

# **Compilerbau**

## **Vorlesung**

### **Wintersemester 2008, 09, 10, 11**

Johannes Waldmann, HTWK Leipzig

30. Januar 2012

# Einleitung

# Beispiel

Eingabe ( $\approx$  Java):

```
{ int i;  
  float prod;  
  float [20] a;  
  float [20] b;  
  prod = 0;  
  i = 1;  
  do {  
    prod = prod  
      + a[i]*b[i];  
    i = i+1;  
  } while (i <= 20);  
}
```

Ausgabe

(Drei-Adress-Code):

```
L1: prod = 0  
L3: i = 1  
L4: t1 = i * 8  
    t2 = a [ t1 ]  
    t3 = i * 8  
    t4 = b [ t3 ]  
    t5 = t2 * t4  
    prod = prod + t5  
L6: i = i + 1  
L5: if i <= 20 goto L4  
L2:
```

# Inhalt

- Motivation, Hintergründe
- lexikalische und syntaktische Analyse (Kombinator-Parser)
- syntaxgesteuerte Übersetzung (Attributgrammatiken)
- Code-Erzeugung (+ Optimierungen)
- statische Typsysteme
- Laufzeitumgebungen

# Sprachverarbeitung

- mit Compiler:
  - Quellprogramm  $\rightarrow$  Compiler  $\rightarrow$  Zielprogramm
  - Eingaben  $\rightarrow$  Zielprogramm  $\rightarrow$  Ausgaben
- mit Interpreter:
  - Quellprogramm, Eingaben  $\rightarrow$  Interpreter  $\rightarrow$  Ausgaben
- Mischform:
  - Quellprogramm  $\rightarrow$  Compiler  $\rightarrow$  Zwischenprogramm
  - Zwischenprogramm, Eingaben  $\rightarrow$  virtuelle Maschine  $\rightarrow$  Ausgaben

# Compiler und andere Werkzeuge

- Quellprogramm
- Präprozessor → modifiziertes Quellprogramm
- Compiler → Assemblerprogramm
- Assembler → verschieblicher Maschinencode
- Linker, Bibliotheken → ausführbares Maschinenprogramm

# Phasen eines Compilers

- Zeichenstrom
- lexikalische Analyse → Tokenstrom
- syntaktische Analyse → Syntaxbaum
- semantische Analyse → annotierter Syntaxbaum
- Zwischencode-Erzeugung → Zwischencode
- maschinenunabhängige Optimierungen → Zwischencode
- Zielcode-Erzeugung → Zielcode
- maschinenabhängige Optimierungen → Zielcode

# Methoden und Modelle

- lexikalische Analyse: reguläre Ausdrücke, endliche Automaten
- syntaktische Analyse: kontextfreie Grammatiken, Kellerautomaten
- semantische Analyse: Attributgrammatiken
- Code-Erzeugung: bei Registerzuordnung: Graphenfärbung



# Anwendungen von Techniken des Compilerbaus

- Implementierung höherer Programmiersprachen
- architekturspezifische Optimierungen (Parallelisierung, Speicherhierarchien)
- Entwurf neuer Architekturen (RISC, spezielle Hardware)
- Programm-Übersetzungen (Binär-Übersetzer, Hardwaresynthese, Datenbankanfragesprachen)
- Software-Werkzeuge

# Literatur

- Franklyn Turbak, David Gifford, Mark Sheldon: *Design Concepts in Programming Languages*, MIT Press, 2008.  
<http://cs.wellesley.edu/~fturbak/>
- Guy Steele, Gerald Sussman: *Lambda: The Ultimate Imperative*, MIT AI Lab Memo AIM-353, 1976  
(the original 'lambda papers',  
<http://library.readscheme.org/page1.html>)
- Alfred V. Aho, Monica S. Lam, Ravi Sethi and Jeffrey D. Ullman: *Compilers: Principles, Techniques, and Tools (2nd edition)* Addison-Wesley, 2007,  
<http://dragonbook.stanford.edu/>

# Organisation

- pro Woche eine Vorlesung, eine Übung.
- Prüfungszulassung: regelmäßiges und erfolgreiches Bearbeiten von Übungsaufgaben
- Prüfung: Klausur (120 min, keine Hilfsmittel)

# Beispiel: Interpreter (I)

arithmetische Ausdrücke:

```
data Exp = Const Integer
         | Plus Exp Exp | Times Exp Exp
  deriving ( Show )

ex1 :: Exp
ex1 = Times ( Plus ( Const 1 ) ( Const 2 ) )

value :: Exp -> Integer
value x = case x of
  Const i -> i
  Plus x y -> value x + value y
  Times x y -> value x * value y
```

# Beispiel: Interpreter (II)

## lokale Variablen und Umgebungen:

```
data Exp = ...
          | Let String Exp Exp | Ref String
ex2 :: Exp
ex2 = Let "x" ( Const 3 )
      ( Times ( Ref "x" ) (Ref "x" ) )
type Env = ( String -> Integer )
value :: Env -> Exp -> Integer
value env x = case x of
  Ref n -> env n
  Let n x b -> value ( \ m ->
    if n == m then value env x else env m ) b
  Const i -> i
  Plus x y -> value env x + value env y
  Times x y -> value env x * value env y
```

# Übung (Haskell)

- Wiederholung Haskell
  - Interpreter/Compiler: `ghci` <http://haskell.org/>
  - Funktionsaufruf nicht `f (a, b, c+d)`, sondern  
`f a b (c+d)`
  - Konstruktor beginnt mit Großbuchstabe und ist auch eine Funktion
- Wiederholung funktionale Programmierung/Entwurfsmuster
  - rekursiver algebraischer Datentyp (ein Typ, mehrere Konstruktoren)  
(OO: Kompositum, ein Interface, mehrere Klassen)

- rekursive Funktion

- Wiederholung Pattern Matching:

- beginnt mit `case ... of`, dann Zweige

- jeder Zweig besteht aus Muster und Folge-Ausdruck

- falls das Muster paßt, werden die Mustervariablen gebunden und der Folge-Ausdruck ausgewertet

# Übung (Interpreter)

- Benutzung:
  - Beispiel für die Verdeckung von Namen bei geschachtelten Let
  - Beispiel dafür, daß der definierte Name während seiner Definition nicht sichtbar ist
- Erweiterung:

Verzweigungen mit C-ähnlicher Semantik:

Bedingung ist arithmetischer Ausdruck, verwende 0 als Falsch und alles andere als Wahr.

```
data Exp = ...
         | If Exp Exp Exp
```



# Umgebungen

Umgebung ist (partielle) Funktion von Name nach Wert

Realisierungen: `type Env = String -> Int`

`import Data.Map ; type Env = Map String Int`

Operationen:

- `empty :: Env` leere Umgebung

- `lookup :: Env -> String -> Int`

Notation:  $e(x)$

- `extend :: Env -> String -> Int -> Env`

Notation:  $e[x/v]$

Spezifikation:

- $e[x/v](x) = v, \quad x \neq y \Rightarrow e[x/v](y) = e(y)$

# Inferenz-Systeme

## Motivation

- inferieren = ableiten
- Inferenzsystem  $I$ , Objekt  $O$ ,  
Eigenschaft  $I \vdash O$  (in  $I$  gibt es eine Ableitung für  $O$ )
- damit ist  $I$  eine *Spezifikation* einer Menge von Objekten
- man ignoriert die *Implementierung* (= das Finden von Ableitungen)
- Anwendungen im Compilerbau:  
Auswertung von Programmen, Typisierung von Programmen

# Definition

ein *Inferenz-System*  $I$  besteht aus

- Regeln (besteht aus Prämissen, Konklusion)

Schreibweise  $\frac{P_1, \dots, P_n}{K}$

- Axiomen (= Regeln ohne Prämissen)

eine *Ableitung* für  $F$  bzgl.  $I$  ist ein Baum:

- jeder Knoten ist mit einer Formel beschriftet
- jeder Knoten (mit Vorgängern) entspricht Regel von  $I$
- Wurzel ist mit  $F$  beschriftet

Schreibweise:  $I \vdash F$

# Inferenz-Systeme (Beispiel 1)

- Grundbereich = Zahlenpaare  $\mathbb{Z} \times \mathbb{Z}$
- Axiom:

$$\overline{(13, 5)}$$

- Regel-Schemata:

$$\frac{(x, y)}{(x - y, y)}, \quad \frac{(x, y)}{(x, y - x)}$$

kann man  $(1, 1)$  ableiten?  $(-1, 5)$ ?  $(2, 4)$ ?

# Inferenz-Systeme (Beispiel 2)

- Grundbereich: Zeichenketten aus  $\{0, 1\}^*$
- Axiom:

$$\overline{01}$$

- Regel-Schemata (für jedes  $u, v$ ):

$$\frac{0u, v0}{u1v}, \quad \frac{1u, v1}{u0v}, \quad \frac{u}{\text{reverse}(u)}$$

Leite 11001 ab. Wieviele Wörter der Länge  $k$  sind ableitbar?

# Inferenz-Systeme (Beispiel 3)

- Grundbereich: endliche Folgen von ganzen Zahlen
- Axiome: jede konstante Folge (Bsp.  $[3, 3, 3, 3]$ )

$$\text{– swap}_k: \frac{[\dots, x_k, x_{k+1}, \dots]}{[\dots, x_{k+1} + 1, x_k - 1, \dots]}$$

- Schlußregeln:

$$\text{– rotate: } \frac{[x_1, \dots, x_n]}{[x_2, \dots, x_n, x_1]}$$

Aufgaben: • Ableitungen für  $[5, 3, 1, 3]$ ,  $[7, 7, 1]$

- jede Folge der Form  $[z, 0, \dots, 0]$  ist ableitbar
- Invarianten,  $[5, 3, 3]$  ist nicht ableitbar

praktische Realisierung: <http://www.siteswap.org/>  
und HTWK-Hochschulsport

# Inferenz von Werten

- Grundbereich: Aussagen der Form  $\text{wert}(p, z)$  mit  $p \in \text{Exp}$ ,  $z \in \mathbb{Z}$

```
data Exp = Const Integer
         | Plus Exp Exp
         | Times Exp Exp
```

- Axiome:  $\text{wert}(\text{Const } z, z)$

- Regeln:

$$\frac{\text{wert}(X, a), \text{wert}(Y, b)}{\text{wert}(\text{Plus } X \ Y, a + b)}, \quad \frac{\text{wert}(X, a), \text{wert}(Y, b)}{\text{wert}(\text{Times } X \ Y, a \cdot b)}, \dots$$

# Umgebungen

- Grundbereich: Aussagen der Form  $\text{wert}(E, p, z)$

(in Umgebung  $E$  hat Programm  $p$  den Wert  $z$ )

Umgebungen konstruiert aus  $\emptyset$  und  $E[v := p]$

- Regeln für Operatoren  $\frac{\text{wert}(E, X, a), \text{wert}(E, Y, b)}{\text{wert}(E, \text{Plus } XY, a + b)}, \dots$

- Regeln für Umgebungen

$$\frac{}{\text{wert}(E[v := b], v, b)}, \quad \frac{\text{wert}(E, v', b')}{\text{wert}(E[v := b], v', b')} \text{ für } v \neq v'$$

- Regeln für Bindung:  $\frac{\text{wert}(E, X, b), \text{wert}(E[v := b], Y, c)}{\text{wert}(E, \text{let } v = X \text{ in } Y, c)}$



# Aussagenlogische Resolution

Formel  $(A \vee \neg B \vee \neg C) \wedge (C \vee D)$  in konjunktiver Normalform dargestellt als  $\{\{A, \neg B, \neg C\}, \{C, D\}\}$

(Formel = Menge von Klauseln, Klausel = Menge von Literalen, Literal = Variable oder negierte Variable)

folgendes Inferenzsystem heißt *Resolution*:

- Axiome: Klauselmenge einer Formel,
- Regel:
  - Prämissen: Klauseln  $K_1, K_2$  mit  $v \in K_1, \neg v \in K_2$
  - Konklusion:  $(K_1 \setminus \{v\}) \cup (K_2 \setminus \{\neg v\})$

# Resolution (Eigenschaften)

*die Formel (Klauselmengemenge) ist nicht erfüllbar  $\iff$  die leere Klausel ist durch Resolution ableitbar.*

Beweispläne:

- $\Rightarrow$  : Gegeben ist die nicht erfüllbare Formel. Gesucht ist eine Ableitung für die leere Klausel. Methode: Induktion nach Anzahl der in der Formel vorkommenden Variablen.
- $\Leftarrow$  : Gegeben ist die Ableitung der leeren Klausel. Zu zeigen ist die Nichterfüllbarkeit der Formel. Methode: Induktion nach Höhe des Ableitungsbaumes.

# Semantische Bereiche

bisher: Wert eines Ausdrucks ist Zahl.

jetzt erweitern (Motivation: if-then-else mit richtigem Typ):

```
data Val = ValInt Int
         | ValBool Bool
```

Dann brauchen wir auch

- `data Val = ... | ValErr String`

- vernünftige Notation (Kombinatoren) zur Einsparung von Fallunterscheidungen bei Verkettung von Rechnungen

```
with_int :: Val -> (Int -> Val) -> Val
```

# Continuations

Programmablauf-Abstraktion durch Continuations:

Definition:

```
with_int    :: Val -> (Int  -> Val) -> Val
with_int v k = case v of
  ValInt i -> k i
  _        -> ValErr "expected ValInt"
```

Benutzung:

```
value env x = case x of
  Plus l r ->
    with_int ( value env l ) $ \ i ->
    with_int ( value env r ) $ \ j ->
    ValInt ( i + j )
```

**Aufgabe:** if/then/else mit `with_bool`

# Unterprogramme

## Beispiele

- in verschiedenen Prog.-Sprachen gibt es verschiedene Formen von Unterprogrammen:  
Prozedur, sog. Funktion, Methode, Operator, Delegate, anonymes Unterprogramm
- allgemeinstes Modell: Kalkül der anonymen Funktionen (Lambda-Kalkül),

# Interpreter mit Funktionen

abstrakte Syntax:

```
data Exp = ...  
  | Abs { formal :: Name , body :: Exp }  
  | App { rator :: Exp , rand :: Exp }
```

konkrete Syntax (Beispiel):

```
let { f = \ x -> x * x } in f (f 3)
```

# Semantik

erweitere den Bereich der Werte:

```
data Val = ... | ValFun ( Value -> Value )
```

erweitere Interpreter:

```
value :: Env -> Exp -> Val
```

```
value env x = case x of
```

```
  ...
```

```
  Abs { } ->
```

```
  App { } ->
```

mit Hilfsfunktion

```
with_fun :: Val -> ...
```

# Testfall (1)

```
let { x = 4 }  
in let { f = \ y -> x * y }  
    in let { x = 5 }  
        in f x
```



# Closures

bisher:

```
eval env x = case x of ...
  Abs n b -> ValFun $ \ v ->
    eval (extend env n v) b
  App f a ->
    with_fun ( eval env f ) $ \ g ->
    with_val ( eval env a ) $ \ v -> g v
```

alternativ: die Umgebung von `Abs` in die Zukunft transportieren:

```
eval env x = case x of ...
  Abs n b -> ValClos env n b
  App f a -> ...
```

# Der Lambda-Kalkül

(Alonzo Church, 1936) Syntax:

- Variablen  $x, y, \dots$
- Applikationen  $xx, (\lambda x.xx)y$
- Abstraktionen  $\lambda x.xx, \lambda x.(\lambda y.x)$

Begriffe: freie Variablen (FV), gebundene Variablen (BV),

# Small-Step-Semantik des Lambda-Kalküls

Basis-Operation ist  $A[x/B]$ :

ersetze jedes freie Vorkommen von  $x$  in  $A$  durch  $B$

- $\beta$ -Konversion:

$$(\lambda x.A)B \rightarrow_{\beta} A[x/B]$$

wobei  $FV(B)$  disjunkt zu  $BV(A)$

- $\alpha$ -Konversion: gebundene Umbenennung

$$(\lambda x.A) \rightarrow_{\alpha} (\lambda y.A[x/y])$$

... und Abschluß unter Kontext (Inferenz-System?)

Bemerkungen:

- warum ist die Bedingung bei  $\rightarrow_{\beta}$  nötig? (Beispiele)

# Mehrstellige Funktionen

... simulieren durch einstellige:

- Abstraktion:  $\lambda xyz.B := \lambda x.\lambda y.\lambda z.B$
- Applikation:  $fPQR := ((fP)Q)R$

weiterer *syntactic sugar*:

```
let { f x = A } in B  
let { f = \ x -> A } in B
```

# Let und Lambda

- `let { x = A } in Q`

kann übersetzt werden in

`(\ x -> Q) A`

- `let { x = a , y = b } in Q`

wird übersetzt in ...

- beachte: das ist nicht das `let` aus Haskell

# Rekursion?

- Das geht nicht, und soll auch nicht gehen:

```
let { x = 1 + x } in x
```

- aber das hätten wir doch gern:

```
let { f = \ x -> if x > 0
      then x * f (x -1) else 1
      } in f 5
```

(nächste Woche)

- aber auch mit nicht rekursiven Funktionen kann man interessante Programme schreiben:

## Testfall (2)

```
let { t f x = f (f x) }  
in  let { s x = x + 1 }  
      in  t t t t s 0
```

- auf dem Papier den Wert bestimmen
- mit Haskell ausrechnen
- mit selbstgebaudem Interpreter ausrechnen

# Fixpunkte

## Motivation

Das geht bisher gar nicht:

```
let { f = \ x -> if x > 0
      then x * f (x - 1) else 1
    } in f 5
```

(Bezeichner  $f$  ist nicht sichtbar)

Lösung:

```
( rec f ( \ x -> if x > 0
              then x * f (x - 1) else 1 ))
```

mit neuem AST-Knotentyp `rec`



# Rekursion

abstrakt:

```
data Exp = ...  
        | Rec Name Exp
```

Semantik von `Rec n b` in Umgebung  $E$

ist der Fixpunkt der Funktion (vom Typ  $\text{Val} \rightarrow \text{Val}$ )

$\lambda c.$ Semantik von  $b$  in  $E[n/c]$

# Existenz von Fixpunkten

Fixpunkt von  $f :: C \rightarrow C$  ist  $x :: C$  mit  $fx = x$ .

Existenz? Eindeutigkeit? Konstruktion?

Satz: Wenn  $C$  *pointed CPO* und  $f$  *stetig*, dann besitzt  $f$  genau einen kleinsten Fixpunkt.

Begriffe:

- CPO = complete partial order = vollständige Halbordnung
- complete = jede monotone Folge besitzt Supremum (= kleinste obere Schranke)
- pointed:  $C$  hat kleinstes Element  $\perp$
- stetig:  $f(\sup \vec{x}) = \sup f(\vec{x})$

Dann  $\text{fix}(f) = \sup[\perp, f(\perp), f^2(\perp), \dots]$

# Funktionen als CPO

- partielle Funktionen  $C = (B \rightarrow B)$
- Bereich  $B \cup \perp$  geordnet durch  $\forall x \in B : \perp < x$
- $C$  geordnet durch  $f \leq g \iff \forall x \in B : f(x) \leq g(x)$ ,
- d. h.  $g$  ist Verfeinerung von  $f$
- Das Bottom-Element von  $C$  ist die überall undefinierte Funktion.

# Funktionen als CPO, Beispiel

Wert von

```
rec f ( \ x -> if (x==0) then 1
          else x * f (x - 1) )
```

ist Fixpunkt der Funktion  $F =$

```
\ f -> ( \ x -> if (x==0) then 1
          else x * f (x - 1) )
```

Iterative Berechnung des Fixpunktes:

$\perp = \emptyset$  überall undefiniert

$F \perp = \{(0, 1)\}$  sonst  $\perp$

$F(F \perp) = \{(0, 1), (1, 1)\}$  sonst  $\perp$

$F^3 \perp = \{(0, 1), (1, 1), (2, 2)\}$  sonst  $\perp$

# Rechnen im Lambda-Kalkül

## Daten als Funktionen

Simulation von Daten (Tupel)  
durch Funktionen (Lambda-Ausdrücke):

- Konstruktor:  $\langle D_1, \dots, D_k \rangle \Rightarrow \lambda s. s D_1 \dots D_k$
- Selektoren:  $s_i \Rightarrow \lambda t. t(\lambda d_1 \dots d_k. d_i)$

dann gilt  $s_i \langle D_1, \dots, D_k \rangle \rightarrow_{\beta}^* D_i$

Anwendungen:

- Auflösung simultaner Rekursion
- Modellierung von Zahlen

# Lambda-Kalkül als universelles Modell

- Wahrheitswerte:

$$\text{True} = \lambda xy.x, \text{False} = \lambda xy.y$$

(damit läßt sich if-then-else leicht aufschreiben)

- natürliche Zahlen:

$$0 = \lambda x.x; (n + 1) = \langle \text{False}, n \rangle$$

(damit kann man leicht  $x > 0$  testen)

- Rekursion?

# Fixpunkt-Kombinatoren

- Definition:  $Y := \lambda f.((\lambda x.f(xx))(\lambda x.f(xx)))$
- Satz:  $Y f$  ist Fixpunkt von  $f$
- d.h.  $Y$  ist *Fixpunkt-Kombinator*
- Beweis: vergleiche  $(Y f)$  und  $f(Y f)$

wir benutzen eine Variante des  $Y$ :

$$Y' = \lambda f.(\lambda x.f(\lambda y.xxy))(\lambda x.f(\lambda y.xxy)),$$

weil sonst die Aufrufe  $(xx)$  nicht halten würden.

Ü: weitere Fixpunktkombinatoren,

$$\Theta = (\lambda xy.(y(xxy)))(\lambda xy.(y(xxy)))$$

# Lambda-Berechenbarkeit

*Satz:* (Church, Turing)

Menge der Turing-berechenbaren Funktionen  
(Zahlen als Wörter auf Band)

= Menge der while-berechenbaren Funktionen  
(Zahlen als Registerinhalte)

= Menge der Lambda-berechenbaren Funktionen  
(Zahlen als Lambda-Ausdrücke)



# Übung Fixpunkte

- Fixpunkt der Folge  $F^k(\perp)$  für

```
F h = \ x -> if x > 23 then x - 11
           else h (h (x + 14))
```

- Fixpunkt der Folge  $F^k(\perp)$  für

```
F h = \ x -> if x > 10 then x + 11
           else h (2 * x - 8)
```

- Turing-Fixpunkt-Kombinator mit Lambda-Calculator

http:

//joerg.endrullis.de/lambdaCalculator/

- Tupel-Konstruktor und Selektoren als Ausdrücke im Interpreter
- gegenseitige Rekursion  $(f, g)$  als Fixpunkt ( $\text{Rec}$ ) einer geeigneten Funktion (benutzt Tupel)
- Hausaufgabe: vorige Aufgabe (im Interpreter) ohne  $\text{Rec}$ , sondern mit einem Fixpunkt-Kombinator

# letrec

Beispiel (aus: D. Hofstadter, GEB)

```
letrec { f = \ x -> if x == 0 then 1
        else x - g(f(x-1))
        , g = \ x -> if x == 0 then 0
        else x - f(g(x-1))
} in f 15
```

Bastelaufgabe: für welche  $x$  gilt  $f(x) \neq g(x)$ ?

AST-Knoten:

```
data Exp = ... | LetRec [(Name, Exp)] Exp
```

weitere Beispiele:

```
letrec { x = 3 + 4 , y = x * x } in x - y
letrec { f = \ x -> .. f (x-1) } in f 3
```

# letrec nach rec

mithilfe der Lambda-Ausdrücke für select und tuple

```
LetRec [(n1, x1), .. (nk, xk)] y
=> ( rec t
      ( let n1 = select1 t
          ...
          nk = selectk t
          in tuple x1 .. xk ) )
( \ n1 .. nk -> y )
```

# Zustand/Speicher

## Motivation

bisherige Programme sind nebenwirkungsfrei, das ist nicht immer erwünscht:

- direktes Rechnen auf von-Neumann-Maschine:  
Änderungen im Hauptspeicher
- direkte Modellierung von Prozessen mit  
Zustandsänderungen ((endl.) Automaten)

Dazu muß semantischer Bereich geändert werden.

- **bisher:** `Val`, **jetzt:** `State -> (State, Val)`

Semantik von (Teil-)Programmen ist Zustandsänderung.

# Speicher

## Modellierung:

```
import qualified Data.Map as M
newtype Addr = Addr Int
type Store = M.Map Addr Val
newtype Action a =
    Action ( Store -> ( Store, a ) )
```

## spezifische Aktionen:

```
new :: Val -> Action Addr
get  :: Addr -> Action Val
put  :: Addr -> Val -> Action ()
```

## Aktion ausführen, Resultat liefern:

```
run :: Store -> Action a -> a
```

# Auswertung von Ausdrücken

Ausdrücke (mit Nebenwirkungen):

```
data Exp = ...
  | New Exp | Get Exp | Put Exp Exp
```

Resultattyp des Interpreters ändern:

```
value      :: Env -> Exp -> Val
evaluate   :: Env -> Exp -> Action Val
```

semantischen Bereich erweitern:

```
data Val = ...
  | ValAddr Addr
  | ValFun ( Val -> Action Val )
```

Aufruf des Interpreters:

```
run Store.empty $ evaluate undefined $ ...
```

# Änderung der Hilfsfunktionen

bisher:

```
with_int :: Val -> ( Int -> Val ) -> Val
with_int v k = case v of
  ValInt i -> k i
  v -> ValErr "ValInt expected"
```

jetzt:

```
with_int :: Action Val
  -> ( Int -> Action Val ) -> Action Val
with_int m k = m >>= \ v -> case v of ...
```

Hauptprogramm muß kaum geändert werden (!)



# Speicher-Aktionen als Monade

generische Aktionen/Verknüpfungen:

- nichts tun (return), • nacheinander (bind, >>=)

```
class Monad m where
  return :: a -> m a
  (>>=)  :: m a
          -> (a -> m b) -- Continuation
          -> m b
```

```
instance Monad Action where
  return x = Action $ \ s -> ( s, x )
  Action a >>= f = Action $ \ s -> ...
```

# Rekursion

... wird benötigt für Wiederholungen (Schleifen).  
mehrere Möglichkeiten zur Realisierung

- mit Fixpunkt-Kombinator
- semantisch (in der Gastsprache des Interpreters)
- (neu:) operational unter Benutzung des Speichers

# Rekursion (operational)

Idee: eine Speicherstelle anlegen und als Vorwärtsreferenz auf das Resultat der Rekursion benutzen

```
evaluate env x = case x of ...
```

```
  Rec n ( Abs x b ) ->
```

```
    new ( ValErr "Rec" ) >>= \ a ->
```

```
      with ( evaluate
```

```
        ( extend env n ... )
```

```
        ( Abs x ... ) ) $ \ v ->
```

```
        put a v >>= \ () ->
```

```
        return v
```

# Rekursion (semantisch)

bisher:

```
fix :: ( a -> a ) -> a
fix f = f ( fix f )
```

jetzt:

```
import Control.Monad.Fix
class MonadFix m where
    mfix :: ( a -> m a ) -> m a

instance MonadFix Action where
mfix f = Action $ \ s0 ->
    let Action a = f v
        ( s1, v ) = a s0
    in ( s1, v )
```

# Speicher—Übung

Code aus Vorlesung:

```
http://dfa.imn.htwk-leipzig.de/cgi-bin/  
gitweb.cgi?p=ws11-cb.git
```

```
git clone git://dfa.imn.htwk-leipzig.de/srv/
```

Fakultät imperativ:

```
let { fak = \ n ->  
    { a := new 1 ;  
      while ( n > 0 )  
        { a := a * n ; n := n - 1 ; }  
      return a ;  
    }  
  } in fak 5
```

1. Schleife durch Rekursion ersetzen und Sequenz durch  
let:

```
fak = let { a = new 1 }  
      in Rec f ( \ n -> ... )
```

2. Syntaxbaumtyp erweitern um Knoten für Sequenz und  
Schleife

# Monaden

## Die Konstruktorklasse Monad

Definition:

```
class Monad c where
  return    :: a -> c a
  ( >>= )   :: c a -> (a -> c b) -> c b
```

Benutzung der Methoden:

```
evaluate e l >>= \ a ->
evaluate e r >>= \ b ->
return ( a + b )
```

# Do-Notation für Monaden

```
evaluate e l >>= \ a ->  
    evaluate e r >>= \ b ->  
        return ( a + b )
```

**do-Notation (explizit geklammert):**

```
do { a <- evaluate e l  
    ; b <- evaluate e r  
    ; return ( a + b )  
}
```

**do-Notation (implizit geklammert):**

```
do a <- evaluate e l  
   b <- evaluate e r  
   return ( a + b )
```

**Haskell: implizite Klammerung nach let, do, case, where**



# Die Zustands-Monade

## Implementierung:

```
data State s a = State ( s -> ( s, a ) )  
instance Monad ( State s ) where ...
```

## Benutzung:

```
import Control.Monad.State  
  
tick :: State Integer ()  
tick = do c <- get ; put $ c + 1  
  
evalState ( do tick ; tick ; get ) 0
```

# List als Monade

```
instance Monad [] where
  return = \ x -> [x]
  m >>= f = case m of
    []      -> []
    x : xs  -> f x ++ ( xs >>= f )

do a <- [ 1 .. 4 ]
   b <- [ 2 .. 3 ]
   return ( a * b )
```

# Kombinator-Parser

## Datentyp für Parser

```
data Parser c a =  
  Parser ( [c] -> [ (a, [c]) ] )
```

- über Eingabestrom von Zeichen (Token)  $c$ ,
- mit Resultattyp  $a$ ,
- nichtdeterministisch (List).

Beispiel-Parser, Aufrufen mit:

```
parse :: Parser c a -> [c] -> [(a, [c])]  
parse (Parser f) w = f w
```

# Elementare Parser (I)

```
-- | das nächste Token
next :: Parser c c
next = Parser $ \ toks -> case toks of
  [] -> []
  ( t : ts ) -> [ ( t, ts ) ]
-- | das Ende des Tokenstroms
eof :: Parser c ()
eof = Parser $ \ toks -> case toks of
  [] -> [ ( (), [] ) ]
  _ -> []
-- | niemals erfolgreich
reject :: Parser c a
reject = Parser $ \ toks -> []
```

# Monadisches Verketteten von Parsern

```
instance Monad ( Parser c ) where
  return x = Parser $ \ s ->
    return ( x, s )
  Parser f >>= g = Parser $ \ s -> do
    ( a, t ) <- f s
    let Parser h = g a
        h t
```

beachte: das *return/do* gehört zur List-Monade

```
p :: Parser c (c, c)
p = do x <- next ; y <- next ; return (x, y)
```

# Elementare Parser (II)

```
satisfy :: ( c -> Bool ) -> Parser c c
```

```
satisfy p = do
```

```
  x <- next
```

```
  if p x then return x else reject
```

```
expect :: Eq c => c -> Parser c c
```

```
expect c = satisfy ( == c )
```

```
ziffer :: Parser Char Integer
```

```
ziffer = do
```

```
  c <- satisfy Data.Char.isDigit
```

```
  return $ fromIntegral
```

```
    $ fromEnum c - fromEnum '0'
```

# Kombinatoren für Parser (I)

- Folge (and then) (ist  $>>=$  aus der Monade)
- Auswahl (or)

```
( <|> ) :: Parser c a -> Parser c a -> Parser c a
Parser f <|> Parser g = Parser $ \ s -> f s ++ g s
```

- Wiederholung (beliebig viele)

```
many, many1 :: Parser c a -> Parser c [a]
many p = many1 p <|> return []
many1 p = do x <- p; xs <- many p; return $ x : xs
```

```
zahl :: Parser Char Integer = do
  zs <- many1 ziffer
  return $ foldl ( \ a z -> 10*a+z ) 0 zs
```

# Kombinator-Parser und Grammatiken

Grammatik mit Regeln  $S \rightarrow aSbS, S \rightarrow \epsilon$  entspricht

```
s :: Parser Char ()
```

```
s = do { expect 'a' ; s ; expect 'b' ; s }
```

```
<|> return ()
```

Anwendung: `exec "abab" $ do s ; eof`



# Robuste Parser-Bibliotheken

Designfragen:

- asymmetrisches  $\langle | \rangle$
- Nichtdeterminismus einschränken
- Fehlermeldungen (Quelltextposition)

Beispiel: Parsec (Autor: Daan Leijen)

`http://www.haskell.org/haskellwiki/Parsec`

# Asymmetrische Komposition

gemeinsam:

$(\langle | \rangle) :: \text{Parser } c \ a \ -> \text{Parser } c \ a$   
 $\quad \quad \quad -> \text{Parser } c \ a$

$\text{Parser } p \ \langle | \rangle \ \text{Parser } q = \text{Parser } \$ \ \backslash \ s \ -> \dots$

- **symmetrisch:**  $p \ s \ ++ \ q \ s$
- **asymmetrisch:**  $\text{if null } p \ s \ \text{then } q \ s \ \text{else } p \ s$

Anwendung: `many` liefert nur maximal mögliche  
Wiederholung (nicht auch alle kürzeren)

# Nichtdeterminismus einschränken

- Nichtdeterminismus = Berechnungsbaum = Backtracking
- asymmetrisches  $p < | > q$  : probiere erst  $p$ , dann  $q$
- häufiger Fall:  $p$  lehnt „sofort“ ab

Festlegung (in Parsec): wenn  $p$  wenigstens ein Zeichen verbraucht, dann wird  $q$  nicht benutzt (d. h.  $p$  muß erfolgreich sein)

Backtracking dann nur durch `try p < | > q`

# Fehlermeldungen

- Fehler = Position im Eingabestrom, bei der es „nicht weitergeht“
- und auch durch Backtracking keine Fortsetzung gefunden wird
- Fehlermeldung enthält:
  - Position
  - Inhalt (Zeichen) der Position
  - Menge der Zeichen mit Fortsetzung

# Pretty-Printing (I)

John Hughes's and Simon Peyton Jones's Pretty Printer Combinators

Based on *The Design of a Pretty-printing Library* in *Advanced Functional Programming*, Johan Jeuring and Erik Meijer (eds), LNCS 925

`http://hackage.haskell.org/packages/archive/pretty/1.0.1.0/doc/html/Text-PrettyPrint-HughesPJ.html`

# Pretty-Printing (II)

- `data Doc` abstrakter Dokumententyp, repräsentiert Textblöcke

- Konstruktoren:

```
text :: String -> Doc
```

- Kombinatoren:

```
vcat      :: [ Doc ] -> Doc -- vertikal
```

```
hcat, hsep :: [ Doc ] -> Doc -- horizontal
```

- **Ausgabe:** `render :: Doc -> String`

# Ablaufsteuerung/Continuations

## Definition

(alles nach: Turbak/Gifford Ch. 17.9)

CPS-Transformation (continuation passing style):

- original: Funktion gibt Wert zurück

$$f == (\text{abs } (x \ y) \ (\text{let } ( \dots ) \ v))$$

- cps: Funktion erhält zusätzliches Argument, das ist eine *Fortsetzung* (continuation), die den Wert verarbeitet:

$$f\text{-cps} == (\text{abs } (x \ y \ k) \ (\text{let } ( \dots ) \ (k \ v)))$$

**aus**  $g \ (f \ 3 \ 2)$  **wird**  $f\text{-cps} \ 3 \ 2 \ g\text{-cps}$

# Motivation

Funktionsaufrufe in CPS-Programm kehren nie zurück, können also als Sprünge implementiert werden!

CPS als einheitlicher Mechanismus für

- Linearisierung (sequentielle Anordnung von primitiven Operationen)
- Ablaufsteuerung (Schleifen, nicht lokale Sprünge)
- Unterprogramme (Übergabe von Argumenten und Resultat)
- Unterprogramme mit mehreren Resultaten



# CPS für Linearisierung

$(a + b) * (c + d)$  wird übersetzt (linearisiert) in

```
( \ top ->  
  plus a b $ \ x ->  
  plus c d $ \ y ->  
  mal  x y top  
) ( \ z -> z )
```

$\text{plus } x \ y \ k = k \ (x + y)$

$\text{mal } x \ y \ k = k \ (x * y)$

später tatsächlich als Programmtransformation  
(Kompilation)

# CPS für Resultat-Tupel

wie modelliert man Funktion mit mehreren Rückgabewerten?

- benutze Datentyp Tupel (Paar):

$$f : A \rightarrow (B, C)$$

- benutze Continuation:

$$f/cps : A \rightarrow (B \rightarrow C \rightarrow D) \rightarrow D$$

# CPS/Tupel-Beispiel

erweiterter Euklidischer Algorithmus:

```
prop_egcd x y =  
  let (p,q) = egcd x y  
  in (p*x + q*y) == gcd x y
```

```
egcd :: Integer -> Integer  
      -> ( Integer, Integer )
```

```
egcd x y = if y == 0 then ???  
           else let (d,m) = divMod x y  
                  (p,q) = egcd y m  
                  in ???
```

vervollständige, übersetze in CPS

# CPS für Ablaufsteuerung

## Beispiel label/jump

```
1 + label exit (2 * (3 - (4 + jump exit 5)))
```

## Vergleiche:

- `label <name>` **deklariert Exception-Handler**
- `jump <name>` **springt zum Handler**

# Semantik für CPS

Semantik von Ausdruck  $x$  in Umgebung  $E$   
ist Funktion von Continuation nach Wert (Action)

$$\begin{aligned} \text{value}(E, \text{label } L \ B) &= \lambda k \rightarrow \\ &\quad \text{value}(E[L/k], B) \ k \\ \text{value}(E, \text{jump } L \ B) &= \lambda k \rightarrow \\ &\quad \text{value}(E, L) \ \$ \ \lambda k' \rightarrow \\ &\quad \text{value}(E, B) \ k' \end{aligned}$$

**Beispiel 1:**

$$\begin{aligned} \text{value}(E, \text{label } x \ x) & \\ &= \lambda k \rightarrow \text{value}(E[x/k], x) \ k \\ &= \lambda k \rightarrow k \ k \end{aligned}$$

## Beispiel 2

value (E, jump (label x x) (label y y))

= \ k ->

value (E, label x x) \$ \ k' ->

value (E, label y y) k'

= \ k ->

value (E, label y y) (value (E, label x x)

= \ k -> ( \ k0 -> k0 k0 ) ( \ k1 -> k1 k1 )

# Semantik

semantischer Bereich:

```
type Continuation a = a -> Action Val
data CPS a
    = CPS ( Continuation a -> Action Val )
evaluate :: Env -> Exp -> CPS Val
```

Plan:

- **Syntax:** Label, Jump, Parser
- **Semantik:**
  - Verkettung durch `>>=` `aus` instance Monad CPS
  - Einbetten von `Action Val` durch `lift`
  - evaluate für bestehende Sprache (CBV)
  - evaluate für label und jump

# CPS als Monade

```
feed :: CPS a -> ( a -> Action Val )  
      -> Action Val
```

```
feed ( CPS s ) c = s c
```

```
feed ( s >>= f ) c =  
  feed s ( \ x -> feed ( f x ) c )
```

```
feed ( return x ) c = c x
```

```
lift :: Action a -> CPS a
```



# Übung CPS

- Parser für `Label String Exp, Jump Exp Exp`
- Continuations als Werte (von Argumenten und Resultaten von Unterprogrammen)
- Rekursion (bzw. Schleifen) mittels Label/Jump (und ohne Rec oder Fixpunkt-Kombinator)
- `jump (label x x) (label y y)`

# Typen

## Grundlagen

Typ = statische Semantik

(Information über mögliches Programm-Verhalten, erhalten ohne Programm-Ausführung)

formale Beschreibung:

- $P$ : Menge der Ausdrücke (Programme)
- $T$ : Menge der Typen
- Aussagen  $p :: t$  (für  $p \in P, t \in T$ )
  - prüfen oder
  - herleiten (inferieren)

# Inferenzsystem für Typen (Syntax)

- Grundbereich: Aussagen der Form  $E \vdash X : T$   
(in Umgebung  $E$  hat Ausdruck  $X$  den Typ  $T$ )
- Menge der Typen:
  - primitiv: Int, Bool
  - zusammengesetzt:
    - \* Funktion  $T_1 \rightarrow T_2$
    - \* Verweistyp  $\text{Ref } T$
    - \* Tupel  $(T_1, \dots, T_n)$ , einschl.  $n = 0$
- Umgebung bildet Namen auf Typen ab

# Inferenzsystem für Typen (Semantik)

- Axiome f. Literale:  $E \vdash \text{Zahl-Literal} : \text{Int}, \dots$
- Regel für prim. Operationen: 
$$\frac{E \vdash X : \text{Int}, E \vdash Y : \text{Int}}{E \vdash (X + Y) : \text{Int}}, \dots$$
- Abstraktion/Applikation:  $\dots$
- Binden/Benutzen von Bindungen:  $\dots$

hierbei (vorläufige) Design-Entscheidungen:

- Typ eines Ausdrucks wird inferiert
- Typ eines Bezeichners wird  $\dots$ 
  - in Abstraktion: deklariert
  - in Let: inferiert

# Inferenz für Let

(alles ganz analog zu Auswertung von Ausdrücken)

- Regeln für Umgebungen

- $E[v := t] \vdash v : t$

- $$\frac{E \vdash v' : t'}{E[v := t] \vdash v' : t'} \text{ für } v \neq v'$$

- Regeln für Bindung:

$$\frac{E \vdash X : s, \quad E[v := s] \vdash Y : t}{E \vdash \text{let } v = X \text{ in } Y : t}$$

# Applikation und Abstraktion

- Applikation:

$$\frac{E \vdash F : T_1 \rightarrow T_2, \quad E \vdash A : T_1}{E \vdash (FA) : T_2}$$

vergleiche mit *modus ponens*

- Abstraktion (mit deklariertem Typ der Variablen)

$$\frac{E[v := T_1] \vdash X : T_2}{E \vdash (\lambda(v :: T_1)X) : T_1 \rightarrow T_2}$$

# Eigenschaften des Typsystems

Wir haben hier den *einfach getypten Lambda-Kalkül* nachgebaut:

- jedes Programm hat höchstens einen Typ
- nicht jedes Programm hat einen Typ.

Der *Y*-Kombinator  $(\lambda x.xx)(\lambda x.xx)$  hat keinen Typ

- jedes getypte Programm terminiert

(Begründung: bei jeder Applikation  $FA$  ist der Typ von  $FA$  kleiner als der Typ von  $F$ )

Übung: typisiere  $t \ t \ t \ t \ \text{succ} \ 0$  mit

$\text{succ} = \lambda x \rightarrow x + 1$  und  $t = \lambda f \ x \rightarrow f \ (f \ x)$

# Polymorphe Typen

## Motivation

ungetypt:

```
let { t = \ f x -> f (f x)
      ; s = \ x -> x + 1
      } in (t t s) 0
```

einfach getypt nur so möglich:

```
let { t2 = \ (f :: (Int -> Int) -> (Int -> I
              (x :: Int -> Int) -> f (f x)
      ; t1 = \ (f :: Int -> Int) (x :: Int) ->
      ; s = \ (x :: Int) -> x + 1
      } in (t2 t1 s) 0
```

wie besser?



# Typ-Argumente (Beispiel)

Typ-Abstraktion, Typ-Applikation:

```
let { t = \ ( t :: Type )
      -> \ ( f :: t -> t ) ->
          \ ( x :: t ) ->
              f ( f x )
      ; s = \ ( x :: Int ) -> x + 1
    }
in ((t [Int -> Int]) (t [Int])) s) 0
```

zur Laufzeit werden die Abstraktionen und  
Typ-Applikationen *ignoriert*

# Typ-Argumente (Regeln)

neuer Typ-Ausdruck  $\forall t.T$ , Inferenz-Regeln:

- Typ-Abstraktion: erzeugt parametrischen Typ

$$\frac{E \vdash \dots}{E \vdash \lambda(t :: \text{Type} \rightarrow X : \dots)}$$

- Typ-Applikation: instantiiert param. Typ

$$\frac{E \vdash F : \dots}{E \vdash F[T_2] : \dots}$$

Ü: Vergleich Typ-Applikation mit expliziter Instantiierung von polymorphen Methoden in C#

# Inferenz allgemeingültige Formeln

Grundbereich: aussagenlogische Formeln (mit Variablen und Implikation)

Axiom-Schemata:

$$\overline{X \rightarrow (Y \rightarrow X)}, \overline{(X \rightarrow (Y \rightarrow Z)) \rightarrow ((X \rightarrow Y) \rightarrow (X \rightarrow Z))}$$

Regel-Schema (*modus ponens*): 
$$\frac{X \rightarrow Y, X}{Y}$$

Beobachtungen/Fragen:

- Übung (autotool): Leite  $p \rightarrow p$  ab.
- (*Korrektheit*): jede ableitbare Formel ist allgemeingültig
- (*Vollständigkeit*): sind alle allgemeingültigen Formeln (in dieser Signatur) ableitbar?

# Typen und Daten

- bisher: Funktionen von Daten nach Daten

$\backslash (x :: \text{Int}) \rightarrow x + 1$

- heute: Funktionen von Typ nach Daten

$\backslash (t :: \text{Type}) \rightarrow \backslash (x :: t) \rightarrow x$

- Funktionen von Typ nach Typ (ML, Haskell, Java, C#)

$\backslash (t :: \text{Type}) \rightarrow \text{List } t$

- Funktionen von Daten nach Typ (*dependent types*)

$\backslash (t :: \text{Typ}) (n :: \text{Int}) \rightarrow \text{Array } t \ n$

Sprachen: Cayenne, Coq, Agda

Eigenschaften: Typkorrektheit i. A. nicht entscheidbar,  
d. h. Programmierer muß Beweis hinschreiben.

# Typ-Rekonstruktion

## Motivation

Bisher: Typ-Deklarationspflicht für Variablen in Lambda.  
scheint sachlich nicht nötig. In vielen Beispielen kann man  
die Typen einfach rekonstruieren:

```
let { t = \ f x -> f (f x)
      ; s = \ x -> x + 1
      } in t s 0
```

Diesen Vorgang automatisieren!

(zunächst für einfaches (nicht polymorphes) Typsystem)

# Realisierung mit Constraints

Inferenz für Aussagen der Form  $E \vdash X : (T, C)$

- $E$ : Umgebung (Name  $\rightarrow$  Typ)
- $X$ : Ausdruck (Exp)
- $T$ : Typ
- $C$ : Menge von Typ-Constraints

wobei

- Menge der Typen  $T$  erweitert um Variablen
- Constraint: Paar von Typen  $(T_1, T_2)$
- Lösung eines Constraints: Substitution  $\sigma$  mit  $T_1\sigma = T_2\sigma$

# Inferenzregeln f. Rekonstruktion (Plan)

Plan:

- Aussage  $E \vdash X : (T, C)$  ableiten,
- dann  $C$  lösen (allgemeinsten Unifikator  $\sigma$  bestimmen)
- dann ist  $T\sigma$  der (allgemeinste) Typ von  $X$  (in Umgebung  $E$ )

Für (fast) jeden Teilausdruck eine eigene („frische“) Typvariable ansetzen, Beziehungen zwischen Typen durch Constraints ausdrücken.

Inferenzregeln? Implementierung? — Testfall:

```
\ f g x y ->  
  if (f x y) then (x+1) else (g (f x True))
```

# Inferenzregeln f. Rekonstruktion

- primitive Operationen (Beispiel)

$$\frac{E \vdash X_1 : (T_1, C_1), \quad E \vdash X_2 : (T_2, C_2)}{E \vdash X_1 + X_2 : (\text{Int}, \{T_1 = \text{Int}, T_2 = \text{Int}\} \cup C_1 \cup C_2)}$$

- Applikation

$$\frac{E \vdash F : (T_1, C_1), \quad E \vdash A : (T_2, C_2)}{E \vdash (F A) : \dots}$$

- Abstraktion

$$\frac{\dots}{E \vdash \lambda x. B : \dots}$$

- (Ü) Konstanten, Variablen, if/then/else



# Substitutionen (Definition)

- Signatur  $\Sigma = \Sigma_0 \cup \dots \cup \Sigma_k$ ,
- $\text{Term}(\Sigma, V)$  ist kleinste Menge  $T$  mit  $V \subseteq T$  und  $\forall 0 \leq i \leq k, f \in \Sigma_i, t_1 \in T, \dots, t_i \in T : f(t_1, \dots, t_i) \in T$ .  
(hier Anwendung für Terme, die Typen beschreiben)
- Substitution: partielle Abbildung  $\sigma : V \rightarrow \text{Term}(\Sigma, V)$ ,  
Definitionsbereich:  $\text{dom } \sigma$ , Bildbereich:  $\text{img } \sigma$ .
- Substitution  $\sigma$  auf Term  $t$  anwenden:  $t\sigma$
- $\sigma$  heißt *pur*, wenn kein  $v \in \text{dom } \sigma$  als Teilterm in  $\text{img } \sigma$  vorkommt.

# Substitutionen: Produkt

Produkt von Substitutionen:  $t(\sigma_1 \circ \sigma_2) = (t\sigma_1)\sigma_2$

Beispiel 1:

$\sigma_1 = \{X \mapsto Y\}, \sigma_2 = \{Y \mapsto a\}, \sigma_1 \circ \sigma_2 = \{X \mapsto a, Y \mapsto a\}$ .

Beispiel 2 (nachrechnen!):

$\sigma_1 = \{X \mapsto Y\}, \sigma_2 = \{Y \mapsto X\}, \sigma_1 \circ \sigma_2 = \sigma_2$

Eigenschaften:

- $\sigma$  pur  $\Rightarrow \sigma$  idempotent:  $\sigma \circ \sigma = \sigma$
- $\sigma_1$  pur  $\wedge \sigma_2$  pur impliziert nicht  $\sigma_1 \circ \sigma_2$  pur

Implementierung:

```
import Data.Map
```

```
type Substitution = Map Identifier Term
```

```
times :: Substitution -> Substitution -> Sub
```

# Substitutionen: Ordnung

Substitution  $\sigma_1$  ist *allgemeiner als* Substitution  $\sigma_2$ :

$$\sigma_1 \lesssim \sigma_2 \iff \exists \tau : \sigma_1 \circ \tau = \sigma_2$$

Beispiele:

- $\{X \mapsto Y\} \lesssim \{X \mapsto a, Y \mapsto a\}$ ,
- $\{X \mapsto Y\} \lesssim \{Y \mapsto X\}$ ,
- $\{Y \mapsto X\} \lesssim \{X \mapsto Y\}$ .

Eigenschaften

- Relation  $\lesssim$  ist Prä-Ordnung ( $\dots$ ,  $\dots$ , aber nicht  $\dots$ )
- Die durch  $\lesssim$  erzeugte Äquivalenzrelation ist die  $\dots$

# Unifikation—Definition

## Unifikationsproblem

- Eingabe: Terme  $t_1, t_2 \in \text{Term}(\Sigma, V)$
- Ausgabe: ein allgemeinsten Unifikator (mgu): Substitution  $\sigma$  mit  $t_1\sigma = t_2\sigma$ .

(allgemeinst: infimum bzgl.  $\lesssim$ )

Satz: jedes Unifikationsproblem ist

- entweder gar nicht
- oder bis auf Umbenennung eindeutig lösbar.

# Unifikation—Algorithmus

$\text{mgu}(s, t)$  nach Fallunterscheidung

- $s$  ist Variable: ...
- $t$  ist Variable: symmetrisch
- $s = (s_1 \rightarrow s_2)$  und  $t = (t_1 \rightarrow t_2)$ : ...

$\text{mgu} :: \text{Term} \rightarrow \text{Term} \rightarrow \text{Maybe Substitution}$

# Unifikation—Komplexität

Bemerkungen:

- gegebene Implementierung ist korrekt, übersichtlich, aber nicht effizient,
- (Ü) es gibt Unif.-Probl. mit exponentiell großer Lösung,
- eine komprimierte Darstellung davon kann man aber in Polynomialzeit ausrechnen.

# Rekonstruktion polymorpher Typen

... ist im Allgemeinen nicht möglich:

Joe Wells: *Typability and Type Checking in System F Are Equivalent and Undecidable*, Annals of Pure and Applied Logic 98 (1998) 111–156, <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.6.6483>

übliche Einschränkung (ML, Haskell): *let-Polymorphism*:  
Typ-Abstraktionen nur für let-gebundene Bezeichner:

```
let { t = \ f x -> f (f x) ; s = \ x -> x+1 }  
in t t s 0
```

folgendes ist dann nicht typisierbar (t ist monomorph):

```
( \ t -> let { s = \ x -> x+1 } in t t s 0 )  
  ( \ f x -> f (f x) )
```

# Implementierung

let-Polymorphie, Hindley/Damas/Milner

- Inferenzsystem ähnlich zu Rekonstruktion monomorpher Typen mit Aussagen der Form  $E \vdash X : (T, C)$
- Umgebung  $E$  ist jetzt partielle Abbildung von Name nach Typschema (nicht wie bisher: nach Typ).
- Bei Typinferenz für let-gebundene Bezeichner wird über die freien Typvariablen generalisiert.
- Dazu Teil-Constraint-Systeme lokal lösen.

Beispiel

```
let { c = ... }  
in let { g = \ f x -> f (if b c x) } in ..
```



# Plan für Compiler

## Transformationen/Ziel

- continuation passing (Programmablauf explizit)
- closure conversion (alle Umgebungen explizit)
- lifting (alle Unterprogramme global)
- Registervergabe (alle Argumente in Registern)

Ziel: maschinen(nahes) Programm mit

- globalen (Register-)Variablen (keine lokalen)
- Sprüngen (kein return)
- automatischer Speicherbereinigung

# CPS-Transformation

## CPS-Transformation: Spezifikation

(als Schritt im Compiler)

- Eingabe: Ausdruck  $X$ , Ausgabe: Ausdruck  $Y$
- Semantik:  $X \equiv Y(\lambda v.v)$
- Syntax:
  - $X \in \text{Exp}$  (fast) beliebig,
  - $Y \in \text{Exp/CPS}$  stark eingeschränkt:
    - \* keine geschachtelten Applikationen
    - \* Argumente von Applikationen und Operationen ( $+$ ,  $*$ ,  $>$ ) sind Variablen oder Literale

# CPS-Transformation: Zielsyntax

$\text{Exp\_CPS} \Rightarrow \text{App Id Exp\_Value}^*$   
|  $\text{If Exp\_Value Exp\_CPS Exp\_CPS}$   
|  $\text{Let Id Exp\_Letable Exp\_CPS}$

$\text{Exp\_Value} \Rightarrow \text{Literal} \mid \text{Identifier}$

$\text{Exp\_Letable} \Rightarrow \text{Literal}$   
|  $\text{Abs Id}^* \text{Exp\_CPS}$   
|  $\text{Exp\_Value Op Exp\_Value}$

## Übung: Übersetze

$(0 - (b * b)) + (4 * (a * c))$

# Beispiel

$(0 - (b * b)) + (4 * (a * c))$

$\Rightarrow$

let { t.3 = b \* b } in

let { t.2 = 0 - t.3 } in

let { t.5 = a \* c } in

let { t.4 = 4 \* t.5 } in

let { t.1 = t.2 + t.4 } in

t.1

# Transformation f. Applikation

```
CPS [ (app f a1 ... an) ] =  
(abs (k)  
  (app CPS[f] (abs (i_0)  
    (app CPS[a1] (abs (i_1)  
      ...  
        (app CPS[an] (abs (i_n)  
          (app i_0 i_1 ... i_n k))))))))
```

dabei sind  $k, i_0, \dots, i_n$  *frische* Namen (= die im gesamten Ausdruck nicht vorkommen)

Ü: ähnlich für Primop (Unterschied?)

# Transformation f. Abstraktion

```
CPS [ (abs (i_1 ... i_n) b) ] =  
(abs (k)  
  (let ((i (abs (i_1 .. i_n c)  
                (app CPS [b] c))))  
    (app k i)))
```

Ü: Transformation für let

# Namen

Bei der Übersetzung werden „frische“ Variablennamen benötigt (= die im Eingangsprogramm nicht vorkommen).

```
import Control.Monad.State
data State s a = State ( s -> ( a, s ) )
get :: State s s ; put :: s -> State ()
```

```
fresh :: State Int String
fresh = do
    k <- get ; put (k+1)
    return $ "f." ++ show k
```

```
type Transform a = State Int a
cps :: Exp -> Transform Exp
```

# Vereinfachungen

um geforderte Syntax (ExpCPS) zu erreichen:

- **implicit-let**

$$(\text{app } (\text{abs } (i\_1 \dots i\_n) b) a\_1 \dots a\_n)$$

$\implies$

$$(\text{let } ((i\_1 a\_1)) (\dots (\text{let } ((i\_n a\_n)) b) \dots))$$

Umbenennungen von Variablen entfernen:

- **copy-prop**

$$(\text{let } ((i i')) b) \implies b [i := i']$$

aber kein allgemeines Inlining



# Teilweise Auswertung

- Interpreter (bisher): komplette Auswertung  
(Continuations sind Funktionen, werden angewendet)
- CPS-Transformator (heute): gar keine Auswertung,  
(Continuations sind Ausdrücke)
- gemischter Transformator: benutzt sowohl
  - Continuations als Ausdrücke (der Zielsprache)
  - als auch Continuations als Funktionen (der  
Gastsprache)

(compile time evaluation, partial evaluation)

# Partial Evaluation

- bisher:

```
transform  :: Exp -> State ... Exp
```

```
transform x = case x of ...
```

```
  ConstInt i -> do
```

```
    k<-fresh; return $ Abs k (app (Ref k) x)
```

- jetzt:

```
type Cont = Exp -> State ... Exp
```

```
transform
```

```
  :: Exp -> ( Cont -> State ... Exp )
```

```
transform x k = case x of ...
```

```
  ConstInt i -> k x
```

# Partial Evaluation (II)

```
CPS [ (app f a1 ... an) ] =  
(m-abs (K)  
  (m-app CPS[f] (m-abs (i_0)  
    ...  
      (m-app CPS[an] (m-abs (i_n)  
        ??? (app i_0 i_1 ... i_n k))) ...))))))
```

ändere letzte Zeile in

```
(let ((i (abs (temp) K[temp])))  
  (app i_0 .. i_n i))
```

# Erklärung CPS-Transformation

Spezifikation (Vorsicht, enthält Typfehler - welche?):

```
eval env x (\ y -> k2 (k1 y))  
=?= eval env (cps x k1) k2
```

Wiederholung CPS-Interpreter:

```
type Cont = Val -> Action Val  
eval :: Env -> Exp -> Cont -> Action Val  
eval env x = \ k -> case x of  
  ConstInt i -> ... ; Plus a b -> ...
```

CPS-Transformator:

```
type Cont = ExpValue -> Transform Exp  
cps :: Exp -> Cont -> Transform Exp  
cps x = \ m -> case x of  
  ConstInt i -> ... ; Plus a b -> ...
```

# Übung CPS-Transformation

- Transformationsregeln für Ref, App, Abs, Let nachvollziehen (im Vergleich zu CPS-Interpreter)
- Transformationsregeln für if/then/else, new/put/get hinzufügen
- anwenden auf eine rekursive Funktion (z. B. Fakultät), wobei Rekursion durch Zeiger auf Abstraktion realisiert wird

# Closure Conversion

## Motivation

(Literatur: DCPL 17.10) — Beispiel:

```
let { linear = \ a -> \ x -> a * x + 1
      ; f = linear 2 ; g = linear 3
    }
in f 4 * g 5
```

beachte nicht lokale Variablen: ( \ x -> .. a .. )

- Semantik-Definition (Interpreter) benutzt Umgebung
- Transformation (closure conversion, environment conversion) (im Compiler) macht Umgebungen explizit.

# Spezifikation

closure conversion:

- Eingabe: Programm  $P$
- Ausgabe: äquivalentes Programm  $P'$ , bei dem alle Abstraktionen *geschlossen* sind
- zusätzlich:  $P$  in CPS  $\Rightarrow P'$  in CPS

geschlossen: alle Variablen sind lokal

Ansatz:

- Werte der benötigten nicht lokalen Variablen  $\Rightarrow$  zusätzliche(s) Argument(e) der Abstraktion
- auch Applikationen entsprechend ändern

# closure passing style

- Umgebung = Tupel der Werte der benötigten nicht lokalen Variablen
- Closure = Paar aus Code und Umgebung  
realisiert als Tupel  $(\text{Code}, \underbrace{W_1, \dots, W_n}_{\text{Umgebung}})$

```
\ x -> a * x + 1
```

```
==>
```

```
\ clo x ->
```

```
  let { a = nth clo 1 } in a * x + 1
```

Closure-Konstruktion?

Komplette Übersetzung des Beispiels?



# Transformation

```
CLC [ \ i_1 .. i_n -> b ] =  
  (tuple ( \ clo i_1 .. i_n ->  
          let { v_1 = nth 1 clo ; .. }  
          in CLC[b]  
        ) v_1 .. )
```

wobei  $\{v_1, \dots\}$  = freie Variablen in  $(\lambda i_1 \dots i_n \rightarrow b)$

```
CLC [ (f a_1 .. a_n) ] =  
  let { clo = CLC[f]  
        ; code = nth 0 clo  
      } in code clo CLC[a_1] .. CLC[a_n]
```

- für alle anderen Fälle: strukturelle Rekursion
- zur Erhaltung der CPS-Form: Spezialfall bei `let`

# Lifting

## Spezifikation

(lambda) lifting:

- Eingabe: Programm  $P$
- Ausgabe: äquivalentes Programm  $P'$ ,  
bei dem alle Abstraktionen global sind

Motivation: in Maschinencode gibt es nur globale  
Sprungziele

(CPS-Transformation: Unterprogramme kehren nie zurück  
 $\Rightarrow$  globale Sprünge)

# Realisierung

nach closure conversion sind alle Abstraktionen geschlossen, diese müssen nur noch aufgesammelt und eindeutig benannt werden.

```
let { g1 = \ v1 .. vn -> b1
      ...
      ; gk = \ v1 .. vn -> bk
    } in b
```

dann in  $b_1, \dots, b_k, b$  keine Abstraktionen gestattet

- Zustandsmonade zur Namensерzeugung ( $g_1, g_2, \dots$ )
- Ausgabemonade (`WriterT`) zum Aufsammeln
- $g_1, \dots, g_k$  dürften nun sogar rekursiv sein (sich gegenseitig aufrufen)

# Kombinatorische Logik

## Motivation

- Lambda-Kalkül zur Modellierung von Abstraktion und Applikation,  
wesentliches Merkmal: benutzerdefinierte Funktionen mit gebundene Variablen.
- *Kombinatorische Logik* ist ein Berechnungsmodell mit einer kleinen, fixierte Menge von (globalen) Funktionen, diese heißen *Kombinatoren*.

Beispiele:  $S = \lambda xyz.xz(yz)$ ,  $K = \lambda xy.x$

# Beispiele

- vordefinierte Kombinatoren:

$$I = \lambda x.x, K = \lambda xy.x, S = \lambda xyz.xz(yz)$$

Ü: Berechne Normalform von  $SKKx$ , von  $SIIx$

- weitere, z. B.

$$B = \lambda xyz.x(yz), C = \lambda xyz.xzy, J = \lambda xyzw.xy(xwz)$$

Ü: simuliere  $B$  und  $C$  durch  $I$  und  $J$

# Systematische Übersetzung

Spezifikation:

- Eingabe: geschlossener Lambda-Ausdruck  $P$
- Ausgabe: äquivalenter Kombinator-Ausdruck  $[P]$   
(Applikationen mit  $S, K, I$ ; sonst keine Variablen und Lambdas)

benutzt  $[\lambda x.A] = \text{lift}_x(A)$  mit Spezifikation:  $\text{lift}_x(A)x \rightarrow^* A$

- $\text{lift}_x(y) = \text{falls } x = y \text{ dann } I \text{ sonst } Ky$
- $\text{lift}_x(AB) = S \text{ lift}_x(A) \text{ lift}_x(B)$
- $\text{lift}_x(\lambda y.A) = \text{lift}_x(\text{lift}_y(A))$

Beispiele:  $\lambda x.xx, \lambda xy.y, \lambda xy.yx$  — Vereinfachungen?

# Kombinator-Basen

Def: Eine Menge  $M$  von Kombinatoren heißt *Basis*, falls es zu jedem Lambda-Ausdruck einen äquivalenten Ausdruck nur aus Applikationen und Kombinatoren aus  $M$  gibt.

Satz:  $\{S, K, I\}$  ist Basis.

Satz:  $\{S, K\}$  ist Basis. — Beweis?  $I = \dots$

Satz: es gibt eine Basis mit nur einem Element. (Schwer.)

Literatur:

- Henk Barendregt: *The Lambda Calculus, its Syntax and Semantics*, 1984. <http://www.cs.ru.nl/~henk/>
- Raymond Smullyan: *How To Mock a Mockingbird*, 1985. <http://www.raymondsmullyan.com/>

# Anwendungen

- Übersetzung von  $\lambda$  nach CL  
entspricht Closure-Conversion und Lifting (beides, gleichzeitig)
- CL: feste Menge (Basis) von Kombinatoren,  
CC+L: Kombinatoren hängen vom Programmtext ab
- CL als Programmiersprache: `http://www.madore.org/~david/programs/unlambda/`

Bsp: Berechnung von Fibonacci-Zahlen in Unlambda:

```
``s``s`si`ki`k.*``s``s`ks  
``s`k`s`ks``s``s`ks``s`k`s`kr``s`k`sikk  
`k``s`ksk
```



# Registervergabe

## Motivation

- (klassische) reale CPU/Rechner hat nur *globalen* Speicher (Register, Hauptspeicher)
- Argumentübergabe (Hauptprogramm  $\rightarrow$  Unterprogramm) muß diesen Speicher benutzen  
(Rückgabe brauchen wir nicht wegen CPS)
- Zugriff auf Register schneller als auf Hauptspeicher  $\Rightarrow$  bevorzugt Register benutzen.

# Plan (I)

- Modell: Rechner mit beliebig vielen Registern ( $R_0, R_1, \dots$ )
- Befehle:
  - Literal laden (in Register)
  - Register laden (kopieren)
  - direkt springen (zu literaler Adresse)
  - indirekt springen (zu Adresse in Register)
- Unterprogramm-Argumente in Registern:
  - für Abstraktionen: ( $R_0, R_1, \dots, R_k$ )  
(genau diese, genau dieser Reihe nach)
  - für primitive Operationen: beliebig
- Transformation: lokale Namen  $\rightarrow$  Registernamen

# Plan (II)

- Modell: Rechner mit begrenzt vielen realen Registern,  
z. B.  $(R_0, \dots, R_7)$
- falls diese nicht ausreichen: *register spilling*  
virtuelle Register in Hauptspeicher abbilden
- Hauptspeicher (viel) langsamer als Register:  
möglichst wenig HS-Operationen:  
geeignete Auswahl der Spill-Register nötig

# Registerbenutzung

Allgemeine Form der Programme:

```
(let* ((r1 (...))
      (r2 (...))
      (r3 (...)))
      ...
      (r4 ...))
```

für jeden Zeitpunkt ausrechnen: Menge der *freien* Register  
(= deren aktueller Wert nicht (mehr) benötigt wird)

nächstes Zuweisungsziel ist niedrigstes freies Register  
(andere Varianten sind denkbar)

vor jedem UP-Aufruf: *register shuffle* (damit die Argumente  
in  $R_0, \dots, R_k$  stehen)

# Automatische Speicherverwaltung

## Motivation

Speicher-Allokation durch Konstruktion von

- Zellen, Tupel, Closures

Modell: Speicherbelegung = gerichteter Graph

Knoten *lebendig*: von Register aus erreichbar.

sonst tot  $\Rightarrow$  automatisch freigeben

Gliederung:

- mark/sweep (pointer reversal, Schorr/Waite 1967)
- twospace (stop-and-copy, Cheney 1970)
- generational (JVM)

# Mark/Sweep

Plan: wenn Speicher voll, dann:

- alle lebenden Zellen markieren
- alle nicht markierten Zellen in Freispeicherliste

Problem: zum Markieren muß man den Graphen durchqueren, man hat aber keinen Platz (z. B. Stack), um das zu organisieren.

Lösung:

H. Schorr, W. Waite: *An efficient machine-independent procedure for garbage collection in various list structures*, Communications of the ACM, 10(8):481-492, August 1967.  
temporäre Änderungen im Graphen selbst (pointer reversal)

# Pointer Reversal (Invariante)

ursprünglicher Graph  $G_0$ , aktueller Graph  $G$ :

Knoten (cons) mit zwei Kindern (head, tail), markiert mit

- 0: noch nicht besucht
- 1: head wird besucht (head-Zeiger ist invertiert)
- 2: tail wird besucht (tail-Zeiger ist invertiert)
- 3: fertig

globale Variablen  $p$  (parent),  $c$  (current).

Invariante: man erhält  $G_0$  aus  $G$ , wenn man

- head/tail-Zeiger aus 1/2-Zellen (nochmals) invertiert
- und Zeiger von  $p$  auf  $c$  hinzufügt.

# Pointer Reversal (Ablauf)

- **pre:**  $p = \text{null}$ ,  $c = \text{root}$ ,  $\forall z : \text{mark}(z) = 0$
- **post:**  $\forall z : \text{mark}(z) = \text{if } (\text{root} \rightarrow^* z) \text{ then } 3 \text{ else } 0$

Schritt (neue Werte immer mit '): falls  $\text{mark}(c) = \dots$

- **0:**  $c' = \text{head}(c)$ ;  $\text{head}'(c) = p$ ;  $\text{mark}'(c) = 1$ ;  $p' = c$ ;
- **1,2,3:** falls  $\text{mark}(p) = \dots$ 
  - **1:**  $\text{head}'(p) = c$ ;  $\text{tail}'(p) = \text{head}(p)$ ;  $\text{mark}'(p) = 2$ ;  $c' = \text{tail}(p)$ ;  $p' = p$
  - **2:**  $\text{tail}'(p) = c$ ;  $\text{mark}'(p) = 3$ ;  $p' = \text{tail}(p)$ ;  $c' = p$ ;

Knoten werden in Tiefensuch-Reihenfolge betreten.



# Eigenschaften Mark/Sweep

- benötigt 2 Bit Markierung pro Zelle, aber keinen weiteren Zusatzspeicher
- Laufzeit für mark  $\sim$  | lebender Speicher |
- Laufzeit für sweep  $\sim$  | gesamter Speicher |
- Fragmentierung (Freispeicherliste springt)

Ablegen von Markierungs-Bits:

- in Zeigern/Zellen selbst  
(Beispiel: Rechner mit Byte-Adressierung, aber Zellen immer auf Adressen  $\equiv 0 \pmod{4}$ : zwei LSB sind frei.)
- in separaten Bitmaps

# Stop-and-copy (Plan)

Plan:

- zwei Speicherbereiche (Fromspace, Tospace)
- Allokation im Fromspace
- wenn Fromspace voll, kopiere lebende Zellen in Tospace und vertausche dann Fromspace  $\leftrightarrow$  Tospace

auch hier: Verwaltung ohne Zusatzspeicher (Stack)

C. J. Cheney: *A nonrecursive list compacting algorithm*,  
Communications of the ACM, 13(11):677–678, 1970.

# Stop-and-copy (Invariante)

fromspace, tospace : array [ 0 ...  $N$  ] of cell

Variablen:  $0 \leq \text{scan} \leq \text{free} \leq N$

einige Zellen im fromspace enthalten Weiterleitung (= Adresse im tospace)

Invarianten:

- $\text{scan} \leq \text{free}$
- Zellen aus tospace [0 ... scan-1] zeigen in tospace
- Zellen aus tospace [scan ... free-1] zeigen in fromspace
- wenn man in  $G$  (mit Wurzel tospace[0]) allen Weiterleitungen folgt, erhält man isomorphes Abbild von  $G_0$  (mit Wurzel fromspace[0]).

# Stop-and-copy (Ablauf)

- pre: tospace[0] = Wurzel, scan = 0, free = 1.
- post: scan = free

Schritt: while scan < free:

- für alle Zeiger  $p$  in tospace[scan]:
  - falls fromspace[ $p$ ] weitergeleitet auf  $q$ , ersetze  $p$  durch  $q$ .
  - falls keine Weiterleitung
    - \* kopiere fromspace[ $p$ ] nach tospace[free],
    - \* Weiterleitung fromspace[ $p$ ] nach free eintragen,
    - \* ersetze  $p$  durch free, erhöhe free.
- erhöhe scan.

Besucht Knoten in Reihenfolge einer Breitensuche.

# Stop-and-copy (Eigenschaften)

- benötigt „doppelten“ Speicherplatz
- Laufzeit  $\sim$  | lebender Speicher |
- kompaktierend
- Breitensuch-Reihenfolge zerstört Lokalität.

# Breiten- und Tiefensuche

put (Wurzel( $G$ ));

while Speicher nicht leer:

$u \leftarrow$  get; wenn  $u$  nicht markiert:

        markiere  $u$ ;

        für alle  $v$  mit  $u \rightarrow_G v$ : put( $v$ );

dabei ist Speicher (mit Operationen put/get):

- Stack (LIFO) (push/pop)  $\Rightarrow$  Tiefensuche,
- Queue (FIFO) (enqueue/dequeue)  $\Rightarrow$  Breitensuche.

woran erkennt man, daß eine Knotenreihenfolge eines gerichteten Graphen  $G$  bei einer Breiten/Tiefensuche entstanden sein könnte? (wenn man Reihenfolge der Nachfolger eines Knoten jeweils beliebig wählen kann)

# Speicher mit Generationen

Beobachtung: es gibt

- (viele) Zellen, die sehr kurz leben
- Zellen, die sehr lange (ewig) leben

Plan:

- bei den kurzlebigen Zellen soll GC-Laufzeit  $\sim$  Leben (und nicht  $\sim$  Leben + Müll) sein
- die langlebigen Zellen möchte man nicht bei jeder GC besuchen/kopieren.

Lösung: benutze Generationen, bei GC in Generation  $k$ : betrachte alle Zellen in Generationen  $> k$  als lebend.

# Speicherverwaltung in JVM

## Speicheraufteilung:

- Generation 0:
  - Eden, Survivor 1, Survivor 2
- Generation 1: Tenured

## Ablauf

- minor collection (Eden voll):  
kompaktierend: Eden + Survivor 1/2 → Survivor 2/1 ...  
... falls dabei Überlauf → Tenured
- major collection (Tenured voll):  
alles nach Survivor 1 (+ Tenured)



# Speicherverwaltung in JVM (II)

- richtige Benutzung der Generationen:
  - bei minor collection (in Gen. 0) gelten Zellen in Tenured (Gen. 1) als lebend (und werden nicht besucht)
  - Spezialbehandlung für Zeiger von Gen. 1 nach Gen. 0 nötig (wie können die überhaupt entstehen?)

- Literatur:

`http://www.imn.htwk-leipzig.de/~waldmann/edu/ws09/pps/folien/main/node78.html`

- Aufgabe:

`http://www.imn.htwk-leipzig.de/~waldmann/edu/ws09/pps/folien/main/node79.html`

# Zusammenfassung

## Semantik

- dynamische (Programmausführung)
  - Interpretation
    - \* funktional, ● imperativ (Speicher)
    - \* Ablaufsteuerung (Continuations)
  - Transformation (Kompilation)
    - \* CPS transformation
    - \* closure passing, lifting, ● Registerzuweisung
- statische: Typisierung (Programmanalyse)
  - monomorph/polymorph
  - deklariert/rekonstruiert

# Monaden zur Programmstrukturierung

```
class Monad m where { return :: a -> m a ;  
    (>>=)    :: m a -> (a -> m b) -> m b }
```

## Anwendungen:

- semantische Bereiche f. Interpreter,
- Parser,
- Unifikation

## Testfragen (für jede Monad-Instanz):

- Typ (z. B. Action)
- anwendungsspezifische Elemente (z. B. new, put)
- Implementierung der Schnittstelle (return, bind)

# Parser

## Ansätze:

- eingebettet: Kombinator-Parser (Parsec)
- separat: lex/yacc (flex/bison), javacc, antlr, ...

## Unterschiede:

- eingebettet: benutzt Typsystem, Abstraktionsmechanismen, Bibliotheken der Gastsprache (separat: diese Ausdrucksmittel fehlen oder müssen simuliert werden)
- diese Einschränkung der Ausdruckskraft (z. B. LR( $k$ )-Grammatiken) gestattet effizientere Realisierung (z. B. deterministische Kellerautomaten)

# Anhang

## Prüfungsvorbereitung

- was ist eine Umgebung ( $\text{Env}$ ), welche Operationen gehören dazu?
- was ist eine Speicher ( $\text{Store}$ ), welche Operationen gehören dazu?
- Gemeinsamkeiten/Unterschiede zw.  $\text{Env}$  und  $\text{Store}$ ?
- Für  $(\lambda x.xx)(\lambda x.xx)$ : zeichne den Syntaxbaum, bestimme die Menge der freien und die Menge der gebundenen Variablen. Markiere im Syntaxbaum alle Redexe. Gib die Menge der direkten Nachfolger an (einen Beta-Schritt

ausführen).

- Definiere Beta-Reduktion und Alpha-Konversion im Lambda-Kalkül. Wozu wird Alpha-Konversion benötigt? (Dafür Beispiel angeben.)
- Wie kann man Records (Paare) durch Funktionen simulieren? (Definiere Lambda-Ausdrücke für `pair`, `first`, `second`)
- welche semantischen Bereiche wurden in den Interpretern benutzt? (definieren Sie `Val`, `Action Val`, `CPS Val`)
- welches sind die jeweils hinzukommenden Ausdrucksmöglichkeiten der Quellsprache (`Exp`)?

- wie lauten die Monad-Instanzen für `Action`, `CPS`, `Parser`, was bedeutet jeweils das `bind` (`>>=`)?
- warum benötigt man `call-by-name` für Abstraktionen über den Programmablauf (warum kann man `if` oder `while` nicht mit `call-by-value` implementieren)?
- wie kann man `call-by-name` simulieren in einer `call-by-value`-Sprache?
- wie kann man `call-by-value` simulieren in einer `call-by-name`-Sprache (Antwort: durch CPS-Transformation)
- Definiere Fakultät mittels Fixpunktoperator (Definiere das

$f \text{ in } fak = fix\ f )$

- Bezüglich welcher Halbordnung ist dieses  $f$  monoton?  
(Definiere die Ordnung, erläutere Monotonie an einem Beispiel.)
- Wie kann man Rekursion durch get/put simulieren?  
(Programmbeispiel ergänzen)
- Wie kann man Rekursion durch label/jump simulieren?  
(Programmbeispiel ergänzen)
- Für die Transformationen CPS, Closure Conv., Lifting, Registervergabe: welche Form haben jeweils Eingabe- und Ausgabeprogramm? Auf welchem Maschinenmodell



kann das Zielprogramm ausgeführt werden? (Welche Operationen muß das Laufzeitsystem bereitstellen?)

- Was sind die Bestandteile eines Inferenzsystems (Antwort: Grundbereich, Axiome, Regeln), wie kann man ein Axiom als Spezialfall einer Regel auffassen?
- wie lauten die Inferenzregeln für das Nachschlagen eines Namens in einer Umgebung?
- Inferenzregeln für Applikation, Abstraktion, Let, If/Then/Else im einfach getypten Kalkül
- Geben Sie ein Programm an, das sich nicht einfach (sondern nur polymorph) typisieren läßt. Geben Sie den polymorphen Typ an.

- Inferenz-Regeln für Typ-Applikation, Typ-Abstraktion im polymorphen Kalkül
- für Typ-Rekonstruktion im einfach getypten Kalkül: Welches ist der Grundbereich des Inferenzsystems?
- geben Sie die Inferenzregel für Typrekonstruktion bei If/Then/Else an
- Geben Sie eine Inferenzregel für Typrekonstruktion an, durch die neue Variablen eingeführt werden.
- Wann ist  $\sigma$  ein Unifikator von zwei Termen  $s, t$ ?
- Geben Sie zwei verschiedene Unifikatoren von  $f(a, X)$  und  $f(Y, Z)$  an. Einer davon soll streng allgemeiner als

der andere sein. Begründen Sie auch diese Beziehung.

- Bestimmen Sie einen Unifikator von

$f(X_n, f(X_{n-1}, \dots, f(X_0, a) \dots))$  und

$f(f(X_{n-1}, X_{n-1}), f(f(X_{n-2}, X_{n-2}), \dots, f(a, a) \dots))$ .