

# Compiler 1: Grundlagen

## Laufzeitorganisation



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

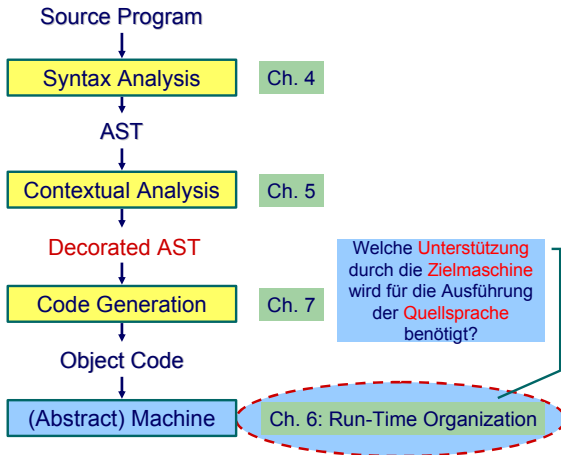
WS 2012/13

Andreas Koch


FG Eingebettete Systeme und ihre Anwendungen  
Informatik, TU Darmstadt



# Einleitung



- ▶ Compiler übersetzt  
Hochsprachenprogramm in **äquivalentes**  
Maschinenprogramm
- ▶ **Laufzeitorganisation** beschreibt  
Darstellung von abstrakten Strukturen der  
Hochsprache auf Maschinenebene
- ▶ Instruktionen und Speicherinhalte





## Wichtige Aspekte

**Datendarstellung** der Werte jedes Typs der Eingabesprache

**Auswertung von Ausdrücken** und Handhabung von Zwischenergebnissen

**Speicherverwaltung** verschiedener Daten: Global, lokal und Heap

**Routinen** zur Implementierung von Prozeduren, Funktionen und ihre Datenübergabe

**Erweiterung auf OO-Sprachen** Objekte, Methoden, Klassen und Vererbung



# Triangle Abstract Machine

# Triangle Abstract Machine (TAM)



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Zwei getrennte Speicherbereiche
- ▶ Datenspeicher: 16b Worte
- ▶ Instruktionsspeicher: 32b Worte

➡ Harvard-Architektur

Adressbereiche über CPU-Register adressiert

# Adressierung des Instruktionsspeichers



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

Programm	CB	Code Base (konstant)
	CT	Code Top (konstant)
	CP	Code Pointer (variabel)
Intrinsics	PB	Primitive Base (konstant)
	PT	Primitive Top (konstant)



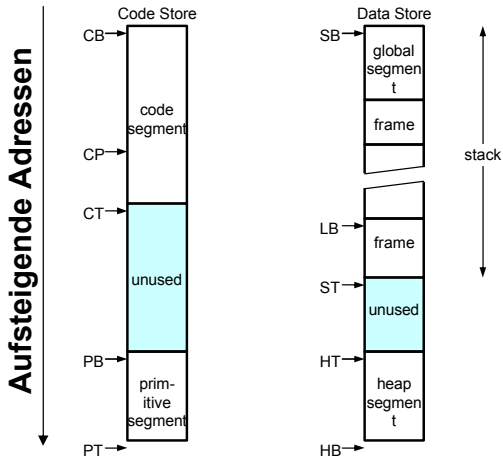
# Adressierung des Datenspeichers



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

Stack	SB	Stack Base (konstant)
	ST	Stack Top (variabel)
Heap	HB	Heap Base (konstant)
	HT	Heap Top (variabel)
	HF	Heap Free (variabel)

# TAM Speicherbereiche





- ▶ 32b Worte im Programmspeicher
- ▶ op, 4b Art der Instruktion
- ▶ r, 4b Registernummer
- ▶ n, 8b Operandengröße in Worten
- ▶ d, 16b Adressverschiebung (displacement, offset)

Beispiel: LOAD (1) 3[ST]

- ▶ op=0 (0000)
- ▶ r=5 (1001)
- ▶ n=1 (00000001)
- ▶ d=3 (0000000000000011)

➡ 0000 1001 0000 0001 0000 0000 0000 0011

Op.	Mnem.	Effect
0	LOAD(n) d[r]	Fetch an n-word object from the data address and push it onto the stack
1	LOADA d[r]	Push the data address onto the stack
2	LOADI(n)	Pop a data address from the stack, fetch an n-word object from that address, push it onto the stack
3	LOADL d	Push the one-word literal value d onto the stack
4	STORE(n) d[r]	Pop an n-word object from the stack, and store it at the data address
5	STOREI(n)	Pop an address from the stack, then pop an n-word object from the stack and store it at that address
6	CALL(n) d[r]	Call the routine at the code address using the address in register n as the static link
7	CALLI	Pop a closure (static link and code address) from the stack, then call the routine
8	RETURN(n) d	Return from the current routine; pop an n-word result from the stack, then pop the topmost frame, then pop d words of arguments, then push the result back (unused)
9	-	
10	PUSH d	Push d words (uninitialised) onto the stack
11	POP(n) d	Pop an n-word result from the stack, then pop d more words, then push the result back on the stack
12	JUMP d[r]	Jump to code address
13	JUMPI	Pop a code address from the stack, then jump to that address
14	JUMPIF(n) d[r]	Pop a one-word value from the stack, then jump to code address if and only if that value equals n
15	HALT	Stop execution of the program

- ▶ Auch Primitive genannt
- ▶ “Magische” Adressen im Programmspeicher
- ▶ Führen bei Aufruf als Routine komplexe Operationen aus
- ▶ ... direkt in der abstrakten Maschine (hier: Java)
- ▶ Keine TAM-Instruktionen mehr!

Addr.	Mnemo.	Arg.	Res.	Effect
...				
2[PB]	not	t	t'	t' = !t
...				
8[PB]	add	i1, i2	i'	i' = i1 + i2
...				
15[PB]	ge	i1, i2	t'	Set t'=true iff i1 ≥ i2
...				
26[PB]	putint	i	-	Write an integer whose value is i



# Darstellung von Daten



**Unverwechselbarkeit** Unterschiedliche Werte sollen unterschiedliche Darstellungen haben

- ▶ Klappt nicht immer (duale Gleitkommadarstellung reeller Zahlen)

**Einzigkeitigkeit** Ein Wert wird immer auf die gleiche Weise dargestellt

**Konstante Größe** Alle Werte eines Typs belegen dieselbe Menge an Speicherplatz

**Art der Darstellung**


- Direkt** Wert einer Variablen  $x$  kann direkt adressiert werden
- Indirekt** Wert einer Variablen  $x$  muß über einen Zeiger bzw. *Handle* adressiert werden

## Direkt



- ▶ Effizienter Zugriff, keine Zeiger verfolgen
- ▶ Effiziente Abspeicherung
- ▶ Implizite Adressierung auf Stack
- ▶ Pascal, C/C++, Java (primitive Typen!)

## Indirekt



- ▶ Für Typen mit **variierender** Darstellungsgröße
  - ▶ Dynamische Arrays
  - ▶ Rekursive Typen
  - ▶ Objekte
- ▶ Zeiger/Handles selber haben **konstante Größe**
- ▶ Lisp, ML, Haskell, Prolog



## Notation

- ▶  $\#[T]$ : Anzahl **unterschiedlicher** Elemente in  $T$
- ▶  $\text{size}[T]$  minimaler Speicherbedarf (in Bit) zur Darstellung eines Wertes aus  $T$

## Primitive Typen

Können nicht weiter in kleinere Typen zerlegt werden.

Beispiele: Integer, Char, Boolean

	$\#[T]$	$\text{size}[T]$	Darstellung
<b>Boolean</b>	2	$\geq 1$	0 and 1
<b>Integer</b>	$2^{16}$ or $2^{32}$	16 / 32	2-complement
<b>Char</b>	$2^8$ or $2^{16}$	8 / 16	ASCII/Unicode
<b>float</b>	infinite	32 / 64	approximation



Es muss immer gelten

$$\text{size}[T] \geq \log_2(\#[T])$$

wenn  $\text{size}[T]$  in Bits gemessen wird.



## TAM

**Boolean** 16b (=1 Datenwort): 00..00, 00..01

**Char** 16b (=1 Datenwort): Unicode

**Integer** 16b (=1 Datenwort):  $\text{maxint} = 2^{15} - 1 = 32767$

## Klassische x86-basierte Systeme

**Boolean** 8b (=1 Byte): 00..00, 11..11

**Char** 8b (=1 Byte): ASCII

**Integer** 16b oder 32b (=1 word, double word)

# Records 1



```
type Date ~ record
  y : Integer,
  m : Integer,
  d : Integer
end;
type Details ~ record
  female : Boolean,
  dob : Date,
  status : Char
end;
var today: Date;
var my: Details
```

Üblicherweise wird ein Record durch die **Anreihung** der Darstellungen seiner **Komponenten** repräsentiert.

Im Beispiel wird angenommen, das **ganze Wörter** adressiert werden. **Verschwenderisch** für Boolean!

today.y 


today.m 

--

today.d 

--

my.female 


my.dob.y 

--

my.dob.m 

--

my.dob.d 

--

my.status 

--



Speicherbedarf und Adressierung

Wo **genau** liegen die einzelnen Daten im Speicher?

```
type Date = record
```

```
  y : Integer,
```

```
  m : Integer,
```

```
  d : Integer
```

```
end;
```

```
var today: Date;
```

- ▶  $\text{size}[\text{Date}] = 3 * \text{size}[\text{Integer}] = 3 \text{ Worte}$
- ▶  $\text{address}[\text{today.y}] = \text{address}[\text{today}]$
- ▶  $\text{address}[\text{today.m}] = \text{address}[\text{today}] + \text{size}[\text{Integer}]$
- ▶  $\text{address}[\text{today.d}] = \text{address}[\text{today}] + 2 * \text{size}[\text{Integer}]$

- ▶ Viele reale Prozessoren haben Anforderungen an Adressausrichtung von Daten
  - ▶ Beispiel: Es können nur 32b Worte als Einheit adressiert werden
  - ▶ Ist schneller, als größere Freiheit zu unterstützen
- ▶ Darstellung von Records im Speicher kann ineffizient werden
  - ▶ Unter Platzgesichtspunkten (wenn optimal ausgerichtet)
  - ▶ Unter Laufzeitgesichtspunkten (wenn optimal gepackt)

# Variante Records (disjoint unions) 1



Ähnlich einer Record, aber zu einem Zeitpunkt existiert immer nur eine Untermenge von Komponenten.


- ▶ Selektion der aktiven Untermenge durch *type tag*

```
type Number =  
  record  
    case (discrete:Boolean) of  
      true: (i: Integer);  
      false: (r: Real)  
    end;  
var num: Number
```

num.discrete	true
num.i	27
	unused

num.discrete	false
num.r	8.23312

## Allgemeiner Aufbau







Adressierung: Lege disjunkte Teile im Speicher **übereinander**

```
type Number = record
  case acc: Boolean of
    true : ( i : Integer );
    false : ( r : Real );
  end;
var num : Number;
```

- ▶  $\text{size}[\text{Number}] = \text{size}[\text{Boolean}] + \max(\text{size}[\text{Integer}], \text{size}[\text{Real}])$
- ▶  $\text{address}[\text{num}. \text{acc}] = \text{address}[\text{Number}]$
- ▶  $\text{address}[\text{num}. \text{i}] = \text{address}[\text{Number}] + \text{size}[\text{Boolean}]$
- ▶  $\text{address}[\text{num}. \text{r}] = \text{address}[\text{Number}] + \text{size}[\text{Boolean}]$



- ▶ Zusammengesetzter Typ
- ▶ Besteht aus ein oder mehreren Elementen des *gleichen* Typs
  - ▶ Unterschied zu Record
- ▶ Zugriff über Index, nicht über Namen
- ▶ **Statische Arrays** haben feste, zur Compile-Zeit bekannte Abmessungen
- ▶ **Dynamische Arrays** haben zur Laufzeit variable Abmessungen

```
type Name = array 4 of Char;  
var me: Name;  
var full: array 2 of Name
```

me[0]	'l'
me[1]	'e'
me[2]	'i'
me[3]	'a'

full[0][0]	'h'
full[0][1]	'a'
full[0][2]	'n'
full[0][3]	's'
full[1][0]	'o'
full[1][1]	't'
full[1][2]	't'
full[1][3]	'o'

## Offensichtliche Darstellung

```
type Name = array 6 of Char;  
var me : Name;
```

- ▶  $\text{size}[\text{Name}] = 6 * \text{size}[\text{Char}] = 6 \text{ Worte}$
- ▶  $\text{address}[\text{me}[0]] = \text{address}[\text{me}]$
- ▶  $\text{address}[\text{me}[1]] = \text{address}[\text{me}] + 1 * \text{size}[\text{Char}]$
- ▶  $\text{address}[\text{me}[i]] = \text{address}[\text{me}] + i * \text{size}[\text{Char}]$

## Kommentare


- ▶ Annahme hier: Indizes beginnen bei 0 (C, Java)
- ▶  $i$  nicht notwendigerweise konstant  
    ➡ Adressberechnung zur Laufzeit



- ▶ Grundsätzlich wie statische Arrays
- ▶ Aber Abmessungen erst zur Laufzeit bekannt
  - ▶ Möglicherweise sogar variabel
- ▶ Indirekte Darstellung über **Deskriptor**
  - ▶ Adresse des ersten Elements
  - ▶ Abmessungen
- ▶ Speicher wird zur Laufzeit angefordert (→ Heap)

# Dynamische Arrays 2

```
char[] buffer;  
buffer = new char[len];
```





Referenziert sich selbst in seiner eigenen Definition

- ▶ Rekursiver Typ  $T$  hat Komponenten vom Type  $T$

```
class IntList {  
    int head;  
    IntList tail;  
}
```

↳ In der Regel nur über Zeiger



# Auswertung von Ausdrücken



- ▶ Beispiel:  $a*a + 2*a*b - 4*a*c$
- ▶ Zugrundeliegende Maschine hat Instruktionen für Addition, Multiplikation, (Division), ...
- ▶ ... fast immer: Rechnen mit **zwei** Operanden
  - ↳ Abarbeiten in Teilausdrücken
- ▶ Wie mit Zwischenergebnissen verfahren? Wo abspeichern?
  - ▶ Registermaschine: In Registern (nicht ganz einfach ...)
  - ▶ Stack-Maschine: Post-Fix Auswertung auf Stack (einfach!)
- ▶ Triangle TAM ist **Stackmaschine**





<i><b>Instr.</b></i>	<i><b>Meaning</b></i>
<b>STORE</b> <i>a</i>	<b>Pop</b> the top value off the stack and <b>store</b> it at <b>address a</b> .
<b>LOAD</b> <i>a</i>	<b>Fetch</b> a value from <b>address a</b> and push it on to the stack.
<b>LOADL</b> <i>n</i>	<b>Push</b> the <b>literal value n</b> onto the stack.
<b>ADD</b>	<b>Replace</b> the <b>two</b> top values on the top by their <b>sum</b> .
<b>SUB</b>	<b>Replace</b> the <b>two</b> top values on the top by their <b>difference</b> .
<b>MUL</b>	<b>Replace</b> the <b>two</b> top values on the stack by their <b>product</b> .



```
d := a*a + 2*a*b - 4*a*c;
```

```
LOAD a
LOAD a
MUL
LOADL 2
LOAD a
MUL
LOAD b
MUL
ADD
LOADL 4
LOAD a
MUL
LOAD c
MUL
SUB
STORE d
```

```
STORE a
LOAD a
LOADL n
ADD
SUB
MUL
```

```
d := a*a + 2*a*b - 4*a
```

```
LOAD a
LOAD a
MUL
LOADL 2
LOAD a
MUL
LOAD b
MUL
ADD
LOADL 4
LOAD a
MUL
LOAD c
MUL
SUB
STORE d
```



...



Sehr schnelle Speicherelemente direkt im Prozessor

- ▶ Für Zwischenergebnisse etc.
- ▶ In der Regel 8/16/32/64b breit
- ▶ Begrenzte Anzahl, üblicherweise 4...32 direkt verwendbar



<i>Instr.</i>	<i>Meaning</i>
<b>STORE</b> $R_i$ $a$	<b>Store</b> the value in $R_i$ into memory location $a$ .
<b>LOAD</b> $R_i$ $a$	<b>Load</b> the value on memory location $a$ into $R_i$ .
<b>MULT</b> $R_i$ $x$	<b>Multiply</b> the values in $R_i$ and $x$ and store the result in $R_i$ (overwriting the old value).
<b>ADD</b> $R_i$ $x$	<b>Subtract</b> the value in $x$ from $R_i$ and store the result in $R_i$ .
...	

$x$  Register  $R_i$ , oder eine Adresse  $a$ , oder ein literaler Wert  $L$

Nicht immer so allgemein verwendbar, häufig Einschränkungen

- ▶ Nur bestimmte Register für bestimmte Operationen
- ▶ Nicht alle Arten von Operanden für alle Operationen



- ▶ Code für Registermaschine ist **effizienter**
- ▶ Compilierung ist aber komplexer
  - ▶ Verwaltung (Allokation) von Registern
  - ▶ Speichere Zwischenergebnisse in Registern
  - ▶ Problem: Endlich viele Register!  
Was, wenn Ausdruck komplizierter (zuviele Zwischenergebnisse)?

Beispiel:

```
d := a*a + 2*a*b - 4*a*c;  
LOAD R1 a ; R1: a  
MULT R1 a ; R1: a*a  
LOAD R2 2 ; R2: 2  
MULT R2 a ; R2: 2*a  
MULT R2 b ; R2: 2*a*b  
ADD R1 R2 ; R1: a*a+2*a*b  
LOAD R2 ; R2: 4  
MULT R2 a ; R2: 4*a  
MULT R2 c ; R2: 4*a*c  
SUB R1 R2 ; R1: a*a + ...  
STORE R1 d ; store result
```



# Speicherverwaltung



Speicher auf der **Zielmaschine**

**Datenspeicher**

- ▶ Beispielsweise: Stack oder Heap
- ▶ Adressierbare Elemente: 8/16/32/64b Worte

**Programmspeicher**


- ▶ Variable Instruktionslänge (x86)
- ▶ Feste Instruktionslänge (RISC)
- ▶ Organisation weniger wichtig für Compiler
- ▶ Ausnahmen: Embedded Systems, virtueller Speicher (Linker)

➔ Computerarchitektur (von-Neumann vs. Harvard, NUMA, COMA, ...)

**Globale** Variablen: Existieren über gesamte Programmlaufzeit

- ▶ Compiler kann bereits Speicherbedarf jeder Variable berechnen
- ▶ Damit kann jeder Variable passender Speicher **zugewiesen** (alloziert) werden
- ▶ Nun bekannt: **Adresse** jeder Variable im Speicher

```
let
  type Date = record
    y: Integer,
    m: Integer,
    d: Integer
  end;
  var a: array 3 of Integer; 3
  var b: Boolean;           1
  var c: Char;              1
  var t: Date               3
in
  ...
```



... könnte auch  
woanders im  
Speicher liegen!





## Einfache Vorgehensweise bei Vergabe von Adressen: Bündige Anreihung

```
let
  var a : Boolean;
  var b : array 3 of Integer;
  var c : Char
in
  ...
```

- ▶  $\text{address}[a] = 0$  (relativ zum Beginn des Datenspeichers)
- ▶  $\text{address}[b] = 1$
- ▶  $\text{address}[b[0]] = \text{address}[b] = 1$
- ▶  $\text{address}[b[1]] = \text{address}[b] + 1 = 2$
- ▶  $\text{address}[b[2]] = \text{address}[b] + 2 = 3$
- ▶  $\text{address}[c] = 4$



## Lokale Variable $\nabla$

- ▶ Ist im Inneren eines Blocks definiert
  - ▶ Prozedur, Funktion, Let
- ▶ Existiert nur, während der Block aktiv ist
  - ▶ Beachte: “Existiert” bedeutet **nicht** auch “zugreifbar”
- ▶ Hat so eine begrenzte **Lebensdauer**

```
let
  var b: Boolean;
  var c: Char
in
  proc Y()
    let var d: Integer
    in ...

  proc Z()
    let var f: Integer
    in ... Y(); ...
  in begin
    ... Y(); ...; Z(); ...
  end
```

Globale Variablen; Lebensdauer: über das gesamte Programm

Lokale Variablen von Y: solange Prozedur Y aktiv ist


Lokale Variablen von Z: solange Prozedur Z aktiv ist

Prozedur kann gleichzeitig mehrfach aktiv sein (Rekursion), dann müssen auch mehrere Kopien der **lokalen Variablen** existieren.

# Verwaltung von Stapelspeicher 2



```
let
  ... ! global variables
proc Y() ~
  let
    ... ! local variables for Y
  in
    ...
proc Z() ~
  let
    ... ! local variables for Z
  in
    ... Y(); ...
in
  ... Y(); Z(); ...
```





## Beobachtungen

- ▶ Nur globale Variablen existieren über die gesamte Programmlaufzeit
- ▶ Lebenszeiten der lokalen Variablen sind hierarchisch verschachtelt

➡ Handhabung via Stack



## Organisationsstruktur: Stack Frame (Activation Record)

- ▶ Jede Prozedur hat einen Stack Frame, enthält
  - ▶ Lokale Variablen
  - ▶ Verwaltungsdaten
  - ▶ Aktuelle Parameter
- ▶ Stack Frame wird angelegt bei Prozeduraufruf
- ▶ ... abgebaut (pop) nach Prozedurende

# Beispiel Stapelspeicher

```
let ...  
in proc Y() ~  
  proc Z() ~ .. Y()  
in .. Y(); Z();
```


after start



after start



program calls Y

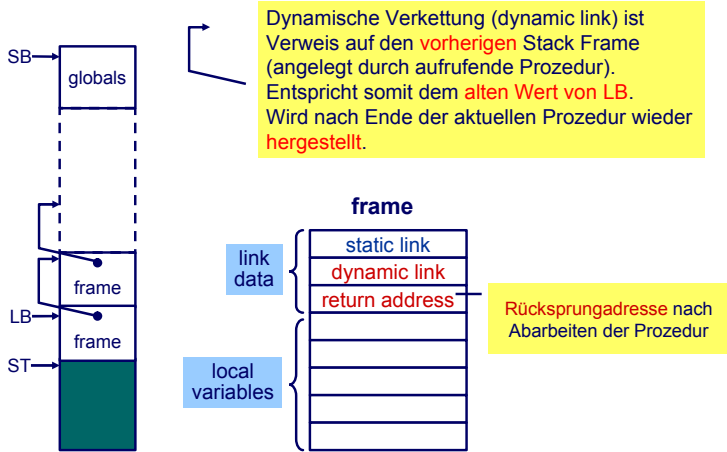


dynamic  
link

registers

SB	Stack Base
LB	Local Base
ST	Stack Top

# Verwaltung Stapelspeicher 1




# Ablauf Prozeduraufruf 1



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Aufruf von  $Y$  aus  $Z$

```
let ...  
in  
  proc  $Y()$  ~  
  proc  $Z()$  ~  
    in ...  $Y()$  ...  
in ...
```







# Ablauf Prozeduraufruf 2

- ▶ Lege neuen Stack Frame für  $Y$  an
- ▶ Merke Rücksprungadresse
- ▶ Verkette dynamisch zu altem Frame über alten LB-Wert


```
let ...  
in  
  proc  $Y()$  ~  
  proc  $Z()$  ~  
    in ...  $Y()$  ...  
in ...
```



# Ablauf Prozeduraufruf 3


- ▶ Markiere neuen Frame als aktuellen durch Umsetzen von LB

```
let ...  
in  
  proc Y() ~  
  proc Z() ~  
    in ... Y() ~ ...  
in ...
```



Nach Ende von Y

- ▶ Setze LB auf alten LB via dynamischer Verkettung zurück
- ▶ Setze ST auf alten Wert zurück
- ▶ Setze Ausführung bei Rücksprungadresse R fort





## Instruktionen für Speicherzugriff

- ▶ **LOAD d[reg]** Lese Adresse d+reg, lege Inhalt auf Stapel ab
- ▶ **STORE d[reg]** Speichere obersten Stapelwert (TOS) an Adresse d+reg


## Zugriff auf Variablen

- ▶ **Globale** Variablen immer im Frame beginnend bei SB
  - ▶ Also: LOAD d[SB] und STORE d[SB]
- ▶ **Lokale** Variablen immer in Frame beginnend bei LB
  - ▶ Also: LOAD d[LB] und STORE d[LB]
- ▶ Vorsicht: Hier **vereinfacht!** (→ statische Verkettung)

# Beispiel Adressierung von Variablen

```
let
  var a: array 3 of Char;
  var b: Boolean;
  var c: Char;
in
  proc Y() ~
    let var d: Integer;
        var e: Integer
    in ...

  proc Z() ~
    let var f: Integer
        var g: Char;
    in
      ... Y(); ...
in begin
  ... Y(); ...; Z(); ...
end
```




Wegen der **Verwaltungsdaten** (3 Worte) beginnen die lokalen Variablen erst bei **Adresse 3** im Stack Frame

var	size	address
a	3	0 [SB]
b	1	3 [SB]
c	1	4 [SB]
d	1	3 [LB]
e	1	4 [LB]
f	1	3 [LB]
g	1	4 [LB]



## Verschachtelte Blockstruktur

- ▶ PPP hat Zugriff auf Variablen von PPP, PP, P und die globalen Variablen.
- ▶ Problem: Mit d[SB] und d[LB] können wir von PPP aus nur **lokale** Variablen von PPP und **globale** Variablen zugreifen
- ▶ Die anderen Variablen aus umschliessenden Prozeduren PP und P **existieren** aber noch auf dem Stapel!
- ▶ P und PP wurden vorher aktiviert
- ▶ Idee: Irgendwie **hochhangeln** und an die Daten kommen





- ▶ Verweis auf Frame der **im Programmtext** umschliessenden Prozedur
- ▶ Unterschied dynamische Verkettung
  - ▶ Hier Verweis auf Frame der **aufzufinden** Prozedur
- ▶ Dient dem Zugriff auf **nicht-lokale** Variablen

Wird nicht von allen Sprachen unterstützt und ist von zweifelhaftem Nutzen (siehe später).



# Beispiel statische Verkettung

```
let
...
proc P() ~
let
...
proc S() ~
let ...
in ... P(); ...

proc Q() ~
let
...
proc R() ~
let
in ... S()
in ... R(); ...

in ... Q(); ...


in ... P(); ...
```





- ▶ Statische Verkettung ist hier  
1. Wort des Stack Frame
- ▶ Wird durch LB referenziert
- ▶ Effekt:  
 $\text{contents}(\text{LB}) =$  umschliessender Stack Frame (von  $R=Q$ )  
 $\text{contents}(\text{contents}(\text{LB})) =$  noch weiter aussenliegender Stack Frame (von  $R=P$ )

```
let proc P()  
in let proc Q()  
    in let proc R()  
    ...
```





Realisierung durch sogenanntes **Display**

display registers

<b>SB</b>		Zeigt auf Frame mit <b>globalen Variablen</b>
<b>LB</b>		Zeigt auf <b>oberste Frame R</b>
<b>L1</b>	contents( <b>LB</b> )	Zeigt auf <b>Frame R'</b> umschließend R
<b>L2</b>	contents( <b>L1</b> )	Zeigt auf <b>Frame R''</b> umschließend R'
<b>L3</b>	contents( <b>L2</b> )	Zeigt auf <b>Frame R'''</b> umschließend R''
<b>L4</b>	contents( <b>L3</b> )	Zeigt auf <b>Frame R''''</b> umschließend R'''
⋮	⋮	⋮
⋮	⋮	⋮

# Bestimmung der statischen Verkettung 1



```
let ! level 0
  var a: Integer;
  proc P() ~
  let ! level 1
    var b: Integer;
    proc Q() ~
    let ! level 2
      var c: Integer;
      proc R() ~
      let ! level 3
        var d: Integer;
        in ...
      in ...
    in ...
  in ...
```

```
let ! level 0
  var a: Integer;
  proc P() ~
  let ! level 1
    var b: Integer;
    proc Q() ~
    let ! level 2
      var c: Integer;
      proc R() ~
      let ! level 3
        var d: Integer;
        in ...
      in ...
    in ...
  in ...
```

In R sind alle Variablen **a, b, c, u**  
**d** zugreifbar. Aus **Kontextanalyse**  
bekannt: **Ebenen** aller  
Geltungsbereiche.

$R$  sei Routine deklariert auf Ebene  $l$ , dann gilt für die statische Verkettung (hier SV)

- ▶ Wenn  $l = 0$  ( $R$  ist globale Routine)  
SV=SB  $\rightarrow R$  sieht statisch nur globale Variablen
- ▶ Wenn  $l > 0$  ( $R$  ist eingeschachtelt deklariert)
  - ▶ SV=LB vor Aufruf  
 $\rightarrow$  wenn Aufruf von  $R$  aus Ebene  $l$  erfolgt
  - ▶ SV=L1 vor Aufruf  
 $\rightarrow$  wenn Aufruf von  $R$  aus Ebene  $l + 1$  erfolgt
  - ▶ SV=L2 vor Aufruf  
 $\rightarrow$  wenn Aufruf von  $R$  aus Ebene  $l + 2$  erfolgt
  - ▶ ... (bis L7 in TAM)

# Beispiel: Bestimmung statische Verkettung




```
let
...
proc P() ~
let
...
proc S() ~
let ...
in ... P(); ...

proc Q() ~
let
...
proc R() ~
let
in ... S()
in ... R(); ...

in ... Q(); ...

in ... P(); ...
```





Wie SV für aufgerufene Routine setzen?

Nur der **Aufrufer** kennt seine Ebene!

➔ In Triangle/TAM: Parameter für CALL-Instruktion

## Beispiel:

S ( ) deklariert auf  $l = 1$ , Aufruf auf  $l = 3$

→ L2 verwenden

```
CALL (L2) s
```



- ▶ Kompliziertere Compilierung
- ▶ Auch Laufzeitoverhead durch statische Verkettung
  - ▶ Komplizierterer Funktionsaufruf
  - ▶ Erhöhter Speicherbedarf

Lohnt sich das ganze überhaupt?

Beispiel Pascal

Art des Zugriffs	Relativer Anteil
Global	49%
Lokal	49%
Nicht-Lokal	2%

➔ Nein, überflüssiger Aufwand!



# Routinen



- ▶ **Routinen** sind Assembler-Äquivalent von Prozeduren und Funktionen einer Hochsprache (HLL)
  - ▶ Wichtige Maschineninstruktionen
    - CALL r** Lege nächste Programmzeigeradresse auf Stapel und springe auf Adresse r
    - RETURN** Nehme einen Wert vom Stapel und springe dorthin
- ↳ Basismechanismus für Routinenaufruf





Weitere Aspekte bei der Abbildung von HLL-Mechanismen

- ▶ **Aufruf** einer Routine und Übergabe von Parametern
- ▶ **Rückkehr** von einer Routine und Rückgabe eines Ergebnisses
- ▶ **Verwaltung** von statischen Verkettungen etc.

➡ In Form eines **Protokolls** definieren (maschinenabhängig)


Oft vom Betriebssystem in Form eines Application Binary Interface (ABI) vorgegeben.




- ▶ Auch **calling conventions** genannt
- ▶ Für Stack-Maschinen häufig
  1. Aufrufer legt Parameter auf Stapel (Reihenfolge?)
  2. Routine wird aufgerufen und benutzt Parameterwerte
  3. Aufgerufene Routine nimmt Parameter vom Stapel und ersetzt sie durch Rückgabewert

➡ Beliebig viele Parameter übergebbar

(1) Just before the call:



(2) Just after return:



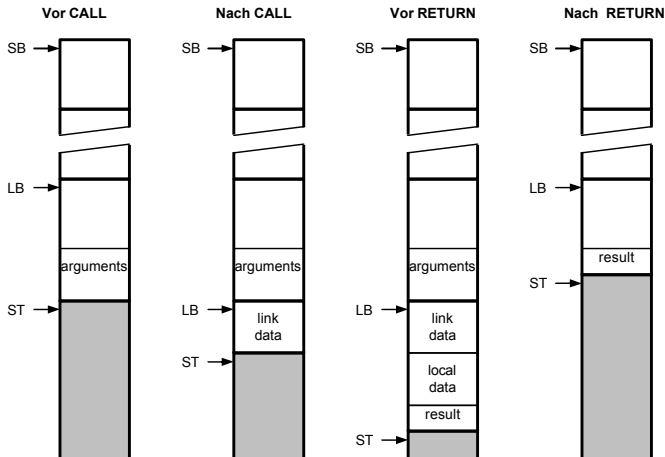


## Relevante TAM Instruktionen

**CALL (reg) addr** ruft Routine an Adresse **addr** auf, verwendet den Wert in **reg** als statische Verkettung bei der Anlage eines neuen Frame

**RETURN (n) d** Sichert **n** Worte als Ergebnis vom Stack, entfernt den aktuellen Frame und **d** Parameter, setzt Ausführung nach Aufrufstelle fort, legt Ergebnis oben auf dem Stack ab

# Routinenprotokoll 4



# Routinenprotokoll 5




TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

```
let var g: Integer;  
  func F(m: Integer, n: Integer)  
    : Integer ~ m*n ;  
  proc W(i:Integer) ~  
    let const s ~ i*i  
    in begin  
      putint(F(i,s));  
      putint(F(s,s))  
    end  
in begin  
  getint(var g);  
  W(g+1)  
end
```

(1) Just after reading g:

(2) Jus





**Parameter** (Argumente) zum Datenaustausch zwischen Aufrufer und Routine

- ▶ **Aktuelle Parameter** verwendet von Aufrufer bei Aufruf der Prozedur
- ▶ **Formale Parameter** innerhalb der Prozedur verwenden
  - ▶ Verhalten sich **innerhalb** der Prozedur wie lokale Variablen
- ▶ Eins-zu-eins Zuordnung von aktuellen und formalen Parametern



- ▶ Lege **Wert** der aktuellen Parameter auf Stack ab
- ▶ Liest Inhalte aus Variablen
- ▶ Effekt: Übergebe eine **Kopie** der Variable
- ▶ Zuweisungen innerhalb der Prozedur **nicht** im Aufrufer sichtbar

```
let
  proc sum(i:Integer, j:Integer) ~ begin
    i := i+j;
    putint(i);
  end
  var x: Integer
in begin
  x := 23; sum(x, 27)
end
```



# Übergabe von Referenzen 1



- ▶ In Triangle durch Schlüsselwort `var`
  - ▶ Bei Deklaration und Aufruf der Prozedur!
- ▶ Übergebe die Variable `selbst`
  - ▶ Nicht nur ihren aktuellen Wert!
  - ▶ Änderungen werden auch außerhalb der aufgerufenen Prozedur sichtbar

# Übergabe von Referenzen 2




Wie implementieren?

- ▶ Übergebe **Adresse** der Variable (als Zeiger)
- ▶ Aufgerufene Routine benutzt dann **Indirektion** um Wert abzurufen (dereferenziert Zeiger)

```
let proc S(var n:Integer, i:Integer) ~ n:=n+i;  
    var today: record  
        y:integer, m:Integer, d:Integer  
    end  
in begin  
    b := {y~2003, m ~ 4, d ~ 10};  
    S(var b.m, 6)  
end
```

# Erweiterung des Stack Frame



# Implementierung der Aufrufkonventionen 1



```
let var g: Integer;  
  func F(m: Integer, n: Integer)  
    : Integer ~ m*n ;  
  proc W(i:Integer) ~  
    let const s ~ i*i  
    in begin  
      putint(F(i,s));  
      putint(F(s,s))  
    end  
in begin  
  getint(var g);  
  W(g+1)  
end
```

g ist var-Parameter

g+1 ist Wert-Parameter

```
PUSH      1  
LOADA    0[SB]  
CALL     getint  
LOAD     0[SB]  
CALL     succ  
CALL(SB) W  
POP      1  
HALT
```

- expand globals to make space for g
- push the address of g
- read an integer into g
- push the value of g
- add 1
- call W (using SB as the static link)
- remove globals
- end the program

# Implementierung der Aufrufkonventionen 2



Parameter liegen direkt unter dem aktuellen Frame.

```
func F(m: Integer, n: Integer)
  : Integer ~ m*n ;
proc W(i:Integer) ~
  let const s ~ i*i
  in begin
    putint(F(i,s));
    putint(F(s,s))
  end
```

W:	LOAD	-1 [LB]	- push the value of <i>i</i>
	LOAD	-1 [LB]	- push the value of <i>i</i>
	CALL	mult	- multiply, the result will be the value of <i>s</i>
	LOAD	-1 [LB]	- push the value of <i>i</i>
	LOAD	3 [LB]	- push the value of <i>s</i>
	CALL (SB)	F	- call <i>F</i> (using <i>SB</i> as static link)
	CALL	putint	- write the value returned
	LOAD	3 [LB]	- push the value of <i>s</i>
	LOAD	3 [LB]	- push the value of <i>s</i>
	CALL (SB)	F	- call <i>F</i> (using <i>SB</i> as static link)
	CALL	putint	- write the value returned
	RETURN (0)	1	- return, replacing the 1-word argument by a 0-word result
F:	LOAD	-2 [LB]	- push the value of <i>m</i>
	LOAD	-1 [LB]	- push the value of <i>n</i>
	CALL	mult	- multiply
	RETURN (1)	2	- return, replacing the 2-word argument pair by a 1-word result

# Sonderfall: Prozeduren/Funktionen als Parameter 1



- ▶ In Triangle, C, Modula, ..., möglich
- ▶ Beispiel: Vergleichsfunktion an Sortierprozedur übergeben

```
let
  func twice(func doit(Integer x): Integer, i: Integer): Integer ~
    doit(doit(i));
  func double(Integer d) ~ d*2;
  var x: Integer
in begin
  x := twice(double, 10);
end
```

# Sonderfall: Prozeduren/Funktionen als Parameter 2



## Implementierung


- ▶ Repräsentiere Funktion durch Paar (Startadresse, statische Verkettung)
- ▶ Sogenannte **closure** or Funktionsdeskriptor
- ▶ Aufruf dann über Closure
- ▶ TAM: Lege Closure auf Stack, dann `CALLI` zum Aufruf

# Rekursion 1: Lebensdauern der Variablen



```
let
  proc P (i : Integer, b: Integer) ~
    let
      const d ~ chr(i//b + ord('0'))
    in
      if i < b then
        put(d)
      else
        begin
          P(i / b, b);
          put(d)
        end;
      var n: Integer
    in
      begin
        getint(var n);
        P(n, 8);

```

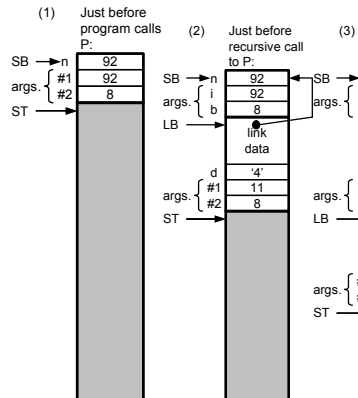




# Rekursion 2



```
let
  proc P (i : Integer, b: Integer) ~
    let
      const d ~ chr(i//b + ord('0'))
    in
      if i < b then
        put(d)
      else
        begin
          P(i / b, b);
          put(d)
        end;
      var n: Integer
    in
      begin
        getint(var n);
        P(n, 8);
      end
  end
```





# Heap-Speicher



- ▶ Bisher Lebenszeit von Variablen gebunden an **Geltungsbereiche**
    - ▶ Auch verschachtelt (statische Verkettung)
  - ▶ Reicht aber nicht immer!
  - ▶ Häufig: Lebenszeiten **unabhängig** von Geltungsbereichen
  - ▶ Beispiel: Datenstrukturen wie Listen, Bäume, etc.
    - ▶ Struktur lebt **unabhängig** von Prozeduren/Funktionen
- ➡ Braucht anderes Speicherverfahren als Stack



- ▶ Auch Halde oder Haufen genannt
- ▶ ... wir bleiben bei Heap
- ▶ Vorteil: **Beliebige** Lebenszeiten realisierbar
- ▶ Nachteil: **Explizite Verwaltung** durch Programm erforderlich
  - ▶ Pascal, C, C++
- ▶ Gilt nicht immer: Teilweise **Automatisierung** möglich
  - ▶ Java, Lisp, Smalltalk




- ▶ Heap in der Regel im selben Speicher wie Stack
- ▶ Verhalten
  - Stack wächst und schrumpft bei Blockeintritt/-austritt
  - Heap wächst bei Anlegen neuer Variablen, schrumpft (?) bei Freigabe
- ▶ Idee: Heap und Stack an unterschiedlichen Enden des Adressraums beginnen
  - ▶ Wachsen aufeinander zu
  - ▶ Bei Zusammentreffen: Out-of-memory
- ▶ Normalerweise: Stack oben, Heap unten
- ▶ TAM: Stack unten, Heap oben

# Beispiel: Heap 1



- ▶ Einfacher Fall: **Neue** Heap-Variablen anlegen.
- ▶ Beispiel hier:  


```
var ns: IntList;  
ps: SymList;
```



# Beispiel: Heap 2




- ▶ Problem: Freigeben von Variablen
  - ▶ IntList: 10
  - ▶ SymList: 'Cu'
- ▶ Vorgehen hier: freien Platz merken (HF Liste)



# Beispiel: Heap 3



- ▶ Neue Heap-Variablen anlegen
  - ▶ IntList: 12
  - ▶ SymList: 'Pt'
- ▶ Freien Platz **bevorzugt** benutzen
- ▶ Hier: **Ersten** freien Platz verwenden
- ▶ Problem: Jetzt viele kleine Löcher in Heap (Fragmentierung)
- ▶ Heap wächst weiter







Viele Ansätze zur Speicherzuteilung, ein Ansatz:

1. Finde **genau passenden** freien Speicherblock in  $HF$  und benutze ihn
2. Finde **größeren** freien Speicherblock in  $HF$  und benutze ihn teilweise
3. **Vergrößere** Heap in Richtung Stack um benötigten Platz
4. Falls nicht möglich: **out-of-memory**



## Fragmentierung bekämpfen

- ▶ Verwende immer **kleinsten passenden** freien Speicherblock (immer sinnvoll?)
- ▶ Verschmelze benachbarte freie Speicherblöcke
- ▶ **Kompaktiere** Heap
  - ▶ Alles **zusammenschieben**
  - ▶ Problem: Alle Zeiger im Programm müssen **aktualisiert** werden
  - ▶ Teillösung: Doppelte Indirektion über **Handles**
    - ▶ Realisiert als Zeiger-auf-Zeiger
    - ▶ Programm operiert mit Handles, werden nicht beeinflusst
    - ▶ Zeiger **innerhalb** von Handles werden durch Kompaktierung aktualisiert



Idee: Automatisiere **Freigabe** von nicht mehr benutztem Speicher

- ▶ **Garbage Collection**
- ▶ In Java, Lisp, Smalltalk, ...
- ▶ Viele verschiedene Ansätze
- ▶ Ganz einfach: Mark-and-sweep
  1. Kennzeichne alle Elemente auf Heap als nicht erreichbar
  2. Gehen nun alle Variablen durch (auf Heap und auf Stack!)
  3. Falls Zeiger: Markiere referenzierten Heap-Block als erreichbar
  4. Trage alle unerreichbaren Speicherblöcke in **HF**-Liste ein



## Probleme bei einfachem Mark-and-Sweep

- ▶ “Falls Zeiger...”: Wie erkennen?
  - ▶ Zeiger besonders kennzeichnen
  - ▶ oder Buch über *alle* angelegten Zeiger führen
- ▶ Heap-Blöcke müssen ihre Größe kennen
- ▶ Was, wenn Zeiger mitten in Heap-Block hinein?

➡ Kompliziert, nicht Compiler-spezifisch



- ▶ Darstellung von Daten auf Maschinenebene
  - ▶ Primitive Typen
  - ▶ Zusammengesetzte Typen
- ▶ Triangle Abstract Machine
- ▶ Auswertung von Ausdrücken
  - ▶ Stack-Maschine, Register-Maschine
- ▶ Speicherverwaltung
  - ▶ Globale, lokale, nicht-lokale Variablen
- ▶ Aufrufkonventionen
  - ▶ Parameter- und Ergebnisübergabe
- ▶ Langlebige Daten
  - ▶ Auf Heap
  - ▶ Verwaltungstechniken