

Korrekte Software: Grundlagen und Methoden

Vorlesung 12 vom 26.06.18: Referenzen und Speichermodelle

Serge Autexier, Christoph L  th

Universit  t Bremen

Sommersemester 2018

10:10:43 2018-07-31

1 [28]



Fahrplan

- Einf  hrung
- Operationale Semantik
- Denotationale Semantik
-   quivalenz der Operationalen und Denotationalen Semantik
- Die Floyd-Hoare-Logik
- Invarianten und die Korrektheit des Floyd-Hoare-Kalk  ls
- Strukturierte Datentypen
- Modellierung und Spezifikation
- Verifikationsbedingungen
- Vorw  rts mit Floyd und Hoare
- Funktionen und Prozeduren
- **Referenzen**
- Ausblick und R  ckblick

Korrekte Software

2 [28]



Motivation

- Warum Referenzen?
 - N  tig f  r *call by reference*
 - Funktion k  nnen sonst nur **globale** Seiteneffekte haben
 - Effizienz
- Kurze Begriffskl  rung:
 - Referenzen: getypt, eingeschr  nkte Arithmetik
 - Zeiger: ungetypt, Zeigerarithmetik

Korrekte Software

3 [28]



Referenzen in C

- Pointer in C ("pointer type"):
 - Schwach getypt (**void** * kompatibel mit allen Zeigertypen, Typumwandlung)
 - Eingeschr  nkte Zeigerarithmetik (Addition, Subtraktion)
 - Felder werden durch Zeigerarithmetik implementiert
- Pointer sind *first-class-values*
- C-Standard l   t das Speichermodell relativ offen
 - Repr  sentation von Objekten

Korrekte Software

4 [28]



Referenzen in anderen Sprachen

- Java:
 - Alles ist eine Referenz
 - Schwach getypt (Subtyping und Typumwandlung)
- Haskell, SML, OCaml:
 - Stark getypt (typsicher)
- Scriptsprachen (Python, Ruby):
 -   hnlich Java

Korrekte Software

5 [28]



Ausdr  cke

- Neue Operatoren: Addressoperator (&a) und Dereferenzierung (*l)
 - Lexp** $l ::= \text{Idt} \mid l[a] \mid !.\text{Idt} \mid *a$
 - Aexp** $a ::= \text{Z} \mid \text{C} \mid \text{Lexp} \mid \&l \mid a_1 + a_2 \mid a_1 - a_2 \mid a_1 * a_2 \mid a_1 / a_2 \mid \text{Idt}(\text{Exp}^*)$
 - Bexp** $b ::= \dots$
 - Exp** $e ::= \text{Aexp} \mid \text{Bexp}$
 - Stmt** $c ::= \dots$
 - Type** $t ::= \text{char} \mid \text{int} \mid *t \mid \text{struct } \text{Idt}^? \{ \text{Decl}^+ \} \mid t \text{ Idt}[a]$

Korrekte Software

6 [28]



Das Problem mit Zeigern

- Bisheriges Speichermodell: $\Sigma = \text{Loc} \rightarrow \mathbf{V}$
- **Aliasing:**
Verschiedene Bezeichner (**Lexp**) f  r die gleiche Lokation $l \in \text{Loc}$
 - ```
int a;
int *p;

p = &a;
a = 0;
// {a = 0}
*p = 7;
// {a = 7}
```
  - Wert von a   ndert sich **ohne dass a erw  hnt** wird.
  - Gro  es Problem f  r Semantik und Hoare-Kalk  l.

Korrekte Software

7 [28]



## Erweiterung des Zustandsmodells

- Bisheriger Zustand  $\Sigma \stackrel{\text{def}}{=} \text{Loc} \rightarrow \mathbf{V}$  mit
  - **Locations:**  $\text{Loc} ::= \text{Idt} \mid \text{Loc}[\mathbb{Z}] \mid \text{Loc}.\text{Idt}$
  - Werte:  $\mathbf{V} = \mathbb{Z}$
- Ansatz reicht nicht mehr:
  - (i) Werte m  ssen auch Locations sein:  $\mathbf{V} \stackrel{\text{def}}{=} \mathbb{Z} + \text{Loc}$
  - (ii) **Idt** als Location nicht ausreichend f  r Referenzen und Funktionen
- Man kann den Zustand **modellbasiert** (wie bisher) oder **axiomatisch** beschreiben.

Korrekte Software

8 [28]



## Axiomatisches Zustandsmodell

- Der Zustand ist ein abstrakter Datentyp  $\Sigma$  (und **Loc**) mit zwei Operationen und folgenden Gleichungen:

$$\begin{aligned} read : \Sigma &\rightarrow \mathbf{Loc} \rightarrow \mathbf{V} \\ upd : \Sigma &\rightarrow \mathbf{Loc} \rightarrow \mathbf{V} \rightarrow \Sigma \\ \mathbf{V} &\stackrel{\text{def}}{=} \mathbb{Z} + \mathbf{Loc} \end{aligned}$$

$$\begin{aligned} read(upd(\sigma, l, v), l) &= v \\ l \neq m &\implies read(upd(\sigma, l, v), m) = read(\sigma, m) \\ upd(upd(\sigma, l, v), l, w) &= upd(\sigma, l, w) \\ l \neq m &\implies upd(upd(\sigma, l, v), m, w) = upd(upd(\sigma, m, w), l, v) \end{aligned}$$

- Diese Gleichungen sind **vollständig**.



## Axiomatisches Speichermodell

- Es gibt einen **leeren** Speicher, und neue ("frische") Adressen:

$$\begin{aligned} empty : \Sigma \\ fresh : \Sigma &\rightarrow \mathbf{Loc} \\ rem : \Sigma &\rightarrow \mathbf{Loc} \rightarrow \Sigma \end{aligned}$$

- fresh* modelliert **Allokation**, *rem* modelliert **Deallokation**
- dom* beschreibt den **Definitionsbereich**:

$$\begin{aligned} dom(\sigma) &= \{l \mid \exists v. read(\sigma, l) = v\} \\ dom(empty) &= \emptyset \end{aligned}$$

- Eigenschaften von *empty*, *fresh* und *rem*:

$$\begin{aligned} fresh(\sigma) &\not\subseteq dom(\sigma) \\ dom(rem(\sigma, l)) &= dom(\sigma) \setminus \{l\} \\ l \neq m &\implies read(rem(\sigma, l), m) = read(\sigma, m) \end{aligned}$$



## Zeigerarithmetik

- Zeigerarithmetik: Rechnen mit Zeigern
  - Implementiert Felder und Strukturen
  - Wir betrachten keine **Differenz** von Zeigern

$$add : \mathbf{Loc} \rightarrow \mathbf{Z} \rightarrow \mathbf{Loc}$$

$$\begin{aligned} add(l, 0) &= l \\ add(add(l, a), b) &= add(l, a + b) \\ add(l, a) = l &\implies a = 0 \\ add(l, a) = add(l, b) &\implies a = b \end{aligned}$$



## Erweiterung der Semantik

- Problem: **Loc** haben unterschiedliche Semantik auf der linken oder rechten Seite einer Zuweisung.
  - $x = x + 1$  — Links: Adresse der Variablen, rechts: Wert an dieser Adresse
- Lösung in C: "Except when it is (...) the operand of the unary & operator, the left operand of the . operator or an assignment operator, an lvalue that does not have array type is converted to the value stored in the designated object (and is no longer an lvalue)"  
*C99 Standard*, §6.3.2.1 (2)
- Nicht spezifisch für C



## Umgebung

- Für Funktionen brauchen wir eine **Umgebung** (Environment):

$$\begin{aligned} \mathbf{Env} &= Id \rightarrow \llbracket \mathbf{FunDef} \rrbracket \\ &= Id \rightarrow \mathbf{V}^N \rightarrow \Sigma \rightarrow (\Sigma \times \mathbf{V}_u) \end{aligned}$$

- Diese muss erweitert werden für Variablen:

$$\mathbf{Env} = Id \rightarrow (\llbracket \mathbf{FunDef} \rrbracket \uplus \mathbf{Loc})$$

- Insbesondere: gleicher Namensraum für Funktionen und Variablen (*C99 Standard*, §6.2.3)



## Erweiterung der Semantik: Lexp

$$\mathcal{L}[-] : \mathbf{Env} \rightarrow \mathbf{Lexp} \rightarrow \Sigma \rightarrow \mathbf{Loc}$$

$$\begin{aligned} \mathcal{L}[x] \Gamma &= \{(\sigma, \Gamma!x) \mid \sigma \in \Sigma\} \\ \mathcal{L}[lexp[a]] \Gamma &= \{(\sigma, add(l, i \cdot sizeof(\tau))) \mid (\sigma, l) \in \mathcal{L}[lexp] \Gamma, (\sigma, i) \in \mathcal{A}[a] \Gamma\} \\ type(\Gamma, lexp) &= \tau \text{ ist der Basistyp des Feldes} \\ \mathcal{L}[lexp.f] \Gamma &= \{(\sigma, l.f) \mid (\sigma, add(l, fld\_off(\tau, f))) \in \mathcal{L}[lexp] \Gamma\} \\ type(\Gamma, lexp) &= \tau \text{ ist der Typ der Struktur} \\ \mathcal{L}[*e] \Gamma &= \mathcal{A}[e] \Gamma \end{aligned}$$

- $type(\Gamma, e)$  ist der **Typ** eines Ausdrucks
- $fld\_off(\tau, f)$  ist der **Offset** des Feldes  $f$  in der Struktur  $\tau$
- $sizeof(\tau)$  ist die **Größe** von Objekten des Typs  $\tau$



## Erweiterung der Semantik: Aexp(1)

$$\mathcal{A}[-] : \mathbf{Env} \rightarrow \mathbf{Aexp} \rightarrow \Sigma \rightarrow \mathbf{V}$$

$$\begin{aligned} \mathcal{A}[n] \Gamma &= \{(\sigma, n) \mid \sigma \in \Sigma\} \text{ für } n \in \mathbb{N} \\ \mathcal{A}[e] \Gamma &= \{(\sigma, read(\sigma, l)) \mid (\sigma, l) \in \mathcal{L}[e] \Gamma\} \\ &\quad e \in \mathbf{Lexp} \text{ und } type(\Gamma, e) \text{ kein Array-Typ} \\ \mathcal{A}[e] \Gamma &= \{(\sigma, l) \mid (\sigma, l) \in \mathcal{L}[e] \Gamma\} \\ &\quad e \in \mathbf{Lexp} \text{ und } type(\Gamma, e) \text{ Array-Typ} \\ \mathcal{A}[\&e] \Gamma &= \{(\sigma, l) \mid (\sigma, l) \in \mathcal{L}[e] \Gamma\} \end{aligned}$$



## Erweiterung der Semantik: Aexp(2)

$$\mathcal{A}[-] : \mathbf{Env} \rightarrow \mathbf{Aexp} \rightarrow \Sigma \rightarrow \mathbf{V}$$

$$\begin{aligned} \mathcal{A}[a_0 + a_1] \Gamma &= \{(\sigma, n_0 + n_1) \mid (\sigma, n_0) \in \mathcal{A}[a_0] \Gamma \wedge (\sigma, n_1) \in \mathcal{A}[a_1] \Gamma\} \\ \mathcal{A}[a_0 - a_1] \Gamma &= \{(\sigma, n_0 - n_1) \mid (\sigma, n_0) \in \mathcal{A}[a_0] \Gamma \wedge (\sigma, n_1) \in \mathcal{A}[a_1] \Gamma\} \\ \mathcal{A}[a_0 * a_1] \Gamma &= \{(\sigma, n_0 * n_1) \mid (\sigma, n_0) \in \mathcal{A}[a_0] \Gamma \wedge (\sigma, n_1) \in \mathcal{A}[a_1] \Gamma\} \\ \mathcal{A}[a_0 / a_1] \Gamma &= \{(\sigma, n_0 / n_1) \mid (\sigma, n_0) \in \mathcal{A}[a_0] \Gamma \wedge (\sigma, n_1) \in \mathcal{A}[a_1] \Gamma \\ &\quad \wedge n_1 \neq 0\} \end{aligned}$$



## Und jetzt?

- Zustand erweitert, so dass wir Zeiger modellieren können.
- Semantik entsprechend erweitert.
- Was machen wir mit dem Hoare-Kalkül, speziell der **Zuweisung**?
- Vorherige Modellierung — Zuweisung durch Substitution modelliert — nicht mehr ausreichend.
- Daher: **explizite Zustandsprädikate**



## Explizite Zustandsprädikate

- Zusicherungen (**Assn**) sind zustandsabhängige Prädikate
  - Mit anderen Worten, Prädikate über Programmvariablen.
- Axiomatische Beschreibung des Zustandes erforderte neue Modellierung auf der Ebene der Prädikate
- Explizite Zustandsprädikate modellieren die Zustandsoperationen *read* und *upd* **explizit**



## Explizite Zustandsprädikate

- Erweiterung von **Aexp<sub>v</sub>** um *read*, neue Sorte **State** mit Operation *upd*:

**Lexp<sub>s</sub>**  $l ::= \dots \mid *a$

**Assn<sub>s</sub>**  $b ::= \dots$

**Aexp<sub>s</sub>**  $a ::= \text{read}(S, l) \mid \mathbf{Z} \mid \mathbf{C} \mid l \mid \&l \mid \dots \mid \backslash \text{old}(e) \mid \dots$

**State**  $S ::= \text{StateVar} \mid \text{upd}(S, l, e)$

- Zustandsvariablen *StateVar*: Aktueller Zustand  $\sigma$ , Vorzustand  $\rho$
- Explizite Zustandsprädikate enthalten kein  $*$  oder  $\&$
- Damit Semantik:

$\mathcal{B}_{sp}[\cdot] : \mathbf{Env} \rightarrow \mathbf{Assn}_s \rightarrow (\Sigma \times (\Sigma \times \mathbf{V}_U)) \rightarrow \mathbb{B}$

$\mathcal{A}_{sp}[\cdot] : \mathbf{Env} \rightarrow \mathbf{Aexp}_s \rightarrow (\Sigma \times (\Sigma \times \mathbf{V}_U)) \rightarrow \mathbf{V}$



## Hoare-Triple

$$\Gamma \models \{P\} c \{Q \mid R\}$$

- $P, Q, R \in \mathbf{Assn}_s$  sind **explizite Zustandsprädikate**
- Deklarationen (**Decl**) allozieren für jede Variable eine Location (*fresh*), und ordnen diese in  $\Gamma$  dem Namen zu.
- Gültigkeit von Hoare-Tripeln (partielle, totale Korrektheit) wie vorher



## Floyd-Hoare-Kalkül mit expliziten Zustandsprädikaten

$$\overline{\Gamma \vdash \{Q[\text{upd}(\sigma, x, e)/\sigma]\} x = e \{Q \mid R\}}$$

- Ein **Lexp**  $l$  auf der rechten Seite  $e$  wird durch  $\text{read}(\sigma, l)$  ersetzt.<sup>1</sup>
- $\&$  dient lediglich dazu, diese Konversion zu verhindern.
- $*$  erzwingt diese Konversion, auch auf der linken Seite  $x$ .
- Beispiel:  $*a = *\&b$ ;

<sup>1</sup>Außer  $l$  ist ein Array-Typ.



## Formal: Konversion in Zustandsprädikate

$(-)^{\dagger} : \mathbf{Lexp} \rightarrow \mathbf{Lexp}_s$

$i^{\dagger} = i \quad (i \in \mathbf{Idt})$

$l.id^{\dagger} = l^{\dagger}.id$

$l[e]^{\dagger} = l^{\dagger}[e^{\#}]$

$*l^{\dagger} = l^{\#}$

$(-)^{\#} : \mathbf{Aexp} \rightarrow \mathbf{Aexp}_s$

$e^{\#} = \text{read}(\sigma, e^{\dagger}) \quad (e \in \mathbf{Lexp})$

$n^{\#} = n$

$v^{\#} = v \quad (v \text{ logische Variable})$

$\&e^{\#} = e^{\dagger}$

$e_1 + e_2^{\#} = e_1^{\#} + e_2^{\#}$

$\backslash \text{result}^{\#} = \backslash \text{result}$

$\backslash \text{old}(e)^{\#} = \backslash \text{old}(e)$

$$\overline{\Gamma \vdash \{Q[\text{upd}(\sigma, x^{\dagger}, e^{\#})/\sigma]\} x = e \{Q \mid R\}}$$



## Zwei kurze Beispiele

```
void foo(){
 int x, y, z;
 // {true}
 z = x;
 x = 0;
 z = 5;
 y = x;
 // {y = 0}
}
```

```
void foo(){
 int x, y, *z;
 // {true}
 z = &x;
 x = 0;
 *z = 5;
 y = x;
 // {y = 5}
}
```



## Ein problematisches Beispiel

```
void foo(int *p)
{
 int x;
 // {true}
 x = 7;
 *p = 99;
 // {x = 7}
}
```

- Können **weder** beweisen, dass  $*p = x$  **noch**  $*p \neq x$
- Erfordert Spezifikation: wenn  $*p$  auf ein **gültiges** Objekt zeigt, dann  $*p \neq x$  da  $x$  **lokale** Variable.
- Generelles Problem — was ist mit `void foo(int *p, int *q) { ... }`
- Können weder beweisen, dass  $*p = *q$  noch  $*p \neq *q$



## Weitere Beispiele: Felder

```
#include <limits.h>
#define N 10
int a[N];

int findmax(int a[], int a_len)
 /** pre \array(a, a_len); */
 /** post $\forall i. 0 \leq i < a_len \rightarrow a[i] \leq \text{result}$; */
{
 int x; int j;

 x= INT_MIN; j= 0;
 while (j< a_len)
 /** inv ($\forall i. 0 \leq i < j \rightarrow a[i] \leq x$) $\wedge j \leq a_len$; */
 {
 if (a[j]> x) x= a[j];
 j= j+1;
 }
 return x;
}
```

Korrekte Software

25 [28]



## Felder und Zeiger revisited

- ▶ In C sind Zeiger und Felder schwach spezifiziert
- ▶ Insbesondere:
  - ▶  $a[j] = *(a+j)$  für a Array-Typ
  - ▶ Dereferenzierung von  $*x$  nur definiert, wenn  $x$  "gültig" ist (d.h. auf ein Objekt zeigt) *C99 Standard*, §6.5.3.2(4)
- ▶ Bisher in den Hoare-Regeln ignoriert — **partielle** Korrektheit.
- ▶ Ist das sinnvoll? Nein, bekannte Fehlerquelle

Korrekte Software

26 [28]



## Spezifikation von Zeigern und Feldern

Das Prädikat  $\text{valid}(x)$

$\text{valid}(x) \iff \text{read}(\sigma, x^\dagger)$  ist definiert

- ▶ Insbesondere:  $\text{valid}(*x) \iff \text{read}(\sigma, \text{read}(\sigma, x))$  ist definiert.
- ▶ Felder als Parameter werden Zeigern konvertiert, deshalb müssen wir spezifizieren können, dass ein Zeiger "in Wirklichkeit" ein Feld ist.
- ▶  $\text{array}(a, n)$  bedeutet: a ist ein Feld der Länge n, d.h.

$$\text{array}(a, n) \iff (\forall i. 0 \leq i < n \implies \text{valid}(a[i]))$$

- ▶ Validität kann abgeleitet werden:

$$\frac{x = \&e}{\text{valid}(*x)} \quad \frac{\text{array}(a, n) \quad 0 \leq i \quad i < n}{\text{valid}(a[i])}$$

Korrekte Software

27 [28]



## Zusammenfassung

- ▶ Um Referenzen (Pointer) in C behandeln zu können, benötigen wir ein erweitertes **Zustandsmodell**
- ▶ Referenzen werden zu Werten wie Zahlen oder Zeichen.
  - ▶ Arrays und Strukturen sind **keine** first-class values.
  - ▶ Großes Problem: **aliasing**
- ▶ Erweiterung der Semantik und der Hoare-Tripel nötig:
  - ▶ Vor/Nachbedingungen werden zu **expliziten Zustandsprädikaten**.
  - ▶ Zuweisung wird zu **Zustandsupdate**.
  - ▶ Problem:
    - ▶ Zustände werden **sehr groß**
    - ▶ Rückwärtsrechnung erzeugt schnell sehr große „unbestimmte“ Zustände, die nicht vereinfacht werden können
    - ▶ Hier ist Vorwärtsrechnung vorteilhaft

Korrekte Software

28 [28]

