

Verifikation von Übersetzern

Wolf Zimmermann

Verifikation von Übersetzern

Wolf Zimmermann 0

Kapitel 1 Einleitung

Wolf Zimmermann

Verifikation von Übersetzern

Wolf Zimmermann 2

Lernziele

- Kenntnis der Methoden der Übersetzerverifikation
- An Hand einfacher Beispiele selbstständig Übersetzer verifizieren können.

- 1 Einleitung
- 2 Grundlagen und Semantik von Programmiersprachen
- 3 Korrektheit der Speicherabbildung
- 4 Korrektheit der Zwischencodeerzeugung
- 5 Korrektheit der Codeerzeugung und der Assemblierung

Wolf Zimmermann 1

Inhalt


Ziele

- Kennenlernen der grundsätzlichen Vorgehensweise bei der Verifikation von Übersetzern
- Verständnis und Beurteilung von Korrektheitsbegriffe
- Skizze einer Verifikation

- 1 Einleitung
- 2 Korrektheit von Übersetzern
- 3 Architektur verifizierter Übersetzer
- 4 Ausblick auf den Rest der Vorlesung

Wolf Zimmermann 3

1.1 Korrektheit von Übersetzern



Modellbasierte Entwicklung

- Ausgangspunkt: Modell des zu erstellenden Systems
- Überprüfung von Eigenschaften mit Modellprüfung
- Codegenerierung (meist C-Code)
- Erfüllt C-Code geprüfte Eigenschaften?
- Erfüllt Binärcode geprüfte Eigenschaften?

Verifikation

- Verifikation des Programms
- Validierung von Eigenschaften (z.B. Schutz, Absturzicherheit)
- Gilt das auch für den Binärcode?

Ja, Übersetzer haben Fehler!

Fehler in Übersetzern

- Borland Pascal Compiler Bug List enthält ca. 50 Fehler im Übersetzer
- Java Compiler Bug Database from Sun enthält ca. 90 Fehler im Übersetzer

Borland Pascal Compiler Bug List: Bug # 539

- Funktionsergebnisse werden in Aktivierungsverbund gespeichert
 - Falls Funktionen keine anderen Funktionen aufrufen, dann wird das Resultat (4 Bytes) im Register eax statt im Aktivierungsverbund gespeichert
 - Bei Rückkehr wurde nicht berücksichtigt, ob Optimierung statt gefunden hat
- ⇒ Kellerzeiger wurde manchmal um 4 Bytes zu viel dekrementiert

Ziele und Randbedingungen

Ziele (Verifix)

Methoden zur Konstruktion von verifizierten Übersetzern

- von realistischen Programmiersprachen
- in Maschinensprachen handelsüblicher Prozessoren,
- die Code derselben Qualität wie unverifizierte Übersetzer erzeugen können.

Grundannahmen

- Hardware ist korrekt
- Betriebssystem ist korrekt

Ja, Übersetzer haben Fehler!

Java Bug Database: Bug # 4078305 (beholden im Release 1.2fcs)

```
class B {
    static int foo = 2
    static {
        System.out.println("Initializing B");
    }
}
class MAIN {
    public static void main(String[] args) {
        int x = B.foo;
    }
}
```



```
class B { ... }
class MAIN {
    public static void main(String[] args) { }
```

- x wird nie benutzt
- ⇒ Anweisung kann gestrichen werden
- Nur korrekt, wenn rechte Seite der Zuweisung keine Nebenwirkungen hat
- Hier ist Nebenwirkung statische Initialisierung

1.2 Korrektheit von Übersetzern

Häufige Definition

Übersetzung ist semantikerhaltend

Problem

Definition ist so einfach wie unklar

1. Versuch

- (Imperative) Programme definieren Zustandsübergänge
- Diese müssen erhalten bleiben

Beispiel 1.1: Korrekte Übersetzung

```
(1) int i=24; (1) printf("i=24 j=12\n");
(2) int j=36; (2) printf("i=12 j=12\n");
(3) while (i!=j) {
(4)   if (i>j) i=i-j;
(5)   else j=j-i;
(6)   printf("i=%d",i);
(7)   printf(" j=%d\n",j);
(8) }
```

• Die Schleife (3)-(8) und die bedingte Anweisung werden im rechten Programm nicht erhalten
⇒ Keine Semantikerhaltung?

• Die Ausgabe der beiden Programme ist jeweils identisch

Was heißt eigentlich Korrektheit?

Determinismus von Programmiersprachen


Sprachstandards enthalten üblicherweise Freiheitsgrade bei Implementierung

☞ Meist bei Ausdrucksauswertung

- In C sind Zuweisungen Ausdrücke
 - Aktualisierung des Speichers durch Zuweisung kann zwischen Sequenzpunkten in beliebiger Reihenfolge ausgeführt werden
- ⇒ Übersetzung muss nur eine dieser Reihenfolge implementieren

Korrekte Übersetzung eines Quellprogramms P in Zielprogramm Z

Jedes beobachtbare Verhalten von Z entspricht einem beobachtbaren Verhalten von P bis auf Verletzung von Ressourcenbeschränkungen



Was heißt eigentlich Korrektheit?

2. Versuch: Erhaltung beobachtbaren Verhaltens

- Programme interagieren bei ihrer Ausführung mit der Umwelt (**beobachtbares Verhalten**)
- ☞ Lesen von Standardeingabe, Schreiben in Standardausgabe, Lesen von einer Datei, Schreiben in eine Datei, Lesen von Sensordaten, Schreiben von Sensordaten
- ⇒ Es gibt beobachtbare Zustände
- Korrektheit = Erhaltung der beobachtbaren Zustandsübergänge

Beispiel 1.2: Erhaltung beobachtbaren Verhaltens

```
(1) void f(int n) {
(2)   int m=100000000;
(3)   double a[m][m];
(4)   if (n==0) return;
(5)   int i,j;
(6)   f(n-1);
(7)   for (i=0;i<m;i++)
(8)     for (j=0;j<m;j++)
(9)       a[i][j]=i+j;
(10) }
(11) int main(void) {
(12)   f(1000000);
(13)   printf("fertig!");
(14) }
```

- Programm endet mit Segmentation fault (core dumped)
- Ursache: Platzbedarf $\approx 8 \cdot 10^{12}$ TByte
- ⇒ Sprengt vorhandenen Platz auf praktisch jeder Maschine
- ⇒ Programm kann nicht korrekt übersetzt werden
- ⇒ Es gibt keinen korrekten Übersetzer

Diskussion

Beispiel 1.2: Ein einfacher korrekter C-Übersetzer

produziert immer folgendes Zielprogramm:

```
int main(void) {
  printf("segmentation fault (core dumped)");
}
```

- Korrekt, aber nutzlos

Nützliche korrekte Übersetzer

- Keine a priori Festlegung der Ressourcen möglich
- ⇒ Ingenieursaufgabe

Formale Definition der Korrektheit: Zustandsübergangssysteme

Definition 1.1 (Zustandsübergangssystem und Lauf)


Ein **Zustandsübergangssystem** ist ein Tripel $S \triangleq (Q, I, \rightarrow)$, wobei Q eine Menge von **Zuständen**, $I \subseteq Q$ eine Menge von **Initialzuständen** und $\rightarrow \subseteq Q \times Q$ eine **Zustandsübergangsrelation** ist. Ein Zustand $q' \in Q$ heißt **Nachfolgezustand** eines Zustands $q \in Q$ gdw. $q \rightarrow q'$. Ein Zustand $f \in Q$ heißt **final** gdw. es keinen Nachfolgezustand zu f gibt.

Ein **Lauf** (engl. *run*) ist eine endliche oder unendliche Folge $\langle q_0, q_1, \dots, q_n, \dots \rangle$, so dass $q_i \rightarrow q_{i+1}$ für alle $i \geq 0$ gilt. Der **Lauf** heißt **vollständig** gdw. $q_0 \in I$ und der Lauf unendlich oder der letzte Zustand im Lauf final ist.

Beispiel 1.3: Vollständiger Lauf eines Programms

```

(1) int i=24;
(2) int j=36;
(3) while (i!=j) {
(4)   if (i>j)
(5)     i=i-j;
(6)   else j=j-i;
(7)   printf("%d ",i);
(8)   printf("%d ",j);
(9) }
    
```



Formale Definition der Korrektheit: Erhaltung beobachtbaren Verhaltens

Definition 1.3 (1-1-Simulation)

Sei $S_1 \triangleq (Q_1, I_1, \rightarrow_1)$ ein Zustandsübergangssystem. Ein Zustandsübergangssystem $S_2 \triangleq (Q_2, I_2, \rightarrow_2)$ **1-1-simuliert** S_1 gdw. es eine Funktion $\phi : Q_1 \rightarrow Q_2$ gibt, so dass für jeden vollständigen Lauf $\langle q_0, q_1, \dots, q_{i-1}, q_i, \dots \rangle$ von S_2 die Folge $\langle \phi(q_0), \phi(q_1), \dots, \phi(q_{i-1}), \phi(q_i), \dots \rangle$ ein vollständiger Lauf von S_1 ist. (**Notation:** $S_2 \lesssim S_1$)

Beispiel 1.4: 1-1-Simulation

```

(1) int i=24;          (1) printf("24 ");
(2) int j=36;          (2) printf("12 ");
(3) while (i!=j) {    (3) printf("12 ");
(4)   if (i>j) i=i-j; (4) printf("12 ");
(5)   else j=j-i;
(6)   printf("%d ",i);
(7)   printf("%d ",j);
(8) }
    
```



Beobachtung

Die Erhaltung beobachtbaren Verhaltens ist eine 1-1-Simulation.

Lemma 1.1 (Hinreichende Bedingung für 1-1-Simulation)

Sei $S_i \triangleq (Q_i, I_i, \rightarrow_i)$, $i = 1, 2$ zwei Zustandsübergangssysteme. Falls es eine Funktion $\phi : Q_1 \rightarrow Q_2$ gibt, so dass $\phi(q) \rightarrow_2 \phi(q')$ für alle $q \rightarrow_1 q'$ gilt, dann gilt $S_1 \lesssim S_2$.

Formale Definition der Korrektheit: Beobachtbares Verhalten

Definition 1.2 (Abstraktion)

Sei $S_1 \triangleq (Q_1, I_1, \rightarrow_1)$ ein Zustandsübergangssystem. Ein Zustandsübergangssystem $S_2 \triangleq (Q_2, I_2, \rightarrow_2)$ heißt **Abstraktion** von S_1 gdw. es eine Funktion $\phi : Q_1 \rightarrow Q_2$ mit den folgenden Eigenschaften gibt:

- i. $\phi(I_1) \subseteq I_2$
- ii. Falls $q_1 \rightarrow_1 q'_1$, dann ist entweder $\phi(q_1) = \phi(q'_1)$ oder $\phi(q_1) \rightarrow_2 \phi(q'_1)$

Beobachtung

Das beobachtbare Verhalten ist eine Abstraktion des Zustandsübergangssystems eines Programms

Formale Definition der Korrektheit: Ressourcenbeschränkungen

Beobachtung

- Ressourcenbeschränkungen bedeuten, dass nicht jeder Zustand des "unten" Zustandsübergangssystems auf das zu 1-1-simulierende "obere" Zustandsübergangssystem abgebildet werden kann.
- ⇒ Abbildungsfunktion ist partiell
- Programme brechen bei Verletzung der Ressourcenbeschränkung ab
- ⇒ Zustände, die nicht abgebildet werden können, sind Finalzustände

Definition 1.3 (Eingeschränkte 1-1-Simulation)

Sei $S_1 \triangleq (Q_1, I_1, \rightarrow_1)$ ein Zustandsübergangssystem. Ein Zustandsübergangssystem $S_2 \triangleq (Q_2, I_2, \rightarrow_2)$ **1-1-simuliert eingeschränkt** S_1 gdw. es eine partielle Funktion $\phi : Q_1 \rightarrow Q_2$ gibt, so dass für jeden vollständigen Lauf $\langle q_0, q_1, \dots, q_{i-1}, q_i, \dots \rangle$ von S_2 eine der beiden folgenden Eigenschaften gilt:

- i. Die Folge $\langle \phi(q_0), \phi(q_1), \dots, \phi(q_{i-1}), \phi(q_i), \dots \rangle$ ist vollständiger Lauf von S_1 .
- ii. Der vollständige Lauf $\langle q_0, q_1, \dots, q_n \rangle$ von S_1 ist endlich, q_n ist nicht im Definitionsbereich von ϕ , q_0, \dots, q_{n-1} ist im Definitionsbereich von ϕ und $\langle \phi(q_0), \dots, \phi(q_{n-1}) \rangle$ ist echter Präfix eines vollständigen Laufs von S_2 .

Notation: $S_2 \lesssim S_1$

Beobachtung

Erhaltung beobachtbaren Verhaltens bedeutet eingeschränkte 1-1-Simulation

- Semantik von Programmiersprachen ordnen jedem Programm π ein Zustandsübergangssystem $\llbracket \pi \rrbracket$ zu.
- Beobachtbares Verhalten $\llbracket \pi \rrbracket'$ ist eine Abstraktion von $\llbracket \pi \rrbracket$ (**beobachtbare Semantik**)
- ☞ Zur Definition der Korrektheit von Übersetzern genügt beobachtbare Semantik
- Falls das Programm anhält ist auch der Finalzustand beobachtbar.

Definition 1.4 (Korrekte Übersetzung, korrekte Übersetzer)

Sei Q eine Programmiersprache mit beobachtbarer Semantik $\llbracket \cdot \rrbracket'_Q$ und Z eine Programmiersprache mit beobachtbarer Semantik $\llbracket \cdot \rrbracket'_Z$. Ein Programm π_Z der Programmiersprache Z heißt **korrekte Übersetzung** eines Programms π_Q der Programmiersprache Q gdw. $\llbracket \pi_Z \rrbracket'_Z \approx \llbracket \pi_Q \rrbracket'_Q$ ist.

Ein Übersetzer \mathcal{C} von Q nach Z heißt **korrekt** gdw. jedes übersetzte Programm $\mathcal{C}(\pi)$ eine korrekte Übersetzung von π ist.

Verwandte Anwendungen

Codegeneratoren für speicherprogrammierbare Steuerungen

- Übersetzen Zeitautomaten nach Structured Text
- Zielprogramme dürfen nicht wegen Ressourcenverletzungen abbrechen
- Zeiteigenschaften (Uhrenstände) müssen erhalten bleiben

Codegeneratoren im Automobilbau

- Modelle arbeiten mit kontinuierlichen Werten und Uhren
 - Steuerung arbeiten mit diskreten Werten und Zeitzuständen
- ⇒ Keine exakte Zuordnung möglich
- ⇒ Anwendungsspezifische Toleranzgrenzen

- Ein korrekter Übersetzer muss nicht jedes Quellprogramm übersetzen können
- Nur für den Fall, dass er tatsächlich ein Zielprogramm definiert, muss sichergestellt werden, dass das beobachtbare Verhalten bis auf Ressourcenbeschränkungen erhalten bleibt
- Die Zuordnung der Semantik und die Abstraktion zum beobachtbaren Verhalten ist zentrale Voraussetzung zum Nachweis der Übersetzerkorrektheit
- Für die bisherigen Überlegungen (und die weiteren in diesem einleitenden Kapitel) genügt es nur zu wissen, dass die Semantik einer Programmiersprache jedem Programm ein Zustandsübergangssystem zuordnet.

1.3 Architektur verifizierter Übersetzer

Grundidee

Zerlege Übersetzung einer Quellsprache Q in eine Zielsprache Z in mehrere Übersetzungen sehr nahe beieinanderliegender Zwischensprachen:

$$Q \Rightarrow IL_1 \Rightarrow IL_2 \mapsto \dots \mapsto IL_{n-1} \Rightarrow Z$$

- Naheliegend: Verwende die typischen Zwischensprachen in einem Übersetzer
- Beweistechnisch kann es sinnvoll sein noch zusätzliche Zwischensprachen einzuführen

Horizontale Dekomposition

Satz 1.2 (Horizontale Dekomposition)


Die beschränkte 1-1-Simulation \approx auf Zustandsübergangssystemen ist transitiv: Wenn $\mathcal{S}_3 \approx \mathcal{S}_2$ und $\mathcal{S}_2 \approx \mathcal{S}_1$, dann gilt auch $\mathcal{S}_3 \approx \mathcal{S}_1$, wobei $\mathcal{S}_i \triangleq (Q_i, I_i, \rightarrow_i)$, $i = 1, 2, 3$ Zustandsübergangssysteme sind.

Beweisskizze

Sei $\mathcal{S}_3 \approx \mathcal{S}_2$ mit $\psi : Q_3 \rightarrow Q_2$ und $\mathcal{S}_2 \approx \mathcal{S}_1$ mit $\phi : Q_2 \rightarrow Q_1$.


Behauptung: $\mathcal{S}_3 \approx \mathcal{S}_1$ mit $\rho \triangleq \phi \circ \psi$

1. Fall: $q_i \in \text{DOM}(\psi)$ und $\psi(q_i) \in \text{DOM}(\phi)$ für alle i



2. Fall: Lauf für \mathcal{S}_3 endlich, $q_n \notin \text{DOM}(\psi)$,

$q_0, \dots, q_{n-1} \in \text{DOM}(\psi)$ und $\psi(q_0), \dots, \psi(q_{n-1}) \in \text{DOM}(\phi)$. Also:
 $q_0, \dots, q_{n-1} \in \text{DOM}(\rho)$ und $q_n \notin \text{DOM}(\rho)$




Horizontale Dekomposition (Forts.)

Beweisskizze

3. Fall: Lauf für \mathcal{S}_3 endlich,


$q_0, \dots, q_n \in \text{DOM}(\psi)$ und $\psi(q_0), \dots, \psi(q_{n-1}) \in \text{DOM}(\phi)$ und $\psi(q_n) \notin \text{DOM}(\phi)$. Also:
 $q_0, \dots, q_{n-1} \in \text{DOM}(\rho)$ und $q_n \notin \text{DOM}(\rho)$



4. Fall: Lauf für \mathcal{S}_3 endlich, $q_n \notin \text{DOM}(\psi)$,

$q_0, \dots, q_{n-1} \in \text{DOM}(\psi)$, $\psi(q_0), \dots, \psi(q_{n-2}) \in \text{DOM}(\phi)$ und $\psi(q_{n-1}) \notin \text{DOM}(\phi)$.
 $\Rightarrow \psi(q_{n-1})$ ist final
 $\Rightarrow \langle \psi(q_0), \dots, \psi(q_{n-1}) \rangle$ kein echter Präfix eines Laufs von \mathcal{S}_2
 $\Rightarrow \mathcal{S}_3 \not\approx \mathcal{S}_2$ **Widerspruch!**

Architektur korrekter Übersetzer



Fazit

Für verifizierte Übersetzer kann die klassische Übersetzerbauarchitektur verwendet werden.

- \Rightarrow Keinerlei Einschränkungen in der Konstruktion
- \Rightarrow Korrektheitsbegriff erlaubt Optimierungen
- \Rightarrow Prinzipiell können verifizierte Übersetzer Code mit derselben Qualität erzeugen wie unverifizierte Übersetzer.

Grundsätzliche Vorgehensweise zur Verifikation von Übersetzern

Beweisverpflichtungen

- Korrektheit der Transformationsregeln in Übersetzungsspezifikation
- Korrektheit der Implementierung des Übersetzers (z.B. in C)
- Korrektheit der Implementierung des Übersetzers in Binärcode

Korrektheit der Transformationsregeln

Beispiel 1.5: Transformationsregel für Schleife

$S[\text{while}(expr, stats)] =$

```

    goto L2
    L1 : S[[stats]]
    L2 : E[[expr]]
        if expr.val then L1 else L3
    L3 :
    
```

- S ist Transformation für Anweisungen
- E ist Transformation für Ausdrücke
- $expr.val$ ist Register, das den Wert des ausgewerteten Ausdrucks enthält
- ☞ Jeder Ausdruck bekommt eindeutiges Register, das bei der Attributierung berechnet wird

Beobachtung

Transformationsregeln sind Schemata zur Übersetzung von Programmfragmenten

- Direkter Nachweis über beobachtbares Verhalten praktisch unmöglich
- ⇒ Direkter Nachweis über die Semantik
- ☞ Simulationsbeweise analog der Berechenbarkeits- oder Komplexitätstheorie

Simulationsbeweise

Ausgangspunkt


- Semantik von Quell- und Zielsprache als Zustandsübergangssysteme $S_i = (Q_i, l_i, \rightarrow_i)$, $i = 1, 2$.
- Relation $\rho \subseteq Q_2 \times Q_1$ an den Grenzen der Transformationsregeln
 - Beobachtbares Verhalten muss erhalten bleiben
 - Einzelne Simulationen müssen zusammengesetzt werden

Beispiel 1.5: Transformationsregel für Schleife

$S[\text{while}(expr, stats)] =$

```

    goto L2
    L1 : S[[stats]]
    L2 : E[[expr]]
        if expr.val then L1 else L3
    L3 :
    
```



Vertikale Dekomposition

Definition 1.5 (Urbild- und Bildbereich von Relationen)

Sei $\rho \subseteq U_1 \times U_2$ eine Relation. Die Menge $\text{DOM}(\rho) \triangleq \{u \in U_1 : \exists u' \in U_2 \bullet (u, u') \in \rho\}$ heißt **Urbildbereich** von ρ . Die Menge $\text{RAN}(\rho) \triangleq \{u \in U_2 : \exists u' \in U_1 \bullet (u', u) \in \rho\}$ heißt **Bildbereich** von ρ .


Was muss gelten?

Gegeben seien zwei Zustandsübergangssysteme $S_i \triangleq (Q_i, l_i, \rightarrow_i)$ mit jeweils Abstraktionen α_i zu beobachtbarem Verhalten $S'_i \triangleq (Q'_i, l'_i, \rightarrow'_i)$, $i = 1, 2$.

Ziel: Definition einer Simulationsbeziehung zwischen S_2 und S_1 , so dass $S'_2 \approx S'_1$ mit Funktion ϕ .

Vorgehen: Definition einer Relation $\rho \subseteq Q_2 \times Q_1$ und Zusammensetzen von "Schnappschüssen":


- Lauf $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ von S_2 mit höchstens einem beobachtbaren Zustandsübergang wird auf Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ mit höchstens einem beobachtbaren Zustandsübergang abgebildet
- $q_0^{(2)}, q_{n-1}^{(2)} \in \text{DOM}(\rho)$ sowie $q_i^{(2)} \notin \text{DOM}(\rho)$ für $i = 1, \dots, n-2$
- $q_0^{(1)}, q_{m-1}^{(1)} \in \text{RAN}(\rho)$ sowie $q_i^{(1)} \notin \text{RAN}(\rho)$ für $i = 1, \dots, m-2$



Vertikale Dekomposition (Forts.)


1. Fall: Lauf $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ hat keinen beobachtbaren Zustandsübergang.

Dann hat Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ ebenfalls keinen beobachtbaren Zustandsübergang, $\alpha_2(q_i^{(2)}) = \alpha_2(q_0^{(2)})$ für alle $i = 1, \dots, n-1$ und $\alpha_1(q_j^{(1)}) = \phi(\alpha_2(q_0^{(2)}))$ für alle $j = 0, \dots, m-1$




2. Fall: $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ hat einen beobachtbaren Zustandsübergang $q_{k-1}^{(2)} \rightarrow_2 q_k^{(2)}$, $q_{n-1}^{(2)} \in \text{DOM}(\rho)$

Dann hat Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ ebenfalls einen beobachtbaren Zustandsübergang $q_{l-1}^{(1)} \rightarrow_1 q_l^{(1)}$ und $\alpha_2(q_i^{(2)}) = \alpha_2(q_0^{(2)})$ für $i = 0, \dots, k-1$, $\alpha_2(q_i^{(2)}) = \alpha_2(q_k^{(2)})$ für $i = k+1, \dots, n-1$, $\alpha_1(q_j^{(1)}) = \phi(\alpha_2(q_0^{(2)}))$ für $j = 0, \dots, l-1$ und $\alpha_1(q_j^{(1)}) = \phi(\alpha_2(q_k^{(2)}))$ für $j = k, \dots, m-1$.



3. Fall: Lauf $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ hat einen beobachtbaren Zustandsübergang und $q_{n-1}^{(2)}$ ist final

Dann kann auch Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ ohne beobachtbaren Zustandsübergang sein, $\alpha_2(q_i^{(2)}) = \alpha_2(q_0^{(2)})$ für $i = 1, \dots, n-2$, $\alpha_1(q_j^{(1)}) = \phi(\alpha_2(q_0^{(2)}))$ für $j = 0, \dots, m-1$ und $\alpha_2(q_{n-1}^{(2)}) \notin \text{DOM}(\phi)$.



Vertikale Dekomposition: n-m-Simulation

Definition 1.6 (n-m-Simulation)

Seien $S_i \triangleq (Q_i, l_i, \rightarrow_i)$, $i = 1, 2$, zwei Zustandsübergangssysteme mit jeweils Abstraktionen α_i zu beobachtbarem Verhalten $S'_i \triangleq (Q'_i, l'_i, \rightarrow'_i)$. Eine Relation $\rho \subseteq Q_2 \times Q_1$ definiert eine **n-m-Simulation** gdw. $l_2 \subseteq \text{DOM}(\rho)$, $\rho(l_2) \subseteq l_1$ und für alle Läufe $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ von S_2 mit $q_0^{(2)} \in \text{DOM}(\rho)$, $q_{n-1}^{(2)} \in \text{DOM}(\rho)$ bzw. $q_{n-1}^{(2)}$ final sowie $q_i^{(2)} \notin \text{DOM}(\rho)$ für $i = 1, \dots, n-2$ existiert ein Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ mit $(q_0^{(2)}, q_0^{(1)}) \in \rho$ und $q_i^{(1)} \notin \text{RAN}(\rho)$ für $i = 1, \dots, m-2$, so dass eine der folgenden Bedingungen erfüllt ist:

- Weder in $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ noch in $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ gibt es einen beobachtbaren Zustandsübergang, $(q_{n-1}^{(2)}, q_{m-1}^{(1)}) \in \rho$, $\alpha_2(q_i^{(2)}) = \alpha_2(q_0^{(2)})$ für alle $i = 1, \dots, n-1$ und $\alpha_1(q_j^{(1)}) = \alpha_2(q_0^{(1)})$ für alle $j = 0, \dots, m-1$
- In $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ gibt es einen beobachtbaren Zustandsübergang $q_{k-1}^{(2)} \rightarrow_2 q_k^{(2)}$, in $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ gibt es einen beobachtbaren Zustandsübergang $q_{l-1}^{(1)} \rightarrow_1 q_l^{(1)}$, $(q_{n-1}^{(2)}, q_{m-1}^{(1)}) \in \rho$, $\alpha_2(q_i^{(2)}) = \alpha_2(q_0^{(2)})$ für $i = 0, \dots, k-1$, $\alpha_2(q_i^{(2)}) = \alpha_2(q_k^{(2)})$ für $i = k+1, \dots, n-1$, $\alpha_1(q_j^{(1)}) = \alpha_2(q_0^{(1)})$ für $j = 0, \dots, l-1$ und $\alpha_1(q_j^{(1)}) = \phi(\alpha_2(q_k^{(2)}))$ für $j = k, \dots, m-1$.
- In $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ gibt es den beobachtbaren Zustandsübergang $q_{n-2}^{(2)} \rightarrow_2 q_{n-1}^{(2)}$, $q_{n-1}^{(2)}$ ist final, $q_{n-1}^{(2)} \notin \text{DOM}(\rho)$, $\alpha_2(q_i^{(2)}) = \alpha_2(q_0^{(2)})$, $\alpha_2(q_{n-1}^{(2)}) \notin \text{DOM}(\phi)$ und $\alpha_1(q_j^{(1)}) = \alpha_2(q_0^{(1)})$ für $j = 0, \dots, m-1$.

Satz 1.3 (n-m-Simulation und eingeschränkte 1-1-Simulation, Gaul/Zimmermann 1997)

Seien $S_i \triangleq (Q_i, l_i, \rightarrow_i)$, $i = 1, 2$, zwei Zustandsübergangssysteme mit jeweils Abstraktionen α_i zu beobachtbarem Verhalten $S'_i \triangleq (Q'_i, l'_i, \rightarrow'_i)$ und $\rho \subseteq Q_2 \times Q_1$ eine n-m-Simulation mit den folgenden Eigenschaften:

- $\phi \triangleq \alpha_1 \circ \rho \circ \alpha_2^{-1} \subseteq Q'_2 \times Q'_1$ ist eine injektive partielle Funktion
 - Für jeden unendlichen Lauf $\langle q_i^{(2)} : i \in \mathbb{N} \rangle$ von S_2 mit $q_0^{(2)} \in \text{DOM}(\rho)$ existiert ein unendlicher Lauf $\langle q_i^{(1)} : i \in \mathbb{N} \rangle$ von S_1 mit $(q_0^{(2)}, q_0^{(1)}) \in \rho$ und entweder $q_i^{(2)} \notin \text{DOM}(\rho)$ für $i > 0$, $q_j^{(2)} \notin \text{RAN}(\rho)$ für $j > 0$ oder $(q_i^{(2)}, q_j^{(2)}) \in \rho$ für $i, j > 0$
 - Für jeden Finalzustand $q^{(2)} \in Q_2$ ist jedes $q^{(1)} \in \rho(q^{(2)})$ final in S_1
- Dann gilt $S'_2 \approx S'_1$.

Beweis (Skizze)


Vorgehen:

- Zeige durch Induktion über die Länge der Läufe von S_2 , dass mit ϕ die Bedingungen für $S'_2 \approx S'_1$ für jeden Präfix $\langle qb_0^{(2)}, \dots, qb_{n-1}^{(2)} \rangle$ eines vollständigen Laufs von S'_2 erfüllt sind
- Zeige durch noethersche Induktion, dass dann auch die Bedingungen für $S'_2 \approx S'_1$ für alle vollständigen Läufe von S'_2 erfüllt sind.

Behauptung 1: Für jeden Lauf $\langle q_0^{(2)}, \dots, q_{k-1}^{(2)} \rangle$ von S_2 mit $q_0^{(2)} \in l_2$ und Abstraktion $\langle qb_0^{(2)}, \dots, qb_{n-1}^{(2)} \rangle$, $q_{k-1}^{(2)} \in \text{DOM}(\rho)$, gibt es einen Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ von S_1 mit $q_0^{(1)} \in l_1$ und Abstraktion $\langle \phi(qb_0^{(2)}), \dots, \phi(qb_{n-1}^{(2)}) \rangle$


Behauptung 2: Die Bedingungen für $S'_2 \approx S'_1$ sind für jeden Präfix $\langle qb_0^{(2)}, \dots, qb_{n-1}^{(2)} \rangle$ eines vollständigen Laufs von S'_2 erfüllt

Die Bedingung (ii) schließt die folgende Situation aus:




Beispiel 1.6: 0-m-Simulation

Implizite Anpassung von ganzen Zahlen an Gleitkommazahlen



Beispiel 1.7: n-0-Simulation

Streichen von Zuweisung an tote Variable




Lemma 1.4 (Endliche Präfixe)

Seien $S_i \triangleq (Q_i, l_i, \rightarrow_i)$, $i = 1, 2$ zwei Zustandsübergangssysteme mit jeweils Abstraktionen α_i zu beobachtbarem Verhalten $S'_i \triangleq (Q'_i, l'_i, \rightarrow'_i)$ und $\rho \subseteq Q_2 \times Q_1$ eine n - m -Simulation, so dass $\phi \triangleq \alpha_1 \circ \rho \circ \alpha_2^{-1} \subseteq Q'_2 \times Q'_1$ eine injektive partielle Funktion ist. Für jeden Lauf $\langle q_0^{(2)}, \dots, q_{k-1}^{(2)} \rangle$ von S_2 mit $q_0^{(2)} \in l_2$, $q_{k-1}^{(2)} \in \text{DOM}(\rho)$ und Abstraktion $\langle qb_0^{(2)}, \dots, qb_{n-1}^{(2)} \rangle$ gibt es einen Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ von S_1 mit $q_0^{(1)} \in l_1$, Abstraktion $\langle \phi(qb_0^{(2)}), \dots, \phi(qb_{n-1}^{(2)}) \rangle$ und $(q_0^{(2)}, q_0^{(1)}), (q_{k-1}^{(2)}, q_{m-1}^{(1)}) \in \rho$.


Beweis durch Induktion über die Länge k

Induktionsanfang: $k = 0$. Dann ist $q_0^{(2)} \in l_2$. Wähle ein $q_0^{(1)} \in l_1$, so dass $(q_0^{(2)}, q_0^{(1)}) \in \rho$. Nach Definition ist $\alpha_1(q_0^{(1)}) = \phi(\alpha_2(q_0^{(2)}))$

Induktionsschritt Da $q_0^{(2)} \in \text{DOM}(\rho)$ ist, existiert ein $h < k$, so dass $q_{h-1}^{(2)} \in \text{DOM}(\rho)$ und $q_j^{(2)} \notin \text{DOM}(\rho)$ für $j = h, \dots, k-2$.



Fortsetzung Beweis Lemma 4



Beweisskizze von Satz 1.3

Lemma 1.5 (Unendliche Läufe)

Seien $\mathcal{S}_i \triangleq (Q_i, l_i, \rightarrow_i)$, $i = 1, 2$, zwei Zustandsübergangssysteme mit jeweils Abstraktionen α_i zu beobachtbarem Verhalten $\mathcal{S}'_i \triangleq (Q'_i, l'_i, \rightarrow'_i)$ und $\rho \subseteq Q_2 \times Q_1$ eine n - m -Simulation mit den folgenden Eigenschaften:

- i. $\phi \triangleq \alpha_1 \circ \rho \circ \alpha_2^{-1} \subseteq Q'_2 \times Q'_1$ ist eine injektive partielle Funktion
- ii. Für jeden unendlichen Lauf $\langle q_i^{(2)} : i \in \mathbb{N} \rangle$ von \mathcal{S}_2 mit $q_0^{(2)} \in \text{DOM}(\rho)$ existiert ein unendlicher Lauf $\langle q_i^{(1)} : i \in \mathbb{N} \rangle$ von \mathcal{S}_1 mit $(q_0^{(2)}, q_0^{(1)}) \in \rho$ und entweder $q_i^{(2)} \notin \text{DOM}(\rho)$ für $i > 0$, $q_j^{(2)} \notin \text{RAN}(\rho)$ für $j > 0$ oder $(q_i^{(2)}, q_j^{(1)}) \in \rho$ für $i, j > 0$

Dann gibt es zu jedem unendlichen Lauf $\langle q_i^{(2)} : i \in \mathbb{N} \rangle$ von \mathcal{S}_2 mit $q_0^{(2)} \in l_2$ einen unendlichen Lauf $\langle q_i^{(1)} : i \in \mathbb{N} \rangle$ von \mathcal{S}_1 mit $(q_0^{(2)}, q_0^{(1)}) \in \rho$, $q_0^{(1)} \in l_1$, so dass $\mathcal{S}'_2 \approx \mathcal{S}'_1$.

Beweis (Skizze)

1. Fall: $q_i^{(2)} \in \text{DOM}(\rho)$ für unendlich viele i

- Nach Lemma 1.4 sind die Bedingungen für $\mathcal{S}'_2 \approx \mathcal{S}'_1$ für jeden endlichen Präfix $\langle q_i^{(2)} : i \in \mathbb{N} \rangle$ erfüllt.
- Die Relation *ist Präfix* ist eine vollständige Halbordnung.
- Die Bedingungen sind stetige Funktionen über dieser Halbordnung

⇒ Aussage folgt durch transfinite Induktion

2. Fall: $q_i^{(2)} \notin \text{DOM}(\rho)$ für fast alle i . Dann folgt die Aussage direkt aus Lemma 1.4 (ii).

Programmprüfung und Validierung von Übersetzungen

Ziel

Verifikation der Implementierung eines Übersetzers

Problem

Praktisch nicht durchführbar

- Weder für generiertem noch manuell entwickeltem Übersetzer
- Auch bei Übersetzergeneratoren nicht machbar
- Ursache ist Umfang und Komplexität des Programms

Beweisskizze von Satz 1.3

Lemma 1.6 (Endliche Läufe)

Seien $\mathcal{S}_i \triangleq (Q_i, l_i, \rightarrow_i)$, $i = 1, 2$, zwei Zustandsübergangssysteme mit jeweils Abstraktionen α_i zu beobachtbarem Verhalten $\mathcal{S}'_i \triangleq (Q'_i, l'_i, \rightarrow'_i)$ und $\rho \subseteq Q_2 \times Q_1$ eine n - m -Simulation mit den folgenden Eigenschaften:

- i. $\phi \triangleq \alpha_1 \circ \rho \circ \alpha_2^{-1} \subseteq Q'_2 \times Q'_1$ ist eine injektive partielle Funktion
- ii. Für jeden Finalzustand $q^{(2)} \in Q_2$ ist jedes $q^{(1)} \in \rho(q^{(2)})$ final in \mathcal{S}_1

Falls ein vollständiger endlicher Lauf $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ von \mathcal{S}_2 mit $q_{n-1}^{(2)} \in \text{DOM}(\rho)$ existiert, gibt es einen vollständigen endlichen Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ mit $(q_0^{(2)}, q_0^{(1)}) \in \rho$, $(q_{n-1}^{(2)}, q_{m-1}^{(1)}) \in \rho$

Beweis (Skizze)

Annahme: Es gäbe $\langle q_0^{(2)}, \dots, q_{n-1}^{(2)} \rangle$ von \mathcal{S}_2 mit $q_0^{(2)}, q_{n-1}^{(2)} \in \text{DOM}(\rho)$, aber es gibt keinen vollständigen endlichen Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ von \mathcal{S}_1 mit $(q_0^{(2)}, q_0^{(1)}), (q_{n-1}^{(2)}, q_{m-1}^{(1)}) \in \rho$.

- Sei $q_0^{(1)} \in \rho(q_0^{(2)})$. Nach Definition 1.6 ist $q_0^{(1)} \in l_1$.
 - Aus Lemma 1.4 folgt, dass es einen Lauf $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ von \mathcal{S}_1 mit $(q_{n-1}^{(2)}, q_{m-1}^{(1)}) \in \rho$ gibt.
 - Mit (ii) folgt, dass $q_{m-1}^{(1)}$ final in \mathcal{S}_1 ist
- ⇒ $\langle q_0^{(1)}, \dots, q_{m-1}^{(1)} \rangle$ ist vollständig **Widerspruch!**

Programmprüfung und Validierung von Übersetzungen

Satz 1.7 (Programmprüfung, Blum 1989)

Sei $T f(U x)$ eine unverifizierte Funktion mit Vorbedingung $P(x)$ und Nachbedingung $Q(x, f(x))$. Weiterhin sei $\text{bool check_f}(U x, T y)$ ein verifiziertes Prädikat mit Vorbedingung $P(x)$ und Nachbedingung $\text{res} = \text{true} \Rightarrow Q(x, y)$. Dann gilt hat das folgende Programm bei Vorbedingung $P(x)$ die Nachbedingung $\text{res} \neq \text{fail} \Rightarrow Q(x, f(x))$:

```
T f'(U x) {
  T z = f(x);
  if (check_f(x,z)) return z;
  else return fail;
}
```

Bemerkungen

- Beweis kann direkt im Hoare-Kalkül geführt werden
- Korrektheit hängt nicht von der Korrektheit von f , sondern nur von der Korrektheit von $\text{check_f}(x, z)$ ab
- Ist f ein Übersetzer, x Quellcode und z Zielcode spricht man von **Übersetzungsvalidierung** (engl. *translation validation*, Pnueli et. al. 1997)
- check_f ist bei Übersetzern wesentlich kleiner und einfacher als f .

Korrektheit des Übersetzers in Binärcode

Vorgehen: Bootstrappmethode (Goerigk, Langmaack et. al., 1998)


- Entwickeln eines einfachen, gemäß den Transformationsregeln verifizierten Übersetzers C für eine Sprache \mathcal{L} in Programmiersprache \mathcal{L}
- Übersetzen von C mit einem unverifizierten \mathcal{L} -Übersetzer
- Manuelle Überprüfung, ob C dadurch korrekt übersetzt wurde
- ☞ Geschickte Organisation erlaubt teilweise Automatisierung dieses Bootstraps.

Korrektheit der semantischen Analyse

Beobachtung

- Attribute enthalten semantische Informationen wie Typen, Zuordnung von Deklarationen
- Spezifikation z.B. durch attributierte Grammatik (nicht die, die im Übersetzer verwendet wird!)
 - Überprüfung, ob Attribute gemäß Attributierungsregeln berechnet wurden

Beispiel 1.8: Überprüfung der semantischen Analyse



Korrektheit der Syntaxanalyse

Beobachtungen

- Definition der Semantik einer Programmiersprache setzt immer auf dem abstrakten Syntaxbaum oder dem attribuierten Strukturbaum auf
- ☞ Insbesondere nie auf dem Quelltext einer Zeichenkette
- ⇒ Syntaxanalyse und semantische Analyse ist bereits durchgeführt
- Übersetzerbauer haben Freiheitsgrade beim Entwurf der abstrakten Syntax
- Syntaxanalyse transformiert einen Text in eine Baumstruktur

Problem

Was ist dann Korrektheit der Syntaxanalyse?


Spezifikation der Syntaxanalyse

Relation zwischen Quelltexten und abstrakten Syntaxbäumen

- ☞ Aus abstraktem Syntaxbaum ist der Quelltext bis auf Leerzeichen, Kommentare, überflüssiger Klammern etc. rekonstruierbar
- ⇒ Überprüfung der Korrektheit mit Programmprüfung

Beispiel 1.9: Prüfung Syntaxanalyse

```
int x=0; // x-Koordinate
if (x==0) {
    x=1;
}
```



- Zwischen zwei aufeinanderfolgenden Elementen dürfen höchstens Leerzeichen, Zeilenumbrüche oder Kommentare folgen
- Mit dem dritten Zweig *skip* der *if*-Anweisung gibt es in der Syntax die Möglichkeiten *else* ; und das Fehlen des *else*-Zweigs
- ☞ geht aus den dem *skip*-Knoten zugeordneten Koordinaten hervor.

1.4 Ausblick auf den Rest der Vorlesung

- Definition der Semantiken der Quellsprache, der Zwischen- und der Zielsprache auf Basis attributierte Strukturbäume
- ☞ Wir verwenden eine Teilmenge von C als Quellsprache und den Binärcode der DEC-Alpha als Zielsprache
- Ideal wäre, wenn der Zustandsraum bei einer Übersetzung erhalten bliebe
- ⇒ Erfüllt bei optimierenden Transformationen
- ⇒ Transformation des Zustandsraums ohne Änderung der Programmiersprache
- ☞ Speicherabbildung, Registerzuteilung
- Verifikation der Implementierung durch Überprüfung der korrekten Anwendung von Transformationsregeln
- Verallgemeinerung auf Übersetzungsvalidierung (engl. *Translation Validation*): Verfahren, die direkt die hinreichende Bedingungen für die eingeschränkte 1-1-Simulation überprüfen.

Inhalt

Ziele

- Kennenlernen der theoretischen Grundlagen
 - Erwerben der Fähigkeit zur Formalisierung der Semantik von Programmiersprachen
 - Umsetzen des Korrektheitsbegriffs auf formale Semantiken
- 1 Motivation
 - 2 Signaturen, Terme, Algebren
 - 3 Abstrakte Zustandsmaschinen
 - 4 Modulare Konstruktion von Semantiken mit ASMs

Kapitel 2

Grundlagen und Semantik von Programmiersprachen

Wolf Zimmermann

Verifikation von Übersetzern

2.1 Motivation

Aufbau einer Programmiersprache

Trennt Syntax und Semantik

Syntax einer Programmiersprache

Was ist wohlgeformtes Programm?

Semantik einer Programmiersprache

- Welche abstrakte Bedeutung hat ein wohlgeformtes Programm?
- Selbstbezug

Pragmatik einer Programmiersprache

- Welche konkrete Bedeutung hat ein wohlgeformtes Programm?
- Bezug auf Umwelt und Rechner

Statische Semantik einer Programmiersprache

- Definiert Eigenschaften von Programmen, die ohne Ausführung bestimmt werden können
 - ↳ Typisierung
 - ↳ Gültigkeitsbereich von Variablen

Dynamische Semantik einer Programmiersprache

- Ordnet Sprachelementen Bedeutung zu
- Definiert Ausführung des Programms

Kriterien für die Übersetzungsverifikation

- Einheitliche Art der formalen Semantik für alle beteiligten Sprachen
- Modularer Aufbau der Sprachsemantiken ermöglicht Modularisierung der Korrektheitsbeweise
 - Formale Semantik für einen einfachen Sprachkern
 - Sukzessive Anreicherung um neue Sprachkonstrukte bis komplette Sprache erreicht wird **ohne** Änderung der bisher definierten Semantik der Teilsprachen

- Prozessorhandbücher ordnen jedem Maschinenbefehl Registertransfers zu

⇒ Operationale Semantik

- Zwischensprachsemantiken und Programmiersprachsemantiken lassen sich mit operationalen Semantiken mindestens so leicht formalisieren wie mit denotationalen Semantiken
- Abstrakte Maschinen sind für Maschinensprachen besser geeignet als strukturell operationale Semantiken
- Zwischensprachen und Programmiersprachsemantiken lassen sich modular über abstrakte Maschinen oft leichter aufbauen als strukturell operationale Semantiken

Denotationale Semantik

Jedem Sprachelement wird eine (evtl. rekursiv) Zustandsübergangsfunktion zugeordnet

- Mathematische Basis: vollständige Halbordnungen, stetige Funktionen

Strukturell operationale Semantik

Jedem Sprachelement wird eine Zustandstransformation zugeordnet

- Mathematische Basis: Inferenzregeln

Abstrakte Maschine

- Jedem Sprachelement werden Befehlsfolgen (evtl. rekursiv) zugeordnet
- Jedem Befehl wird eine Zustandstransformation zugeordnet
- Basis: Algebren und Abstrakte Zustandsmaschinen

Fazit und Ausblick auf den Rest des Kapitels

Fazit

Formalisierung der Semantiken der beteiligten Programmiersprachen über abstrakte Maschinen

Durchführung

Definition der abstrakten Maschinen mit Spezifikationsmethode **Abstrakte Zustandsmaschinen** (engl. *Abstract State Machines* oder kurz: ASM):

- Zustände sind Σ -Algebren über einer Signatur Σ
- Zustandsübergänge ändern die Interpretation von Σ -Termen

⇒ Abstrakte Zustandsmaschinen spezifizieren ein Zustandsübergangssystem

⇒ Begriffe der Korrektheit aus Kapitel 1 können direkt eingesetzt werden

⇒ Es genügt die Definition beobachtbaren Verhaltens und der Nachweis von n - m -Simulationen

Definition 2.3 (Σ -Algebra)

Sei $\Sigma = (S, F)$ eine mehrsortige Signatur mit Variablen $(X_s)_{s \in S}$. Eine Σ -Algebra ist ein Paar $\mathcal{A} = (A, \Phi)$ wobei

- $A = (A_s)_{s \in S}$ wobei A_s eine Menge mit $X_s \subseteq A_s$ ist (**Trägermenge der Sorte s**)
- $\Phi = \{f_A : A_{s_1} \times \dots \times A_{s_n} \rightarrow A_s \mid f : s_1 \times \dots \times s_n \rightarrow s \in \Sigma\}$, d.h., jedem Operationssymbol f der Stelligkeit $s_1 \dots s_n$, s wird eine Funktion $f_A : A_{s_1} \times \dots \times A_{s_n} \rightarrow A_s$ zugeordnet

Beispiel 2.2: Algebra der ganzen Zahlen

Signatur

sig INT
 sorts INT
 operations $\dots, -2, -1, 0, 1, 2, \dots : \text{INT} \times \text{INT} \rightarrow \text{INT}$
 $\text{plus, mal, minus} \rightarrow \text{INT}$

INT-Algebra

$\mathbb{Z} \triangleq \langle \mathbb{Z}, \Phi_{\mathbb{Z}} \rangle$

- Trägermenge $\text{INT}_{\mathbb{Z}} \triangleq \mathbb{Z}$
- Interpretationen Φ :
 $\dots, -2_{\mathbb{Z}} \triangleq -2, -1_{\mathbb{Z}} \triangleq -1, 0_{\mathbb{Z}} \triangleq 0, 1_{\mathbb{Z}} \triangleq 1, 2_{\mathbb{Z}} \triangleq 2, \dots$
 $\text{plus}_{\mathbb{Z}} \triangleq +$
 $\text{mal}_{\mathbb{Z}} \triangleq *$
 $\text{minus}_{\mathbb{Z}} \triangleq -$

Interpretation eines Terms

$$\llbracket \text{plus}(\text{mkintconst}(3), \text{mkintconst}(5)) \rrbracket = \text{plus}_{\mathbb{Z}}(\llbracket \text{mkintconst}(3) \rrbracket, \llbracket \text{mkintconst}(5) \rrbracket) = \llbracket \text{mkintconst}(3) \rrbracket + \llbracket \text{mkintconst}(5) \rrbracket = 3 + 5 = 8$$

Definition 2.4 (Variablenbelegung, Interpretation)

Sei $\Sigma \triangleq (S, F)$ eine mehrsortige Signatur mit Variablen $(X_s)_{s \in S}$ und $\mathcal{A} = (A, \Phi)$ eine Σ -Algebra. Eine **Variablenbelegung** ist eine Familie von Abbildungen $(\beta_s : X_s \rightarrow A_s)_{s \in S}$.

Die **Interpretation von Termen** β und \mathcal{A} ist eine Familie von Abbildungen $(\llbracket \cdot \rrbracket_s^\beta : T_s(\Sigma, X) \rightarrow A_s)_{s \in S}$, die wie folgt definiert ist:

- $\llbracket x \rrbracket_s^\beta \triangleq \beta_s(x)$ für $x \in X_s$
- $\llbracket f \rrbracket_s^\beta \triangleq f_A$ für $f : \rightarrow s \in F$
- $\llbracket f(t_1, \dots, t_n) \rrbracket_s^\beta \triangleq f_A(\llbracket t_1 \rrbracket_s^\beta, \dots, \llbracket t_n \rrbracket_s^\beta)$ für $f : s_1 \times \dots \times s_n \rightarrow s \in F$ und Terme $t_1 \in T_{s_1}(\Sigma, X), \dots, t_n \in T_{s_n}(\Sigma, X)$

Beobachtung

Abstrakte Syntaxbäume können als Term interpretiert werden


- Algebra $\mathcal{T} = (T_s(\Sigma, X), \iota)$ (**Termalgebra**)

Beispiel 2.3: Navigation in abstrakten Syntaxbäumen

Idee

Verwende Listen ganzer Zahlen zum Navigieren

- Leere Liste entspricht Wurzel
- Falls Liste l auf Knoten k verweist, verweist Liste $l.i$ auf i -tes Kind von k



- 1 verweist auf Anweisungsteil
- 1.0.1 verweist auf **while**-Schleife
- 1.0.1.0 verweist auf Bedingung der **while**-Schleife
- 2.0.5 verweist auf keinen AST-Knoten

Beobachtungen

- Signatur WHILE muss erweitert werden
- Aus Sicht der Navigation müssen alle Strukturbaumknoten einheitlich behandelt werden
- Es gibt Navigationslisten (engl *occurrences*), die auf keinen AST-Knoten verweisen.

Lösungen

- Signaturerweiterungen mit entsprechender Erweiterung der Algebren
- Einführung von Untersorten
- Einführung von partiellen Operationen

Σ -Algebren für partielle Signaturen mit Untersorten

Definition 2.7 (Partielle ordnungssortierte Algebra)

Sei $\Sigma = \langle S, \sqsubseteq, F, F' \rangle$ eine partielle Signatur mit Untersorten. Eine **partielle ordnungssortierte Σ -Algebra** ist ein Paar $\mathfrak{A} = \langle A, \Phi \rangle$ mit

i. $A = \langle A_s \rangle_{s \in S}$ ist eine Familie von **Trägermengen** ist, so dass $A_s \subseteq A_{s'}$ falls $s \sqsubseteq s'$ ist.

ii. Für alle Funktionssymbole $f : s_1^{(1)} \times \dots \times s_n^{(1)} \rightarrow s^{(1)}, \dots,$

$$f : s_1^{(m)} \times \dots \times s_n^{(m)} \rightarrow s^{(m)} \in F \text{ ist } f_A : \bigcup_{j=1}^m A_{s_1}^{(j)} \times \dots \times \bigcup_{j=1}^m A_{s_n}^{(j)} \rightarrow \bigcup_{j=1}^m A_s^{(j)}$$

eine totale Funktion (**Interpretation des Operationssymbols f**), die folgende Bedingung erfüllt: Falls $f : s_1 \times \dots \times s_n \rightarrow s \in F$ und $a_1 \in A_{s_1}, \dots, a_n \in A_{s_n}$ dann ist auch $f_A(a_1, \dots, a_n) \in A_s$.

iii. Für alle Funktionssymbole $f : s_1^{(1)} \times \dots \times s_n^{(1)} \rightarrow ?s^{(1)}, \dots,$

$$f : s_1^{(m)} \times \dots \times s_n^{(m)} \rightarrow ?s^{(m)} \in F' \text{ ist } f_A : \bigcup_{j=1}^m A_{s_1}^{(j)} \times \dots \times \bigcup_{j=1}^m A_{s_n}^{(j)} \rightarrow \bigcup_{j=1}^m A_s^{(j)}$$

eine partielle Funktion (**Interpretation des Operationssymbols f**), die folgende Bedingung erfüllt: Falls $f : s_1 \times \dots \times s_n \rightarrow ?s \in F'$ und $a_1 \in A_{s_1}, \dots, a_n \in A_{s_n}$ dann ist auch $f_A(a_1, \dots, a_n) \in A_s$.

Definition 2.5 (Partielle Signaturen mit Untersorten)

Tupel $\Sigma = \langle S, \sqsubseteq, F, F' \rangle$ wobei

- S endliche Menge von **Sortensymbolen**
- $\sqsubseteq \subseteq S \times S$ ist eine Halbordnung auf S (**Untersortenbeziehung**)
- $F = \langle F_{w,s} \rangle_{w \in S^*, s \in S}$ ist eine Familie von Operationssymbolen (**totale Operationssymbole**) mit folgender Eigenschaft
Wenn $f : s_1 \times \dots \times s_n \rightarrow s \in F, s'_1 \sqsubseteq s_1, \dots, s'_n \sqsubseteq s_n$ und $s \sqsubseteq s'$, dann ist $f : s'_1 \times \dots \times s'_n \rightarrow s' \in F$
- $F' = \langle F'_{w,s} \rangle_{w \in S^*, s \in S}$ ist eine von F disjunkte Familie von Operationssymbolen, d.h. $F_{w,s} \cap F'_{w,s} = \emptyset$, (**partielle Operationssymbole**) mit folgender Eigenschaft:
Wenn $f : s_1 \times \dots \times s_n \rightarrow ?s \in F', s'_1 \sqsubseteq s_1, \dots, s'_n \sqsubseteq s_n$ und $s \sqsubseteq s'$, dann ist $f : s'_1 \times \dots \times s'_n \rightarrow ?s' \in F'$

Notationen

- $f : s_1 \times \dots \times s_n \rightarrow s \in F$ statt $f \in F_{s_1 \dots s_n, s}$
- $f : s_1 \times \dots \times s_n \rightarrow ?s \in F'$ statt $f \in F'_{s_1 \dots s_n, s}$

Definition 2.6 (Σ -Terme)

Definition analog den klassischen Signaturen
 \Rightarrow Sei $s \sqsubseteq s'$. Dann ist $T_s(\Sigma, X) \subseteq T_{s'}(\Sigma, X)$

Erweiterungen von Signaturen

Definition 2.8 (Signaturerweiterung)

Sei $\Sigma = \langle S, \sqsubseteq, F, F' \rangle$ eine Signatur. Eine Signatur $\bar{\Sigma} = \langle \bar{S}, \bar{\sqsubseteq}, \bar{F}, \bar{F}' \rangle$ mit $S \subseteq \bar{S}, \sqsubseteq \subseteq \bar{\sqsubseteq}, F \subseteq \bar{F}$ und $F' \subseteq \bar{F}'$ heißt **Erweiterung der Signatur Σ** .

Notationen

- $\Sigma \subseteq \Sigma'$ notiert die Erweiterung Σ' von Σ
- **sig Σ extends $\Sigma_1, \dots, \Sigma_n$ by sorts S subsorts \sqsubseteq operations $F \uplus F'$**
 $\triangleq \Sigma = \langle \cup S_i, \cup \sqsubseteq_i, \cup F_i, \cup F'_i \rangle$
wobei $\Sigma_i = \langle S_i, \sqsubseteq_i, F_i, F'_i \rangle$.

Definition 2.9 (Restriktion einer Σ -Algebra)

Sei $\mathfrak{A} = \langle A, \Phi \rangle$ eine Σ_1 -Algebra zu einer partiellen Signatur Σ_1 und $\Sigma_0 \triangleq \langle \langle S_0, \sqsubseteq_0, F_0, F'_0 \rangle \subseteq \Sigma_1$. Die **Restriktion von \mathfrak{A} bzgl. Σ** ist definiert durch: $\mathfrak{A}|_{\Sigma_0} \triangleq \langle A', \Phi' \rangle$ wobei $A'_s \triangleq A_s$ für alle $s \in S_0$ und $f_{A'} \triangleq f_A$ für alle $f \in F_0 \cup F'_0$.

Beobachtung

$\mathfrak{A}|_{\Sigma_0}$ ist eine Σ_0 -Algebra, die für die Sorten und für die Operationssymbole aus $\Sigma_0 \subseteq \Sigma_1$ dieselbe Interpretation hat wie die Σ_1 -Algebra \mathfrak{A} .

Idee

- Führe Signatur und Algebra für Listen ganzer Zahlen ein
- Erweitere Signatur für abstrakte Syntaxbäume um Navigationsleisten
- Definiere entsprechende Algebra

Listen ganzer Zahlen

sig OCC extends INT

sorts OCC
 operations $() : OCC \times INT \rightarrow OCC$ leere Liste
 $(.) : OCC \times INT \rightarrow OCC$ Infixnotation

OCC-Algebra: $\mathcal{D} \triangleq \langle \mathcal{O}, \Phi \rangle$ wobei

- $\mathcal{D}_{INT} = \mathbb{Z}$ und
- $\mathcal{D}_{INT'} = \mathcal{T}(INT')$, $INT' \triangleq \{\{INT\}, \{\dots, -2, -1, 0, 1, 2, \dots\} \rightarrow INT\}$
- \mathcal{O}_{OCC} sind alle endlichen Listen ganzer Zahlen, d.h.
 $\mathcal{O}_{OCC} \triangleq \{[x_1, \dots, x_n] : n \geq 0, x_i \in \mathbb{Z}\}$
- $(.)_O([x_1, \dots, x_n], x) \triangleq [x_1, \dots, x_n, x]$

Diskussion

Problem

Semantik wird an der konkreten Definition der Algebra festgelegt

- Eigenschaften nicht transparent auf Spezifikations-Ebene
- Umständliche Definition

Idee

Spezifikation der Eigenschaften durch Gleichungen, Formeln etc.

- Nachweis von Eigenschaften über Beweiskalküle
- Hier genügen zunächst bedingte und unbedingte Gleichungen

Navigation in abstrakten Syntaxbäumen

sig PROG extends WHILE, OCC
 sorts ASSIGN, READ, WRITE, WHILE, IF, PLUS, GEQ, MINUS, NODE
 suborts ASSIGN, READ, WRITE, WHILE, IF, PLUS, GEQ, MINUS, NODE, STAT, IF, STAT, DES, EXPR, PLUS, EXPR, GEQ, EXPR, MINUS, EXPR, ID, NODE, INTCONST, NODE, BOOLCONST, NODE, OP, NODE, PROG, NODE, STATS, NODE, DECLS, NODE, DECL, NODE, TYPE, NODE, STAT, NODE, EXPR, NODE
 operations $mkassign : DES \times EXPR \rightarrow ASSIGN$
 $mkif : EXPR \times STATS \times STATS \rightarrow IF$
 $mkwhile : EXPR \times STATS \rightarrow WHILE$
 $mkread : DES \rightarrow READ$
 $mkwrite : EXPR \rightarrow WRITE$
 $mkgeq : EXPR \times OP \times EXPR \rightarrow GEQ$
 $mkplus : EXPR \times OP \times EXPR \rightarrow PLUS$
 $mkminus : EXPR \times OP \times EXPR \rightarrow MINUS$
 $mkdes : NAME \rightarrow EXPR$
 $occ : OCC \times NODE \rightarrow ?NODE$
 $parent : OCC \rightarrow ?OCC$

PROG-Algebra \mathfrak{P} ist definiert durch: $\mathfrak{P} \stackrel{\Delta}{=} \mathcal{T}(WHILE)$
 $\mathfrak{P} \stackrel{\Delta}{=} \mathcal{D}$
 occ ist in Beispiel 2.3 informell definiert

- $P_{NODE} \triangleq P_{ID} \cup \dots \cup P_{EXPR}$
- Falls $occ_P([], t) = t$ für alle $t \in P_{NODE}$
- Falls $occ_P(o, t) = mkprog(d, s)$ ist, dann ist $occ_P(o++[0], t) = d$, $occ_P(o++[1], t) = s$ und $occ_P(o++[i], t) = \perp_{NODE}$ für $i \geq 2$
- Falls $occ_P(o, t) = mkif(e, s_1, s_2)$ ist, dann ist $occ_P(o++[0], t) = e$, $occ_P(o++[1], t) = s_1$, $occ_P(o++[2], t) = s_2$ und $occ_P(o++[i], t) = \perp_{NODE}$ für $i \geq 3$ usw.
- $parent_P(o++[i]) = o$

Gleichungen und bedingte Gleichungen

Definition 2.10 ((Bedingte) Σ -Gleichung, Σ -Definitionsbereichsprädikat, Σ -Sortenprüfung)

Sei $\Sigma \triangleq (S, \sqsubseteq, F, F')$ eine Signatur. Eine Σ -**Gleichung** ist ein Paar von Σ -Termen $t_1 \doteq t_2$, $t_1, t_2 \in T_s(\Sigma, X)$ für eine Sorte s und Variablen X . Für $s \in S$, $t \in T_s(\Sigma, X)$ heißen $D_s(t)$ und $\neg D_s(t)$ Σ -**Definitionsbereichsprädikat** sowie t is s und $\neg(t$ is $s)$ Σ -**Sortenprüfung**. Eine **bedingte Σ -Gleichung** ist ein $n+1$ -Tupel $eq_1 \wedge \dots \wedge eq_n \Rightarrow eq$, $n \geq 0$, wobei $eq_1, \dots, eq_n, eq \in E(\Sigma, X) \cup D(\Sigma, X) \cup S(\Sigma, X)$.

Notationen:

- $E(\Sigma, X)$ notiert die Menge der Σ -Gleichungen mit Variablen X .
- $D(\Sigma, X)$ notiert die Menge der Σ -Definitionsbereichsprädikate mit Variablen X .
- $S(\Sigma, X)$ notiert die Menge der Σ -Sortenprüfungen mit Variablen X .
- $C(\Sigma, X)$ notiert die Menge der bedingten Σ -Gleichungen mit Variablen X .

Erfüllung von Gleichungen und bedingten Gleichungen

Definition 2.11 (Erfüllung)

Sei $\mathfrak{A} = \langle A, \Phi \rangle$ eine Σ -Algebra und X eine Menge von Variablen.

- i. \mathfrak{A} erfüllt Σ -Gleichung $t_1 \doteq t_2$ gdw. $\llbracket t_1 \rrbracket_{\mathfrak{A}}^{\beta} = \llbracket t_2 \rrbracket_{\mathfrak{A}}^{\beta}$ für alle Belegungen $\beta : X \rightarrow A$ (Notation: $\mathfrak{A} \models t_1 \doteq t_2$)
- ii. \mathfrak{A} erfüllt Definitionsprädikat $D_s(t)$ gdw. $\llbracket t \rrbracket_{\mathfrak{A}}^{\beta} \neq \perp$ für alle Belegungen β mit $\beta_s(x) \neq \perp_s$ (Notation: $\mathfrak{A} \models D_s(t)$) und $\mathfrak{A} \models \neg D_s(t)$ gdw. $\mathfrak{A} \not\models D_s(t)$
- iii. \mathfrak{A} erfüllt Typprüfung t is s gdw. $\llbracket t \rrbracket_{\mathfrak{A}}^{\beta} \in A_s$ für alle Belegungen β . (Notation: $\mathfrak{A} \models t$ is s) und $\mathfrak{A} \models \neg(t$ is $s)$ gdw. $\mathfrak{A} \not\models t$ is s
- iv. \mathfrak{A} erfüllt bedingte Σ -Gleichung $eq_1 \wedge \dots \wedge eq_n \Rightarrow eq$ gdw. $\mathfrak{A} \models eq_1, \dots, \mathfrak{A} \models eq_n$ impliziert $\mathfrak{A} \models eq$. (Notation: $\mathfrak{A} \models eq_1 \wedge \dots \wedge eq_n \Rightarrow eq$)

Beobachtungen

- Kann erweitert werden auf Mengen von Algebren und Mengen von Gleichungen
 - Umkehrung: Menge bedingter Gleichungen definiert eine Menge von Algebren, die diese Gleichungen erfüllen
 - Falls $\Sigma \subseteq \Sigma'$, $c \in C(\Sigma, X)$ und $\mathfrak{A} \models c$ für eine Σ' -Algebra \mathfrak{A} , dann gilt auch $\mathfrak{A}|_{\Sigma} \models c$
- ⇒ Verwende bedingte Gleichungen zur Spezifikation gewünschter Eigenschaften

Fazit

Zusammenfassung

- Abstrakte Datentypen sind geeignet statische Strukturen einer Programmiersprache zu modellieren
- Die abstrakte Syntax kann durch eine Termalgebra dargestellt werden
- Eigenschaften können durch Algebren oder bedingte Gleichungen dargestellt werden
- Um in abstrakten Syntaxbäumen zu navigieren benötigt man partielle Operationssymbole und Untersorten

Abstrakte Datentypen

Definition 2.12 (Abstrakter Datentyp und Interpretation)

Ein **abstrakter Datentyp** ist ein Tripel $\mathcal{A} \triangleq \langle \Sigma, X, C \rangle$ wobei Σ Signatur, X Menge von Variablen und C Menge bedingter Σ -Gleichungen mit Variablen X (**Axiome**). Die **Interpretation** von \mathcal{A} ist die Menge $\mathcal{I}_{\mathcal{A}} \triangleq \{\mathfrak{A} \in \text{Alg}(\Sigma) : \mathfrak{A} \models C\}$

Beispiel 2.5: Navigationslisten

```

spec PROG extends WHILE, OCC
sorts      ASSIGN, READ, WRITE, WHILE, IF, PLUS, GEQ, MINUS, NODE
subsorts  ASSIGN ⊆ STAT, READ ⊆ STAT, WRITE ⊆ STAT, WHILE ⊆ STAT, IF ⊆ STAT,
          DES ⊆ EXPR, PLUS ⊆ EXPR, GEQ ⊆ EXPR, MINUS ⊆ EXPR,
          ID ⊆ NODE, INTCONST ⊆ NODE, BOOLCONST ⊆ NODE,
          OPT ⊆ NODE, PROG ⊆ NODE, STATS ⊆ NODE, DECLS ⊆ NODE,
          DECL ⊆ NODE, TYPE ⊆ NODE, STAT ⊆ NODE, EXPR ⊆ NODE
operations
mkassign : DES × EXPR      → ASSIGN
mkif     : EXPR × STATS × STATS → IF
mkwhile  : EXPR × STATS     → WHILE
mkread   : DES             → READ
mkwrite  : EXPR            → WRITE
mkgeq    : EXPR × OP × EXPR → GEQ
mkplus   : EXPR × OP × EXPR → PLUS
mkminus  : EXPR × OP × EXPR → MINUS
mkdes    : NAME           → EXPR
occ      : OCC × NODE     → ?NODE
parent   : OCC           → ?OCC
vars
axioms   x : NODE; o : OCC; d : DECLS; s, s1, s2 : STAT; i : INT
          occ((), x)      ≐ x
          occ(o.0, x)     ≐ d
          occ(o.1, x)     ≐ s
          occ(o, x) ≐ mkprog(d, s) ⇒ occ(0.i, x) ⇒ i > 0 ≐ true
          occ(o, x) ≐ mkprog(d, s) ∧ Docc(occ(0.i), x) ⇒ i >= 1 ≐ true
          ...
          -Docc(parent(()))
          parent(o.i) ≐ o
    
```

2.3 Abstrakte Zustandsmaschinen


Vorgehen zur Definition einer Programmiersprachsemantik

- Definition der abstrakten Syntax samt Navigation
- Definition des nächsten auszuführenden Befehls (Bestandteil der statischen Semantik)
- Definition des Zustandsraums
- Definition des Anfangszustands
- Definition der Zustandsübergänge

Beobachtungen

- Abstrakte Syntax und Navigation wurde bereits durch die Spezifikation PROG definiert.
- Zustandsraum und Zustandsübergangssystem muss noch definiert werden

$\mathfrak{S}_4 \triangleq next_{\mathbb{U}_4}(\mathfrak{S}_3)$ bzgl. $\mathbb{U}_4 \triangleq \{pc := yes(prog, pc)\}$



$$\llbracket mem \rrbracket_I(id) = \begin{cases} 12 & \text{falls } id = x \\ 5 & \text{falls } id = y \\ 1 & \text{falls } id = r \\ \perp \text{VALUE} & \text{sonst} \end{cases} \rightarrow \llbracket mem \rrbracket_I(id) = \begin{cases} 12 & \text{falls } id = x \\ 5 & \text{falls } id = y \\ 1 & \text{falls } id = r \\ \perp \text{VALUE} & \text{sonst} \end{cases}$$

$$\llbracket in \rrbracket_I = \llbracket out \rrbracket_I = \llbracket pc \rrbracket_I = \llbracket () \cdot 1.0.1 \rrbracket_I \rightarrow \llbracket in \rrbracket_I = \llbracket out \rrbracket_I = \llbracket pc \rrbracket_I = \llbracket () \cdot 1.0.1.1.0.1 \rrbracket_I$$

Wolf Zimmermann

79

Übung


Bestimmen Sie die folgenden STATE-Algebren:

- $\mathfrak{S}_6 \triangleq next_{\mathbb{U}_6}(\mathfrak{S}_5)$ bzgl.
 $\mathbb{U}_6 \triangleq \{ mem(x) := eval(mkminus(des(x), des(y))), pc := next(prog, pc) \}$
- $\mathfrak{S}_7 \triangleq next_{\mathbb{U}_7}(\mathfrak{S}_6)$ bzgl. $\mathbb{U}_7 \triangleq \{ pc := yes(prog, pc) \}$
- $\mathfrak{S}_8 \triangleq next_{\mathbb{U}_8}(\mathfrak{S}_7)$ bzgl. $\mathbb{U}_8 \triangleq \{ mem(r) := eval(binexpr(des(r), plus, mkintconst(1))), pc := next(prog, pc) \}$
- $\mathfrak{S}_9 \triangleq next_{\mathbb{U}_9}(\mathfrak{S}_8)$ bzgl.
 $\mathbb{U}_9 \triangleq \{ mem(x) := eval(mkminus(des(x), des(y))), pc := next(prog, pc) \}$
- $\mathfrak{S}_{10} \triangleq next_{\mathbb{U}_{10}}(\mathfrak{S}_9)$ bzgl. $\mathbb{U}_{10} \triangleq \{ pc := yes(prog, pc) \}$
- $\mathfrak{S}_{11} \triangleq next_{\mathbb{U}_{11}}(\mathfrak{S}_{10})$ bzgl.
 $\mathbb{U}_{11} \triangleq \{ out := out.eval(des(r)), pc := next(prog, pc) \}$

Wolf Zimmermann

81

$\mathfrak{S}_5 \triangleq next_{\mathbb{U}_5}(\mathfrak{S}_4)$, $\mathbb{U}_5 \triangleq \{ mem(r) := eval(mkplus(des(r), mkintconst(1))), pc := next(prog, pc) \}$



$$\llbracket mem \rrbracket_I(id) = \begin{cases} 12 & \text{falls } id = x \\ 5 & \text{falls } id = y \\ 1 & \text{falls } id = r \\ \perp \text{VALUE} & \text{sonst} \end{cases} \rightarrow \llbracket mem \rrbracket_I(id) = \begin{cases} 12 & \text{falls } id = x \\ 5 & \text{falls } id = y \\ 2 & \text{falls } id = r \\ \perp \text{VALUE} & \text{sonst} \end{cases}$$

$$\llbracket in \rrbracket_I = \llbracket out \rrbracket_I = \llbracket pc \rrbracket_I = \llbracket () \cdot 1.0.1.1.0.1 \rrbracket_I \rightarrow \llbracket in \rrbracket_I = \llbracket out \rrbracket_I = \llbracket pc \rrbracket_I = \llbracket () \cdot 1.0.1.1.1.1 \rrbracket_I$$

Wolf Zimmermann

80

Diskussion

Beobachtungen

- Die Aktualisierungsmengen \mathbb{U}_1 – \mathbb{U}_5 führen die Aktualisierungen der ersten 5 Anweisungen durch
- Die Trägermengen bleiben erhalten
- Die Interpretation vieler Operationssymbole bleiben erhalten

Weiteres Vorgehen

- Spezifikation der Zustandsübergangsregeln
- Semantik eines Programms ist Zustandsübergangsfolge

Wolf Zimmermann

82

Definition 2.14 (Abstrakte Zustandsmaschine (engl. Abstract State Machine, kurz ASM))

Sei Σ Signatur. Eine Σ -ASM ist ein Tupel $\mathcal{A} \triangleq \langle \Sigma, \mathbb{I}, \mathbb{A}, R \rangle$ wobei

- i. \mathbb{A} eine Menge von Σ -Algebren ist (**Zustände**)
- ii. $\mathbb{I} \subseteq \mathbb{A}$ (**Anfangszustände**)
- iii. und R endliche Menge von Regeln der Form **if** φ **then** \mathbb{U} , φ eine prädikatenlogische Formel über Σ und \mathbb{U} eine endliche Menge von Σ -Aktualisierungen ist

Die Menge $Update_{\mathcal{A}}(\mathbb{A}) \triangleq \{u \in \mathbb{U} : \exists \varphi \text{ then } \mathbb{U} \in R \bullet \mathbb{A} \models \varphi\}$ heißt **Aktualisierungsmenge im Zustand** \mathbb{A} .

Notation: $ASM(\Sigma)$ ist die Menge aller Σ -ASMs

Beispiel 2.11: Aktualisierungsmengen

<pre> if $occ(pc, prog)$ is ASSIGN then $mem(lhs(pc, prog)) := eval(rhs(pc, prog))$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is READ then $mem(dest(pc, prog)) := head(inp)$ $inp := tail(inp)$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is WRITE then $out := out.eval(arg(pc, prog))$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is WHILE $\wedge eval(cond(pc, prog)) \doteq true$ then $pc := yes(prog, pc)$ if $occ(pc, prog)$ is WHILE $\wedge eval(cond(pc, prog)) \doteq false$ then $pc := no(prog, pc)$ </pre>	<pre> int x; int y; int r; read(x); read(y); r=1; while (x>=y) { r=r+1; x=x-y; } print(r); </pre>	<p>Zustand $\mathcal{J} : \llbracket mem \rrbracket_I(x) \triangleq \perp_{VALUE}$ $\llbracket inp \rrbracket_I \triangleq [5, 12]$ $\llbracket out \rrbracket_I \triangleq []$ $\llbracket pc \rrbracket_I \triangleq [().1.0.0.0.1]_I$</p> <ul style="list-style-type: none"> • Es gilt nur $\mathcal{J} \models occ(prog, pc) \in READ$. <p>$\Rightarrow Update_{\mathcal{W}}(\mathcal{J}) = \{ mem(x) := head(inp), inp := tail(inp), pc := next(prog, pc) \}$</p>
<p> $D(lhs(o, p)) \Leftrightarrow occ(o, p) \text{ is ASSIGN}$ $lhs(o, p) \triangleq occ(o.0, p)$ $D(rhs(o, p)) \Leftrightarrow occ(o, p) \text{ is ASSIGN}$ $rhs(o, p) \triangleq occ(o.1, p)$ $D(dest(o, p)) \Leftrightarrow occ(o, p) \text{ is READ}$ $dest(o, p) \triangleq occ(o.0, p)$ $D(arg(o, p)) \Leftrightarrow occ(o, p) \text{ is WRITE}$ $arg(o, p) \triangleq occ(o.0, p)$ $D(cond(o, p)) \Leftrightarrow occ(o, p) \text{ is WHILE } \vee occ(o, p) \text{ is IF}$ $cond(o, p) \triangleq occ(o.0, p)$ </p>		

<pre> if $occ(pc, prog)$ is ASSIGN then $mem(lhs(pc, prog)) := eval(rhs(pc, prog))$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is READ then $mem(dest(pc, prog)) := head(inp)$ $inp := tail(inp)$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is WRITE then $out := out.eval(arg(pc, prog))$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is WHILE $\wedge eval(cond(pc, prog)) \doteq true$ then $pc := yes(prog, pc)$ if $occ(pc, prog)$ is WHILE $\wedge eval(cond(pc, prog)) \doteq false$ then $pc := no(prog, pc)$ </pre>	<pre> int x; int y; int r; read(x); read(y); r=1; while (x>=y) { r=r+1; x=x-y; } print(r); </pre>	
<p> $D(lhs(o, p)) \Leftrightarrow occ(o, p) \text{ is ASSIGN}$ $lhs(o, p) \triangleq occ(o.0, p)$ $D(rhs(o, p)) \Leftrightarrow occ(o, p) \text{ is ASSIGN}$ $rhs(o, p) \triangleq occ(o.1, p)$ $D(dest(o, p)) \Leftrightarrow occ(o, p) \text{ is READ}$ $dest(o, p) \triangleq occ(o.0, p)$ $D(arg(o, p)) \Leftrightarrow occ(o, p) \text{ is WRITE}$ $arg(o, p) \triangleq occ(o.0, p)$ $D(cond(o, p)) \Leftrightarrow occ(o, p) \text{ is WHILE } \vee occ(o, p) \text{ is IF}$ $cond(o, p) \triangleq occ(o.0, p)$ </p>		

Beispiel 2.11: Aktualisierungsmengen

<pre> if $occ(pc, prog)$ is ASSIGN then $mem(lhs(pc, prog)) := eval(rhs(pc, prog))$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is READ then $mem(dest(pc, prog)) := head(inp)$ $inp := tail(inp)$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is WRITE then $out := out.eval(arg(pc, prog))$ $pc := next(prog, pc)$ if $occ(pc, prog)$ is WHILE $\wedge eval(cond(pc, prog)) \doteq true$ then $pc := yes(prog, pc)$ if $occ(pc, prog)$ is WHILE $\wedge eval(cond(pc, prog)) \doteq false$ then $pc := no(prog, pc)$ </pre>	<pre> int x; int y; int r; read(x); read(y); r=1; while (x>=y) { r=r+1; x=x-y; } print(r); </pre>	<p>Zustand $\mathcal{G}_1 = next_{Update_{\mathcal{W}}}(\mathcal{J})(\mathcal{J})$:</p> <p> $\llbracket mem \rrbracket_I(id) = \begin{cases} 12 & \text{falls } id = x \\ \perp_{VALUE} & \text{sonst} \end{cases}$ $\llbracket inp \rrbracket_I = [5]$ $\llbracket out \rrbracket_I = []$ $\llbracket pc \rrbracket_I = [().1.0.0.0.1]_I$ </p> <ul style="list-style-type: none"> • Es gilt nur $\mathcal{G}_1 \models occ(prog, pc) \in READ$. <p>$\Rightarrow Update_{\mathcal{W}}(\mathcal{G}_1) = \{ mem(y) := head(inp), inp := tail(inp), pc := next(prog, pc) \}$</p>
<p> $D(lhs(o, p)) \Leftrightarrow occ(o, p) \text{ is ASSIGN}$ $lhs(o, p) \triangleq occ(o.0, p)$ $D(rhs(o, p)) \Leftrightarrow occ(o, p) \text{ is ASSIGN}$ $rhs(o, p) \triangleq occ(o.1, p)$ $D(dest(o, p)) \Leftrightarrow occ(o, p) \text{ is READ}$ $dest(o, p) \triangleq occ(o.0, p)$ $D(arg(o, p)) \Leftrightarrow occ(o, p) \text{ is WRITE}$ $arg(o, p) \triangleq occ(o.0, p)$ $D(cond(o, p)) \Leftrightarrow occ(o, p) \text{ is WHILE } \vee occ(o, p) \text{ is IF}$ $cond(o, p) \triangleq occ(o.0, p)$ </p>		

Beispiel 2.11: Aktualisierungsmengen

```

if occ(pc, prog) is ASSIGN then
  mem(lhs(pc, prog)) := eval(rhs(pc, prog))
  pc := next(prog, pc)
if occ(pc, prog) is READ then
  mem(dest(pc, prog)) := head(inp)
  inp := tail(inp)
  pc := next(prog, pc)
if occ(pc, prog) is WRITE then
  out := out.eval(arg(pc, prog))
  pc := next(prog, pc)
if occ(pc, prog) is WHILE ^ eval(cond(pc, prog) = true then
  pc := yes(prog, pc)
if occ(pc, prog) is WHILE ^ eval(cond(pc, prog) = false then
  pc := no(prog, pc)

```

```

int x;
int y;
int r;
read(x);
read(y);
r=1;
while (x>=y) {
  r=r+1;
  x=x-y;
}
print(r);

```

Zustand $\mathfrak{G}_2 = next_{Update_{\mathcal{W}}}(\mathfrak{G}_1)$:

$$\llbracket mem \rrbracket_I(id) = \begin{cases} 12 & \text{falls } id = x \\ 5 & \text{falls } id = y \\ \perp \text{VALUE} & \text{sonst} \end{cases}$$

$$\llbracket inp \rrbracket_I = \llbracket out \rrbracket_I = \llbracket pc \rrbracket_I = \llbracket () \cdot 1.0.0.1 \rrbracket_I$$

• Es gilt nur $\mathfrak{G}_2 \models occ(prog, pc) \in ASSIGN$.
 $\Rightarrow Update_{\mathcal{W}}(\mathfrak{G}_2) = \{ mem(r) := 1, pc := next(prog, pc) \}$

$lhs : OCC \times PROG \rightarrow ?NODE$
 $rhs : OCC \times PROG \rightarrow ?NODE$
 $dest : OCC \times PROG \rightarrow ?NODE$
 $arg : OCC \times PROG \rightarrow ?NODE$
 $cond : OCC \times PROG \rightarrow ?NODE$
 $D(lhs(o, p)) \Leftrightarrow occ(o, p) \text{ is ASSIGN}$
 $D(rhs(o, p)) \Leftrightarrow occ(o, p) \text{ is ASSIGN}$
 $D(dest(o, p)) \Leftrightarrow occ(o, p) \text{ is READ}$
 $D(arg(o, p)) \Leftrightarrow occ(o, p) \text{ is WRITE}$
 $D(cond(o, p)) \Leftrightarrow occ(o, p) \text{ is WHILE } \vee occ(o, p) \text{ is IF}$

Makros und Notationen zur besseren Lesbarkeit

Beobachtungen

- Einige Aktualisierungen und Terme werden häufig benutzt
- Einige Terme sind unübersichtlich
- ⇒ Einführung von Abkürzungen
- Bei der Semantik einer while-Schleife würde eine "lokale" Regel einsichtiger sein

Beispiel 2.12: Abkürzungen

```

if CT is ASSIGN then
  mem(Dest) := eval(Src)
  Proceed
if CT is READ then
  mem(Des) := head(inp)
  inp := tail(inp)
  Proceed
if CT is WRITE then
  out := out.eval(Expr)
  Proceed
if CT is WHILE then
  if eval(Cond) = true then
    pc := yes(prog, pc)
  else pc := no(prog, pc)

```

$Proceed \triangleq pc := next(prog, pc)$
 $CT \triangleq occ(pc, prog)$
 $Dest \triangleq lhs(pc, prog)$
 $Src \triangleq rhs(pc, prog)$
 $Des \triangleq dest(pc, prog)$
 $Expr \triangleq arg(pc, prog)$
 $Cond \triangleq cond(pc, prog)$

$if \varphi \text{ then}$
 $if \psi \text{ then } U_1 \triangleq if \varphi \wedge \psi \text{ then } U_1$
 $else U_2 \triangleq if \varphi \wedge \neg \psi \text{ then } U_2$

Beispiel 2.11: Aktualisierungsmengen

```

if occ(pc, prog) is ASSIGN then
  mem(lhs(pc, prog)) := eval(rhs(pc, prog))
  pc := next(prog, pc)
if occ(pc, prog) is READ then
  mem(dest(pc, prog)) := head(inp)
  inp := tail(inp)
  pc := next(prog, pc)
if occ(pc, prog) is WRITE then
  out := out.eval(arg(pc, prog))
  pc := next(prog, pc)
if occ(pc, prog) is WHILE ^ eval(cond(pc, prog) = true then
  pc := yes(prog, pc)
if occ(pc, prog) is WHILE ^ eval(cond(pc, prog) = false then
  pc := no(prog, pc)

```

```

int x;
int y;
int r;
read(x);
read(y);
r=1;
while (x>=y) {
  r=r+1;
  x=x-y;
}
print(r);

```

Zustand $\mathfrak{G}_3 = next_{Update_{\mathcal{W}}}(\mathfrak{G}_2)$:

$$\llbracket mem \rrbracket_I(id) = \begin{cases} 12 & \text{falls } id = x \\ 5 & \text{falls } id = y \\ 1 & \text{falls } id = r \\ \perp \text{VALUE} & \text{sonst} \end{cases}$$

$$\llbracket inp \rrbracket_I = \llbracket out \rrbracket_I = \llbracket pc \rrbracket_I = \llbracket () \cdot 1.0.1 \rrbracket_I$$

• Es gilt $\mathfrak{G}_3 \models occ(prog, pc) \in WHILE$ und
 $\mathfrak{G}_3 \models eval(x \geq y) = true$
 $\Rightarrow Update_{\mathcal{W}}(\mathfrak{G}_3) = \{ pc := yes(prog, pc) \}$

Übung Bestimmen Sie die Aktualisierungsmengen der Zustände $\mathfrak{G}_{i+1} = next_{Update_{\mathcal{W}}}(\mathfrak{G}_i)(\mathfrak{G}_i)$, $i = 4, \dots$

Abstrakte Zustandsmaschinen: Interpretation als Zustandsübergangssystem

Satz 2.1 (ASM und Zustandsübergangssystem)

Sei Σ eine Signatur, $\mathcal{A} \triangleq \langle \Sigma, \mathbb{I}, \mathbb{A}, R \rangle$ eine Σ -ASM. Dann ist \mathcal{A} ein Zustandsübergangssystem $\mathcal{S} \triangleq (Q, I, \rightarrow_R)$ mit $Q \triangleq \mathbb{A}$, $I \triangleq \mathbb{I}$ und $\rightarrow_R \triangleq \{ (\mathfrak{A}_1, \mathfrak{A}_2) : \mathfrak{A}_1 \in \mathbb{A} \wedge \mathfrak{A}_2 = next_{Update_{\mathcal{A}}}(\mathfrak{A}_1)(\mathfrak{A}_1) \}$. Eine Σ -Algebra $\mathfrak{F} \in \mathbb{A}$ ist genau dann final, wenn $Update_{\mathcal{A}}(\mathfrak{F})$ inkonsistent oder $Update_{\mathcal{A}}(\mathfrak{F}) = \emptyset$ ist.

Beweis

Folgt direkt aus Definition 1.1, Definition 2.13, $\rightarrow_R \subseteq \mathbb{A} \times \mathbb{A}$ und Definition 2.14.

Diskussion

Beobachtung

Alle Begriffe aus Kapitel 1 sind für ASMs definiert:

- (Vollständiger) Lauf einer ASM
- Abstraktion einer ASM
- Beobachtbares Verhalten
- ASM \mathcal{A}_1 1-1-simuliert (eingeschränkt) ASM \mathcal{A}_2
- Wenn $\llbracket \cdot \rrbracket : \mathcal{T}_{\text{PROG}} \rightarrow \langle \Sigma, \text{ASM}(\Sigma) \rangle$ den Programmen einer Programmiersprache eine Semantik als ASM zuordnet, ist auch der Begriff der korrekten Übersetzung bzw. des korrekten Übersetzers definiert.
- (Eingeschränkte) n - m -Simulation

Folgerung

Auch die Sätze für Zustandsübergangssystem gelten für ASMs

- Horizontale Dekomposition
- Vertikale Dekomposition
- Satz 1.3 (Voraussetzung, dass n - m -Simulation eine eingeschränkte 1-1-Simulation auf beobachtbarem Verhalten impliziert)

Diskussion

Konvention

Ab sofort betrachten wir noch ASMs $\mathcal{A} \triangleq \langle \Sigma, \mathbb{A}, \mathbb{I}, R \rangle$, bei denen jedes $\mathfrak{A} \in \mathbb{A}$ von einem Initialzustand $\mathfrak{J} \in \mathbb{I}$ erreichbar ist.

Korollar 2.2 (Eigenschaften von Zuständen einer ASM)

Sei $\mathcal{A} \triangleq \langle \Sigma, \mathbb{A}, \mathbb{I}, R \rangle$ eine ASM, $\Delta \subseteq \Sigma$ die Signatur der statischen Funktionen und Γ die Signatur der konstanten Funktionen von \mathcal{A} . Dann gilt:

- $\mathfrak{A}|_{\Delta} = \mathfrak{A}'|_{\Delta}$ für alle $\mathfrak{A}, \mathfrak{A}' \in \mathbb{A}$ (**statische Algebra**)
- Für jedes $\mathfrak{J} \in \mathbb{I}$ gilt: $\mathfrak{A}|_{\Delta \cup \Gamma} = \mathfrak{J}|_{\Delta \cup \Gamma}$ für alle von \mathfrak{J} aus erreichbaren Zustände \mathfrak{A} .

Beobachtungen

- Bei Erstellung einer ASM sollten direkte und abgeleitete Funktionen strikt voneinander getrennt werden.
- ⇒ Keine Axiome für direkte dynamische Funktionen
- ⇒ Aus den Axiomen für abgeleitete dynamische Funktionen dürfen keine Aussagen über direkte dynamische Funktionen gefolgert werden können
- ☠ Gefahr von inkonsistenten Spezifikationen

Statische und dynamische Funktionen

Zusammenfassung des Beispiels (außer abstrakter Syntax, Navigation und Basistypen)

if CT is ASSIGN then $mem(Dest) := eval(Src)$ Proceed	if CT is WRITE then $out := out.eval(Expr)$ Proceed	$Proceed \triangleq pc := next(prog, pc)$ $CT \triangleq occ(pc, prog)$ $Dest \triangleq lhs(pc, prog)$ $Src \triangleq rhs(pc, prog)$ $Des \triangleq dest(pc, prog)$ $Expr \triangleq arg(pc, prog)$ $Cond \triangleq cond(pc, prog)$
if CT is READ then $mem(Des) := head(inp)$ $inp := t(inp)$ Proceed	if CT is WHILE then if $eval(Cond) \doteq true$ then $pc := yes(pc)$ else $pc := no(pc)$	$eval(mkdes(mkname(x))) \doteq mem(x)$ $eval(mkintconst(n)) \doteq n$ $eval(mkboolconst(b)) \doteq b$ $eval(mkgeq(e_1, e_2)) \doteq intgeq(eval(e_1), eval(e_2))$ $eval(mkplus(e_1, e_2)) \doteq intplus(eval(e_1), eval(e_2))$ $eval(mkminus(e_1, e_2)) \doteq intminus(eval(e_1), eval(e_2))$
$lhs(o, p) \doteq occ(o, 0, p)$ $rhs(o, p) \doteq occ(o, 1, p)$ $dest(o, p) \doteq occ(o, 0, p)$ $arg(o, p) \doteq occ(o, 0, p)$ $cond(o, p) \doteq occ(o, 0, p)$		

- Die Funktionen $mem, pc, inp, out, eval$ und $prog$ sind dynamisch. alle anderen Funktionen sind statisch.
- $prog$ ist konstant; die übrigen dynamischen Funktionen sind nicht konstant.
- Die Funktionen mem, pc, inp, out sind direkt; $eval$ ist abgeleitet.

Definition 2.15 (Statische und dynamische Funktionen)

Sei $\mathcal{A} \triangleq \langle S, \sqsubseteq, F, F' \rangle$ eine Signatur und $\mathcal{A} \triangleq \langle \Sigma, \mathbb{A}, \mathbb{I}, R \rangle$, so dass \mathbb{A} die Menge der von \mathbb{I} erreichbaren Zustände ist. Eine Funktion $f \in F \cup F'$ heißt **dynamisch** gdw. wenn es $\mathfrak{A}, \mathfrak{A}'$ gibt, so dass $\llbracket f \rrbracket_{\mathfrak{A}} \neq \llbracket f \rrbracket_{\mathfrak{A}'}$ ist. Ansonsten heißt $f \in F \cup F'$ heißt **statisch**. Eine dynamische Funktion f heißt **konstant** gdw. für jeden Initialzustand $\mathfrak{J} \in \mathbb{I}$ die Eigenschaft $\llbracket f \rrbracket_{\mathfrak{A}} = \llbracket f \rrbracket_{\mathfrak{J}}$ für alle von \mathfrak{J} aus erreichbaren Zustände \mathfrak{A} gilt. Eine nicht-konstante dynamische Funktion f heißt **direkt**, wenn es eine Regel **if** φ **then** U und Terme t_1, \dots, t_n, t gibt, so dass $f(t_1, \dots, t_n) := t \in U$ ist. Andernfalls heißt f **abgeleitet**.

Zusammenfassung

- Abstrakte Zustandsmaschinen sind Zustandsübergangssysteme
- Zustände sind Σ -Algebren über einer Signatur Σ
- Zustandsübergangsregeln definieren die Änderung der Interpretation von Funktionssymbolen
- Initialzustände und die statischen Algebren werden über abstrakte Datentypen spezifiziert.
- Abgeleitete dynamische Funktionen werden ebenfalls durch Gleichungen definiert.

2.4 Modulare Konstruktion von Semantiken mit ASMs

Ziele

- Formale Definition einer Semantik von ASMs ausgehend von einer Kernsprache, die dann sukzessive erweitert wird
 - Erweiterungen sollen keine Änderungen der bisherigen Zustandsübergangsregeln und Axiome erfordern
- ⇒ Auch Korrektheitsbeweise können entsprechend modular aufgebaut werden.

- 1 Allgemeines Vorgehen
- 2 Die Sprache C--
- 3 Steuerstrukturen (C0)
- 4 Verbunde und Verbundzeiger (C1)
- 5 Prozeduren und Funktionen

Diskussion

Probleme

- Bei der Definition des Zustandsraums müssen manchmal auch zukünftige Erweiterungen berücksichtigt werden.
- Wenn neue Sprachkonzepte eingeführt werden, müssen manchmal auch für alte Sprachkonstrukte neue Zustandsübergänge eingeführt werden.

Beispiel 2.13: Probleme beim Erweitern der einfachen While-Sprache

- Ausdrucksauswertung mit *eval* kann so nicht mehr formuliert werden, wenn Funktionsaufrufe eingeführt werden
- ⇒ Jeder Ausdruck hat einen Wert und diese Zuordnung ist zu definieren.
- Bei Einführung von Prozeduren und zusammengesetzten Datentypen können mehrere Objekte demselben Namen zugeordnet sein
- ⇒ Speicher $mem : ID \rightarrow VALUE$ funktioniert so nicht
- ⇒ Bindung von Variablen an Adressen und Adressen an Werte: $bind : ID \rightarrow LOC$ und $mem : LOC \rightarrow VALUE$ - Bei Einführung von Ausnahmen muss bei Zuweisung etc. die Fortsetzung zur Ausnahmebehandlung definiert werden.

☞ Ohne Ausnahmebehandlung endet man in finalem Zustand bei Auftreten einer Ausnahme (z.B. Division durch 0)

Lösungen

- Allgemeinere Konzepte zur Definition des Zustandsraums
 - Neue Zustandsübergänge für alte Befehle durch neue Regeln
- ☞ Bei alten Befehlen werden die alten und neuen Aktualisierungen vereinigt

2.4.1 Allgemeines Vorgehen

Schritte

- Definition der abstrakten Syntax
- Definition der Navigation
- Definition des Zustandsraums
- Definition der Zustandsübergangsregeln

Modularisierung

- Schrittweise Erweiterung der abstrakten Syntax
- Schrittweise Erweiterung der Navigation
- Schrittweise Erweiterung der Definition des Zustandsraums
- Schrittweise Erweiterung der Zustandsübergangsregeln


Ausblick

Weiteres Vorgehen in diesem Abschnitt

- Informelle Vorstellung eines reduzierten C-Dialekts
- Definition des Zustandsraums
- Bei der Definition der Semantik wird die informelle Definition, die abstrakte Syntax, die Navigation und die Zustandsübergangsregel(n) eingeführt

Notationen

- Die abstrakte Syntax wird als Baum notiert. Die Knoten werden mit den entsprechenden Sorten gekennzeichnet. Rechtecke stehen für komplette Unterbäume. Alternativen werden als Produktion angegeben.
- Navigationen sind von der Sorte OCC und werden als Pfeile notiert.
- Jeder Unterbaum hat einen Anfang und mögliche Ausgänge, die durch ein- bzw. ausgehende Pfeile notiert werden.
- Eine Navigation auf einen kompletten Unterbaum hat als Ziel dessen Eingang
- Eine Navigation aus einem kompletten Unterbaum hat als Quellen alle Ausgänge des Unterbaums



2.4.2 Die Sprache C--

Programme

prog ::= *decl** *block*

- Die in den Deklarationen vereinbarten Namen sind im Hauptprogramm *block* sichtbar (**Gültigkeitsbereich**)
- Die in den Deklarationen vereinbarten Namen müssen eindeutig sein.
- Die in den Deklarationen vereinbarten Variablen, Prozeduren und Typen heißen **global**.
- Die Ausführung eines Programms führt den Block aus.

Basistypen und Anpassung

type ::= *id*

- Basisdatentypen sind ganze Zahlen (Typ *int*), Gleitkommazahlen (Typ *float*) und Wahrheitswerte (Typ *bool*) mit den üblichen Operationen und Konstanten
- Die Darstellung ganzer Zahlen entspricht der Darstellung ganzer Zahlen auf der Zielmaschine. Die Arithmetik ist Ringarithmetik (z.B ist *maxint* + 1 = *minint*)
- Die Gleitkommazahlen werden gemäß IEEE 754-1985 dargestellt. Die Genauigkeit entspricht der Wortlänge der Zielmaschine.
- Ganze Zahlen können automatisch in Gleitkommazahlen konvertiert werden.
- Konstanten werden in der selben Syntax wie C notiert

Zugriffspfade

des ::= *id*|*fieldaccess*

fieldaccess ::= *des*.*id*

- Zugriffspfade verweisen auf Objekte
- Falls ein Zugriffspfad aus einem Bezeichner *id* besteht, muss dieses Objekt im Kontext durch eine Variablendeklaration vereinbart sein. In diesem Fall verweist der Zugriffspfad auf dieses Objekt.
- Bei einem Feldzugriff muss der Typ des Zugriffspfads *des* ein Verbund- oder Klassentyp sein, der ein Feld mit dem Namen *id* enthält.
- Falls *des* Verbundtyp ist, bezeichnet der Zugriffspfad das durch *id* definierte Teilobjekt
- Falls *des* Klassentyp ist, muss der Wert von *des* ≠ NULL sein, ansonsten bricht das Programm mit einer `NullPointerException` ab.
- Wenn der Wert von *des* ≠ NULL ist, wird zunächst das durch den Zeiger verwiesene Objekt ermittelt (**Dereferenzieren**). Der Klassenfeldzugriff verweist dann auf das durch *id* definierte Teilobjekt.

Deklarationen

Zusammengesetzte Typen

decl ::= *vardecl*|*typeddecl*|*procdecl*
typeddecl ::= *struct*|*class*
struct ::= *struct id* {*vardecl**}
class ::= *class id* {*vardecl**}

- Ein Verbundtyp (*struct*) definiert ein kartesisches Produkt. Verbundobjekte (*struct*) bestehen aus Teilobjekten, die durch die Variablendeklarationen des Verbundtyps gegeben sind (**Verbundfelder**)
- Ein Klassentyp (*class*) definiert einen Zeigertyp auf Verbundtypen. Ein Klassenobjekt ist ein Zeiger auf ein Verbundobjekt, dessen Teilobjekte durch die Verbundfelder des Klassentyps definiert sind. Zeiger können auch leer sein (NULL)
- *id* ist jeweils der Name des Verbund- bzw. Klassentyps.
- Die Verbundfeldnamen müssen paarweise verschieden sein.

Variablendeklarationen

vardecl ::= *type id*;

- Eine Variablendeklaration vereinbart ein Objekt, in dem Werte des Typs *type* gespeichert werden können
- Der Bezeichner *id* ist der Name der Variablen. Mit diesem Namen kann die Variable in ihrem Gültigkeitsbereich angesprochen werden.

Ausdrücke (Syntax und statische Semantik)

expr ::= *null*|*intconst*|*fltconst*|*boolconst*|*des*|*unexpr*|*binexpr*|*call*|*new*(*expr*)
unexpr ::= *unop expr*
unop ::= !|-|+
binexpr ::= *expr binop expr*
unop ::= *eqop*|*relop*|*addop*|*mulop*
eqop ::= ==|!=
relop ::= <|>|<=|>=
addop ::= +|-
mulop ::= *|/|%
boolop ::= |||&&
new ::= *new type*

- Die Prioritäten der Operatoren sind in der folgenden Reihenfolge definiert: unäres + und -, *mulop*, *addop*, *relop*, *eqop*, &&, ||, !.
- Die binären Operatoren (außer *relop*) sind linksassoziativ geklammert.
- Der Typ eines Zugriffspfads ist der Typ des durch ihn bezeichneten Objekts.
- Boolesche Operatoren erwarten von ihren Operanden den Typ *bool*. Boolesche Ausdrücke haben den Typ *bool*.
- Gleichheitsausdrücke erwarten entweder von beiden Operanden denselben Typ oder einer der Operanden muss vom Typ *int* und der andere vom Typ *bool* sein. Der Typ eines Gleichheitsausdrucks ist *bool*.
- Der Operator % erwarten von beiden Operanden den Typ *int*. Der Ausdruck ist vom Typ *int*.
- Relationale Ausdrücke (*relop*) und arithmetische Ausdrücke (außer %) erwarten von ihren Operanden den Typ *int* oder *float*. Der Typ eines relationalen Ausdrucks ist *bool*. Der Typ eines arithmetischen Ausdrucks ist *int*, wenn alle seine Operanden vom Typ *int* sind, ansonsten ist der Typ *float*.
- Der Typ einer *new*-Operation muss eine Klasse sein. Dieser Typ ist der Typ des Ausdrucks

Ausdrücke (dynamische Semantik)

- Ausdrücke werden ausgewertet. Die Auswertereihenfolge arithmetischer und relationaler Ausdrücke ist implementierungsabhängig.
- Boolesche Ausdrücke werden durch Kurzauswertung ausgewertet.
- Der Wert einer Konstanten entspricht dem im Programm bezeichneten Wert
- Der Wert eines Zugriffspfad *des* ist der Inhalt des Objekts, auf das *des* verweist.
- Der Wert eines unärer Ausdrucks wendet den Operator auf den Wert des Operanden an (! ist die logische Negation)
- Die Werte binärer Ausdrücke verknüpfen die beiden Werte mit dem Operator des Ausdrucks (|| ist die logische Disjunktion, && die logische Konjunktion und % der Rest bzgl. der Division)
- Hat der rechte Operand von / oder % den Wert 0, dann bricht das Programm mit der Ausnahme `DivByZeroException` ab.
- Eine `new`-Operation erzeugt ein Objekt der Klasse und liefert einen Verweis auf dieses Objekt

Anweisung(en)

Lese-Anweisung

`read ::= read (des) ;`

- Der Zugriffspfad darf kein Verbund- oder Klassentyp haben.
- Die Lese-Anweisung bestimmt das Objekt, auf das der Zugriffspfad verweist und schreibt dort den aktuellen Wert des Eingabestroms. Die aktuelle Position des Eingabestroms auf den nächsten Wert fortgeschaltet.
- Danach wird mit der nächsten Anweisung fortgefahren.

Schreibe-Anweisung

`write ::= write (expr) ;`

- Der Ausdruck darf kein Verbund- oder Klassentyp haben.
- Die Schreibe-Anweisung wertet den Ausdruck aus und schreibt dessen Wert an das Ende des Ausgabestroms.
- Danach wird mit der nächsten Anweisung fortgefahren.

Anweisungen

Zuweisung

`stat ::= assign|read|write|if|while|break|continue|call ;|return|block`
`assign ::= des = expr ;`

- Der Typ von *expr* muss an den Typ *des* anpassbar sein.
- Der Zugriffspfad wird zu einem Verweis auf ein Objekt ausgewertet und der Ausdruck wird ausgewertet. Der Wert des Ausdrucks wird in das durch den Zugriffspfad verwiesene Objekt geschrieben. Die Auswertereihenfolge ist implementierungsabhängig.
- Danach wird mit der nächsten Anweisung fortgefahren.
- Wird an ein Verbundobjekt zugewiesen, dann werden die Werte der Verbundfelder in das Teilobjekt, auf das entsprechende Verbundfeld verweist, geschrieben. Wird an ein Verbundzeigerobjekt zugewiesen wird der Zeiger in das Objekt, auf das die linke Seite verweist, geschrieben.

Anweisung(en)

Verzweigung

`if ::= if (expr) stat [else stat]`

- Der Ausdruck muss vom Typ `bool` sein.
- Der Ausdruck wird ausgewertet. Ist das Ergebnis `true` so wird die erste Anweisung ausgeführt. Danach wird die Anweisung nach der Verzweigung ausgeführt. Ist das Ergebnis `false` und keine `else`-Anweisung vorhanden, dann wird die Anweisung nach der Verzweigung ausgeführt. Ansonsten wird zuerst die `else`-Anweisung und dann die Anweisung nach der Verzweigung ausgeführt.

Schleifen

`if ::= while (expr) stat`

- Der Ausdruck muss vom Typ `bool` sein.
- Der Ausdruck wird ausgewertet. Ist das Ergebnis `true` so wird die Anweisung ausgeführt. Danach wird wieder die Schleife ausgeführt. Ist das Ergebnis `false`, dann wird die Anweisung nach der Schleife ausgeführt.

Anweisung(en)

Schleifenabbruch und –fortsetzung

```
break ::= break ;
continue ::= continue ;
```

- Eine `break`- oder `continue`-Anweisung darf nur innerhalb des Blocks einer Schleifenanweisung stehen.
- Bei Ausführen einer `break`-Anweisung wird die Schleife abgebrochen und danach die Anweisung nach der Schleife ausgeführt.
- Bei Ausführen einer `continue`-Anweisung wird die aktuelle Ausführung des Schleifenrumpfs abgebrochen und danach die Schleifenanweisung ausgeführt.

Blockanweisung

```
block ::= { vardecl* stat* }
```

- Die durch die Variablendeklarationen eingeführten Namen eines Blocks müssen paarweise verschieden sein.
- Die Namen der deklarierten Variablen sind nur im Block sichtbar. Sie verdecken Bezeichner desselben Namens, die außerhalb des Blocks sichtbar sind.
- Die Ausführung eines Blocks führt alle seine Anweisungen nacheinander aus. Danach wird die Anweisung nach dem Block ausgeführt.

Prozeduren und Funktionen (dynamische Semantik)

- Mit dem Prozedur-/Funktionsaufruf werden den Parametern Objekte zugeordnet.
- Bei einem Prozedur- oder Funktionsaufruf werden die Argumente ausgewertet und an die Parameter positional übergeben, d.h. der Wert eines Arguments wird in das Objekt geschrieben, auf das der Parameter verweist. Danach wird der Prozedurrumpf ausgeführt. Die Reihenfolge der Auswertung der Argumente ist implementierungsabhängig.
- Ein Prozedur- oder Funktionsaufruf **kehrt zurück**, wenn die letzte Anweisung des Prozedurrumpfs oder eine `return`-Anweisung ausgeführt wurde.
- Nach Rückkehr von einem Prozeduraufruf wird mit die Anweisung nach dem Aufruf ausgeführt.
- Nach Rückkehr von einem Funktionsaufruf wird mit der Ausführung der Anweisung, in der der Aufruf vorkam, fortgefahren. Der Wert eines Funktionsaufrufs ist der Wert des Ausdrucks der ausgeführten `return`-Anweisung.

Prozeduren und Funktionen (Syntax und statische Semantik)

```
procdecl ::= type id ( pars ) block
pars ::= [type id ( , type id)*]
call ::= id ( args )
args ::= [expr ( , expr)*]
return ::= return [expr]
```

- Die Parameter sind im Prozedurrumpf (`block`) sichtbar.
- Die Namen der Parameter müssen paarweise verschieden sein.
- Der Typ in einer Prozedurdeklaration heißt **Rückgabetyt**. Ist der Rückgabetyt `void` so redet man von **Prozeduren**, sonst von **Funktionen**.
- Prozeduraufrufe sind Anweisungen, Funktionsaufrufe sind Ausdrücke. Der Typ eines Funktionsaufrufs ist der Rückgabetyt der aufgerufenen Funktion.
- Bei einem Aufruf einer Prozedur/Funktion muss die Anzahl der Parameter der aufgerufenen Prozedur `id` mit der Anzahl der Argumente übereinstimmen. Vom i -ten Argument wird der Typ des i -ten Parameters erwartet.
- Eine `return`-Anweisung darf nur innerhalb eines Prozedur- oder Funktionsrumpfs vorkommen. Bei einer Prozedur darf nur die `return`-Anweisung ohne Ausdruck verwendet werden. Bei einer Prozedur muss die `return`-Anweisung mit Ausdruck verwendet werden. Von diesem Ausdruck wird erwartet, dass er Typ gleich dem Rückgabetyt der Funktion ist.

2.4.3 Steuerstrukturen (C0)

Ausgangspunkt

- Spezifikationen `INT` für ganze Zahlen (64-Bit, 2-Komplement, Ringarithmetik)
- `FLOAT` für Gleitkommazahlen (64-Bit 754-1985)
- Spezifikation `BOOL` für Wahrheitswerte
- `spec VALUE extends INT, FLOAT, BOOL`
`sorts VALUE`
`subsorts INT \sqsubseteq VALUE, FLOAT \sqsubseteq VALUE, BOOL \sqsubseteq VALUE`
- Spezifikation `OCC` für Listen ganzer Zahlen
- Spezifikation `LISTOFVAL` für Listen von Werten
- Spezifikation `PROG extends OCC, LISTOFVAL \dots` , die die abstrakte Syntax, Attributierung und Navigation definiert

Vorgehen

- Definition des Zustandsraums und des Anfangszustands
- Graphische Angabe der abstrakten Syntax und der Navigationen
- Pro Konzept eine Zustandsübergangsregel

Zustandsraum

Umgebung und Speicher

- Umgebungen binden Variablenbezeichner an Adressen:

```

spec ENV extends PROG
sorts ENV, LOC, IDLIST
operations
  mkenv : ENV → ENV erzeugt leere Umgebung
  newbind : ENV × ID × LOC → ?ENV neue Zuordnung
  isUsed : ENV × LOC → BOOL wahr gdw. Adresse gebunden
  isBound : ENV × ID → BOOL prüft Bindung
  bind : ENV × ID → ?LOC ermittelt Bindung
  delbind : ENV × ID → ENV beseitigt Bindung
  (++) : ENV × ENV → ENV Anhängen zweier Umgebungen
  (\) : ENV × IDLIST → ENV
  
```

axioms

$$D(\text{newbind}(e, x, l)) \Leftrightarrow \text{isUsed}(e, l) \doteq \text{false}$$

$$D(\text{bind}(e, x)) \Leftrightarrow \text{isBound}(e, x) \doteq \text{true}$$

$$\text{bind}(\text{newbind}(e, x, l), x) \doteq l$$

$$\neg x \doteq y \Rightarrow \text{bind}(\text{newbind}(e, y, l), x) \doteq \text{bind}(e, x)$$

$$\text{delbind}(\text{mkenv}, x) \doteq \text{mkenv}$$

$$\text{delbind}(\text{newbind}(e, x, l), x) \doteq e$$

$$\neg x \doteq y \Rightarrow \text{delbind}(\text{newbind}(e, y, l), x) \doteq \text{delbind}(e, x)$$

Übrige Axiome sind zur Übung überlassen

- $\text{ENV} \models \forall x, y : \text{ID} \ \forall e : \text{ENV} \bullet$
 $D(\text{bind}(e, x)) \wedge D(\text{bind}(e, y)) \wedge \text{bind}(e, x) \doteq \text{bind}(e, y) \Rightarrow x \doteq y$
- Speicher binden Werte an Adressen: $\text{mem} : \text{LOC} \rightarrow ?\text{VALUE}$
- $e \setminus i$ beseitigt die Bindungen der Bezeichner in Liste i aus e_1

Ausdrucksauswertung

Problem

Definition mit *eval* ist wegen Funktionsaufrufen nicht erweiterbar

- Jeder Operator ist auszuwertender Befehl
- Ausdruckswert wird Knoten zugeordnet
- Direkte dynamische Funktion $\text{val} : \text{OCC} \rightarrow ?\text{VALUE}$
- Zugriffspfade bestimmen zusätzlich den Ort des Objekts, auf das sie verweisen: dynamische Funktion $\text{loc} : \text{OCC} \rightarrow ?\text{LOC}$


Beobachtungen

- Ausdrücke benötigen die Werte ihrer Operanden
- Schleifen und Verzweigungen benötigen den Wert ihrer Bedingung
- Die Schreibanweisung benötigt den Wert ihres Argument
- Einführung von Datenflusskanten analog der Steuerflusskanten:

$\text{lop} :$	$\text{PROG} \times \text{OCC}$	$\rightarrow ?\text{OCC}$	linker Operand eines Ausdrucks
$\text{rop} :$	$\text{PROG} \times \text{OCC}$	$\rightarrow ?\text{OCC}$	rechter Operand eines Ausdrucks
$\text{opd} :$	$\text{PROG} \times \text{OCC}$	$\rightarrow ?\text{OCC}$	Operand eines unären Ausdrucks
$\text{cond} :$	$\text{PROG} \times \text{OCC}$	$\rightarrow ?\text{OCC}$	Bedingung einer Schleife oder Verzweigung
$\text{arg} :$	$\text{PROG} \times \text{OCC}$	$\rightarrow ?\text{OCC}$	Auszudruckender Ausdruck

Use-Def-Beziehungen

- Notation durch gestrichelte Pfeile:
- Eine Datenflusskante auf einen kompletten Unterbaum hat als Ziel dessen Wurzel
- Die Quelle einer Datenflusskante ist immer ein AST-Knoten



Zustandsraum und Anfangszustand

Zustand

Ein Zustand besteht aus einer Umgebung, einem Speicher, einem Eingabe- und Ausgabestrom, dem Programm sowie einem Befehlszeiger:

```

spec STATE extends ENV
operations
  env : ENV → ENV
  mem : LOC → ?VALUE
  inp : → LISTOFVAL
  out : → LISTOFVAL
  prog : → PROG
  pc : → OCC
  
```

Anfangszustand

Am Anfang ist der Speicher leer, der Ausgabestrom leer, die Umgebung leer und der Befehlszeiger verweist auf die erste auszuführende Anweisung

```

spec INITSTATE extends STATE
axioms
  ¬D(mem(x))
  out = []
  env = mkenv
  pc = first(prog)
  
```

- Bezug auf Attribute des attribuierten Strukturbaums
- Die globalen Variablen des Hauptprogramms sind bereits zur Übersetzungszeit an Objekte gebunden
- Statische Funktion $\text{globenv} : \text{PROG} \rightarrow \text{ENV}$

Ausdrucksauswertereihenfolgen

Problem

Spezifikation der implementierungsabhängigen Reihenfolge

- Aus Sicht der Sprachsemantik sind alle Reihenfolgen zulässig, nur die linken Operanden von AND bzw. OR müssen vor den rechten ausgewertet werden
- Nur der Datenfluss muss eingehalten werden

Beobachtung

Eine Programmiersprache definiert eine Halbordnung, welche Operatoren vor anderen Operatoren berechnet werden müssen.

- Jede topologische Sortierung dieser Halbordnung ist eine gültige Reihenfolge
- Bei strenger Links-Rechts-Auswertereihenfolge (wie z.B. in Java oder C#) ist die Halbordnung sogar eine Totalordnung.

Ausdrucksauswertereihenfolgen

Formalisierung

- Wenn ein Ausdruck ausgewertet werden soll, wird irgendein Knoten k gewählt, der minimal bzgl. der Halbordnung ist.
 - Nichtdeterministische Auswahl einer topologischen Sortierung, die k als erstes Element enthält
 - Abarbeitung dieser topologischen Sortierung
- ⇒ Weitere Form von Zustandsübergangsregeln erforderlich: **choose** $x : S \bullet \varphi$ **from** U Jede Menge $U \triangleq U[t/x]$ von Aktualisierungen mit $\mathfrak{A} \models \varphi[t/x]$ ist eine Aktualisierungsmenge im Zustand \mathfrak{A}

ASM-Zustandsübergangsregel


- Dynamische Funktion $toBeEval : \rightarrow LISTOFOCC$
 - Falls ein Ausdruck das erste Mal betreten wird, wird nichtdeterministisch eine topologische Sortierung gewählt:
- if** $next(pc, prog)$ **is** EXPR **then**
choose $o : OCC \bullet isMin(o, next(pc, prog))$ **from** $pc := o$
choose $l : LISTOFOCC \bullet isTopOrder(l, next(pc, prog))$ **from** $toBeEval := l$

Bemerkung

Wir betrachten hier der Einfachheit halber eine Links-Rechts-Auswertereihenfolge

Konstanten

Der Wert einer Konstanten entspricht dem im Programm bezeichneten Wert




Untersorten: $INTCONST \sqsubseteq CONST$, $FLTCONST \sqsubseteq CONST$, $BOOLCONST \sqsubseteq CONST$

Statische Funktion: $const : OCC \times PROG \rightarrow ?VALUE$ zur Bestimmung der Konstanten

Zugriffspfade

- Falls ein Zugriffspfad aus einem Bezeichner id besteht, muss dieses Objekt im Kontext durch eine Variablendeklaration vereinbart sein. In diesem Fall verweist der Zugriffspfad auf dieses Objekt.
- Der Wert eines Zugriffspfad des ist der Inhalt des Objekts, auf das des verweist.




Statische Funktionen:

- $id : OCC \times PROG \rightarrow ?ID$ zur Bestimmung des Bezeichners eines Zugriffspfads
- $pri, post : PROG \times OCC \rightarrow ?TYPE$ ist der Typ des Ausdrucks bzw. der vom Kontext erwartete Typ
- $coerce : VALUE \times TYPE \times TYPE \rightarrow ?VALUE$ konvertiert einen Wert des ersten Typs in einen äquivalenten Wert des zweiten Typs

Binärer Operationen

Binäre Ausdrücke (ohne Divisionsoperatoren)


- Die Werte binärer Ausdrücke verknüpfen die beiden Werte mit dem Operator des Ausdrucks
- Ganze Zahlen werden – falls erforderlich – automatisch in Gleitkommazahlen konvertiert werden.



Multiplikation und Subtraktion werden analog behandelt.

Division

- Die Werte binärer Ausdrücke verknüpfen die beiden Werte mit dem Operator des Ausdrucks
- Hat der rechte Operand von / oder % den Wert 0, dann bricht das Programm mit der Ausnahme $DivByZero$ Exception ab.



- $handle : EXCEPTION \rightarrow OCC$ spezifiziert die Anweisung, mit der bei Ausnahme fortgefahren werden muss
- Division wird analog behandelt.

Unäre Ausdrücke

Der Wert eines unärer Ausdrucks wendet den Operator auf den Wert des Operanden an.



if CT is NOT then

$val(pc) := not(Opd)$

Proceed

$Opd \triangleq val(opd(pc, prog))$

Unäres Minus und Plus wird analog behandelt unter Berücksichtigung von Anpassungen

Anweisungen: Zuweisung

- Der Zugriffspfad wird zu einem Verweis auf ein Objekt ausgewertet und der Ausdruck wird ausgewertet. Der Wert des Ausdrucks wird in das durch den Zugriffspfad verwiesene Objekt geschrieben.
- Danach wird mit der nächsten Anweisung fortgefahren.

STAT ::= ...|ASSIGN|...



if CT is ASSIGN \wedge isAtomic(Pri(lhs)) then
 $mem(loc(lhs)) := val(rhs)$
 Proceed

- Das geht nur für atomare Werte

⇒ Statische Funktion $isAtomic : TYPE \rightarrow BOOL$

- $isAtomic(x) \doteq true$ für die Typen $x = INT, BOOL$ und $FLOAT$

Anweisungsfolgen

Leere Anweisungsfolge

Eine leere Anweisungsfolge hat keinen Effekt.

Stats ::= NoStats


if CT is NOSTATS then Proceed



Nichtleere Anweisungsfolge

Die Ausführung eines Blocks führt alle seine Anweisungen nacheinander aus.

Keine Zustandsübergangsregel erforderlich, da das Fortschalten des Befehlszeigers bei den einzelnen Anweisungen erfolgt



Anweisungen: Lesen und Schreiben

Leseanweisung

- Die Lese-Anweisung bestimmt das Objekt, auf das der Zugriffspfad verweist und schreibt dort den aktuellen Wert des Eingabestroms. Die aktuelle Position des Eingabestroms auf den nächsten Wert fortgeschaltet.
- Danach wird mit der nächsten Anweisung fortgefahren.

STAT ::= ...|READ|...

if CT is READ then

$mem(loc(dest)) := head(inp)$

$inp := tail(inp)$

Proceed



Der Zugriffspfad darf kein Verbund- oder Klassentyp haben.

Schreibe-anweisung

- Die Schreibe-Anweisung wertet den Ausdruck aus und schreibt dessen Wert an das Ende des Ausgabestroms.
- Danach wird mit der nächsten Anweisung fortgefahren.

STAT ::= ...|WRITE|...

if CT is WRITE then

$out := out.val(Arg)$

Proceed




$Arg \triangleq arg(pc, prog)$

Anweisungen: Verzweigungen und Schleifen

Verzweigung


Der Ausdruck wird ausgewertet. Ist das Ergebnis *true* so wird die erste Anweisung ausgeführt. Danach wird die Anweisung nach der Verzweigung ausgeführt. Ist das Ergebnis *false* und keine *else*-Anweisung vorhanden, dann wird die Anweisung nach der Verzweigung ausgeführt. Ansonsten wird zuerst die *else*-Anweisung und dann die Anweisung nach der Verzweigung ausgeführt.



if *CT* is IF then
 if $val(cond) \doteq true$ then
 $pc := yes(pc, prog)$
 else $pc := no(pc, prog)$

Schleifen

Der Ausdruck wird ausgewertet. Ist das Ergebnis *true* so wird die Anweisung ausgeführt. Danach wird wieder die Schleife ausgeführt. Ist das Ergebnis *false*, dann wird die Anweisung nach der Schleife ausgeführt.



if *CT* is WHILE then
 if $val(cond) \doteq true$ then
 $pc := yes(pc, prog)$
 else $pc := no(pc, prog)$


Wolf Zimmermann

123

Blockanweisung

Die Ausführung eines Blocks führt alle seine Anweisungen nacheinander aus. Danach wird die Anweisung nach dem Block ausgeführt.

STAT ::= ...|BLOCK|...



Beobachtungen

- Den lokalen Variablen des Blocks müssen bei Betreten **unterschiedliche** Objekte zugeordnet werden und diese Zuordnung bei Verlassen wieder aufgehoben werden.
- ⇒ Der Blockknoten wird zwei Mal betreten
- ⇒ Zwei Zustandsübergangsregeln
- ⇒ Dynamische Funktion $entered : OCC \rightarrow ?BOOL$

Zustandsübergangsregeln

if *CT* is BLOCK $\wedge entered(pc) \doteq false$ then
 $AllocateVars(locVars(prog, pc))$
 $entered(pc) := true$
 $pc := first(prog, pc)$

if *CT* is BLOCK $\wedge entered(pc) \doteq true$ then
 $DeAllocateVars(locVars(prog, pc))$
 $entered(pc) := false$
 Proceed

wobei $locVars : PROG \times OCC \rightarrow ?IDLIST$ die Liste der lokalen Variablen eines Blocks ergibt.

Wolf Zimmermann

125


Anweisungen: Schleifenabbruch- und Fortsetzung

Grundprinzip

- Jede Schleife kennt über *no* die Anweisung nach der Schleife und den ersten Befehl der Schleifenbedingung
 - Diese werden über $break : PROG \times OCC \rightarrow ?$ bzw. $continue : PROG \times OCC \rightarrow ?$ auf die Anweisungen des Schleifenrumpfs fortgeschrieben
- ⇒ Teil der statischen Semantik


Break-Anweisung

Bei Ausführen einer *break*-Anweisung wird die Schleife abgebrochen und danach die Anweisung nach der Schleife ausgeführt



Continue-Anweisung

Bei Ausführen einer *continue*-Anweisung wird die Schleife abgebrochen und danach und danach die Schleifenanweisung ausgeführt.



Wolf Zimmermann

124

Allokation und Deallokation von Objekten

Allokation

Idee: Bestimmung einer Umgebung der lokalen Variablen mit Bindungen an paarweise unterschiedliche Objekte, die alle verschieden von den bisher gebundenen Objekten sind.

Eigenschaften: $Good(e, ids) \triangleq$

$\forall x : ID \bullet isBound(e, x) \doteq true \Leftrightarrow isElem(x, ids) \doteq true \wedge$

$\forall x, y : ID \bullet D(bind(e, x)) \wedge D(bind(e, y)) \wedge bind(e, x) \doteq bind(e, y) \Rightarrow x \doteq y \wedge$

$\forall x : ID \bullet isBound(e, x) \doteq true \Rightarrow IsUsed(bind(e, x)) \doteq false$

wobei das Makro $IsUsed(l)$ angibt, ob ein Verweis l schon benutzt wurde (wird später definiert).

Makro: $AllocateVars(ids) \triangleq$ choose $e : ENV \bullet Good(e, ids)$ do
 $env := e++env$

Deallokation

Bindungen werden wieder bei Verlassen des Blocks zerstört:

$DeAllocateVars(ids) \triangleq env := env \setminus ids$


Wolf Zimmermann

126

- Der Zustandsraum ist nun:
spec STATE **extends** ENV
sorts EXCEPTION
operations *env* : → ENV
mem : LOC →?VALUE
inp : → LISTOFVAL
out : → LISTOFVAL
prog : → PROG
pc : → OCC
exc : → EXCEPTION
val : OCC →?VALUE
loc : OCC →?LOC
entered : OCC →?BOOL
- Makro *IsUsed*, das angibt, ob ein Verweis *l* schon benutzt wurde, muss noch definiert werden.
- ☞ Es muss aber auf jeden Fall gelten:
 $isUsed(l) \doteq true \Rightarrow IsUsed(env, l) \doteq true$

Verbundfeld- und Klassenfeldzugriffe

- Falls *des* Verbundtyp ist, bezeichnet der Zugriffspfad das durch *id* definierte Teilobjekt
- Falls *des* Klassentyp ist, muss der Wert von *des* ≠ NULL sein, ansonsten bricht das Programm mit einer *NullPointerException* ab.
- Wenn der Wert von *des* ≠ NULL ist, wird zunächst das durch den Zeiger verwiesene Objekt ermittelt (**Dereferenzieren**). Der Klassenfeldzugriff verweist dann auf das durch *id* definierte Teilobjekt.



```

if CT is FIELD then
  if isClass(Pri(pc)) then
    if loc(pc) = null then
      exc := nullPointerDeref
      pc := handle(nullPointerDeref, pc)
    else
      loc(pc) := FldLoc(ClassLoc)
      Coerce(val(pc), mem(FldLoc(ClassLoc)), pc)
      Proceed
    else
      loc(pc) := FldLoc(StrctLoc)
      Coerce(val(pc), mem(FldLoc(StrctLoc)), pc)
      Proceed
  
```

```

StrctLoc  ≙ loc(strct(prog, pc))
ClassLoc ≙ mem(StrctLoc)
FldLoc(l) ≙ floc(l, field(prog, pc))
  
```

Verbundobjekte

- Werte sind Tupel. Der Zugriff auf die Komponenten erfolgt über die Namen der Felder
- ⇒ Unter jedem der Namen ist ein Wert gespeichert
- ⇒ Für jeden der Namen ist ein Verweis auf ein Objekt zugeordnet
- ⇒ Zugriff auf Verbundfelder ergeben den dem Namen zugeordneten Verweis
- ⇒ Verbunde sind ebenfalls Umgebungen
- Aber bei Zuweisung müssen explizit die einzelnen Verbundfelder kopiert werden

Klassen

- Klassen sind Zeiger auf Verbunde
- ⇒ Es werden Verweise auf Verbunde gespeichert
- Bei Zugriff auf eine Komponente muss erst diesem Verweis gefolgt werden.

Zustandsraum

```

spec ENV1 extends ENV
subsorts LOC ⊆ VALUE
operations floc : LOC × ID → LOC
              null : → LOC
spec STATE1 extends STATE, ENV1
spec INITSTATE1 extends STATE1, INITSTATE
  
```

Zuweisung

Wird an ein Verbundobjekt zugewiesen, dann werden die Werte der Verbundfelder in das Teilobjekt, auf das entsprechende Verbundfeld verweist, geschrieben. Wird an ein Verbundzeigerobjekt zugewiesen wird der Zeiger in das Objekt, auf das die linke Seite verweist, geschrieben.

⇒ Nur für Verbundtypen *A* gilt $isAtomic(A) \doteq false$

```

STAT ::= ...|ASSIGN|...
if CT is ASSIGN ∧ isAtomic(Pri(lhs)) = false then
  StructCopy(lhs, rhs)
  Proceed
  
```



```

StructCopy(dest, src) ≙ forall x : ID • isField(Pri(dest), x) do
  if isAtomic(gettype(fields(Pri(dest), x))) then
    mem(FldLoc(loc(dest))) := mem(FldLoc(loc(src)))
  else StructCopy(FldLoc(loc(dest)), FldLoc(loc(src)))
  
```

Bemerkung

StructCopy ist definiert, da jedes Verbundobjekt endlich ist.

forall und choose

Definition 2.16 (forall-Aktualisierungen)

Sei Σ eine Signatur und $\mathcal{A} \triangleq \langle \Sigma, \mathbb{A}, \mathbb{I}, R \rangle$ eine ASM, wobei in einer Regel **if** φ **then** U auch Aktualisierungen der Form **FORALL** \triangleq **forall** $x : A \bullet \psi$ **do** U' und **CHOOSE** \triangleq **choose** $x : A \bullet \chi$ **do** U'' vorkommen dürfen.

- Durch **forall** wird eine Aktualisierungsmenge $Update_{\mathfrak{A}}(\text{FORALL}) \triangleq \{u[t/x] : t \in \mathcal{T}_A(\Sigma) \wedge u \in U' \wedge \mathfrak{A} \models \psi[t/x]\}$. Die **forall**-Aktualisierungsmenge ist **beschränkt** gdw. $|\{(\llbracket t_1 \rrbracket_{\mathfrak{A}}, \llbracket t_2 \rrbracket_{\mathfrak{A}}) : t_1 := t_2 \in Update_{\mathfrak{A}}(\text{FORALL})\}| < \infty$ ist.
- Jede Aktualisierungsmenge $\{u[x/t] : u \in U''\}$ für ein $t \in \mathcal{T}_A(\Sigma)$ mit $\mathfrak{A} \models \chi[t/x]$ ist eine **CHOOSE-Aktualisierungsmenge**.
- Sei $U = U_1 \uplus U_2 \uplus U_3$ wobei U_1 eine Menge von Aktualisierungen der Form $t_1 := t_2$, U_2 eine Menge von **forall**-Aktualisierungen und U_3 eine Menge von **choose**-Aktualisierungen ist. Weiter sei $\mathfrak{A} \in \mathbb{A}$ ein Zustand. Eine Menge $\bar{U} \triangleq U_1 \cup \bigcup_{f \in U_2} Update_{\mathfrak{A}}(f) \cup \bigcup_{c \in U_3} \{u : u \text{ ist } c\text{-Aktualisierung}\}$ heißt durch \mathfrak{A} und U definierte Aktualisierungsmenge.
- Sei $\mathbb{U} \triangleq \{\bar{U} : \exists \text{if } \varphi \text{ then } U \in R \bullet \mathfrak{A} \models \varphi \wedge \bar{U} \text{ ist durch } \mathfrak{A} \text{ und } U \text{ definierte Aktualisierungsmenge}\}$ eine Menge von Aktualisierungsmengen. Eine Menge $Update_{\mathcal{A}}(\mathfrak{A}) = \bigcup_{\bar{U} \in \mathbb{U}} \bar{U}$ heißt **Aktualisierungsmenge** im Zustand \mathfrak{A} . Ein Zustand \mathfrak{A}' heißt **Nachfolgezustand** von \mathfrak{A} gdw. $\mathfrak{A}' = next_U(\mathfrak{A})$ für eine Aktualisierungsmenge U im Zustand \mathfrak{A} .

2.4.5 Prozeduren und Funktionen

Beobachtung

- Prozeduraufruf sichert Zustand (Bindungen, Ausdruckswerte) und legt neue Objekte an
 - Dabei werden Parameter übergeben
 - Nach Rückkehr aus der Prozedur wird der alte Zustand wieder hergestellt
 - Dabei werden Funktionsresultate übergeben
- ⇒ Klassisches Verhalten eines Kellers (engl. *stack*)

Laufzeitkeller

spec ENV₂ extends ENV₁

sorts FRAME, FRAMESTACK, EXPRVALS

operations <i>mkframe</i> :	ENV × OCC × EXPRVALS	→ FRAME
<i>mkstack</i> :		→ FRAMESTACK
<i>push</i> :	FRAMESTACK × FRAME	→ FRAMESTACK
<i>pop</i> :	FRAMESTACK	→ ?FRAMESTACK
<i>getenv</i> :	FRAMESTACK	→ ?ENV
<i>getpc</i> :	FRAMESTACK	→ ?OCC
<i>getval</i> :	FRAMESTACK	→ ?EXPRVALS
<i>novals</i> :		→ EXPRVALS
<i>addval</i> :	OCC × VALUE × EXPRVALS	→ EXPRVALS
<i>findval</i> :	OCC × EXPRVALS	→ ?VALUE


- mkframe* verwaltet den Zustand
- Mit *getenv*, *getpc* und *getval* ist die Wiederherstellung des Zustands möglich

Erzeugen von Objekten

Eine **new**-Operation erzeugt ein Objekt der Klasse und liefert einen Verweis auf dieses Objekt.

⇒ Dieser Verweis darf nicht benutzt worden sein

EXPR ::= ... | NEW | ...



if CT **is** **NEW** **then**
choose $l : LOC \bullet isUsed(l) \doteq false$ **do**
 $loc(pc) := l$
Proceed

Benutzte Verweise

- Verweise auf Verbundfelder werden immer benutzt
- ⇒ $isUsed(e, floc(l, x)) \doteq false$

Erweiterung des Zustandsraums und des Anfangszustands

Erweiterung des Zustandsraums

Für die Verwaltung der Prozeduraufrufe muss noch zusätzlich gegenüber C0 ein Prozedurkeller eingeführt werden.

spec STATE₂ extends STATE₁, ENV₂

operations *procstack* :→ FRAMESTACK

Anfangszustand

Zusätzlich zu den Bedingungen in C0 muss noch der Prozedurkeller leer sein:

spec INITSTATE₁ extends STATE₁, INITSTATE


axioms *procstack* \doteq *mkstack*

Anlegen der Parameter und Parameterübergabe

Vorgehen

- Anlegen der Objekte für die Parameter
- ⇒ Parameter können übergeben werden
- Vorbereiten für andere Übergabemodi
- ⇒ Statische Funktion $mode : OCC \rightarrow ?MODE$

Auswerten der Argumente



Parameterübergabe

$PASS(ids) \triangleq$

```

choose e : ENV • Good(e, ids) do
  env := e
  forall i : INT • 0 ≤ i < length(ids) do
    if isAtomic(Post(Arg(i))) ≐ true then
      mem(bind(e, x)) := val(Arg(i))
    else StructCopy(bind(e, x), Arg(i))
  
```

$Arg(i) \triangleq arg(prog, pc, i)$


Zustandssicherung

Was ist zu tun?

- Sichern des Befehlszeigers
- Sichern der Bindungen lokaler Variable an Objekte
- Bei Funktionen müssen noch Zwischenergebnisse des Ausdrucks der gerade berechnet wird, gesichert werden.
 - Statische Funktion $exproccs : PROG \times OCC \rightarrow OCCLIST$; $exproccs(p, o)$ ist die eine Liste der Navigationslisten, die zum selben Ausdruck wie o gehören. Die Liste ist leer, falls $\neg occ(p, o)$ is EXPR.
 - Sorte SAVELIST mit Funktionen
 - $mksavelist : \rightarrow SAVELIST$
 - $save : OCC \times VALUE \times SAVELIST \rightarrow SAVELIST$
 - $findval : OCC \times SAVELIST \rightarrow VALUE$
 - Abgeleitete dynamische Funktion $save : OCCLIST \rightarrow ?SAVELIST$:
 - $save(nil) \doteq mksavelist$
 - $save(cons(o, occs)) \doteq save(o, val(o), save(occs))$

Prozeduraufruf

- Mit dem Prozedur-/Funktionsaufruf werden den Parametern Objekte zugeordnet.
- Bei einem Prozedur- oder Funktionsaufruf werden die Argumente ausgewertet und an die Parameter positional übergeben, d.h. der Wert eines Arguments wird in das Objekt geschrieben, auf das der Parameter verweist. Danach wird der Prozedurrumpf ausgeführt.




$Frame \triangleq mkframe(env, pc, save(exproccs(pc)))$

$CurProc \triangleq identifyDef(deftab(prog, pc), occ(prog, pc.0))$

- $deftab$ ist eine Definitionstabelle, $identifyDef$ identifiziert eine Deklaration
- Eine Prozedurdefinition speichert u.A. die Parameter(namen) und den Rumpf

Prozedurrückkehr

- Ein Prozedur- oder Funktionsaufruf **kehrt zurück**, wenn die letzte Anweisung des Prozedurrumpfs oder eine return-Anweisung ausgeführt wurde.
- Nach Rückkehr von einem Prozeduraufruf wird die Anweisung nach dem Aufruf ausgeführt.
- Nach Rückkehr von einem Funktionsaufruf wird mit der Ausführung der Anweisung, in der der Aufruf vorkam, fortgefahren. Der Wert eines Funktionsaufrufs ist der Wert des Ausdrucks der ausgeführten return-Anweisung.



$OldPc \triangleq getpc(procstack)$

$OldEnv \triangleq getenv(procstack)$

$OldVals \triangleq getval(procstack)$

$Arg \triangleq arg(prog, pc)$

Statische Funktion $rettype : PROCDEF \rightarrow TYPE$ ergibt Rückgabtyp der Funktion

- Der Zustandsraum ist nun:

```
spec STATE extends ENV1
sorts EXCEPTION
operations
  env :      → ENV
  mem : LOC  → ?VALUE
  inp :      → LISTOFVAL
  out :      → LISTOFVAL
  prog :     → PROG
  pc :       → OCC
  exc :      → EXCEPTION
  val : OCC  → ?VALUE
  loc : OCC  → ?LOC
  entered :  OCC → ?BOOL
  procstack : → ?FRAMESTACK
```

- Makro *IsUsed*, das angibt, ob ein Verweis *l* schon benutzt wurde, muss noch definiert werden.
 - Auch Verweise im Prozedurkeller werden benutzt: Funktion $isUsed : FRAMESTACK \times LOC \rightarrow BOOL$
- $\Rightarrow isUsed(l) \triangleq isUsed(env, l) \dot{=} true \vee isUsed(procstack, l) \dot{=} true$

Übung: Einführen von Reihungen

```
arrtype ::= type [ ]
arracc  ::= des [ expr [] ]
arrcreate ::= new type [ expr [] ]
```

- Reihungen ordnen Indices Werten zu
- Reihungszugriffe sind Zugriffspfade
- Der Typ eines Reihungszugriffs ist der Elementtyp der Reihung
- Der Typ des Indexausdrucks muss *int* sein.
- Der Typ einer Reihungserzeugung ist der Elementtyp.
- Der Typ des Ausdrucks einer Reihungserzeugung muss *int* sein.
- Ein Reihungszugriff werden den Indexausdruck zu einer Zahl *n* aus. Ist $n < 0$ oder *n* größer gleich des Reihungsumfangs, so wird die Ausnahme `IndexOutOfBoundsException` ausgelöst. Ansonsten bezeichnet der Reihungszugriff das *n* + 1-te Element der Reihung bzw. dessen Wert
- Eine Reihungserzeugung wertet den Ausdruck zu einer Zahl *n* aus. Ist $n \leq 0$ so wird die Ausnahme `IndexOutOfBoundsException` ausgelöst. Ansonsten wird eine Reihung mit *n* Elementen erzeugt. Das Ergebnis ist ein Verweis auf die erzeugte Reihung

- Erweitern Sie die Semantik um Ausnahmebehandlung:
 $exception ::= try\ block$
 $(when\ excp\ stat)^+$
 $[otherwise\ stat]$

Wird in *block* eine Ausnahme ausgelöst, die in einem der *when*-Fälle aufgeführt ist, dann wird die entsprechend Anweisung ausgeführt. Danach wird die Anweisung nach dem Block ausgeführt. Mit *otherwise* werden alle nicht-aufgeführt Ausnahmen behandelt. Ein Prozedur- oder Funktionsaufruf endet mit einer Ausnahme, wenn sie im Rumpf nicht behandelt wird.

- Einführung von Benutzerdefinierten Ausnahmen:
 $exceptdecl ::= exception\ id$
 $raise ::= raise\ id$
 - Die Ausnahmen müssen global deklariert werden. Die Bezeichner in allen Deklarationen müssen paarweise verschieden sein.
 - Mit der *raise*-Anweisung wird explizit eine Ausnahme ausgelöst. Die ausgelöste Ausnahme muss deklariert sein.
- Einführung von Referenzaufruf (Modus *ref*) und Wert-/Ergebnisaufruf (Modus *inout*)

Kapitel 3

Korrektheit der Speicherabbildung

Wolf Zimmermann

Verifikation von Übersetzern

Ziele

- Kennenlernen der allgemeinen Vorgehensweise bei Transformation des Zustandsraums
 - Korrektheitsnachweis der Speicherabbildung
 - Bewusstsein für das Zusammenwirken mit der statischen Semantik
- 1 Transformation des Zustandsraums
 - 2 Verifikation der Speicherabbildung

Kapitel 4

Korrektheit der Zwischencodeerzeugung

Wolf Zimmermann

Verifikation von Übersetzern

Ziele

- Funktionsweise von Simulationsbeweisen
 - Verifikation von Transformationsregeln
 - Konzept der Übersetzungsvalidierung
- 1 Simulationsbeweise
 - 2 Verifikation der Zwischencodeerzeugung
 - 3 Übersetzungsvalidierung
 - 4 Ausblick: Optimierungen

Kapitel 5

Korrektheit der Codeerzeugung und der Assemblierung

Wolf Zimmermann

Verifikation von Übersetzern

Ziele

- Kennenlernen der termersetzungs-basierten Codeerzeugung
 - Verifikation der Codeerzeugung
 - Bewusstsein für die Problematik des Zusammenwirkens von Registerzuteilung und Codeerzeugung
 - Verifikation der Assemblierung
-
- 1 Codeerzeugung durch Termersetzung
 - 2 Verifikation von termersetzungs-basierter Codeerzeugung
 - 3 Überprüfung der Korrektheit der Codeerzeugung
 - 4 Verifikation der Assemblierung