

24 Strukturierte Daten

Im Folgenden wollen wir unsere funktionale Programmiersprache um einfache Datentypen erweitern. Wir beginnen mit der Einführung von **Tupeln**.

24.1 Tupel

Tupel werden mithilfe k -stelliger Konstruktoren ($k \geq 0$) $(., \dots, .)$ aufgebaut und mithilfe der Projektions-Funktionen $\#j$ ($j \in \mathbb{N}_0$) wieder zerlegt.

Entsprechend erweitern wir die Syntax unserer Programm-Ausdrücke durch:

$$e ::= \dots \mid (e_0, \dots, e_{k-1}) \mid \#j e$$
$$\text{match } e_1 \text{ with } (x_0, \dots, x_{k-1}) \rightarrow e_0$$


- Tupel werden angelegt, indem erst die Folge der Referenzen auf ihre Komponenten auf dem Keller gesammelt und dann mithilfe der Operation `mkvec` in den Heap gelegt werden.
- Auf Komponenten greifen wir zu, indem wir innerhalb des Tupels einen indizierten Zugriff vornehmen.

$$\begin{aligned}
 \text{code}_V (e_0, \dots, e_{k-1}) \rho \text{kp} &= \text{code}_C e_0 \rho \text{kp} \\
 &\quad \text{code}_C e_1 \rho (\text{kp} + 1) \\
 &\quad \dots \\
 &\quad \text{code}_C e_{k-1} \rho (\text{kp} + k - 1) \\
 &\quad \text{mkvec } k
 \end{aligned}$$

$$\begin{aligned}
 \text{code}_V (\#j e) \rho \text{kp} &= \text{code}_V e \rho \text{kp} \\
 &\quad \text{get } j \\
 &\quad \text{eval}
 \end{aligned}$$

Im Falle von `CBV` können natürlich direkt die Werte der e_i berechnet werden.

Dabei ist:



```
if (S[SP] == (V,g,v))  
    S[SP] = v[j];  
else Error "Vector expected!";
```

Möchte man nicht auf einzelne, sondern gegebenenfalls alle Komponenten eines Tupels zugreifen, kann man dies mithilfe des Ausdrucks

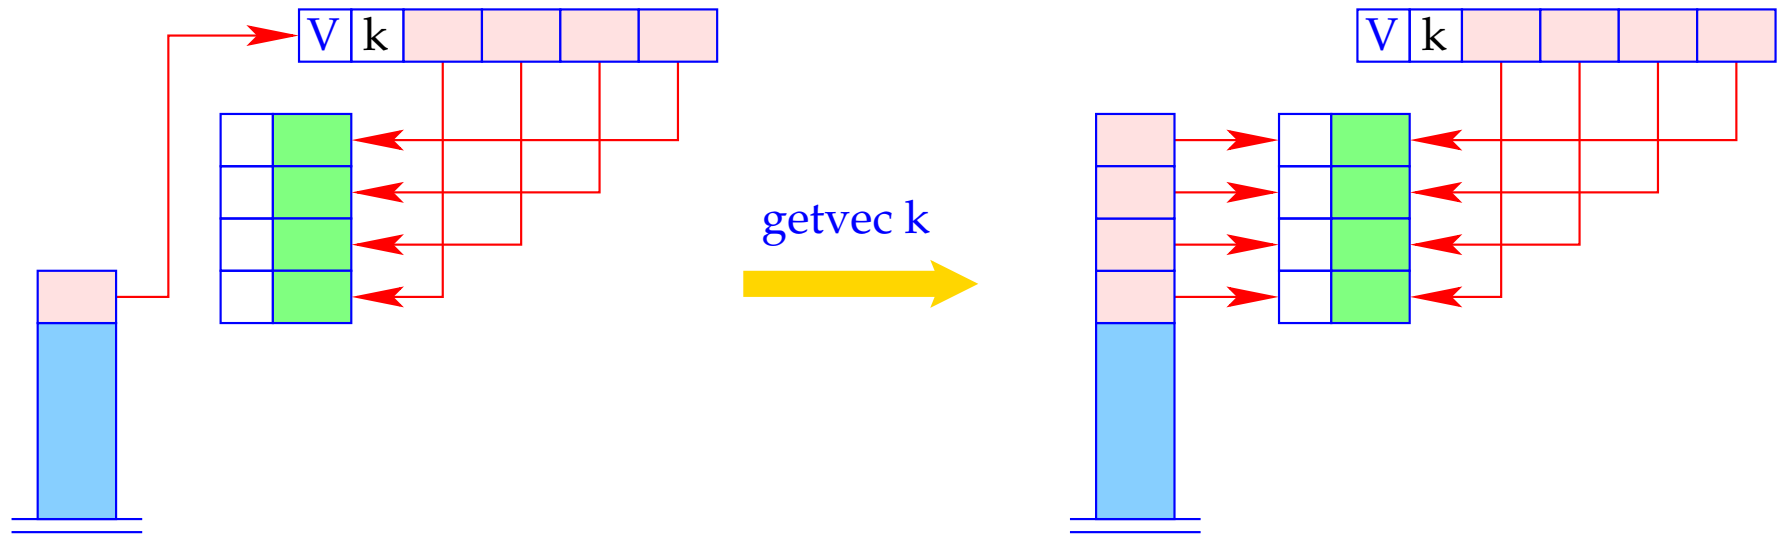
$e \equiv \mathbf{match} \ e_1 \ \mathbf{with} \ (y_0, \dots, y_{k-1}) \rightarrow e_0$ tun.

Diesen übersetzen wir wie folgt:

$$\begin{aligned} \mathbf{code}_V \ e \ \rho \ \mathbf{kp} &= \mathbf{code}_V \ e_1 \ \rho \ \mathbf{kp} \\ &\quad \mathbf{getvec} \ k \\ &\quad \mathbf{code}_V \ e_0 \ \rho' \ (\mathbf{kp} + k) \\ &\quad \mathbf{slide} \ k \end{aligned}$$

wobei $\rho' = \rho \oplus \{y_i \mapsto (L, kp + i + 1) \mid i = 0, \dots, k - 1\}$.

Der Befehl `getvec k` legt die Komponenten eines Vektors der Länge k auf den Keller:



```

if (S[SP] == (V,k,v)) {
    SP--;
    for(i=0; i<k; i++) {
        SP++; S[SP] = v[i];
    }
} else Error "Vector expected!";

```

24.2 Listen

Als Beispiel eines weiteren Datentyps betrachten wir [Listen](#).

Listen werden aus Listen-Elementen mithilfe der Konstante `[]` (“Nil” – die leere Liste) und des rechts-assoziativen Operators `::` (“Cons” – dem Listen-Konstruktor) aufgebaut.

Ein **match**-Ausdruck gestattet den Zugriff auf die Komponenten einer Liste.

Beispiel: Die Append-Funktion `app`:

```
let rec app = fun l, y → match l with
  [] → y
  | h :: t → h :: (app t y)
```


Folglich erweitern wir die Syntax von Ausdrücken e um:

$$e ::= \dots \mid [] \mid (e_1 :: e_2) \\ \mid (\mathbf{match} \ e_0 \ \mathbf{with} \ [] \rightarrow e_1 \mid h :: t \rightarrow e_2)$$

Neue Halden-Objekte:



leere Liste



nicht-leere Liste

24.3 Der Aufbau von Listen


Für das Anlegen von Listen-Knoten führen wir die Befehle `nil` und `cons` ein.

Damit erhalten wir für **CBN**:


$$\begin{aligned}\text{code}_V [] \rho \text{kp} &= \text{nil} \\ \text{code}_V (e_1 :: e_2) \rho \text{kp} &= \text{code}_C e_1 \rho \text{kp} \\ &\quad \text{code}_C e_2 \rho (\text{kp} + 1) \\ &\quad \text{cons}\end{aligned}$$

Beachte:

- Bei **CBN** werden für die Argumente von “::” Abschlüsse angelegt.
- Bei **CBV** müssen sie dagegen erst ausgewertet werden.



$SP++; S[SP] = \text{new } (L, \text{Nil});$



$S[SP-1] = \text{new } (L, \text{Cons}, S[SP-1], S[SP]);$
 $SP--;$

24.4 Pattern-Matching

Betrachte den Ausdruck $e \equiv \mathbf{match} \ e_0 \ \mathbf{with} \ [] \rightarrow e_1 \mid h :: t \rightarrow e_2$.

Auswertung von e erfordert:


- Auswertung von e_0 ;
- Überprüfung, ob e_0 ein L-Objekt ist;
- Falls e_0 gleich der leeren Liste ist, Auswertung von e_1 ...
- ... andernfalls Kellern der Verweise des L-Objekts und Auswertung von e_2 .

Folglich erhalten wir (für CBN wie CBV):

$$\text{code}_V e \rho \text{kp} = \begin{array}{l} \text{code}_V e_0 \rho \text{kp} \\ \text{tlist A} \\ \text{code}_V e_1 \rho \text{kp} \\ \text{jump B} \\ \text{A : } \text{code}_V e_2 \rho' (\text{kp} + 2) \\ \text{slide 2} \\ \text{B : } \dots \end{array}$$

wobei $\rho' = \rho \oplus \{h \mapsto (L, \text{kp} + 1), t \mapsto (L, \text{kp} + 2)\}$.


Der neue Befehl `tlist A` führt die notwendigen Überprüfungen durch und legt (im Cons-Fall) zwei neue lokale Variablen an:



```

h = S[SP];
if (H[h] != (L,...))
    Error "no list!";
if (H[h] == (_,Nil)) SP- -;
...

```



```

... else {
  S[SP+1] = S[SP]→s[1];
  S[SP] = S[SP]→s[0];
  SP++; PC = A;
}

```

Beispiel: Der (entwirrte) Rumpf der Funktion `app` mit $\text{app} \mapsto (G, 0)$:

0	targ 2	3	pushglob 0	0	C:	mark D
0	pushloc 0	4	pushloc 2	3		pushglob 2
1	eval	5	pushloc 6	4		pushglob 1
1	tlist A	6	mkvec 3	5		pushglob 0
0	pushloc 1	4	mkclos C	6		eval
1	eval	4	cons	6		apply
1	jump B	3	slide 2	1	D:	update
2	A: pushloc 1	1	B: return 2			

Beachte:

Hat man Datentypen mit mehr als zwei Konstruktoren, benötigt man eine Verallgemeinerung des `tlist`-Befehls, der einer `switch`-Anweisung entspricht :-)

24.5 Abschlüsse von Tupeln und Listen

Das generelle Schema für code_C lässt sich auch bei Tupeln und Listen optimieren:

$$\begin{aligned} \text{code}_C (e_0, \dots, e_{k-1}) \rho \text{kp} &= \text{code}_V (e_0, \dots, e_{k-1}) \rho \text{kp} = \text{code}_C e_0 \rho \text{kp} \\ &\quad \text{code}_C e_1 \rho (\text{kp} + 1) \\ &\quad \dots \\ &\quad \text{code}_C e_{k-1} \rho (\text{kp} + k - 1) \\ &\quad \text{mkvec } k \\ \text{code}_C [] \rho \text{kp} &= \text{code}_V [] \rho \text{kp} = \text{nil} \\ \text{code}_C (e_1 :: e_2) \rho \text{kp} &= \text{code}_V (e_1 :: e_2) \rho \text{kp} = \text{code}_C e_1 \rho \text{kp} \\ &\quad \text{code}_C e_2 \rho (\text{kp} + 1) \\ &\quad \text{cons} \end{aligned}$$

25 Letzte Aufrufe

Das Aufruf-Vorkommen $l \equiv e' e_0 \dots e_{m-1}$ heißt **letzt** in einem Ausdruck e , falls die Auswertung von l den Wert für e liefern kann.

Beispiele:

$r\ t\ (h :: y)$ ist **letzt** in `match x with [] → y | h :: t → r t (h :: y)`
 $f\ (x - 1)$ ist **nicht letzt** in `if x ≤ 1 then 1 else x * f (x - 1)`

Beobachtung:

Letzte Aufrufe eines Funktions-Rumpfs benötigen **keinen neuen** Kellerrahmen!



Automatische Transformation von Tail Recursion in Schleifen !!!

Der Code für einen letzten Aufruf $l \equiv (e' e_0 \dots e_{m-1})$ in einer Funktion f mit k Argumenten muss:

- die aktuellen Parameter e_i anlegen und die Funktion e' bestimmen;
- die lokalen Variablen sowie die k verbrauchten Argumente von f frei geben;
- `apply` ausführen.

```

codeV l ρ kp = codeC em-1 ρ kp
                codeC em-2 ρ (kp + 1)
                ...
                codeC e0 ρ (kp + m - 1)
                codeV e' ρ (kp + m)           // Auswerten der Funktion
                move r (m + 1)                // Freigabe
                apply

```

wobei $r = kp + k$ die Anzahl der freizugebenden stack-Zellen ist.


Beispiel:

Der Rumpf der Funktion

$$r = \mathbf{fun} \ x, y \rightarrow \mathbf{match} \ x \ \mathbf{with} \ [] \rightarrow y \mid h :: t \rightarrow r \ t \ (h :: y)$$

0	targ 2	1	jump B	4	pushglob 0
0	pushloc 0			5	eval
1	eval	2	A: pushloc 1	5	move 4 3
1	tlist A	3	pushloc 4		apply
0	pushloc 1	4	cons		slide 2
1	eval	3	pushloc 1	1	B: return 2

Da der alte Kellerrahmen beibehalten wird, wird **return 2** nur über den direkten Sprung am Ende der []-Alternative erreicht.



```

SP = SP - k - r;
for (i=1; i ≤ k; i++)
    S[SP+i] = S[SP+i+r];
SP = SP + k;

```

Die Übersetzung logischer Programmiersprachen

26 Die Sprache PuP

Wir betrachten hier nur die Mini-Sprache PuP (“Pure Prolog”). Insbesondere verzichten wir auf:

- Arithmetik;
- den Cut-Operator (vorerst :-)
- Selbst-Modifikation von Programmen mittels `assert` und `retract`.

Beispiel:

$\text{bigger}(X, Y) \leftarrow X = \textit{elephant}, Y = \textit{horse}$

$\text{bigger}(X, Y) \leftarrow X = \textit{horse}, Y = \textit{donkey}$

$\text{bigger}(X, Y) \leftarrow X = \textit{donkey}, Y = \textit{dog}$

$\text{bigger}(X, Y) \leftarrow X = \textit{donkey}, Y = \textit{monkey}$

$\text{is_bigger}(X, Y) \leftarrow \text{bigger}(X, Y)$

$\text{is_bigger}(X, Y) \leftarrow \text{bigger}(X, Z), \text{is_bigger}(Z, Y)$

? $\text{is_bigger}(\textit{elephant}, \textit{dog})$

Ein realistischeres Beispiel:

$$\text{app}(X, Y, Z) \leftarrow X = [], Y = Z$$

$$\text{app}(X, Y, Z) \leftarrow X = [H|X'], Z = [H|Z'], \text{app}(X', Y, Z')$$

$$? \text{ app}(X, [Y, c], [a, b, Z])$$

Ein realistischeres Beispiel:

$\text{app}(X, Y, Z) \leftarrow X = [], Y = Z$

$\text{app}(X, Y, Z) \leftarrow X = [H|X'], Z = [H|Z'], \text{app}(X', Y, Z')$

? $\text{app}(X, [Y, c], [a, b, Z])$

Bemerkung:

$[]$ \equiv das Atom **leere Liste**

$[H|Z]$ \equiv **binäre** Constructor-Anwendung

$[a, b, Z]$ \equiv Abkürzung für: $[a|[b|[Z|[]]]]$

Ein Programm p ist darum wie folgt aufgebaut:

$$\begin{aligned}t & ::= a \mid X \mid _ \mid f(t_1, \dots, t_n) \\g & ::= p(t_1, \dots, t_k) \mid X = t \\c & ::= p(X_1, \dots, X_k) \leftarrow g_1, \dots, g_r \\p & ::= c_1 \dots c_m ? g\end{aligned}$$

- Ein **Term** t ist entweder ein Atom, eine (evt. anonyme) Variable oder eine Konstruktor-Anwendung.
- Ein **Ziel** g ist entweder ein Literal, d.h. ein Prädikats-Aufruf, oder eine Unifikation.
- Eine **Klausel** c besteht aus einem **Kopf** $p(X_1, \dots, X_k)$ mit Prädikats-Namen und Liste der formalen Parameter sowie einer Folge von Zielen als **Rumpf**.
- Ein **Programm** besteht aus einer Folge von Klauseln sowie einem Ziel als **Anfrage**.

Prozedurale Sicht auf PuP-Programme:

Ziel	==	Prozedur-Aufruf
Prädikat	==	Prozedur
Definition	==	Rumpf
Term	==	Wert
Unifikation	==	elementarer Berechnungsschritt
Bindung von Variablen	==	Seiteneffekt


Achtung: Prädikat-Aufrufe ...

- ... liefern keinen Rückgabewert!
- ... beeinflussen den Aufrufer einzig durch Seiteneffekte :-)
- ... können **fehlschlagen**. Dann wird die nächste Definition probiert :-))

⇒ backtracking

27 Architektur der WiM:

Der Code-Speicher:



C = Code Speicher – enthält WiM-Programm;
jede Zelle enthält einen Befehl;

PC = Program Counter – zeigt auf nächsten auszuführenden Befehl.