```
class Stack [G]      feature
  count : INTEGER
  item  : G is require not empty do ... end
  empty : BOOLEAN is do .. end
  full  : BOOLEAN is do .. end
  put (x: G) is
    require not full do ...
    ensure not empty
      item = x
      count = old count + 1
```

Beispiel sinngemäß aus: B. Meyer: Object Oriented Software Construction, Prentice Hall 1997

Hoare-Kalkül

Kalkül: für jede Anweisung ein Axiom, das die schwächste Vorbedingung (weakest precondition) beschreibt.

Beispiele

- $\{ N[x/E] \} x := E \{ N \}$
- $\{ V \text{ und } B \} C \{ N \}$
und $\{ V \text{ und not } B \} D \{ N \}$
 $\Rightarrow \{ V \} \text{ if } (B) \text{ then } C \text{ else } D \{ N \}$
- Schleife ... benötigt Invariante

Axiom für Schleifen

wenn $\{ I \text{ and } B \} A \{ I \}$,
dann $\{ I \} \text{ while } (B) \text{ do } A \{ I \text{ and not } B \}$

Beispiel:

```
Eingabe int p, q;  
// p = P und q = Q  
int c = 0;  
// inv: p * q + c = P * Q  
while (q > 0) {  
    ???  
}  
// c = P * Q
```

Moral: erst Schleifeninvariante (Spezifikation), dann Implementierung.

Übungen (Invarianten)

Ergänze das Programm:

```
Eingabe: natürliche Zahlen a, b;  
// a = A und b = B  
int p = 1; int c = ???;  
// Invariante:  $c^b * p = A^B$   
while (b > 0) {  
    ???  
    b = abrunden (b/2);  
}  
Ausgabe: p; // p =  $A^B$ 
```

4 Typen

Warum Typen?

- Typ ist Menge von Werten mit Operationen
- für jede eigene Menge von Werten (Variablen) aus dem *Anwendungsbereich* benutze eine eigenen Typ
- halte verschiedene Typen sauber getrennt, mit Hilfe der Programmiersprache
- der Typ einer Variablen/Funktion ist ihre beste Dokumentation

Historische Entwicklung

- keine Typen (alles ist int)
- vorgegebene Typen (Fortran: Integer, Real, Arrays)
- nutzerdefinierte Typen
- abstrakte Datentypen

Überblick

- einfache (primitive) Typen
 - Zahlen, Wahrheitswerte, Zeichen
 - nutzerdefinierte Aufzählungstypen
 - Teilbereiche
- zusammengesetzte (strukturierte) Typen
 - Produkt (records)
 - Summe (unions)
 - Potenz (Funktionen: Arrays, (Hash-)Maps, Unterprogramme)
 - Verweistypen (Zeiger)

Aufzählungstypen

können einer Teilmenge ganzer Zahlen zugeordnet werden

- vorgegeben: int, char, boolean
- nutzerdefiniert (enum)

```
typedef enum {  
    Mon, Tue, Wed, Thu, Fri, Sat, Sun  
} day;
```

Designfragen:

- automatisch nach int umgewandelt?
- automatisch von int umgewandelt?
- eine Konstante in mehreren Aufzählungen möglich?

Keine Aufzählungstypen

das ist nett gemeint, aber vergeblich:

```
#define Mon 0  
#define Tue 1  
...  
#define Sun 6  
  
typedef int day;  
  
int main () {  
    day x = Sat;  
    day y = x * x;  
}
```

Aufzählungstypen in C

im wesentlichen genauso nutzlos:

```
typedef enum {  
    Mon, Tue, Wed, Thu, Fri, Sat, Sun  
} day;
```

```
int main () {
    day x = Sat;
    day y = x * x;
}
```

Übung: was ist in C++ besser?

Aufzählungstypen in Java

```
enum Day {
    Mon, Tue, Wed, Thu, Fri, Sat, Sun;

    public static void main (String [] argv) {
        for (Day d : Day.values ()) {
            System.out.println (d);
        }
    }
}
```

verhält sich wie Klasse
(genauer: Schnittstelle mit 7 Implementierungen)
siehe Übung (jetzt oder bei Objekten)

Teilbereichstypen in Ada

```
with Ada.Text_IO;
procedure Day is
    type Day is ( Mon, Tue, Thu, Fri, Sat, Sun );
    subtype Weekday is Day range Mon .. Fri;
    X, Y : Day;
begin
    X := Fri;      Ada.Text_IO.Put (Day' Image (X));
    Y := Day' Succ (X); Ada.Text_IO.Put (Day' Image (Y));
end Day;
```

mit Bereichsprüfung bei jeder Zuweisung.
einige Tests können aber vom Compiler statisch ausgeführt werden!

Abgeleitete Typen in Ada

```
procedure Fruit is
  subtype Natural is
    Integer range 0 .. Integer'Last;
  type Apples is new Natural;
  type Oranges is new Natural;
  A : Apples; O : Oranges; I : Integer;
begin -- nicht alles korrekt:
  A := 4; O := A + 1; I := A * A;
end Fruit;
```

Natural, Äpfel und Orangen sind isomorph, aber nicht zuweisungskompatibel.
Sonderfall: Zahlenkonstanten gehören zu jedem abgeleiteten Typ.

Zusammengesetzte Typen

Typ = Menge, Zusammensetzung = Mengenoperation:

- Produkt (record, struct)
- Summe (union)
- Potenz (Funktion)

Produkttypen (Records)

$$R = A \times B \times C$$

Kreuzprodukt mit benannten Komponenten:

```
typedef struct {
  A foo;
  B bar;
  C baz;
} R;
```

```
R x; ... B x.bar; ...
```

erstmalig in COBOL (≤ 1960)

Übung: Record-Konstruktion (in C, C++)?

Summen-Typen

$$R = A \cup B \cup C$$

disjunkte (diskriminierte) Vereinigung (Pascal)

```
type tag = ( eins, zwei, drei );
type R = record case t : tag of
  eins : ( a_value : A );
  zwei : ( b_value : B );
  drei : ( c_value : C );
end record;
```

nicht diskriminiert (C):

```
typedef union {
  A a_value; B b_value; C c_value;
}
```

Potenz-Typen

$B^A := \{f : A \rightarrow B\}$ (Menge aller Funktionen von A nach B)

ist sinnvolle Notation, denn $|B|^{|A|} = |B^A|$

spezielle Realisierungen:

- Funktionen (Unterprogramme)
- Wertetabellen (Funktion mit endlichem Definitionsbereich) (Assoziative Felder, Hashmaps)
- Felder (Definitionsbereich ist Aufzählungstyp) (Arrays)
- Zeichenketten (Strings)

die unterschiedliche Notation dafür (Beispiele?) ist bedauerlich.

Felder (Arrays)

Design-Entscheidungen:

- welche Index-Typen erlaubt? (Zahlen? Aufzählungen?)
- Bereichsprüfungen bei Indizierungen?
- Index-Bereiche statisch oder dynamisch?

- Allokation statisch oder dynamisch?
- Initialisierung?
- mehrdimensionale Felder gemischt oder rechteckig?

Felder in C

```
int main () {
    int a [10][10];
    a[3][2] = 8;
    printf ("%d\n", a[2][12]);
}
```

statische Dimensionierung, dynamische Allokation, keine Bereichsprüfungen.

Form: rechteckig, Adress-Rechnung:

```
int [M][N];
a[x][y] ==> *(&a + (N*x + y))
```

Felder in Java

```
int [][] feld =
    { {1,2,3}, {3,4}, {5}, {} };
for (int [] line : feld) {
    for (int item : line) {
        System.out.print (item + " ");
    }
    System.out.println ();
}
```

dynamische Dimensionierung und Allokation, Bereichsprüfungen. Nicht notwendig rechteckig.

Nicht rechteckige Felder in C?

Das geht:

```
int a [] = {1,2,3};
int b [] = {4,5};
int c [] = {6};
    e     = {a,b,c};
printf ("%d\n", e[1][1]);
```

aber welches ist dann der Typ von e?

(es ist nicht `int e [][]`.)

Dynamische Feldgrößen

Designfrage: kann ein Feld (auch: String) seine Größe ändern?

(C: wird sowieso nicht geprüft, Java: nein, Perl: ja)

in Java: wenn man das will, dann will man statt Array eine LinkedList, statt String einen StringBuffer.

wenn man mit Strings arbeitet, dann ist es meist ein Fehler:

benutze Strings *zwischen* Programmen, aber niemals *innerhalb* eines Programms.

in einem Programm: benutze immer anwendungsspezifische Datentypen.

... deren externe Syntax spiel überhaupt keine Rolle

5 Speicherverwaltung

Speicherplatz für Objekte

- statisch (vor Programmstart bestimmt)
- dynamisch (während Programmlauf bestimmt)
 - flüchtig (Lebensdauer: Block)
Stack, Register
 - permanent (lebt länger als Block)
Heap

Zur Benutzung permanenter dynamische Daten benötigt man *Zeiger*.

Zeiger- und Verweistypen

Zeiger = *Adresse* eines Wertes. — Wofür?

- dynamische Speicherzellen (im Heap)
- verkettete Strukturen (Listen, Bäume)
- gemeinsame Teilstrukturen (sharing)
- Adresse ist einfacher zu transportieren als Wert

Designfragen:

- Typsicherheit
- Zeiger oder Verweis?
- Verfolgung (De-Referenzierung) implizit oder explizit?

Zeiger- und Verweistypen

Zeiger = *Adresse* eines Wertes. — Wofür?

- dynamische Speicherzellen (im Heap)
- verkettete Strukturen (Listen, Bäume)
- gemeinsame Teilstrukturen (sharing)
- Adresse ist einfacher zu transportieren als Wert

Designfragen:

- Typsicherheit
- Zeiger oder Verweis?
- Verfolgung (De-Referenzierung) implizit oder explizit?

Zeiger (pointer) in C

Typ T, Zeigertyp T * p
Adresse feststellen:

```
T x;  
T * p = &x;
```

Zeiger (einmal) verfolgen (de-referenzieren):

```
T y = *p;
```

Vorsicht: `int* a, b;`

Zeiger-Arithmetik:

```
char * c = malloc(sizeof(int) * 20);  
*((int*)c + 4) = 42;  
printf ("%d\n", *((int*)(c + 4)));
```

Verweise (references) in C++

Typ T, Verweistyp T & p
Adresse feststellen (implizit):

```
int x = 9;  
int & p = x;
```

Verweis verfolgen (implizit):

```
int y = p;
```

keine Änderungen von Verweisen

```
int z = 10; p = z;    p = 8; cout << z;  
vgl.      p = &z; *p = 8;
```

Zeiger/Verweise in Java?

- scheint es nicht zu geben...
- doch: es gibt Wert-Typen (int, boolean, ...) und Verweis-Typen (alle Klassen)
- (aber keine Zeiger)

```
static class T { int foo = 8; }
public static void main (String [] args) {
    T x = new T ();
    System.out.println ( x.foo );
    T y = x;
    y.foo = 9;
    System.out.println ( x.foo );
}
```

Zeiger in C#

- class: Zeigersemantik
- struct: Wert-Semantik

```
class/struct Foo { public int bar; }

public static void Main () {
    Foo x = new Foo (); x.bar = 3;
    System.Console.WriteLine (x.bar);
    Foo y = x;          y.bar = 4;
    System.Console.WriteLine (x.bar);
}
```

Probleme mit Zeigern

- tote Zeiger (wg. verfrühter Freigabe)

```
T *p = malloc (...); T *q = p; free (p); .. *q ..
```
- Speichermüll (wg. vergessener Freigabe)

```
while (.. )
    { T *p = malloc (...); .. *p .. }
```
- verschiedene Namen für gleiche Objekte (aliasing) erschweren Programmanalyse

Aliasing

... erschwert Programmanalyse (für Menschen und optimierende Compiler)

```
f.c:
void f (int * p) {
    *p = 9;
}

g.c:
void f (int * p);
void g () {
    int x = 8;
    int *p = &x;
    f (p);
    printf ("%d\n", x);
}
```

Übung: was wird besser durch `const`? Wo?

Automatische Freigabe

Müllsammeln (garbage collection)

- Verweiszähler
- markierende Kollektoren
- kopierende (kompaktierende) Kollektoren
- Generationen
- Platzbedarf, Zeitgarantien
- nebenläufige Ausführung (zunehmend wichtig)

Erfunden von McCarthy für LISP (≤ 1960), seitdem in jeder F(L)P-Sprache, seit Java, C# im imperativen Mainstream.

```
java -Xloggc:Foo.gc Foo
```

Verweiszähler

- jedes Objekt x hat Zähler für Anzahl der Verweise auf x .
- bei Anlegen eines Verweise Zähler erhöhen
- bei Löschen verringern
- bei Zähler 0 freigeben und verwiesene Objekte löschen (\rightarrow Rekursion)
- Zähler brauchen Platz
- Löschen ist aufwendig
- funktioniert nicht bei Kreisverweisen

Markierende Kollektoren

- bei Speicheranforderung, die nicht erfüllt werden kann:
- alle *lebenden*, d. h. von Wurzeln erreichbaren Objekte werden markiert (mark)
- restliche in Freispeicherliste (sweep)
- Markierung: 1 Bit; Zeit \sim Speicher, auch bei viel Müll.
- benötigt Stack (gerade dann, wenn wir keinen Platz mehr haben)? — Nein, *pointer reversal* möglich.
- ist *konservativ*: anwendbar auch bei Sprachen, bei denen Zeiger nicht sicher erkennbar sind
- http://www.hpl.hp.com/personal/Hans_Boehm/gc/
(z. B. benutzt in GNU JVM, mono)

Kopieren/Kompaktieren

- (wenigstens) zwei Speicherbereiche: Fromspace und Tospace
- lebende Zellen im Fromspace werden nach Tospace kopiert,
- dabei Verweise passend umgebogen
- was nicht kopiert wurde (Rest des Fromspaces), ist Müll
- Zeit \sim lebender Anteil des Speichers
- muß alles kopieren (auch Nicht-Zeiger).
- muß Zeiger sicher erkennen

Generationen usw.

- Generation k : Speicherbereich für die Objekte, die schon k garbage collections überlebt haben
- je älter, desto weniger Elemente
- Kollektor arbeitet bevorzugt auf neuester Generation

Realisierung in JVM:

- Eden
- Survivor spaces (1, 2)
- Tenured

Literatur GC

Hans Boehm: *Allocation and GC Myths* http://www.hp1.hp.com/personal/Hans_Boehm/gc/myths.ps

Brian Goetz: *Garbage collection in the HotSpot JVM* <http://www-128.ibm.com/developerworks/java/library/j-jtp11253/>

Sun: *Tuning Garbage Collection with the 5.0 Java[tm] Virtual Machine* http://java.sun.com/docs/hotspot/gc5.0/gc_tuning_5.html

Sun: *Garbage Collection FAQ* <http://java.sun.com/docs/hotspot/gc1.4.2/faq.html>

Bertram Felgenhauer: *Parallele GC* <http://141.57.11.224/~bf3/gc/>

Übung GC (I)

Finden Sie geeignete JVM-Konfigurationen für das Programm *KnockedForLoops*:

- <http://www.imn.htwk-leipzig.de/~waldmann/edu/ws09/pps/extra/kfl/KnockedForLoops.jar>
- Archiv mit Eingabedateien (TPDB 5.0.2): <http://dev.aspsimon.org/projects/termcomp/downloads/>
- Testfall:

```
java -jar KnockedForLoops.jar tpdb-5.0/SRS/Gebhardt/06.srs
```

sollte (sehr schnell) eine Ausgabe dieser Form liefern:

```
Enumerating derivations modulo  
( RULES 0 0 0 0 -> 0 1 0 1 , 1 0 0 1 -> 0 1 0 0 )
```

```
NO
```

```
Loop of length 27 starting with a string of length 15  
found after enumerating 14077 derivations:
```

```
.aaaa.ababbababaa  
rule aaaa -> baba at position 0  
...
```

- Resultatliste zum Vergleich: <http://www.lri.fr/~marche/termination-competition/2007/webform.cgi?command=srs&file=srs-standard.db&timelimit=120>

alle Zeilen mit wenigstens einem roten Block sollten zu einer Ausgabe führen und darüber hinaus möglichst viele komplett gelbe.

Interessante Testfälle: SRS/Gebhardt/10.srs, SRS/Endrullis/08.srs, SRS/Waldmann07a/size-11-alpha-3-num-4.srs, SRS/Waldmann07b/size-12-alpha-3-num-{174, 292, 340, 363, 386, 400, 403, 408, 430}.srs

Probieren Sie aus,

- mit welchen JVM-Optionen Sie diese Probleme möglichst schnell lösen können
- und evtl. welche weiteren (gelben).

Dramatis Personae:

- Autor des Programmes **KnockedForLoops** ist **Dieter Hofbauer** <http://www.theory.informatik.uni-kassel.de/~hofbauer/>
- Autor vieler Terminationsprobleme ist **Andreas Gebhardt** <http://www.informatik.uni-halle.de/arbeitsgruppen/datenstrukturen/mitarbeiter/gebhardt/>
- **Information zur Termination Competition:** http://www.termination-portal.org/wiki/Termination_Competition
- Wenn Sie ein Diplom/Master-Thema aus diesem Bereich bearbeiten möchten, dann melden Sie sich bei mir (J.W.)

Übung GC (II)

Richtig viel Müll erzeugen:

```
import java.util.*;
class Garbage {
    static long sum (int top) {
        List<Integer> l = new LinkedList<Integer>();
        for (int x = 0; x < top; x++) {
            l.add (x);
        }
        long result = 0;
        for (int x : l) {
            result += x;
        }
    }
}
```

```

        return result;
    }
    public static void main (String [] args) {
        for (int i = 0; i < 1000*1000; i+=10000) {
            System.out.println ( i + " : " + sum(i));
        }
    }
}

```

ausführen mit:

```
time java -Xmx400M -XX:NewSize=40M -XX:+PrintGCDetails Garbage
```

verschiedene Werte für NewSize ausprobieren, Messungen erklären.

6 Ausdrücke

Einleitung

Semantik:

- Ausdruck hat *Wert* (Zahl, Objekt, ...)
(Ausdruck wird *ausgewertet*)
- Anweisung hat *Wirkung* (Änderung des Programm/Welt-Zustandes)
(Anweisung wird *ausgeführt*)

Vgl. Trennung (in Pascal, Ada)

- Funktion (Aufruf ist Ausdruck)
- Prozedur (Aufruf ist Anweisung)

in den allen imperativen Sprachen gibt es Ausdrücke mit Nebenwirkungen

Designfragen für Ausdrücke

- Präzedenzen (Vorrang)
- Assoziativitäten (Gruppierung)
- Ausdrücke dürfen (Neben-)Wirkungen haben?

- in welcher Reihenfolge treten die auf?
- welche impliziten Typumwandlungen?
- explizite Typumwandlungen (cast)?
- kann Programmierer Operatoren definieren? überladen?

Syntax von Ausdrücken

- einfache Ausdrücke : Konstante, Variable
- zusammengesetzte Ausdrücke:
 - Operator-Symbol zwischen Argumenten
 - Funktions-Symbol vor Argument-Tupel

wichtige Spezialfälle für Operatoren:

- arithmetische, relationale, boolesche

Wdhlg: Syntaxbaum, Präzedenz, Assoziativität.

Syntax von Konstanten

Was druckt diese Anweisung?

```
System.out.println ( 12345 + 54321 );
```

dieses und einige der folgenden Beispiele aus: Joshua Bloch, Neil Gafter: *Java Puzzlers*, Addison-Wesley, 2005.

Der Plus-Operator in Java

... addiert Zahlen und verkettet Strings.

```
System.out.println ("foo" + 3 + 4);
System.out.println (3 + 4 + "bar");
```

Überladene Operatornamen

aus praktischen Gründen sind arithmetische und relationale Operatornamen *überladen* (d. h.: ein Name für mehrere Bedeutungen)

Überladung wird aufgelöst durch die Typen der Argumente.

```
int x = 3; int y = 4; ... x + y ...
double a; double b; ... a + b ...
String p; String q; ... p + q ...
```

Automatische Typanpassungen

in vielen Sprachen postuliert man eine Hierarchie von Zahlbereichstypen:

$\text{byte} \subseteq \text{int} \subseteq \text{float} \subseteq \text{double}$

im allgemeinen ist das eine Halbordnung.

Operator mit Argumenten verschiedener Typen: $(x :: \text{int}) + (y :: \text{float})$

beide Argumente werden zu kleinstem gemeinsamen Obertyp promoviert, falls dieser eindeutig ist (sonst statischer Typfehler)

(Halbordnung \rightarrow Halbverband)

Implizite/Explizite Typumwandlungen

Was druckt dieses Programm?

```
long x = 1000 * 1000 * 1000 * 1000;
long y = 1000 * 1000;
System.out.println ( x / y );
```

Was druckt dieses Programm?

```
System.out.println ((int) (char) (byte) -1);
```

Moral: wenn man nicht auf den ersten Blick sieht, was ein Programm macht, dann macht es wahrscheinlich nicht das, was man will.

Explizite Typumwandlungen

sieht gleich aus und heißt gleich (cast), hat aber verschiedene Bedeutungen:

- Datum soll in anderen Typ gewandelt werden, Repräsentation ändert sich:

```
double x = (double) 2 / (double) 3;
```

- Programmierer weiß es besser (als der Compiler), Repräsentation ändert sich nicht:

```
List books;  
Book b = (Book) books.get (7);
```

... kommt nur vor, wenn man die falsche Programmiersprache benutzt (nämlich Java vor 1.5)

Der Verzweigungs-Operator

Absicht: statt

```
if ( 0 == x % 2 ) {  
    x = x / 2;  
} else {  
    x = 3 * x + 1;  
}
```

lieber

```
x = if ( 0 == x % 2 ) {  
    x / 2  
} else {  
    3 * x + 1  
} ;
```

historische Notation dafür

```
x = ( 0 == x % 2 ) ? x / 2 : 3 * x + 1;
```

?/: ist *ternärer* Operator

Verzweigungs-Operator(II)

(... ? ... : ...) in C, C++, Java

Anwendung im Ziel einer Zuweisung (C++):

```
int main () {  
    int a = 4; int b = 5; int c = 6;  
    ( c < 7 ? a : b ) = 8;  
}
```

Relationale Operatoren

kleiner, größer, gleich,...

Was tut dieses Programm (C? Java?)

```
int a = -4; int b = -3; int c = -2;  
if (a < b < c) {  
    printf ("aufsteigend");  
}
```

Logische (Boolesche) Ausdrücke

- und `&&`, `||` oder, nicht `!`, gleich, ungleich, kleiner, ...
- nicht verwechseln mit Bit-Operationen `&`, `|`
(in C gefährlich, in Java ungefährlich—warum?)
- verkürzte Auswertung?

```
int [] a = ...; int k = ...;
if ( k >= 0 && a[k] > 7 ) { ... }
```

(Ü: wie sieht das in Ada aus?)

Noch mehr Quizfragen

- `System.out.println ("H" + "a");`
`System.out.println ('H' + 'a');`
- `char x = 'X'; int i = 0;`
`System.out.print (true ? x : 0);`
`System.out.print (false ? i : x);`

Erklären durch Verweis auf Java Language Spec.

Der Zuweisungs-Operator

Syntax:

- Algol, Pascal: Zuweisung `:=`, Vergleich `=`
- Fortran, C, Java: Zuweisung `=`, Vergleich `==`

Semantik der Zuweisung `a = b`:

Ausdrücke links und rechts werden verschieden behandelt:

- bestimme Adresse (lvalue) p von a
- bestimme Wert (rvalue) v von b
- schreibe v auf p

Weitere Formen der Zuweisung

(in C-ähnlichen Sprachen)

- verkürzte Zuweisung: `a += b`
entsprechend für andere binäre Operatoren
 - lvalue p von a wird bestimmt (nur einmal)
 - rvalue v von b wird bestimmt
 - Wert auf Adresse $\$p$ wird um v erhöht
- Inkrement/Dekrement
 - Präfix-Version `++i`, `--j`: Wert ist der geänderte
 - Suffix-Version `i++`, `j--`: Wert ist der vorherige

Ausdrücke mit Nebenwirkungen

(*side effect*; falsche Übersetzung: Seiteneffekt)

in C-ähnlichen Sprachen: Zuweisungs-Operatoren bilden Ausdrücke, d. h. Zuweisungen sind Ausdrücke und können als Teile von Ausdrücken vorkommen.

Wert einer Zuweisung ist der zugewiesene Wert

```
int a; int b; a = b = 5; // wie geklammert?
```

Komma-Operator zur Verkettung von Ausdrücken (mit Nebenwirkungen)

```
for (... ; ... ; i++, j--) { ... }
```

Auswertungsreihenfolgen

Kritisch: wenn Wert des Ausdrucks von Auswertungsreihenfolge abhängt:

```
int a; int b = (a = 5) + (a = 6);  
int d = 3; int e = (d++) - (++d);
```

- keine Nebenwirkungen: egal
- mit Nebenwirkungen:
 - C, C++: Reihenfolge nicht spezifiziert, wenn Wert davon abhängt, dann ist Verhalten *nicht definiert*
 - Java, C#: Reihenfolge genau spezifiziert (siehe JLS)

Auswertungsreihenfolge in C

Sprachstandard (C99, C++) benutzt Begriff *sequence point* (Meilenstein):
bei Komma, Fragezeichen, && und ||

die Nebenwirkungen zwischen Meilensteinen müssen unabhängig sein (nicht die gleiche Speicherstelle betreffen),

ansonsten ist das Verhalten undefiniert (d.h., der Compiler darf machen, was er will)

```
int x = 3; int y = ++x + ++x + ++x;
```

vgl. Aussagen zu sequence points in <http://gcc.gnu.org/readings.html>

Gurevich, Huggins: Semantics of C, <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.29.6755>

7 Anweisungen

Definition

Semantik: Anweisung hat *Wirkung* (Zustandsänderung), die bei Ausführung eintritt.
abstrakte Syntax:

- einfache Anweisung:
 - Zuweisung
 - Unterprogramm-Aufruf
- zusammengesetzte Anweisung:
 - Nacheinanderausführung (Block)
 - Verzweigung (zweifach: if, mehrfach: switch)
 - Wiederholung (Sprung, Schleife)

Programm-Ablauf-Steuerung

Ausführen eines Programms im von-Neumann-Modell:

Was? (Operation) Womit? (Operanden) Wohin? (Resultat) Wie weiter? (nächste Anweisung)

strukturierte Programmierung:

- Nacheinander
- außer der Reihe (Sprung, Unterprogramm, Exception)

- Verzweigung
- Wiederholung

engl. *control flow*, falsche Übersetzung: Kontrollfluß;
to control = steuern, *to check* = kontrollieren/prüfen

Blöcke

Folge von (Deklarationen und) Anweisungen
 Designfrage: Blöcke

- explizit (Klammern, begin/end)
- implizit (if ... then ... end if)

Designfrage: Deklarationen gestattet

- am Beginn des (Unter-)Programms (Pascal)
- am Beginn des Blocks (C)
- an jeder Stelle des Blocks (C++, Java)

Verzweigungen (zweifach)

in den meisten Sprachen:

```
if Bedingung then Anweisung1 [ else Anweisung2 ]
```

Designfragen:

- was ist als Bedingung gestattet (gibt es einen Typ für Wahrheitswerte?)
- dangling else
 - gelöst durch Festlegung (else gehört zu letztem if)
 - vermieden durch Block-Bildung (Perl, Ada)
 - tritt nicht auf, weil man else nie weglassen darf (vgl. ?/;) (Haskell)

Mehrfach-Verzweigung

```
switch (e) {
    case c1 : s1 ;
    case c2 : s2 ;
    [ default : sn; ]
}
```

Designfragen:

- welche Typen für e ?
- welche Werte für c_i ?
- Wertebereiche?
- was passiert, wenn mehrere Fälle zutreffen?
- was passiert, wenn kein Fall zutrifft (default?)
- (effiziente Kompilation?)

Switch/break

das macht eben in C, C++, Java nicht das, was man denkt:

```
switch (index) {
    case 1 : odd ++;
    case 2 : even ++;
    default :
        printf ("wrong index %d\n", index);
}
```

C#: jeder Fall *muß* mit break (oder goto) enden.

Kompilation

ein switch (mit vielen cases) wird übersetzt in:

- (naiv) eine lineare Folge von binären Verzweigungen (if, elsif)
- (semi-clever) einen balancierter Baum von binären Verzweigungen
- (clever) eine Sprungtabelle

Übung:

- einen langen Switch (1000 Fälle) erzeugen (durch ein Programm!)
- Assembler/Bytecode anschauen

Wiederholungen

- Maschine, Assembler: (un-)bedingter Sprung
- strukturiert: Schleifen

Designfragen für Schleifen:

- wie wird Schleife gesteuert? (Bedingung, Zähler, Daten)
- an welcher Stelle in der Schleife findet Steuerung statt (Anfang, Ende, dazwischen, evtl. mehreres)

Schleifen steuern durch...

- Zähler

```
for p in 1 .. 10 loop .. end loop;
```

- Daten

```
map (\x -> x*x) [1,2,3] ==> [1,4,9]
```

```
Collection<String> c  
    = new LinkedList<String> ();  
for (String s : c) { ... }
```

- Bedingung

```
while ( x > 0 ) { if ( ... ) { x = ... } ... }
```

Zählschleifen

Idee: vor Beginn steht Anzahl der Durchläufe fest.

richtig realisiert ist das nur in Ada:

```
for p in 1 .. 10 loop ... end loop;
```

- Zähler p wird implizit deklariert
- Zähler ist im Schleifenkörper konstant

Vergleiche (beide Punkte) mit Java, C++, C

Termination

Satz: Jedes Programm aus

- Zuweisungen
- Verzweigungen
- Zählschleifen

terminiert (hält) für jede Eingabe.

Äquivalenter Begriff (für Bäume anstatt Zahlen): strukturelle Induktion (fold, Visitor, primitive Rekursion)

Satz: es gibt berechenbare Funktionen, die nicht primitiv rekursiv sind.

Beispiel: Interpreter für primitiv rekursive Programme.

Schleifen mit Bedingungen

das ist die allgemeinste Form, ergibt (partielle) rekursive Funktionen, die terminieren nicht notwendig für alle Argumente.

Steuerung

- am Anfang: while (Bedingung) Anweisung
- am Ende: do Anweisung while (Bedingung)

Weitere Änderung des Ablaufes:

- vorzeitiger Abbruch (break)
- vorzeitige Wiederholung (continue)
- beides auch nicht lokal

Abarbeitung von Schleifen

operationale Semantik durch Sprünge:

```
while (B) A;  
==>  
start : if (!B) goto end;  
        A;  
        goto start;  
end   : skip;
```

(das ist auch die Notation der autotool-Aufgabe)

Ü: do A while (B);

vorzeitiges Verlassen

- ... der Schleife

```
while ( B1 ) {
    A1;
    if ( B2 ) break;
    A2;
}
```

- ... des Schleifenkörpers

```
while ( B1 ) {
    A1;
    if ( B2 ) continue;
    A2;
}
```

Geschachtelte Schleifen

manche Sprachen gestatten Markierungen (Labels) an Schleifen, auf die man sich in break beziehen kann:

```
foo : for (int i = ...) {
    bar : for (int j = ...) {

        if (...) break foo;

    }
}
```

Wie könnte man das simulieren?

Sprünge

- bedingte, unbedingte (mit bekanntem Ziel)
 - Maschinensprachen, Assembler, Java-Bytecode
 - Fortran, Basic: if Bedingung then Zeilennummer
 - Fortran: dreifach-Verzweigung (arithmetic-if)
- “computed goto” (Zeilenr. des Sprungziels ausrechnen)

Sprünge und Schleifen

- man kann jedes while-Programm in ein goto-Programm übersetzen
- und jedes goto-Programm in ein while-Programm ...
- ... das normalerweise besser zu verstehen ist.
- strukturierte Programmierung = jeder Programmbaustein hat genau einen Eingang und genau einen Ausgang
- aber: vorzeitiges Verlassen von Schleifen
- aber: Ausnahmen (Exceptions)

Sprünge und Schleifen (Beweis)

Satz: zu jedem goto-Programm gibt es ein äquivalentes while-Programm.

Beweis-Idee: `1 : A1, 2 : A2; .. 5: goto 7; .. =>`

```
while (true) {
  switch (pc) {
    case 1 : A1 ; pc++ ; break; ...
    case 5 : pc = 7 ; break; ...
  }
}
```

Das nützt aber softwaretechnisch wenig, das übersetzte Programm ist genauso schwer zu warten wie das Original.

Schleifen und Unterprogramme

zu jedem while-Programm kann man ein äquivalentes angeben, das nur Verzweigungen (if) und Unterprogramme benutzt.

Beweis-Idee: `while (B) A; =>`

```
void s () {
  if (B) { A; s (); }
}
```

Anwendung: C-Programme ohne Schlüsselwörter.

Denotationale Semantik (I)

vereinfachtes Modell, damit Eigenschaften entscheidbar werden (sind die Programme P_1, P_2 äquivalent?)

Syntax: Programme

- Aktionen,
- Zustandsprädikate (in Tests)
- Sequenz/Block, if, goto/while.

Beispiel:

```
while (B && !C) { P; if (C) Q; }
```

Denotationale Semantik (II)

Semantik des Programms P ist Menge der Spuren von P .

- *Spur* = eine Folge von Paaren von Zustand und Aktion,
- ein *Zustand* ist eine Belegung der Prädikatsymbole,
- jede Aktion zerstört alle Zustandsinformation.

Satz: Diese Spursprachen (von goto- und while-Programmen) sind *regulär*.

Beweis: Konstruktion über endlichen Automaten.

- Zustandsmenge = Prädikatbelegungen \times Anweisungs-Nummer
- Transitionen? (Beispiele)

Damit ist Spur-Äquivalenz von Programmen entscheidbar.

Beziehung zu tatsächlicher Äquivalenz?

8 Unterprogramme

Grundsätzliches

Ein Unterprogramm ist ein benannter Block mit einer Schnittstelle. Diese beschreibt den Datentransport zwischen Aufrufer und Unterprogramm.

- Funktion
 - liefert Wert

- Aufruf ist Ausdruck
- Prozedur
 - hat Wirkung, liefert keinen Wert (void)
 - Aufruf ist Anweisung

Argumente/Parameter

- in der Deklaration benutzte Namen heißen (formale) *Parameter*,
- bei Aufruf benutzte Ausdrücke heißen *Argumente*
(... nicht: aktuelle Parameter, denn engl. *actual* = dt. tatsächlich)

Designfragen bei Parameterzuordnung:

- über Position oder Namen? gemischt?
- defaults für fehlende Argumente?
- beliebig lange Argumentlisten?

Positionelle/benannte Argumente

Üblich ist Zuordnung über Position

```
void p (int height, String name) { ... }
p (8, "foo");
```

in Ada: Zuordnung über Namen möglich

```
procedure Paint (height : Float; width : Float);
Paint (width => 30, height => 40);
```

nach erstem benanntem Argument keine positionellen mehr erlaubt

code smell: lange Parameterliste,
refactoring: Parameterobjekt einführen
allerdings fehlt (in Java) benannte Notation für Record-Konstanten.

Default-Werte

C++:

```
void p (int x, int y, int z = 8);  
p (3, 4, 5); p (3, 4);
```

Default-Parameter müssen in Deklaration am Ende der Liste stehen

Ada:

```
procedure P  
  (X : Integer; Y : Integer := 8; Z : Integer);  
P (4, Z => 7);
```

Beim Aufruf nach weggelassenem Argument nur noch benannte Notation

Variable Argumentanzahl (C)

wieso geht das eigentlich:

```
#include <stdio.h>  
char * fmt = really_complicated();  
printf (fmt, x, y, z);
```

Anzahl und Typ der weiteren Argumente werden überhaupt nicht geprüft:

```
extern int printf  
  (__const char *__restrict __format, ...);
```

Variable Argumentanzahl (Java)

```
static void check (String x, int ... ys) {  
  for (int y : ys) { System.out.println (y); }  
}
```

```
check ("foo",1,2); check ("bar",1,2,3,4);
```

letzter formaler Parameter kann für beliebig viele des gleichen Typs stehen.

tatsächlich gilt `int [] ys`,
das ergibt leider Probleme bei generischen Typen

Parameter-Übergabe (Semantik)

Datenaustausch zw. Aufrufer (caller) und Aufgerufenem (callee): über globalen Speicher

```
#include <errno.h>
extern int errno;
```

oder über Parameter.

Datentransport (entspr. Schlüsselwörtern in Ada)

- in: (Argumente) vom Aufrufer zum Aufgerufenen
- out: (Resultate) vom Aufgerufenen zum Aufrufer
- in out: in beide Richtungen

Parameter-Übergabe (Implementierungen)

- pass-by-value (Wert)
- copy in/copy out (Wert)
- pass-by-reference (Verweis)
- pass-by-name (textuelle Substitution)
selten ... Algol68, CPP-Macros ... Vorsicht!

Parameterübergabe

häufig benutzte Implementierungen:

- Pascal: by-value (default) oder by-reference (VAR)
- C: by-value (Verweise ggf. selbst herstellen)
- C++ unterscheidet zwischen Zeigern (*, wie in C) und Referenzen (&, verweisen immer auf die gleiche Stelle, werden automatisch dereferenziert)
- Java: primitive Typen *und* Referenz-Typen (= Verweise auf Objekte) by-value

Call-by-name

äquivalent zu textueller Ersetzung

Algol(68): Jensen's device

```
sum (int i, int n; int f) {
  int s = 0;
  for (i=0; i<n; i++) { s += f; }
  return s;
}
int [10] a; int i; sum (i, 10, a[i]);
```

Call-by-name (Macros)

```
#define thrice(x) 3*x // gefährlich
thrice (4+y) ==> 3*4+y
```

“the need for a preprocessor shows omissions in the language”

- fehlendes Modulsystem (Header-Includes)
- fehlende generische Polymorphie
(\Rightarrow Templates in C+)

weitere Argumente:

- mangelndes Vertrauen in optimierende Compiler (inlining)
- bedingte Übersetzung

Aufgaben zu Parameter-Modi (I)

Erklären Sie den Unterschied zwischen (Ada)

```
with Ada.Text_IO; use Ada.Text_IO;
procedure Check is
  procedure Sub (X: in out Integer;
                Y: in out Integer;
                Z: in out Integer) is
  begin
    Y := 8; Z := X;
  end;
```

```

    Foo: Integer := 9;   Bar: Integer := 7;
begin
    Sub (Foo, Foo, Bar);
    Put_Line (Integer' Image (Foo));
    Put_Line (Integer' Image (Bar));
end Check;

```

(in Datei Check.adb schreiben, kompilieren mit gnatmake Check.adb)
und (C++)

```

#include <iostream>

void sub (int & x, int & y, int & z) {
    y = 8;
    z = x;
}

int main () {
    int foo = 9;
    int bar = 7;

    sub (foo, foo, bar);
    std::cout << foo << std::endl;
    std::cout << bar << std::endl;
}

```

Aufgaben zu Parameter-Modi (II)

Durch welchen Aufruf kann man diese beiden Unterprogramme semantisch voneinander unterscheiden:

Funktion (C++): (call by reference)

```

void swap (int & x, int & y)
{ int h = x; x = y; y = h; }

```

Makro (C): (call by name)

```

#define swap(x, y) \
{ int h = x; x = y; y = h; }

```

Kann man jedes der beiden von copy-in/copy-out unterscheiden?

Lokale Unterprogramme

Unterprogramme sind wichtiges Mittel zur Abstraktion
das möchte man überall einsetzen

also sind auch lokale Unterprogramme wünschenswert
(Konzepte *Block* und *Unterprogramm* sollen orthogonal sein)

Dann entsteht Frage: Wie greifen lokale Unterprogramme auf nichtlokale Variablen zu?

Statische und dynamische Sichtbarkeit

Was druckt dieses Programm?

```
int main () {
    int x = 4;
    int f(int y) { return x+y; }
    int g(int x) { return f(3*x); }
    printf ("%d\n", g(5) );
}
```

- statische Sichtbarkeit: textuell umgebender Block
(Pascal, Ada, Scheme-LISP, Haskell ...)
- dynamische Sichtbarkeit: Aufruf-Reihenfolge
((Common-LISP), (Perl))

Übung: Perl-Beispiel (local/my)

Frames, Ketten

Während ein Unterprogramm rechnet, stehen seine lokalen Daten in einem Aktivationsverbund (Frame), jeder Frame hat zwei Vorgänger:

- dynamischer V. (Frame des aufrufenden UP) (benutzt zum Rückkehren)
- statischer V. (Frame des textuell umgebenden UP) (benutzt zum Zugriff auf "fremde" lokale Variablen)

Beispiel: zeichnen Frames und statische/dynamische Links für $a(3, 4)$ bei

```
int a (int x, int y) {
    int b (int z) { return z > 0 ? 1 + b (z-1) : x; }
    return b (y);
}
```

Übung: Assemblercode verstehen (`gcc -S`)

Unterprogramme als Argumente

```
int d ( int g(int x) ) { return g(g(1)); }

int p (int x) {
    int f (int y) { return x + y ; }
    return d (f);
}
```

Betrachte Aufruf $p(3)$.

Das innere Unterprogramm f muß auf den p -Frame zugreifen, um den Wert von x zu finden.

Dieser Frame lebt.

Wenn Unterprogramme nur “nach innen” als Argumente übergeben werden, können die Frames auf einem Stack stehen.

Übung: Assemblercode verstehen

Unterprogramme als Resultate

```
int x1 = 3;

int (*s (int foo)) (int x2) {
    int f (int y) { return x1 + y; }
    return &f;
}

int main (int argc, char ** argv) {
    int (*p) (int) = s(4);
    printf ("%d\n", (*p)(3));
}
```

In f ersetze $x1$ durch $x2$.

Assemblercode erklären.

Unterprogramme/Zusammenfassung

in prozeduralen Sprachen:

- alle UP global: dynamische Kette reicht

- lokale UP: benötigt auch statische Kette
- lokale UP as Daten: benötigt Closures
= (Code, statischer Link)
- UP als Argumente: Closures auf Stack
- UP als Resultate: Closures im Heap

vgl. <http://www.function-pointer.org/>

in objektorientierten Sprachen: keine lokalen UP, aber lokale (inner, nested) Klassen.

9 Polymorphie und Objektorientierung

Polymorphie

poly-morph = viel-gestaltig

ein Bezeichner (z. B. Unterprogrammname) mit mehreren Bedeutungen

Formen der Polymorphie:

- ad-hoc:
einfaches Überladen von Bezeichnern
- parametrisch (und statisch):
Typparameter für generische Klassen und Methoden
- dynamisch:
Auswahl der Methoden-Implementierung durch Laufzeittyp des Objektes

Objekte, Methoden

Motivation: Objekt = Daten + Verhalten

```
typedef struct {
    int x; int y; // Daten
    void (*print) (FILE *fp); // Verhalten
} point;
point *p; ... ; (*(p->print))(stdout);
```

Klassen

Motivation: Klasse = gemeinsame Datenform und Verhalten von Objekten

```
typedef struct {
    int (*method[5]) ();
} obj;
obj *o; ... (*(o->method) [3]) ();
```

allgemein: Klasse:

- Deklaration von Daten (Attributen)
- Deklaration und Implementierung von Methoden.

this

Motivation: Methode soll wissen, für welches Argument sie gerufen wurde

```
typedef struct {
    int (*data) [3];
    int (*method[5]) ();
} obj;
obj *o; ... (*(o->method) [3]) (o);

int sum (obj *this) {
    return this->data[0] + this->data[1];
}
```

jede Methode bekommt *this* als (verstecktes) erstes Argument

Vererbung

Klasse *D* abgeleitet von Klasse *C*:

- *D* kann Menge der Attribute- und Methodendeklarationen von *C* erweitern (aber nicht verkleinern oder ändern)
- *D* kann Implementierungen von in *C* deklarierten Methoden übernehmen oder eigene festlegen (überschreiben).

Dynamische Polymorphie (OO)

```
class C {
    int x = 2; int p () { return this.x + 3; }
}
C x = new C() ; int y = x.p ();
```

Überschreiben:

```
class E extends C {
    int p () { return this.x + 4; }
}
C x =          // statischer Typ: C
    new E() ; // dynamischer Typ: E
int y = x.p ();
```

Wo ein Objekt der Basisklasse (C) erwartet wird, kann ein Objekt einer abgeleiteten Klasse (E) benutzt werden.

Equals richtig implementieren

```
class C {
    final int x; final int y;
    C (int x, int y) { this.x = x; this.y = y; }
    int hashCode () { return this.x + 31 * this.y; }
}
```

nicht so:

```
public boolean equals (C that) {
    return this.x == that.x && this.y == that.y;
}
```

Equals richtig implementieren (II)

...sondern so:

```
public boolean equals (Object o) {
    if (! (o instanceof C)) return false;
    C that = (C) o;
    return this.x == that.x && this.y == that.y;
}
```

Die Methode `boolean equals(Object o)` wird aus `HashSet` aufgerufen.

Sie muß deswegen *überschrieben* werden.

Das `boolean equals(C that)` hat den Methodenamen nur *überladen*.

Überladen

- wenn mehrere Methoden gleiche Namens sichtbar sind, wird die vom *passenden* Typ ausgewählt.
- wenn mehrere vom passenden Typ sichtbar sind (z. B. wegen Vererbungs-Beziehungen), dann wird die mit dem *spezifischsten* Typ ausgewählt
- ... falls das genau eine ist (ein minimales Element in der entsprechenden Halbordnung)—sonst Fehler

Überschreiben und Überladen

- C++: Methode, die überschrieben werden darf, muß `virtual` deklariert werden
- C#: Das Überschreiben muß durch `override` angezeigt werden
- Java: alle Methoden sind `virtual`, deswegen ist Überschreiben von Überladen schlecht zu unterscheiden:
Quelle von Programmierfehlern
- IDEs unterstützen Annotation `@overrides`

Vererbung bricht Kapselung

```
class C {  
    void p () { ... q(); ... };  
    void q () { .. };  
}
```

Jetzt wird `q` überschrieben (evtl. auch unabsichtlich—in Java), dadurch ändert sich das Verhalten von `p`.

```
class D extends C {  
    void q () { ... }  
}
```

Man muß beim Programmieren von `D` wissen, wie `C.p()` implementiert ist!

Statische Attribute und Methoden

für diese findet *kein* dynamischer Dispatch statt. (Beispiele—Puzzle 48, 54)

Damit das klar ist, wird dieser Schreibstil empfohlen:

- dynamisch: immer mit Objektnamen qualifiziert, auch wenn dieser `this` lautet,
- statisch: immer mit Klassennamen qualifiziert (niemals mit Objektnamen)

Lokale Klassen

- static nested class: dient lediglich zur Gruppierung

```
class C { static class D { .. } .. }
```

- nested inner class:

```
class C { class D { .. } .. }
```

jedes D-Objekt hat einen Verweis auf ein C-Objekt (\approx statische Kette) (bezeichnet durch `C.this`)

- local inner class: (Zugriff auf lokale Variablen in *m* nur, wenn diese final sind. Warum?)

```
class C { void m () { class D { .. } .. } }
```

Generische Polymorphie

parametrische Polymorphie:

- Klassen und Methoden können Typ-Parameter erhalten.
- innerhalb der Implementierung der Klasse/Methode wird der formale Typ-Parameter als (unbekannter) Typ behandelt
- bei der Benutzung der Klasse/Methode müssen alle Typ-Argumente angegeben werden
(oder der Compiler inferiert diese in einigen Fällen)
- separate Kompilation (auch von generischen Klassen) mit statischer Typprüfung

Bsp: Generische Klasse in Java

```
class Pair<A,B> {
    final A first; final B second;
    Pair(A a, B b)
        { this.first = a; this.second = b; }
}
Pair<String,Integer> p =
    new Pair<String,Integer>("foo", 42);
int x = p.second + 3;
```

vor allem für Container-Typen (Liste, Menge, Keller, Schlange, Baum, ...)

Bsp: Generische Methode in Java

```
class C {
    static <A,B> Pair<B,A> swap (Pair<A,B> p) {
        return new Pair<B,A>(p.second, p.first);
    }
}
Pair<String,Integer> p =
    new Pair<String,Integer>("foo", 42);
Pair<Integer,String> q = C.swap(p);
```

bei Benutzung werden Typargumente inferiert
in C#: Typargumente könne auch angegeben werden.

```
Pair<Integer,String> q =
    C.swap<String,Integer>(p);
```

Schranken für Typparameter (I)

- kovariant: <T extends S>
als Argument ist jeder Typ *T* erlaubt, der *S* implementiert

```
interface Comparable<T>
    { int compareTo(T x); }
static <T extends Comparable<T>>
    T max (Collection<T> c) { .. }
```

Schranken für Typparameter (II)

- kontravariant: `<S super T>`

Als Argument ist jeder Typ S erlaubt, der Obertyp von T ist.

```
static <T> int binarySearch
    (List<? extends T> list, T key,
    Comparator<? super T> c)
```

Anonyme Typen (Wildcards)

Wenn man einen generischen Typparameter nur einmal braucht, dann kann er `?` heißen.

```
List<?> x = Arrays.asList
    (new String[] {"foo", "bar"});
Collections.reverse(x);
System.out.println(x);
```

jedes Fragezeichen bezeichnet einen anderen (neuen) Typ:

```
List<?> x = Arrays.asList
    (new String[] {"foo", "bar"});
List<?> y = x;
y.add(x.get(0));
```

Wildcards und Bounds

```
List<? extends Number> z =
    Arrays.asList(new Double[]{1.0, 2.0});
z.add(new Double(3.0));
```

Typinformation zur Laufzeit

- (Java) nicht vorhanden (type erasure), die Collection weiß nicht, welches ihr Elementtyp ist
- (C#) ist bekannt

Typen haben aber verschiedene Repräsentationen (verschieden primitive, Verweistypen), also:

- Java: alle Typparameter müssen Verweistypen sein (ggf. (Auto)boxing); nur eine Instanz der Collection
- C#: beliebige Typen gestattet (auch primitive); dafür dann mehrere Instanzen.

Generics und Subtypen

Warum geht das nicht:

```
class C { }

class E extends C { void m () { } }

List<E> x = new LinkedList<E>();

List<C> y = x; // Typfehler
```

Antwort: wenn das erlaubt wäre, dann:

Generics und Arrays

das gibt keinen Typfehler:

```
class C { }
class E extends C { void m () { } }

E [] x = { new E (), new E () };
C [] y = x;

y [0] = new C ();
x [0].m();
```

aber...(Übung)

Generics und Arrays (II)

warum ist die Typprüfung für Arrays schwächer als für Collections?

Historische Gründe. Das sollte gehen:

```
void fill (Object[] a, Object x) { .. }
String [] a = new String [3];
fill (a, "foo");
```

Das sieht aber mit Generics besser so aus: ...

10 Abstraktion und Kapselung

Einleitung

Abstraktion:

- (mehrere) Einzelheiten zusammenfassen
- und gleichzeitig verstecken

typische Formen:

- Vorgangs-Abstraktion (Unterprogramme)
- Daten-Abstraktion (Typen) —uraltet Beispiel(!): `double`
- gemischt (Klassen), übergreifend (Pakete, Namensbereiche)

Polymorphie

Abstraktionen sind nur dann sinnvoll, wenn sie flexibel benutzt werden können, `interface Map<K, V>` für beliebige Typen `K, V`.

D. h.: Abstraktionen benötigen Parameter. Häufig:

- Unterprogramm bekommt Argumente (Daten)
- Typschablone bekommt Argumente (Typen)

auch andere denkbar und nützlich:

- Unterprogramm bekommt Typ als Argument (statisch oder dynamisch)
- Typschablone bekommt Datum als Argument (dependent types)

Klassen, Interfaces

abstrakter Datentyp: Operationen mit Zusicherungen

```
interface Map<K, V> {  
    void put (K key, V value);  
    V get (K key);  
}  
class TreeMap<K, V> implements Map<K, V> { ... }  
class HashMap<K, V> implements Map<K, V> { ... }
```

... ist aus der Mathematik längst bekannt:

```

interface Halbgruppe<M> { M mal (M x, M y); }
interface Monoid<M> extends Halbgruppe<M>
  { M eins (); }
interface Gruppe<M> extends Monoid<M>
  { M inverse (M x); }

```

Algebraische Spezifikation

- Interface = abstrakter Datentyp
- besitzt algebraische Spezifikation = Signatur und Axiome (Formeln)
- Implementierung = konkreter Datentyp = eine Algebra = Modell einer Spezifikation

Literatur: z. B. Ehrich, Gogolla, Lipeck: *Algebraische Spezifikation abstrakter Datentypen*. Teubner, Stuttgart, 1989.

Signaturen, Algebren

- *Signatur*: Menge von Funktionssymbolen, jedes mit Stelligkeit (Argumentzahl).
Bsp: $\Sigma = \{a_0, b_0, f_2, g_2\}$.
- Σ -*Algebra*: Trägermenge D und zu jedem k -stelligen Symbol f eine k -stellige Funktion $[f] : D^k \rightarrow D$.
Bsp: $D = \mathbb{N}$, $[a] = 0$, $[b] = 1$, $[f](x, y) = x + y$, $[g](x, y) = xy$.
Bsp: $D = \{F, T\}$, $[a] = F$, $[b] = T$, $[f] = \vee$, $[g] = \wedge$.

Axiome, Modelle

Axiom: prädikatenlogische Formel, die (nur) Funktionssymbole der Signatur benutzt.

$$\begin{aligned}
& \forall x : F(A, x) = x \wedge F(x, A) = x \\
& \wedge \forall x, y, z : F(F(x, y), z) = F(x, F(y, z)) \\
& \wedge \forall x : G(B, x) = x \wedge G(x, B) = x \\
& \wedge \forall x : G(A, x) = A \wedge G(x, A) = A \\
& \wedge \forall x, y, z : G(G(x, y), z) = G(x, G(y, z)) \\
& \wedge \forall x, y, z : G(F(x, y), z) = F(G(x, z), G(y, z)) \\
& \wedge \forall x, y, z : G(x, F(y, z)) = F(G(x, y), G(x, z))
\end{aligned}$$

*[-5pt] *Modell*: eine Σ -Algebra, die die Axiome erfüllt.

Ü: Gesucht: *alle* Modelle von A mit Träger $\{F, T\}$.

ADT in realen Programmiersprachen

- Signatur: Interface (statische Prüfung)
- Axiome: Vor/Nachbedingungen von Methoden
(Prüfung dynamisch: Test, statisch: Beweis)

Realisierung von Interfaces in OOP:

- interface ist (voll) abstrakte Klasse
(alle Methoden sind abstrakt: nur deklariert, aber nicht implementiert)
- Schnittstellen-Implementierung: konkrete Klasse „erbt“ von interface
- das ist *keine* Implementierungsvererbung

Module, Komponenten

- Softwareprojekte bestehen aus Teilen (Modulen, Komponenten), die getrennt spezifiziert, implementiert, angewendet werden.
- Programmiersprache sollte Entwicklung von Teilprogrammen unterstützen
- getrennte Typprüfung/Kompilation von Modulen: benötigt Spezifikation von anderen Modulen.

Designfrage: Spezifikation von Implementierung trennen?

- Ja: Ada (.ads/.adb), C (.h/.c)
- Nein: Java, C#

Build-Systeme

Designfrage: Modulabhängigkeiten in der Sprache oder außerhalb der Sprache?
Wenn außerhalb, dann wird zusätzlich zu Compiler noch ein Build-System benötigt.

- C: Abhängigkeiten in Makefiles,
können generiert werden (`gcc -M`)
- Java: Abhängigkeiten in Quellen (`import`)
trotzdem Suchpfade für Pakete
Build-Systeme: ant, maven

Sichtbarkeiten

Information dadurch verstecken, daß sie keinen Namen hat:

Java: Bezeichner sind sichtbar

- lokal: nur im Block
- private: nur in eigener Klasse
- (default): nur im eigenen Paket
- protected: in abgeleiteten Klassen
- public: in allen Paketen

Namen (Designfragen)

- wodurch entsteht Namens-Hierarchie?
Java: package, class; C++: namespace, class
- muß man die Benutzung eines Namens deklarieren?
Ada: `with Text_IO; ... Text_IO.Put (..)`
Java: `java.util.TreeMap<Foo, Bar>`
- kann der voll qualifizierte Name abgekürzt werden?
Ada: `with Text_IO; use Text_IO; Put (..)`
Java: `import java.util.*; TreeMap<Foo, Bar>`
- sind Abkürzungen global oder lokal?
C++: `using namespace ...`

11 Zusammenfassung

Themen

- formale Methoden zur Beschreibung von
 - Syntax (lexikalisch, grammatikalisch, abstrakt)
 - Semantik (statisch: Attributgrammatiken, dynamisch: denotational, operational, axiomatisch)

- Anwendung bei:
 - Typen
 - Ausdrücke, Anweisungen
 - Unterprogramme
 - Polymorphie (OO, parametrisch)

Hierarchien (Bäume)

- Baum: Blatt/Verzweigung (Kompositum)
- Syntax: einfache/zusammengesetzte Ausdrücke, Anweisungen
- Typen und ihre Elemente (Daten):
einfach/zusammengesetzt
- abstrakte Datentypen (Signatur einer Algebra)
(Bsp: reguläre Ausdrücke)

Statik/Dynamik

Definition:

- statisch: Analyse (+ Übersetzung) des Programmes
- dynamisch: Ausführung des Programmes

Eigenschaften:

- (Vor-)Arbeit zur Übersetzungszeit spart (Nach-)Arbeit zur Laufzeit (Bsp: Typprüfungen, Bereichsprüfungen, Initialisierungs-Prüfungen)
- statische Prüfungen sollen *entscheidbar* sein, deswegen nicht für jede Programmeigenschaft anwendbar (Sätze von Gödel/Church/Turing/Rice)
- Auswege: Compiler approximiert, Programmierer hilft mit.

Abstraktionen

Programmiersprache dient dazu, ...

- ausführbaren Code zu beschreiben,
- Abstraktionen auszudrücken.

(allgemeine und anwendungsspezifische)

Abstraktion besteht aus:

- Schema (das Gemeinsame)
- Parametern (das Unterschiedliche).

Bsp: Unterprog., Klasse, abstr. Datentyp, generischer Typ.

zugrundeliegendes Prinzip: Funktion. (\Rightarrow Lambda-Kalkül) vgl. Steele, Sussman: "Lambda, the ultimate ..." <http://library.readscheme.org/page1.html>