Prinzipien von Programmiersprachen
Vorlesung
Wintersemester 2006

Johannes Waldmann, HTWK Leipzig

23. Januar 2007

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
  dienstags, 7:30–9:00, HB207
- Übungen
  - freitags 12:00–13:30, Z423
  - freitags 17:15–18:45, Z423
  - (neu) dienstags (ungerade) 11:00–12:30, Z423 *und* donnerstags (gerade) 19:00–20:30, Z423

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

Literatur

- http://www.imn.htwk-leipzig.de/~waldmann/edu/ws06/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 Stri
find workspace/ -name "*.java"   -exec grep -l Stri
```

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 $ prod
```

Kellermaschine in PostScript.

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 ($\rightarrow$ Folge von Token)
- syntaktische Analyse ($\rightarrow$ Baum)
- semantische Analyse ($\rightarrow$ annotierter Baum)
- Zwischencode-Erzeugung ($\rightarrow$ Befehlsfolge)
- Code-Erzeugung ($\rightarrow$ 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
gcc -o bar bar.o # linkt (lädt) Objektcode (Resulta
./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)

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

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

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

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

r

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:
$R_1 = \{1000 \rightarrow 0001110\}, R_2 = \{aabb \rightarrow bbbaaa\}$?

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: $\star$ oder weglassen)
  - (Vereinigung) $A + B \in E$ (autotool: $+$)
  - (Stern, Hülle) $A^* \in E$ (autotool: $\hat{}\star$)

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:
$G = (\{a, b\}, \{S\}, S, \{S \to aSbS, S \to \epsilon\})$.
Bsp: Palindrome:
$G = (\{a, b\}, \{S\}, S, \{S \to aSa, S \to bSb, S \to \epsilon)$.
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) `<digit>^+`
- Auslassungen

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

kann in BNF übersetzt werden

Ableitungsbäume für CF-Sprachen

Def: ein geordneter Baum T mit Markierung
$m : T \to \Sigma \cup \{\epsilon\} \cup V$ 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 $k_1, k_2, \ldots, k_n$ gilt $(m(k), m(k_1)m(k_2)\ldots m(k_n)) \in R(G)$ (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:
$\text{rand}(k) = \text{rand}(k_1)\,\text{rand}(k_2)\ldots\text{rand}(k_n)$
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 $\{S \to aSb|SS|\epsilon\}$ eindeutig?
(beachte: mehrere Ableitungen $S \to_R^* w$ sind erlaubt, und wg. Kontextfreiheit auch gar nicht zu vermeiden.)

Die naheliegende Grammatik für arith. Ausdr.

```
expr -> number | expr + expr | expr * 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;
  \item
    ``Wadler's law of language design''
  ```
- reguläre Ausdrücke
- kontextfreie Grammatiken
- eindeutige Grammatiken für arithmetische Ausdrücke

Statische und dynamische Semantik

Semantik = Bedeutung

- statisch (kann zur Übersetzungszeit geprüft werden)
  Bsp: Typ-Korrektheit von Ausdrücken, Bedeutung (Bindung) von Bezeichnern
  Hilfsmittel: Attributgrammatiken
- dynamisch (beschreibt Ausführung des Programms)
  Operational, Axiomatisch, Denotational

Attributgrammatiken

Attribut: Annotation an Knoten des Syntaxbaums.

- ererbt:
  hängt nur von Attributwerten in Elternknoten ab
- synthetisiert:
  hängt nur von Attributwerten in Kindknoten ab

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

Attributgrammatiken–Beispiele

- Auswertung arithmetischer Ausdrücke (dynamisch)
- Typprüfung (statisch)
- Kompilation (für Kellermaschine) (statisch)

Regeln zur Typprüfung

. . . bei geschachtelten Funktionsaufrufen

- Funktion f hat Typ $A \to B$
- 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!
Beispiel: Java-Bytecode (javac, javap)

Dynamische Semantik

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

Bsp: Operationale Semantik

Schleife

```
while (B) A
```

wird übersetzt in Sprungbefehle

```
if (B) ...
```

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

Axiomatische Semantik

Hoare-Kalkül

`{ V } A { N }`

(Wenn V gilt, dann A ausgeführt wird, gilt danach N.)
Kalkül: für jede Anweisung ein Axiom, das die schwächste Vorbedingung (weakest precondition) beschreibt.
Beispiele

- $\mathrm{wp}(x := E, N) = N[x/E]$
- $\mathrm{wp}(\texttt{if } (B) \texttt{ then } C \texttt{ else } D, N) =$
  $B \wedge \mathrm{wp}(C, N) \vee \neg B \wedge \mathrm{wp}(D, N)$
- Schleife . . . benötigt Invariante

(siehe Vorlesung Verifikation)

Denotationale Semantik

Beispiele

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

Übungen

- dangling else in Java, Ada
- Gleitkomma-Addition nicht assoziativ
- Java-Bytecode für arithmetische Ausdrücke (Programmrekonstruktion)

Schreiben Sie eine Java-Methode, deren Kompilation genau diesen Bytecode erzeugt. Was macht die Methode?

```
static int f(int, int);
  Code:
    0:   iconst_0
    1:   istore_2
    2:   iload_1
    3:   ifle    17
    6:   iload_2
    7:   iload_0
    8:   iadd
    9:   istore_2
    10:  iload_1
    11:  iconst_1
```

Variablen

vereinfacht: Variable bezeichnet eine (logische) Speicherzelle
genauer: Variable besitzt Attribute

- Name
- Adresse
- Wert
- Typ
- Lebensdauer
- Sichtbarkeitsbereich

Bindungen dieser Attribute *statisch* oder *dynamisch*

Namen

- welche Buchstaben/Zeichen sind erlaubt?
- reservierte Bezeichner?
- Groß/Kleinschreibung?
- Konvention: `long_name` oder `longName` (camel-case)

  (Fortran: `long name`)

  im Zweifelsfall: Konvention der Umgebung einhalten
- Konvention: Typ im Namen (schlecht, weil so Implementierungsdetails verraten werden)

  schlecht: `myStack = ...`

  besser: `Stack<Ding> rest_of_input = ...`

Typen für Variablen

- dynamisch
- statisch
  - deklariert (durch Programmierer)
  - inferiert (durch Übersetzer)
    z. B. `let` in C#3

Vor/Nachteile: Lesbarkeit, Sicherheit, Kosten

bei Zuweisungen `lhs := rhs`
Wie genau muß Typ von rhs (Ausdruck) übereinstimmen mit deklariertem Typ von lhs (Variable)?
Beachte: Objekttypen, Zahltypen

Konstanten

= Variablen, an die genau einmal zugewiesen wird

- C: const (ist Attribut für Typ)
- Java: final (ist Attribut für Variable)

Vorsicht:

```
class C { int foo; }
static void g (final C x) { x.foo ++; }
```

in funktionaler Programmierung (Haskell) sind *alle* „Variablen“ konstant und alle Objekte immutable.
das sollte man auch in imperativen Sprachen so weit wie möglich nachmachen.
Merksatz: alle Deklarationen so (lokal und so) konstant wie möglich!

Lebensort und -Dauer von Variablen

- statisch (global, aber auch lokal:)

```
int f (int x) {
    static int y = 3; y++; return x+y;
}
```

- dynamisch
  - Stack `{ int x = ... }`
  - Heap
    - explizit (new/delete, malloc/free)
    - implizit

Sichtbarkeit von Namen

= Bereich der Anweisungen/Deklarationen, in denen ein Name benutzt werden kann.

- global
- lokal: Block (und Unterblöcke)

Üblich ist: Sichtbarkeit beginnt *nach* Deklaration und endet am Ende des umgebenden Blockes

Überdeckungen

Namen sind auch in inneren Blöcken sichtbar:

```
int x;
while (..) {
  int y;
  ... x + y ...
}
```

innere Deklarationen verdecken äußere:

```
int x;
while (..) {
  int x;
  ... x ...
}
```

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)

Sichtbarkeit und Lebensdauer

. . . stimmen nicht immer überein:

- static-Variablen in C-Funktionen
  sichtbar: in Funktion, Leben: Programm
- lokale Variablen in Unterprogrammen
  sichtbar: innere Blöcke, Leben: bis Ende Unterpr.

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

```
type Day is ( Mon, Tue, Thu, Fri, Sat, Sun );
subtype Weekday is Day range Mon .. Fri;

procedure Day is
   X, Y : Day;
begin
   X := Fri;      Text_Io.Put (Day'Image(X));
   Y := Succ(X); 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 ($\leq$ 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

$B^A := \{f : A \to B\}$ (Menge aller Funktionen von A nach B)
ist sinnvolle Notation, denn $|B|^{|A|} = \left|B^A\right|$
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.

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.

ein einem Programm: benutze immer anwendungsspezifische Datentypen.

. . . deren externe Syntax spiel überhaupt keine Rolle

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 );
}
```

Probleme mit Zeigern

- verschiedene Namen für gleiche Objekte (aliasing) erschweren Programmanalyse
- tote Zeiger (wg. verfrühter Freigabe)

```
T *p = malloc (...); T *q = p; free (p); .. *q .
```

- Speichermüll (wg. vergessener Freigabe)

```
while (.. )
  { T *p = malloc (...); .. *p .. }
```

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
- nebenläufige Ausführung, Platzbedarf, Zeitgarantien

```
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 Zähler verringern (usw.)
- Zähler brauchen Platz
- Löschen ist aufwendig
- geht 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 nur ein Bit; Zeit $\sim$ Speicher, auch bei viel Müll.
- 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)

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).

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
- Spezialbehandlung für Verweise von alt nach neu

Siehe auch:
Hans Boehm: Allocation and GC Myths `http://www.hpl.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/`
Garbage Collection FAQ `http://java.sun.com/docs/hotspot/gc1.4.2/faq.html`

Übung GC

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)
        }
```

Definitionen

Semantik:

- Ausdruck hat Wert (wird ausgewertet) (Wert hat Typ)
- Anweisung hat Wirkung (wird ausgeführt)

Syntax:

- einfach: Konstante, Variable
- zusammengesetzt: Operator/Funktions-Symbol mit Argumenten

wichtige Spezialfälle für Operatoren:

- arithmetische, relationale, boolesche

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 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");
```

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;
}
```

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*

Ausdrücke mit Nebenwirkungen

(*side effect*; falsche Übersetzung: Seiteneffekt)

- Zuweisungen

```
int a; int b = (a = 5) + (a = 6);
System.out.println (a);
```

- verkürzte Zuweisungen

```
a += b; <==> a = a + b;  (wirklich?)
```

- Inkrement/Dekrement

```
int d = 3; System.out.println ((d++) - (++d));
```

Reihenfolge von Nebenwirkungen

```
int x = 3;
printf ("%d %d %d\n", ++x, ++x, ++x);

int y = 3;
printf ("%d\n", ++y * ++y * ++y);
```

(Übung: swap meat!)

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)
- 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);
  ```

Programm-Ablauf-Steuerung

durch Zusammensetzen von Anweisungen:

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

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 immer 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 `ci`?
- 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. . .

- Bedingung

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

- Zähler

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

- Daten

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

Zählschleifen

- Idee: vor Beginn steht Anzahl der Durchläufe fest.
- dann erhält man die Klasse der primitiv rekursiven Funktionen, die terminieren immer!

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

Schleifen mit Bedingungen

- das ist die allgemeinste Form, ergibt (partielle) rekursive Funktionen,
- die terminieren nicht immer

Steuerung am Anfang oder Ende:

```
while Bedingung Anweisung;

do Anweisung while Bedingung;
```

Abarbeitung von Schleifen

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” (Zeilennr. 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; ..` $\Rightarrow$

```
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;` $\Rightarrow$

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

Anwendung: C-Programme ohne Schlüsselwörter.

setjmp/longjmp in C

Das wird wirklich nicht zur Nachahmung empfohlen:

```
#include <setjmp.h>

static jmp_buf buf;
int dup (int x) { return succ (2*x); }
int succ (int x) { longjmp (buf, 5); }

int main () {
  int x = setjmp(buf);
  int y = x ? 3*x : dup (x);
}
```

siehe auch `http://en.wikipedia.org/wiki/Longjmp`

Was ist hier los?

```
class What {
    public static void main (String [] args) {
        System.out.println ("mozilla:open");
        http://haskell.org
        System.out.println ("mozilla:close");
    }
}
```

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

Beispiele für Unterprogramme (Funktionen)

$$
\begin{aligned}
f(x) &= \textbf{if } x > 100 \textbf{ then } x - 10 \textbf{ else } f\big(f(x+11)\big) \\
t(x,y,z) &= \textbf{if } x \leq y \textbf{ then } y \\
&\quad \textbf{else } t\big(t(x-1,y,z),\ t(y-1,z,x),\ t(z-1,x,y)\big)
\end{aligned}
$$

Aufgaben: $f(7)$, $t(30,20,10)$, allgemein äquivalente nicht rekursive Darstellung
Beobachtung: es ist gar nicht klar,...

- (denotationale Semantik) ... ob solche Gleichungen überhaupt eine oder genau eine Funktion als Lösung haben.
- (operationale Semantik) ... ob und nach welcher Zeit man durch mutiges Ausrechnen Funktionswerte findet.

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 benannten Argument keine positionellen mehr erlaubt

code smell: lange Parameterliste,
refactoring: Parameterobjekt einführen
allerdings fehlt (in Java usw.) 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.

Semantik von Unterprogrammen

Designfragen:

- Typprüfung
- generische Typen?
- Überladung von Namen?
- Wertübergabe
- lokale Unterprogramme erlaubt?
- Bürgerrechte für Unterprogramme?

Typprüfungen

- Typen bei Argumentübergabe und Resultatrückgabe müssen *passen*.
- vgl. Diskussion bei Variablen (Initialisierung, Zuweisung).
-
  - Namensgleichheit
  - Konvertierbarkeit (long → double? usw.)
  - Instantiierung einer Typschablone

Generische Polymorphie

generische Methode:

```
static <E> int length (Collection<E> c) {
  int n = 0; for (E x : c) {n++}; return n;
}
```

hierbei ist *E* eine Typvariable
Bei Benutzung

```
Collection<String> text =
    Arrays.asList (new String [] { "foo", "bar" });
System.out.println (length (text));
```

wird Typvariable instantiiert (durch einen konkreten Typ ersetzt).

Das Überladen von Namen

ein Name mit *verschiedenen* Bedeutungen:

```
void p (String x) { ... }
void p (int    x) { ... }

p ("foo"); p (4);
```

Java: Überladen gestattet, Auflösung durch Liste der Argumenttypen.
Warum geht das folgende nicht?

```
int     f (String x) { ... }
boolean f (String x) { ... }
```

Parameter-Übergabe (Semantik)

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

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

oder über Parameter.
Datentransport (entspr. Schüsselwörtern 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

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
```

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?

Resultate der Umfrage zur Vorlesung

http://www.imn.htwk-leipzig.de/~waldmann/edu/ws06/pps/umfrage/

Warum sind Funktionen wichtig?

- eine Funktion ist ein parametrisiertes Muster.
- die Theorie dafür ist der Lambda-Kalkül (Church, 1936)
- durch (Wieder-)Verwendung von Mustern kann man sich viel Arbeit sparen und Fehler vermeiden
- das hat immense softwaretechnische Bedeutung
- vgl. code smell “duplicated code”, refactoring “introduce method”.

Übersicht

- Funktionen als Daten
- strenges, polymorphes Typsystem
- keine Zuweisungen (nur Deklarationen mit Initialisierung)
- Bedarfs-Auswertung

Funktionen als Daten

ein Datum (Objekt) kann man

- speichern (in Variable, in Struktur)
- übergeben (an und von Unterprogramm)

eine Funktion, deren erstes Argument eine Funktion ist:

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

```
map f xs =
    if null xs then []
    else f (head xs) : map f (tail xs)
```

zweites Argument: Liste von Funktionen

```
map ( \ f -> f 3 ) [ sin, cos, log ]
```

Funktionen als Daten (II)

in anderen Sprachen verfügbar:

- C#: delegates
- C# 3: anonyme Funktionen (Lambda-Ausdrücke)

oder simuliert (Java): Beispiel Strategie-Muster:
ein Objekt, das das gewünschte Unterprogramm als (einzige) Methode hat,
vgl. interface ActionListener

Typsysteme

- statisch (Prüfung zur Übersetzungszeit, nicht zur Laufzeit)
- generisch polymorph
  Bsp: allgemeinster Typ von `map`?

vgl. generische Polymorphie in C++ (STL), Java (Collections Framework)

LISP, Prolog habe dynamisches Typsystem;
ML, Haskell, Mercury statisches.

Deklarative Programmierung

in streng funktionale Sprachen sind alle „Variablen“ tatsächlich Konstanten.

- nur Deklaration mit Initialisierung
- keine Zuweisung, keine Nebenwirkungen

vgl. Code-Richtlinien:

- Unveränderliche Variablen als solche deklarieren
- unveränderliche (immutable) Klassen sind einfacher zu beherrschen
- vgl. zustandsfreie Web-Service-Objekte (Beans)
- vgl. refactoring “introduce state object”

Eifrige (eager) Auswertung

Das geht gut:

```
int fac (int x) {
    if (x>0) { return x * fac (x-1); }
    else     { return 1; }
}
```

aber das nicht (in Java usw.):

```
int if_positive (int x, int j, int n) {
    if (x > 0) { return j; } else { return n;}
}
int fac (int x) {
    return if_positive (x, x*fac(x-1), 1);
}
```

(welche Lösung/Hack in C?)

Bedarfs-Auswertung (faul, lazy)

- in den üblichen imperativen Sprachen werden alle Argumente vor Funktionsaufruf komplett ausgewertet
- das ist bei manchen Umformungen hinderlich (zu eifrige Auswertung)
- in manchen funktionalen Sprachen (LISP und ML nein, Haskell ja) werden alle Argumente erst *bei Bedarf* ausgewertet
- das ist 1. effizient und 2. unsichtbar (es gibt eine Nebenwirkungen dieser Auswertungen)

Unendliche Datenstrukturen

Argumente für Konstruktoren werden auch verzögert ausgewertet, deswegen kann man mit unendlichen Listen, Bäumen usw. rechnen.

```
nats :: [ Int ]
nats = nats_from 0 where
    nats_from n = n : nats_from (n+1)
```

Das geht gut, solange man sich immer nur einen endlichen Teil ansieht

```
take 10 nats  -- OK
take 10 $ map ( \ x -> x * x) nats -- OK
length nats > 20 -- nicht OK
```

Operationen auf Maschinenzahlen sind strikt (erfordern ausgewertete Argumente)

Producer/Transformer/Consumer

```
sum $ map ( \ x -> x ^ 3 ) $ take 20 nats
```

- Datenstrukturen (hier: Listen) werden erzeugt, transformiert, verbraucht.
- die o.g. Notation ist dafür die direkteste,
- bei eifriger Auswertung verbraucht das zuviel Platz,
- man müßte das Programm umschreiben, dadurch wird es unübersichtlich,
- bei Bedarfs-Auswertung benötigt o.g. Programm genauso wenig Platz wie von Hand umgeschriebenes

Programmtransformationen

der Compiler kann Programme umformen, damit Objekte, die gleich wieder konsumiert werden, gar nicht erst erzeugt werden, z. B.

```
map f . map g = map (f . g)
```

Umformungen (refactoring) leicht möglich, da keine Nebenwirkungen zu berücksichtigen.

Dabei ist `(.)` die Funktionskomposition

```
(.) :: ...
(f . g) x = f (g (x))
```

(und zwar falschherum, würde jeder Algebraiker sagen)

Fktl. Modellierg. von Zustandsänderungen

wie schreibt man in Haskell auf die Konsole? Das ist eine Zustandsänderung!

```
main =  putStrLn $ show $ take 20 nats
```

es gibt eine Typschablone `IO a` für Aktionen mit Resultattyp `a`.

```
main :: IO () -- entspr. "void" (kein Resultat)
readFile :: FilePath -> IO String
writeFile :: FilePath -> String -> IO ()
```

solche Aktionen kann man wie Daten verwalten, aber zur Ausführung muß man eine Reihenfolge angeben.
das Typsystem unterscheidet streng `IO Int` (Aktion) von `Int` (Wert), das garantiert Nebenwirkungsfreiheit und damit Sicherheit.

Zusammenfassung

- nicht alle „funktionalen“ Sprachen haben alle genannten Eigenschaften
- auch in modernen imperativen Sprachen kann man mehr oder weniger funktional programmieren
- dieser Stil wird zunehmend durch Richtlinien, Entwurfsmuster, sprachliche Mittel unterstützt
- und wenn nicht: . . . a good programmer can write LISP in any language
- Nachteil heutiger funktionaler Programmierung: ist noch zu stark an konkreten Datentypen (z. B. Listen) orientiert, (Haskell hat kein allgemein akzeptiertes abstraktes Collections-Framework)

Einleitung

Sebesta: Conc. of Prog. Lang., Kap. 13
Nebenläufigkeit: (scheinbar) gleichzeitiges Ausführen von

- Befehlen der Maschinensprache
- Befehlen der Hochsprache
- Unterprogrammen
- Programmen

Arten der Nebenläufigkeit:

- physische NL (mehrere Prozessoren)
- logische NL (mehrere virtuelle P.)

Nebenläufige Unterprogramme

(Task, Thread, Prozeß)
Datenaustausch über

- gemeinsame (nicht-lokale) Variable
- message passing
- Parameter

Probleme:

- ohne Synchronisation: inkonsistente Daten (siehe Beispiel)
- mit Synchronisation: . . .

Shop-Simulation

Ein Angestellter (clerk) verkauft Brötchen an Kunden (customer):

```
public class Customer implements Runnable { ...
  public void run() {
    for (int i = 0; i<items; i++) {
      int x = clerk.get();
} } }
public class Clerk { ...
  private int current = 0;
  public int get() {
    int result = current; current++;
    return result;
} }
```

jedes Brötchen soll genau einmal verkauft werden

Shop-Simulation (II)

```
public static void main(String[] args) {
  Clerk bäcker = new Clerk ();
  for (int i=0; i<3; i++) {
    Customer c = new Customer
      (Integer.toString(i), bäcker, 10);
    new Thread(c).start();
} }
public static void abwarten() {
  int d = (int) Math.random () * 1000;
  Thread.sleep(d);
}
```

Ziele der Synchronisation

- gegenseitiger Ausschluß (competition synch.)
  bei gleichzeitigem Versuch des Zugriffs auf Daten
- Kommunikation (cooperation synch.)
  Datentransport

Synchronisation durch Semaphore

(Dijsktra, ca. 1960)
Semaphor enthält

- natürliche Zahl
- Warteschlange (Queue) für Tasks

Operationen

- *wait*: falls Zähler > 0, dann um eins verringern,
  falls Zähler $= 0$, dann aufrufende Task in Queue und blockieren
- *release*: falls Queue leer, dann Zähler erhöhen,
  falls Queue nicht leer, dann eine Task aus Queue entfernen und aktivieren

Semaphore (II)

- Operationen müssen atomar sein, Realisierung ist Aufgabe des Betriebs/Laufzeitsystems
- S. können Aufgabe des gegenseitigen Ausschlusses (exklusive Ausführung eines Programmteils) lösen
- sind anfällig gegen Programmierfehler
- werden versteckt als Grundlage besser strukturierter Lösungen benutzt
- Bsp: synchronisierte Methoden in Java
  zu jedem Zeitpunkt darf höchstens ein Thread eine synchronized Methode eines Objektes ausführen.

Fünf Philosophen

ein klassisches Beispiel für multi-threading:

- 5 Philosophen.
  Jeder einzelne: denkt, wird hungrig, ißt, denkt, wird hungrig, ißt, ...
- runder Tisch, in der Mitte ein Topf Spaghetti (wird nie alle)
- es gibt zwischen je zwei Tellern genau eine Gabel, zum Essen benötigt man beide.

Die Ressourcen (Gabeln) müssen den Clients (Philosophen) sinnvoll zugeteilt werden, *so daß keiner verhungert*.

Gefahr 1: Deadlock (Verklemmen)

- wechselseitiger Ausschluß (jede Ressource von nur einem Prozeß benutzbar)
- besitzen und warten (Prozeß besitzt bereits Ressourcen und wartet auf weitere)
- kein Ressourcenentzug (kein anderer als der Besitzer-Prozeß selbst kann die Ressource freigeben) (beachte: bis hierher sind es sehr vernünftige Forderungen)
- Zyklisches Warten (jeder Prozeß besitzt wenigstens eine Ressource, auf die ein andere wartet)

Gefahr 2: Unfairness (Verhungern)

falls es einen Ablauf der Ereignisse gibt, bei dem wenigstens ein Prozeß nie die gewünschten Ressourcen erhält.
(. . . weil ihm die anderen abwechselnd alles wegnehmen)

Deadlock?

Dieser Ansatz hat Deadlock (ausprobieren):

```
class Philo {
  void run () {
    while (true) {
      System.out.println (id() + " hat Hunger");
      right.take (this);
      left.take (this);
      System.out.println (id() + " ist satt");
      right.drop (this);
      left.drop (this);
} } }
```

Wie kann man das verhindern?

Eine Gabel (im Prinzip)

```
class Fork {
    private int me;
    String id () { return "Fork-" + me; }
    private boolean taken;
    Fork (int m) { me = m; taken = false; }

    synchronized void drop (Philo p) { .. }
    synchronized void take (Philo p) { .. }
}
```

Ein Philosoph (im Prinzip)

```
class Philo implements Runnable {
  private int me;
  String id () { return "Philo-" + me; }
  private Fork left; private Fork right;
  Philo ( int m, Fork l, Fork r ) {
      me = m; left = l; right = r;
  }
  public void run () {
    while (true) {
      right.take (this); left.take (this);
      right.drop (this); left.drop (this);
    }
  }
}
```

Das Hauptprogramm

```
class Philo { ...
  public static void main (String [] argv) {
    int size = 5;
    Fork  fo [] = new Fork  [size];
    for (int i=0 ; i<size; i++) {
      fo[i] = new Fork (i);
    }
    Philo ph [] = new Philo [size];
    for (int i=0 ; i<size; i++) {
      ph[i] = new Philo
          (i, fo[i], fo[(i+1) % size]);
      new Thread (ph[i]).start ();
} } }
```

Eine Gabel (genauer)

```
class Fork {
  boolean taken;
  synchronized void drop (Philo p) {
    taken = false;
    notify ();
  }
  synchronized void take (Philo p) {
    while (taken) {
        wait ();
    }
    taken = true;
  }
}
```

Eine Gabel (wait/notify)

Durch `wait()` wird der aufrufende Thread angehalten (er wartet auf das Objekt (die Gabel)).
Jedes Objekt hat eine Warteschlange von Threads.
Durch `notify` wird *irgendein* Thread aus der Warteschlange ausgewählt und fortgesetzt.

Synchrone Kommunikation (Rendezvous)

```
task body Server is
   Sum : Integer := 0;
begin loop
      accept Foo (Item : in Integer)
        do Sum := Sum + Item; end Foo;
      accept Bar (Item : out Integer)
        do Item := Sum; end Bar;
   end loop;
end Server;
A : Server; B : Integer;
begin
   A.Foo (4); A.Bar (B); A.Foo (5); A.Bar (B);
end B;
```

Rendezvous (II)

- beide Partner müssen aufeinander warten
- implementiert in Ada
- allgemeinere Form

```
select
     when X < Y =>
     accept Foo (Item : in Integer) do .. end;
  or when Y < Z =>
     accept Bar ( ... )
end select;
```

- viele Fehlermöglichkeiten, Korrektheit nicht offensichtlich
- Server sollte zustandslos sein

Datentransport durch Kanäle

- häufig gibt es eine Trennung:
  - Prozesse erzeugen Daten (producer)
  - Prozesse verbrauchen Daten (consumer)
- Verbindung durch eine Kanal (vgl. Unix: Pipe)
- beschränkte Kapazität des Kanals führt auch zu Synchronisation (producer blockiert, wenn Kanal voll ist)
- mehrere producer können Kanal nach Bedarf nutzen

Kanäle (Beispiel)

```
collector <- newChan
let m = 10
sequence $ do
    d <- [ 0 .. m - 1 ]
    return $ forkIO $ do
        let p = sum [ d , d + m .. n ]
        writeChan collector p
xs <- sequence $ replicate ( fromIntegral m )
                 $ readChan collector
print $ sum xs
```

```
ghc -smp --make Foo -o Foo; ./Foo +RTS -N2
http://hackage.haskell.org/trac/ghc/wiki/GhcConcurrency
http://pugs.blogs.com/pugs/2006/10/smp_paralleliza.html
```

Einleitung

Abstraktion:

- (mehrere) Einzelheiten zusammenfassen
- und gleichzeitig verstecken

typische Formen:

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

Information verstecken

schlecht:`class C { int foo; }`,
besser:

```
class C {  private int foo;
  int getFoo () { return this.foo; }
  void setFoo (int foo) { this.foo = foo; }
}
```

(Eclipse: source: generate getter/setter, refactor: encapsulate field)
. . . am besten

```
class C { private final int foo;
   C (int foo) { this.foo = foo; }
}
```

(Eclipse: generate constructor . . .)

Attribute in C#

(properties, übernommen von Delphi)

```
class C {
   private int foo;
   int Foo {
      get { return this.foo; }
      set { this.foo = value; }
   }
}
C x; C y; ... x.Foo = 1 + y.Foo;
```

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); }
```

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 (run time type information)
- Typschablone bekommt Datum als Argument (dependent types)

Eingeschränkte Polymorphie

`TreeSet<E>` nur dann sinnvoll, wenn die Schlüssel total geordnet sind
Bedingungen an Schablonenparameter stellen:

```
interface Comparable<E> {
   int compareTo (E x);
}
class TreeSet<E implements Comparable<E>> { }
```

Übung: Axiome für totale Ordnungen in Java-API-Doc nachlesen

Strategie-Muster

vorige Folie ist nicht ganz die Wahrheit, weil man eventuell auch eine andere als die natürliche Ordnung benutzen möchte. Deswegen auch Konstruktor

```
TreeSet<E> ( Comparator<E> c );
```

wobei

```
interface Comparator<E> { int compare (E x, E y); }
```

Benutzung z. B. mit anonymer Klasse

```
TreeSet<String> s = new TreeSet<String> (
  new Comparator<String> {
    int compare (String x, String y) {
        return ...
    }
  });
```

Interfaces benutzen

- Variablen immer durch Interface-Typ deklarieren!
  nicht: `TreeMap<Foo,Bar> m;` sondern

  ```
  Map<Foo,Bar> m = new TreeMap<Foo,Bar>();
  ```
- wenn es keinen passenden Interface-Typ gibt, dann selbst einen erfinden
  (Eclipse: refactor: extract interface)
- Beziehungen zwischen Klassen nur durch Beziehungen zwischen Schnittstellen ausdrücken
  häufige, sinnvolle Beziehungsmuster: Entwurfsmuster (design patterns)

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 ...`