

# Compilerbau Vorlesung Wintersemester 2008

Johannes Waldmann, HTWK Leipzig

12. Oktober 2010



# 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 → Compiler → Zielprogramm
  - ▶ Eingaben → Zielprogramm → Ausgaben
- ▶ mit Interpreter:
  - ▶ Quellprogramm, Eingaben → Interpreter → Ausgaben
- ▶ Mischform:
  - ▶ Quellprogramm → Compiler → Zwischenprogramm
  - ▶ Zwischenprogramm, Eingaben → virtuelle Maschine → 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:
  - ▶ Hausaufgaben (klein),
  - ▶ Projekt (mittelklein)
- ▶ Prüfung: Projektverteidigung  
(enthält auch Compilerbau-Fragen außerhalb des Projektes)

# Projekt-Themen

- ▶ Erkennen von Codeverdopplungen, Extrahieren von Mustern, Erkennen der Anwendbarkeit von Mustern
- ▶ Refactorings als Eclipsefp-Plugin  
<http://eclipsefp.sourceforge.net/>
- ▶ Erweiterung der autotool-Aufgabe zu Java-Methodenaufrufen  
<https://autotool.imn.htwk-leipzig.de/cgi-bin/Trial.cgi?topic=TypeCheck-Quiz> (static → nonstatic, generic)
- ▶ SQL-Syntaxbäume (Query-Objekte)

# 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  $\gg=$  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`

# Parser für (geschachtelte) Listen

konkrete Syntax:

```
(foo (bar baz ()) 1234)
```

abstrakte Syntax:

```
data Expression
  = Identifier String
  | List [ Expression ]
```

- ▶ **parse:** String -> Expression
- ▶ **print:** Expression -> String
- ▶ **pretty-print:** Expression -> Doc

# Robuste Parser-Bibliotheken

Designfragen:

- ▶ Nichtdeterminismus einschränken
- ▶ Fehlermeldungen (Quelltextposition)

Beispiel: Parsec (Autor: Daan Leijen)

<http://www.haskell.org/haskellwiki/Parsec>

Übungen:

- ▶ parsec-Parser aufrufen
- ▶ parsec-Parser selbst schreiben (elementare, Kombinatoren)
- ▶ buildExpressionParser

# 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](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`

# Motivation (I)

- ▶ wollen uns in (diesem) Compilerbau nicht mit *konkreter Syntax* beschäftigen,  
(ist zwar ein klassisches Gebiet: kontextfreie Grammatiken, Kellerautomaten, LL/LR-Parser usw., aber leider haben wir keine Zeit—und mit Parsec kommt man schon sehr sehr weit)
- ▶ sondern mit *Semantik* (Interpretation, Kompilation) dazu muß nur die abstrakte Syntax möglichst einfach und systematisch repräsentiert werden.

# Motivation (II)

## Datenaustausch

- ▶ in einem Programm: Objekte der Programmiersprache (Graphen, Bäume)
- ▶ zwischen Programmen gleicher Sprache: binäre Serialisierung
- ▶ zwischen Programmen verschiedener Sprachen: textuelle, sprachunabhängige Serialisierung

Ziel: Anwendungs- und sprachunabhängige konkrete Syntax.



# Varianten

- ▶ 199?: XML(-RPC)
- ▶ 200?: JSON
- ▶ 196?: LISP

die konkrete Syntax von LISP (für Daten *und* Programme) löst das Problem bereits so gut wie möglich

vgl. Phil Wadler: *The Essence of XML* (slides of 2002 POPL talk) <http://homepages.inf.ed.ac.uk/wadler/topics/xml.html>

# JSON

`http://json.org/`

Java Script Object Notation

value →

- ▶ string, number, (true, false, null)
- ▶ object { foo = value1, bar = value2 }
- ▶ array [ value1, value2, value3 ]

# Zweistufige Syntax

(für die Beispielsprachen aus dem Compilerbau, wie im Buch Design Concepts of Programming Languages)

- ▶ konkret: String
- ▶ konkret abstrakt: LISP, S(ymbolic) Exp(ressions)
- ▶ abstrakt: anwendungsspezifisch

Transformationen:

- ▶ String  $\leftrightarrow$  Sexp:  
Typklassen `Autolib.Reader/ToDoc`
- ▶ Sexp  $\leftrightarrow$  abstrakt:  
Typklassen `DCPL.Input/Output`

# 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), Syntax besteht aus:
  - ▶ Variablen  $x, y, \dots$
  - ▶ Applikationen  $xx, (\lambda x.xx)y$
  - ▶ Abstraktionen  $\lambda x.xx, \lambda x.(\lambda y.x)$

# Konkrete Abstrakte Syntax

**abstrakt:**

```
data Exp = I S.Id -- Bezeichner (Variable)
  | Abstraction
      { formal :: S.Id , body :: Exp }
  | Application
      { rator  :: Exp , rand  :: Exp }
```

**konkret:**

```
(lam g (lam a (lam b (app (app g b) a))))
```

(nach Turbak, Gifford: Design Concepts in Programming Languages)

# Primitive Operationen

(= Funktionen, die keine Lambda-Ausdrücke sind, weil sie direkt auf primitiven Werten rechnen)

**abstrakt:**

```
data Exp = ...
  | Literal Integer
  | PrimitiveApplication
    { primop :: PrimOp , arg :: [ Exp ] }
data PrimOp
  = PrimOp { name :: S.Id }
```

**konkret:**

```
(prim + 2 (prim * 3 4))
```

# Wiederholung: Operationale Semantik

(SOS - small step operational semantics)

Ein-Schritt-Relation

- ▶  $\beta$ -Reduktion:  $(\lambda x.M)N \rightarrow_{\beta} M[x := N]$

falls  $\text{bound-vars}(M)$  und  $\text{free-vars}(N)$  disjunkt.

bei Bedarf gebundene Var. umbenennen

- ▶  $\alpha$ -Reduktion:  $\lambda x.M \rightarrow_{\alpha} \lambda y.M[x := y]$

Abschluß von  $\rightarrow_{\beta}$  unter Kontexten:

- ▶  $A_1 \rightarrow_{\beta} A_2 \Rightarrow A_1 B \rightarrow_{\beta} A_2 B, BA_1 \rightarrow_{\beta} BA_2, \lambda x A_1 \rightarrow_{\beta} \lambda x A_2$

operationale Semantik (= Programmausführung)

ist reflexive transitive Hülle  $\rightarrow_{\beta}^*$  (Mehr-Schritt-Relation)

# Denotationale Semantik

Denotationale Semantik eines Unterprogrammes (in einer deklarativen Programmiersprache) ist eine *Funktion*.

- ▶ Semantik von Literalen:  
bezeichnen (primitive) Objekte selbst
- ▶ Semantik primitiver Operationen:
  - ▶ (Zahlen-)Werte der Argumente bestimmen,
  - ▶ dann Operation anwenden
- ▶ Semantik von Lambda-Ausdrücken (Abstraktionen, Applikationen)?



## Denotationale Semantik (II)

Semantik von *lokalen* Unterprogrammen hängt ab von weiter außen gebundenen Variablen.

zutreffendes Modell ist deswegen:

- ▶ Semantik  $:: \text{Exp} \times \text{Env} \rightarrow \text{Value}$
- ▶ Exp ... Menge der Ausdrücke
- ▶ Value ... Menge der Werte
- ▶ Umgebungen  $\text{Env} :: \text{Var} \rightarrow \text{Value}$
- ▶ Var ... Menge der Variablen

(Vorsicht, das ist teilw. vereinfacht, Verallgemeinerung folgt)

# Umgebungen

- ▶ Umgebungen  $\text{Env} :: \text{Var} \rightarrow (\text{Value} \cup \text{Error})$

(Variable nicht gebunden: Error)

Operationen mit Umgebungen:

- ▶  $\text{lookup} :: \text{Var} \rightarrow \text{Env} \rightarrow (\text{Value} \cup \text{Error})$   
 $\text{lookup } i \ e = e_i$
- ▶ leere Umgebung = const Error =  $\lambda j. \text{Error}$
- ▶ neue Bindung:  
 $e[i/v] := \lambda j. \text{if } i = j \text{ then } v \text{ else } e_j$

# Semantische Bereiche

Value = ...

- ▶ Zahlen (für prim. Op. )
- ▶ Wahrheitswerte (für prim. Op.)
- ▶ in Applikation ( $\text{app } f \ a$ ) ist der Wert von  $f$  eine Funktion (Sprechweise hier: procedural value)

unvollständig und vereinfacht:

```
data Value
  = VInt Integer
  | VBool Bool
  | VProc ( Value -> Value )
```

# call-by-value

Semantik von Applikation ( $\text{app } f \ a$ ) in Umgebung  $e$

- ▶ Sem. von  $f$  in  $e$  ist  $\text{VProc } p \ :: \ \text{Value}$
- ▶ Sem. von  $a$  in  $e$  ist  $v \ :: \ \text{Value}$
- ▶ berechne  $p \ v$

Semantik von Abstraktion ( $\text{lam } i \ b$ ) in Umgebung  $e$

- ▶ ist Funktion  $\lambda x. \dots$
- ▶ Semantik von  $b$  in  $e[i/x]$

Semantik von Bezeichner  $i$  in Umgebung  $e$

- ▶  $\text{lookup } i \ e$

# Andere Semantiken?

Beispiel:

```
(prim / 1 0) ==> (error divide-by-zero)
(app (lam x 3) (prim / 1 0)) =?=> 3
```

Umgebung speichert für Namen ( $x$ ):

- ▶ call-by-value:  
*Wert* des Arguments
- ▶ call-by-name:  
*Rechnung*, die diesen Wert ergibt

# Call-by-name

Semantik von Applikation (`app f a`) in Umgebung  $e$

- ▶ Sem. von  $f$  in  $e$  ist  $V_{\text{Proc}} p :: \text{Value}$
- ▶ wende  $p$  an auf Sem. von  $a$  in  $e$

Semantik von Abstraktion (`lam i b`) in Umgebung  $e$

- ▶ ist Funktion  $\lambda x. \dots$
- ▶ Semantik von  $b$  in  $e[i/x]$

# Zusammenfassung bisher

allgemein:

- ▶ Value (Werte): Zahl, Proc, ...
- ▶ Comp (Rechnung): Resultat der Semantik-Funktionen
- ▶ Nameable: kann benannt werden, steht in Umgebungen  
beachte:  $\text{Value} = \dots \text{VProc} (\text{Nameable} \rightarrow \text{Comp})$

nebenwirkungsfreie (deklarative) Sprachen:

- ▶  $\text{Comp} = (\text{Value} \cup \text{Error})_{\perp} \dots$  (OK, Fehler, Divergenz)

call-by-value:  $\text{Nameable} = \text{Value}$

call-by-name:  $\text{Nameable} = \text{Comp}$

später: Nebenwirkungen:  $\text{Comp} = \text{State} \rightarrow (\text{Value}, \text{State})$

# Motivation

Semantik für Spracheigenschaft:

- ▶ direkt implementieren (z. B. Interpreter)
- ▶ indirekt implementieren (durch Transformation auf Kernsprache)

Transformationen sind „nur Syntax“, daher die Bezeichnung *syntactic sugar*.



# Mehrfach-Abstraktion/Applikation

bereits im Lambda-Kalkül vereinbart:

$$((\lambda xy.M)AB) \equiv (((\lambda x.(\lambda y.M))A)B)$$

bisher: konkret: `(lam x b)`, `(app f a)`, abstrakt:

```
| Abstraction { formal :: S.Id , body :: Exp }  
| Application { rator :: Exp, rand :: Exp }
```

neu: konkret: `(abs (x y) b)`, `(f a b c)`, abstrakt:

```
| MultiAbstraction  
  { mformal :: [ S.Id ] , body :: Exp }  
| MultiApplication  
  { rator :: Exp, mrand :: [ Exp ] }
```

# Mehrfach-Abstraktion/Applikation

Desugaring durch Ersetzungsregeln:

$$(\text{abs } [] \quad b) \rightarrow b$$
$$(\text{abs } (x:xs) \quad b) \rightarrow (\text{lam } x \quad (\text{abs } xs \quad b))$$
$$(\text{f } [] \quad ) \rightarrow \text{f}$$
$$(\text{f } (x:xs)) \rightarrow ((\text{app } \text{f } x) \quad xs)$$

nützliche Abkürzung für primitive Operationen:

$$(\text{prim } + \quad 3 \quad 4) \rightarrow (@+ \quad 3 \quad 4)$$

# Lokale Bindungen

konkret:

```
(let ((n1 x1) (n2 x2)) y)
```

abstrakt:

```
data Exp = ...
| LocalBinding
    { binders :: [ Binder ] , body :: Exp }
data Binder =
    Binder { bname :: S.Id, bdefn  :: Exp }
```

Übersetzung in Applikation/Abstraktion

Was folgt daraus über Sichtbarkeiten?

# Lokale Bindungen (Übersetzung)

## Übersetzung in Multi-Applikation/Abstraktion

```
(let [(n1, x1), ..., (nk, xk)] y)
  -> ((abs [n1, ..., nk] y) x1 .. xk)
```

Beachte: das geht nicht:

```
(let ((x (@+ 3 4)) (y (@* x x))) (@- x y))
```

die  $x$  in Definition von  $y$  beziehen sich nicht auf das  $x$  aus der ersten Definition

Abhilfe:

```
(let ((x (@+ 3 4)))
      (let ((y (@* x x))) (@- x y))) )
```

# Motivation

Das geht bisher gar nicht:

```
(let ((f (lam x (if (= x 0)
                    1
                    (@* x (app f (@- x 1)))))) ))
  (app f 3) )
```

(Bezeichner  $f$  ist nicht sichtbar)

Lösung:

```
( (rec f (lam x (if ... (app f ...)))) 3)
```

mit neuem primitiven Knotentyp `rec`

# Rekursion

abstrakt:

```
data Exp = ...  
| Recursion { rname :: S.Id, body :: Exp }
```

konkret:

```
(rec n b)
```

Semantik von `rec n b` in Umgebung  $E$   
ist der Fixpunkt (vom Typ `Comp`)  
der Funktion (vom Typ `Comp`  $\rightarrow$  `Comp`)

$\lambda c.$  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 (lam x
  (if (@= x 0) 1 (@* x (app f (@- x 1))))))
```

ist Fixpunkt der Funktion  $F =$

```
(lam f (lam x
  (if (@= x 0) 1 (@* x (app 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  $\perp$

# letrec

konkret:

```
(letrec ((n1 x1) (n2 x2)) y)
```

wobei  $n_1$ ,  $n_2$  sichtbar in  $x_1$ ,  $x_2$

abstrakt:

```
data Exp = ...  
| RecursiveBinding  
  { binders :: [ Binder ] , body :: Exp }
```

Beispiele:

```
(letrec ((x (@+ 3 4)) (y (@* x x))) (@- x y))  
(letrec ((f (lam x (.. (f (@- x 1)) ..)))) (f 3))
```

## letrec: Transformation nach rec

(DCPL Fig. 6.7 p. 233)

```
(letrec ((n1 x1) .. (nk xk)) y)
```

->

```
(app (rec t
      (lam s
        (s (t (abs (n1..nk) x1)
              ...
              (abs (n1..nk) xk) )))
      (abs (n1..nk) y) )
```

# Fixpunkt-Kombinatoren

- ▶ Definition:  $Y := \lambda f.((\lambda x.f(xx))(\lambda x.f(xx)))$
- ▶ Satz:  $Yf$  ist Fixpunkt von  $f$
- ▶ d.h.  $Y$  ist *Fixpunkt-Kombinator*
- ▶ Beweis: vergleiche  $(Yf)$  und  $f(Yf)$
- ▶ Folgerung: `rec` wird eigentlich nicht benötigt

# Paare

## Syntax:

`(pair x y)` -- Konstruktor

`(fst p)` -- Destruktor

`(snd p)` -- Destruktor

## Semantik (Plan):

für alle  $x, y$ :

$(fst (pair\ x\ y)) == x$

$(snd (pair\ x\ y)) == y$

# Listen

mit solchen Paaren kann man im Prinzip alles ausdrücken, z. B.  
Listen durch syntactic sugar:

```
(list      []) --> #u
```

```
(list (x:xs) ) --> (pair x (list xs))
```

# Semantik für Paare

was soll die Semantik dieses Ausdrucks sein?

```
(fst (pair 1 (@/ 1 0)))
```

- ▶ 1 : pair-Konstruktor ist *nicht strikt*
- ▶ (error divide-by-zero) : pair-Konstruktor ist *strikt*

# Strikte Paare

```
data Value = ...  
           | Pair Value Value
```

Semantik von `(pair X1 X2)` in Umgebung  $E$  ist die folgende Rechnung:

- ▶ führe Semantik von  $X1$  in  $E$  aus, liefert  $v1 :: \text{Value}$
- ▶ führe Semantik von  $X2$  in  $E$  aus, liefert  $v2 :: \text{Value}$
- ▶ Resultat ist `Pair v1 v2`

Semantik von `(fst p)`: führe Semantik von  $p$  aus, liefert `Pair v1 v2`, Resultat ist  $v1$ .



# Nicht strikte Paare

```
data Value = ...  
           | Pair Comp Comp
```

Semantik von `(pair X1 X2)` in Umgebung  $E$  ist diese Rechnung:

- ▶ Semantik von  $X1$  in  $E$  ist  $c1 :: \text{Comp}$
- ▶ Semantik von  $X2$  in  $E$  ist  $c2 :: \text{Comp}$
- ▶ Resultat ist `Pair c1 c2`

Semantik von `(fst p)`: führe Semantik von  $p$  aus, liefert `Pair c1 c2`, führe  $c1$  aus, Resultat ist  $v1$ .

# Simulation von nicht strikten Paaren

```
(ns-pair X Y)  
--> (pair (abs (u) X) (abs (u) Y))
```

```
(ns-fst P) --> ((fst P) #u)
```

- ▶ in CBV müssen das desugaring-Regeln sein, `ns-pair` ist keine CBV-Funktion.
- ▶ `u` darf nicht in `X`, `Y` vorkommen
- ▶ `(abs (u) X)` heißt *thunk*

mit thunking nur für zweites pair-Argument erhält man (lazy) streams,  
vgl. Iterator/Enumerator in Java/C#

# 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:**  $\text{Comp} = \text{Value} + \text{Error}$
- ▶ **jetzt:**  $\text{Comp} = \text{State} \rightarrow (\text{Value}, \text{State})$

Semantik von (Teil-)Programmen ist Zustandsänderung.

# Speicher

```
type Store = Map Location Value
```

## Syntax: Ausdrücke:

```
data Exp = ...  
  | (cell Exp) -- CellCreation  
  | (begin Exp Exp) -- SimpleSequencing
```

## Primops:

- ▶ lesen ( $@^{\wedge} E$ )
- ▶ schreiben ( $@ := E1 E2$ ),
- ▶ testen (ist Location?) ( $@_{\text{cell}}? E$ ),
- ▶ test (gleiche Location?) ( $_{\text{cell}}=? E1 E2$ ).

Beachte: explizite Dereferenzierung ( $@^{\wedge}$ )

# Syntactic Sugar

- ▶ Anweisungsfolgen beliebiger Länge

```
(begin) --> #u ; (begin E) --> E  
(begin (E:Es)) --> (begin E (begin Es))
```

- ▶ „if ohne else“

```
(if test yeah) --> (if test yeah #u)
```

- ▶ Wiederholung

```
(while test body) -->  
  (letrec ((loop (...))) loop)
```

# Semantik f. Speicher

```
type Store = Map Location Value
```

```
type State = Store
```

```
type Comp = State -> ( Value, State )
```

Das ist genau die Zustands-Monade aus Haskell.  
primitive Operationen (vgl. DCPL.Store)

- ▶ allocating
- ▶ fetching
- ▶ update

# Veränderliche Variablen

(bis jetzt sind unsere „Variablen“ konstant und nur die Zellen veränderlich.)

neue Syntax (`set! I E`),  $I \dots$  Identifier,  $E \dots$  Exp

erfordert Änderung in der Semantik: bisher:  $\text{Nameable} = \text{Value}$ ,  
jetzt:  $\text{Nameable} = \text{Location}$

Realisierung von  $(\text{Name} \rightarrow \text{Wert})$  durch *zwei* Bindungen:

- ▶ (in Umgebung:)  $\text{Name} \rightarrow \text{Location}$
- ▶ (im Speicher:)  $\text{Location} \rightarrow \text{Value}$

Ausblick:

- ▶ CBV, CBN, CBReference
- ▶ Übersetzung: veränd. Var  $\rightarrow$  veränd. Zellen

# Assignment Conversion

(als Transformationsschritt im Compiler):

- ▶ Eingabe: Programm mit veränderlichen Variablen
- ▶ Ausgabe: Programm mit „konstanten Variablen“ und veränderlichen Zellen

Variable ersetzen durch (Verweis auf) Zelle:

```
(begin (set! x (@* 2 y)) x))
```

==>

```
(let ((x (cell x)) (y (cell y)))  
      (begin (@:= x (@* 2 (@^ y))) (@^ x)))
```

Bessere Implementierung: nur für die Variablen, die tatsächlich Zuweisungsziel sind (im Bsp:  $y$  nicht)



# Definition

(alles nach: Turbak/Gifford Ch. 17.9)

CPS-Transformation (continuation passing style):

- ▶ original: Funktion gibt Wert zurück

```
f == (abs (x y) (let ( ... ) v))
```

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

```
f-cps == (abs (x y k) (let ( ... ) (k v)))
```

aus `g (f 3 2)` wird `f-cps 3 2 g-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 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 abs (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))))))
```

semantischer Bereich:

```
data Value = ... | VCtrlPoint Expcont
```

d. h. Continuations sind Werte

```
Expcont = Value -> State Store Value
```

```
Comp = Expcont -> State Store Value
```

**Modul:** DCPL.Semantics.FLICK.Cont

# Semantik für CPS

Semantik von Ausdruck  $x$   
in Umgebung  $E$  mit Continuation  $k$

- ▶  $x = (\text{app } f \ a)$   
Semantik von  $f$  in  $E$  mit Continuation:  $\lambda p.$   
Semantik von  $a$  in  $E$  mit Continuation:  $\lambda v.p \ v \ k$
- ▶  $x = (\text{label } L \ B)$   
Semantik von  $B$  in Umgebung  $E[L/k]$  mit  $k$
- ▶  $x = (\text{jump } L \ B)$   
let  $k' =$  gebundener Wert von  $L$  in  $E$ ,  
Semantik von  $B$  in  $E$  mit  $k'$

# CPS-Transformation: Spezifikation

(als Schritt im Compiler)

- ▶ Eingabe: Ausdruck  $X$ , Ausgabe: Ausdruck  $Y$
- ▶ Semantik:  $X \equiv Y(\lambda v.v)$   
(triviale top-level continuation)
- ▶ Syntax:
  - ▶  $X \in \text{Exp}$  (fast) beliebig,
  - ▶  $Y \in \text{ExpCPS}$  stark eingeschränkt
    - ▶ keine geschachtelten Applikationen
    - ▶ Argumente von Applikationen und Primops sind Variablen oder Literale

# CPS-Transformation: Zielsyntax

```
Exp/CPS ==> (app Id Exp/Value^*)  
            | (if Exp/Value Exp/CPS Exp/CPS)  
            | (let ((Id Exp/Letable)) Exp/CPS)  
            | (error Msg)
```

```
Exp/Value ==> Literal + Identifier
```

```
Exp/Letable ==> Literal  
               | (abs Id^* Exp/CPS)  
               | (prim Primop Exp/Value^*)
```

## Übersetze

```
(@+ (@- 0 (@* b b)) (@* 4 (@* a c)))
```



# Beispiel

```
(@+ (@- 0 (@* b b)) (@* 4 (@* a c)))
```

==>

```
(let ((t.3 (@* b b)))  
  (let ((t.2 (@- 0 t.3)))  
    (let ((t.5 (@* a c)))  
      (let ((t.4 (@* 4 t.5)))  
        (let ((t.1 (+ t.2 t.4)))  
          (app ktop.0 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  $k$ ,  $i_0$ , ..  $i_n$  *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

# Vereinfachungen

um geforderte Syntax (ExpCPS) zu erreichen:

- ▶ **implicit-let**

```
(app (abs (i_1 .. i_n) b) a_1 .. a_n)
==>
(let ((i_1 a_1)) ( .. (let ((i_n a_n)) b)..))
```

Umbenennungen von Variablen entfernen:

- ▶ **copy-prop**

```
(let ((i i')) b) ==> b [i:=i']
```

aber kein allgemeines Inlining

# Besser: Meta-Continuations

- ▶ bisher: CPS:  $\text{Exp} \rightarrow \text{Exp}$
- ▶ jetzt: CPS:  $\text{Exp} \rightarrow \text{MetaCont} \rightarrow \text{Exp}$

```
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))
```

# Motivation

(Literatur: DCPL 17.10) — Beispiel:

```
(let ((linear
      (abs(a b) (abs (x) (@+ (@* a x) b))))))
  (let ((f (linear 4 5)) (g (linear 6 7)))
    (@+ (f 8) (g 9)) ))
```

beachte nicht lokale Variablen: (abs (x) .. a .. b )

- ▶ 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 (Code, Wert<sub>1</sub>, ..., Wert<sub>n</sub>)

```
(abs (x) (@+ (@* a x) b) )
```

```
==>
```

```
(abs (clo x)
      (let ((a (@get 2 clo))
            (b (@get 3 clo)))
          (@+ (@* a x) b) ) )
```

Closure-Konstruktion?

Komplette Übersetzung des Beispiels?



# Transformation

```
CLP[ (abs (i_1 .. i_n) b) ] =  
  (@prod (abs (clo i_1 .. i_n)  
          (let ((v_1 (@get 2 clo)) .. )  
                CLP[b] ))  
        v_1 .. )
```

wobei  $\{v_1, \dots\}$  = freie Variablen in  $b$

```
CLP[ (app f a_1 .. a_n) ] =  
  (let ((clo CLP[f])  
        (code (@get 1 clo)))  
    (app code clo CLP[a_1] .. CLP[a_n]) )
```

zur Erhaltung der CPS-Form: anstatt erster Regel

```
CLP[ (let ((i (abs (..) ..))) b) ] = ...
```

# Zuweisungen und Closures

die Werte der nicht lokalen Variablen werden kopiert (in die Closures).

falls Zuweisungen an Variablen erlaubt sind (`set!`):

- ▶ *erst* assignment conversion
- ▶ *danach* closure conversion

## Vergleich mit inneren Klassen

```
interface Fun { int app (int x); }
class Linear {
    static Fun linear (int a, int b) {
        return new Fun() {
            int app (int x) { return a * x + b; }
        } }
    static int example() {
        Fun f = linear (4,5);
        Fun g = linear (6,7);
        return f.app(8) + g.app(9);
    } }
```

Fehler? Bytecode?

# 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.

Syntax-Erweiterung:

```
(program (a_1 .. a_n)
  -- body:
  (let ( ... ) ...)
  -- ab hier neu:
  (def sub0 (abs (...)) body0))
  ...
)
```

dann in `body*` keine Abstraktionen gestattet

# Motivation

bisher: closure conversion + lifting:

beliebiges Programm (Lambda-Ausdruck)  $\Rightarrow$  Programm mit nur globalen Funktionen (und Tupeln)

man kann sogar jeden Lambda-Ausdruck in äquivalentes Programm mit wenigen und feststehenden globalen Funktionen (Kombinatoren) übersetzen.

# Beispiel

vordefinierte Kombinatoren:

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

Programm:  $P = \lambda x.xx$

Übersetzung:  $P' = SII$

Begründung:  $P'x = SIIx \rightarrow Ix(Ix) \rightarrow x(Ix) \rightarrow xx$

# 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/>

# Rechnen mit Kombinatoren

- ▶ Standard-Basis:  $Kxy \rightarrow x$ ,  $lx \rightarrow x$ ,  $Sxyz \rightarrow xz(yz)$
- ▶ Tupel :  $\langle A_1, \dots, A_n \rangle := \lambda x. xA_1 \dots A_n$
- ▶ Projektionen:  $P_i^n \langle A_1, \dots, A_n \rangle \rightarrow A_i$
- ▶  $X = \langle K, S, K \rangle$
- ▶  $XXX \rightarrow ?$ ,  $X(XX) \rightarrow ?$
- ▶ Zahlen (nach Church):  $[n] := \lambda fx. f^n(x)$
- ▶ Nachfolger? Summe?

(Barendregt, S. 140, 166)

# Motivation

- ▶ (klassische) reale CPU/Rechner hat nur *globalen* Speicher (Register, Hauptspeicher)
- ▶ Argumentübergabe (Hauptprogramm → Unterprogramm) muß diesen Speicher benutzen (Rückgabe brauchen wir nicht wegen CPS)
- ▶ Zugriff auf Register schneller als auf Hauptspeicher ⇒ 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)

# Registervergabe und Graphenfärbung

Gegeben Programm (das Let innerhalb einer Abstraktion),  
konstruiere Graph  $G = (V, E)$

- ▶ Knoten  $V$ : die lokal gebundenen Namen
- ▶ Kanten  $E$ : falls  $x$  und  $y$  gleichzeitig benötigt, dann  $xy \in E$ .

gesucht ist konfliktfreie Färbung mit geringer Farbzahl:

- ▶ Farben  $C$ : (virtuelle) Register
- ▶ Färbung: Abbildung  $f : V \rightarrow C$
- ▶ konfliktfrei:  $\forall xy \in E : f(x) \neq f(y)$

# Algorithmen zur Färbung

Das Entscheidungsproblem COL

- ▶ Eingabe:  $(G, k)$
- ▶ Frage: existiert konfliktfreie Färbung  $f$  für  $G$  mit  $|\text{img } f| \leq k$

... ist NP-vollständig

⇒ kein effizienter Algorithmus bekannt

Näherungsverfahren (für Farben  $\{1, 2, \dots\}$ ):

- ▶ färbe der Reihe nach jeden Punkt mit der kleinsten freien Farbe (= die nicht unter seinen Nachbarn vorkommt)

Heuristik für gute Reihenfolge?



# Graphenparameter

- ▶ Maximalgrad  $\Delta(G)$
- ▶ chromatische Zahl  $\chi(G)$   
kleinstes  $k$ , für das  $G$  eine konfliktfreie  $k$ -Färbung besitzt
- ▶ Cliquenzahl  $\omega(G)$ : maximale Knotenzahl einer Clique  
(= vollständig verbundener Teilgraph)

## Anwendungen:

- ▶ Folgerung aus Algorithmus:  $\chi(G) \leq \Delta(G) + 1$ .  
Für welche Graphen gilt Gleichheit?
- ▶ größter Fehler des heuristischen Algorithmus?
- ▶ trivial  $\omega(G) \leq \chi(G)$ . Möglicher Abstand?

# Register-Files

## SPARC-Architektur:

- ▶ Register-File besteht aus Blöcken von je 8 Registern
- ▶ Register-Window zeigt je drei benachbarte Blöcke
- ▶ bei UP-Aufruf/Rückkehr wandert Window um zwei (!) Blöcke nach rechts/links (d. h. die Fenster überlappen)

## Registersatz besteht aus

- ▶ global  $G_0, \dots, G_7$
- ▶ in  $I_0, \dots, I_7$  (links im Fenster)
- ▶ lokal  $L_0, \dots, L_7$  (mitte)
- ▶ out  $O_1, \dots, O_7$  (rechts)

# 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:  $\text{tospace}[0] = \text{Wurzel}$ ,  $\text{scan} = 0, \text{free} = 1$ .
- ▶ post:  $\text{scan} = \text{free}$

Schritt: while  $\text{scan} < \text{free}$ :

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

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/fohlen/main/node78.html>

- ▶ **Aufgabe:**

<http://www.imn.htwk-leipzig.de/~waldmann/edu/ws09/pps/fohlen/main/node79.html>

# Semantik definiert durch. . .

- ▶ Interpretation

- ▶ funktional (CBV, CBN), Fixpunkte
- ▶ imperativ (Speicher)
- ▶ Ablaufsteuerung (Continuations)

- ▶ Transformation

- ▶ desugaring (let  $\rightarrow$  lambda)
- ▶ assignment conversion
- ▶ CPS transformation
- ▶ closure passing, lifting

```
git clone git://dfa.imn.htwk-leipzig.de/var/www/dcpl
```