

Hilfreiche Definitionen

1 Einführung

Dieses Dokument beinhaltet einige formale Definitionen und Spezifikationen für den Stoff der Vorlesung, für die Punkte, an denen die Operationen durch Bilder o.ä. definiert wurden. Diese sind nicht zwangsweise die einzige mögliche formalisierung des Stoffs. In der Klausur ist es nur wichtig, dass Sie formal korrekt argumentieren, Sie müssen nicht unbedingt diese formalen Definitionen benutzen. Dieses Dokument hat nicht das Ziel, diese Definitionen zu erklären; dazu dient die Vorlesung.

2 Union-Find

Gegeben eine Menge von Objekten X , ist der Zustand des Systems nach $t \in \mathbb{N}$ Operationen gegeben durch

- Menge von Mengen S

$$S_t \subseteq P(X)$$

- Parentfunktion

$$p_t : \bigcup S_t \rightarrow \bigcup S_t$$

- Rankfunktion

$$r_t : \bigcup S_t \rightarrow \mathbb{N}_0$$

Welches die folgenden Invarianten besitzt:

- Disjunktheit

$$R_1, R_2 \in S_t \wedge R_1 \cap R_2 \neq \emptyset \rightarrow R_1 = R_2$$

- Endliche Anzahl von Vorfahren bis man zu einem Zyklus der Größe 1 kommt

$$x \in \bigcup S_t \rightarrow \exists i. p_t^i(x) = p_t^{i+1}(x)$$

Die t -te operation sei

$$op_t$$

und der Ursprungszustand gegeben durch

$$(S_0, p_0, r_0) = (\emptyset, \emptyset, \emptyset)$$

Wir verwenden implizite t -Notation und primed notation. Mit anderen Worten, wir benutzen Abkürzungen

$$p(x) \text{ für } p_t(x)$$

und

$$p'(x) \text{ für } p_{t+1}(x)$$

und so weiter, vorausgesetzt es ist eindeutig um welches t es sich handelt.

Variablen x, y, z haben den Wertebereich X . Aufgrund von disjunktheit können wir für $x \in \bigcup S$ die eindeutige Menge $S(x)$ finden, in der x enthalten ist

$$S(x) = \epsilon \{ R \in S \mid x \in R \}$$

Die folgenden Operationen sind möglich.

Hilfreiche Definitionen

- $op = makeset(x)$ wenn $x \notin \bigcup S$.

Dann gilt

$$S' = S \cup \{ \{ x \} \}, \quad p'(x) = x, \quad r'(x) = 0$$

und alles andere ist unverändert. Die Klausel “alles andere ist unverändert” ist eine Abkürzung dafür, dass sich alle Komponenten der Konfigurationen vor Schritt t und nach Schritt $t + 1$ nur auf die oben genannte Art unterscheiden. In diesem Fall gilt also

$$a \neq x \quad \rightarrow \quad p'(a) = p(a)$$

sowie

$$a \neq x \quad \rightarrow \quad r'(a) = r(a)$$

- $op = find(x)$ wenn $x \in \bigcup S$.

Sei s die Anzahl von Eltern bis man einen Knoten erreicht, der sein eigenes Elter¹ ist

$$s = \min \{ s > 0 \mid p^s(x) = p^{s-1}(x) \}$$

Wir definieren eine null-basierte Sequenz (x_i) der Länge s durch

$$x_{s-1} = x, \quad x_{i-1} = p(x_i)$$

Dann gilt

$$p'(x_i) = x_0$$

und alles andere ist unverändert. Es gilt also *zum Beispiel*

$$(\nexists i. a = x_i) \quad \rightarrow \quad r'(a) = r(a)$$

Weiterhin gilt

$$find(x) = x_0$$

- $op = link(x, y)$ wenn $x \neq y, x, y \in \bigcup S, p(x) = x, p(y) = y$.

Dann gilt

$$S' = (S \setminus \{ S(x), S(y) \}) \cup \{ S(x) \cup S(y) \}$$

$$r(x) < r(y) \quad \rightarrow \quad p'(x) = y$$

$$r(x) = r(y) \quad \rightarrow \quad p'(x) = y \wedge r'(y) = r(y) + 1$$

$$r(x) > r(y) \quad \rightarrow \quad p'(y) = x$$

und alles andere ist unverändert. Es gelten also *zum Beispiel*

$$r(x) < r(y) \wedge a \neq x \quad \rightarrow \quad p'(a) = p(a)$$

und

$$r(x) < r(y) \quad \rightarrow \quad r'(a) = r(a)$$

und

$$r(x) = r(y) \wedge a \neq y \quad \rightarrow \quad r'(a) = r(a)$$

¹Ja, das Wort steht im Duden! <https://www.duden.de/rechtschreibung/Elter>

Hilfreiche Definitionen

3 Programmiersprache

Für unsere Zwecke reicht eine einfache Programmiersprache ohne Heap, mit nur einem Basistyp (`int`), und ohne Funktionsaufrufen/Seiteneffekten in Ausdrücken. Typdeklarationen und die dadurch definierten Typen sind sonst wie in der Vorlesung eingeführt. Dann führen wir für jeden so definierten Typen T noch einen Typen

$$V_T$$

ein, den wir für Variablen mit Typ T verwenden (diese haben zusätzlich zu einem right-value, den alle Ausdrücke vom Typ T haben, noch einen left-value). Wir überladen Typen und ihre Wertebereiche. Dann gilt

$$V_T = T^* \times T$$

3.1 Ausdrücke und Ihre Typen

Folgende Ausdrücke sind erlaubt und haben folgenden Typ:

- Ganzzahlige Operationen $\circ \in \{ <, =, !=, ||, \&\&, +, -, *, / \}$

$$e, \hat{e} \text{ sind vom Typ } \text{int} \quad \rightarrow \quad e \circ \hat{e} \text{ ist vom Typ } \text{int}$$

- Zahlen

$$x \in [0 : 9]^* \quad \rightarrow \quad x \text{ ist vom Typ } \text{int}$$

- Nullpointer

$$\text{null ist vom Typ } T^*$$

- Vergleiche $\circ \in \{ =, != \}$ auf Pointertypen

$$e, \hat{e} \text{ sind vom Typ } T^* \quad \rightarrow \quad e \circ \hat{e} \text{ ist vom Typ } \text{int}$$

- Feldzugriff

$$e \text{ ist vom Typ } V_{\{ \dots; t_i \ n_i; \dots \}} \quad \rightarrow \quad e.n_i \text{ ist vom Typ } V_{t_i}$$

- Arrayzugriff

$$e \text{ ist vom Typ } V_{T[n]} \wedge \hat{e} \text{ ist vom Typ } \text{int} \quad \rightarrow \quad e[\hat{e}] \text{ ist vom Typ } V_T$$

- Dereferenzierung

$$e \text{ ist vom Typ } T^* \quad \rightarrow \quad e^* \text{ ist vom Typ } V_T$$

- Variablen

$$x \text{ ist eine in der Funktion deklarierte Variable/Parameter mit Typ } T \quad \rightarrow \quad x \text{ ist vom Typ } V_T$$

- Right-Value für Pointer- und Basistypen $T = \text{int} \vee T = U^*$

$$e \text{ ist vom Typ } V_T \quad \rightarrow \quad e \text{ ist vom Typ } T$$

- Adresse (Left-Value)

$$e \text{ ist vom Typ } V_T \quad \rightarrow \quad \&e \text{ ist vom Typ } T^*$$

Hilfreiche Definitionen

3.2 Statements

Die Programmiersprache hat die folgenden Statements:

- Zuweisung

$$d = e$$

wobei es einen Typ T geben muss sodass d ein Ausdruck vom Typ V_T ist und e ein Ausdruck vom Typ T ist.

- Schleife mit Substatement S

$$\begin{array}{l} \text{while } e \\ S \end{array}$$

wobei e ein Ausdruck vom Typ `int` ist

- Konditional mit Substatement S

$$\begin{array}{l} \text{if } e \\ S \end{array}$$

wobei e ein Ausdruck vom Typ `int` ist

- Funktionsaufrufe

$$e = f(e_1, \dots, e_s)$$

Wobei f eine Funktion mit Signatur

$$T f(T_1, \dots, T_s)$$

ist und e ein Ausdruck vom Typ V_T ist, und e_i ein Ausdruck vom Typ T_i ist.

- Rücksprung

$$\text{return } e$$

in einer Funktion mit Rückgabotyp T wobei e den Typ T hat.

- Sequenz von $s \geq 1$ top-level Statements

$$\begin{array}{l} \{ \\ S_1 \\ \vdots \\ S_s \\ \} \end{array}$$

Hilfreiche Definitionen

3.3 Zustände und Auswertung

Ein Zustand des Programms ist ein Tupel c bestehend aus

- Programmzeiger

$$c.pc \in \mathbb{N}_0$$

der die aktuelle Zeile im Programmtext angibt.

- Stapel (stack)

$$c.st \in \bigcup_n ([0 : n - 1] \rightarrow S)$$

wobei S die Menge aller Schachteln (stack frames) ist, die selbst wiederum Tupel s mit folgenden Komponenten sind:

- Funktion

$$s.f \in FN$$

- Rücksprungadresse

$$s.ra \in \mathbb{N}_0$$

- Rückgabeadresse

$$s.rd \in T^*$$

wobei $s.f$ die folgende Signatur hat:

$$T \ s.f(\dots)$$

- Parameter+Variablenwerte

$$s.m : \bigcup (\{ n_i \} \rightarrow T_i)$$

wobei n_i der Name und T_i der Typ des/der i -ten deklarierten Parameter/Variablen ist

Wir definieren nun einige Wertebereiche von Typen. Die Idee ist dass wir als arrays 0-basierte listen nehmen, die nichts anderes als Funktionen sind, die jedem index den Wert des Arrays an diesem Index zuweisen. Für structs nehmen wir Tupel, deren Komponenten genau die Komponenten des Structs sind. Pointer sind stets relativ zu einem Objekt zu verstehen und zeigen auf ein Teilobjekt, also zB auf das 5te feld der Komponente x :

$$o.x[5]$$

Wir stellen diese als Sequenzen von array-indizes und feldnamen dar, im obigen beispiel

$$(x, 5)$$

Also haben Objekte von Pointertypen die Form

$$T^* = (\mathbb{N}_0 \cup FN)^* \cup \{ \text{null} \}$$

wobei FN die Menge aller möglichen Feldnamen von Structs ist. Die Objekte von Arraytypen $T[n]$ sind Funktionen die jedem Wert im Wertebereich $[0 : n - 1]$ ein Objekt des Typs T zuweisen

$$T[n] = [0 : n - 1] \rightarrow T$$

Hilfreiche Definitionen

Die Objekte von Structtypen

$$s \in \{ \dots; t_i \ n_i ; \dots \}$$

sind Tupel mit Komponenten n_i vom Typ t_i

$$s.n_i \in t_i$$

Deshalb ist jede Konfiguration c selbst ein Objekt eines Structs, mit insbesondere Komponente

$$c.st \in [0 : |c.st| - 1] \rightarrow S$$

die selbst ein Objekt eines Arraytyps ist.

Das Objekt auf den ein Pointer xs innerhalb eines Objekts o Zeigt ist dann rekursiv wie folgt definiert:

$$m(o, \epsilon) = \epsilon$$

$$m(o, x \circ cs) = \begin{cases} m(o(x), xs) & x \in \mathbb{N}_0 \\ m(o.x, xs) & x \in VN \end{cases}$$

Man folgt also von links nach rechts den Feldnamen oder Array indices, und bekommt in vorherigem beispiel

$$m(o, (\mathbf{x}, 5)) = m(o.\mathbf{x}, (5)) = m(o.\mathbf{x}(5), \epsilon) = o.\mathbf{x}(5)$$

Da jede Konfiguration selbst auch ein Objekt ist können wir insbesondere auch folgendes machen:

$$m(c, (\mathbf{st}, i, \mathbf{m}, x)) = c.st(i).\mathbf{m}.x$$

und dadurch den Wert der/des Variablen/Parameters x auf dem i -ten Stackframe abfragen.

In einem Zustand c sind der Left-Value und Right-Value des Ausdrucks e , denotiert durch

$$[e]'_c, [e]_c$$

rekursiv definiert:

$$[e \circ \hat{e}]_c = [e]_c \circ [\hat{e}]_c$$

(vorausgesetzt es liegt noch im Wertebereich), wobei für Wahrheitswerte 1 (wahr) bzw 0 (falsch) verwendet werden

$$[z]_c = bin(z)$$

(vorausgesetzt die Zahl z liegt noch im Wertebereich)

$$\begin{aligned} [\mathbf{null}]_c &= \mathbf{null} \\ [e.n]'_c &= [e]'_c \circ n \\ [e.n]_c &= e[c].n \\ [e[\hat{e}]]'_c &= [e]'_c \circ [\hat{e}]_c \\ [e[\hat{e}]]_c &= [e]_c([\hat{e}]_c) \end{aligned}$$

Hilfreiche Definitionen

(vorausgesetzt $[\hat{e}]_c$ ist im entsprechenden Wertebereich)

$$\begin{aligned} [e*]'_c &= [e]_c \\ [e*]_c &= m(c, [e]_c) \\ [x]'_c &= (\mathbf{st}, |c.\mathbf{st}| - 1, \mathbf{m}, x) \\ [x]_c &= m(c, [x]'_c) \\ [\&e]_c &= [e]'_c \end{aligned}$$

Wir definieren auch einen Default-wert für Variablen rekursiv. Beim Default-wert werden alle Integerfelder mit 0 und alle Pointerfelder mit `null` aufgefüllt

$$\begin{aligned} \mathit{default}(\mathbf{int}) &= 0 \\ \mathit{default}(T*) &= \mathbf{null} \\ \mathit{default}(\{ \dots; t_i \ n_i ; \dots \}) &= \mathit{default}(t_i) \\ \mathit{default}(T[n])(i) &= \mathit{default}(T) \end{aligned}$$

3.4 Ausführung

Die Programmausführung betrachtet nun das Programm als Sequenz (P_i) von Statements, wobei das Statement an Position i im Programmtext in Zeile i steht. Wir definieren von aussen nach innen einen Syntaktischen Nachfolger $N(i)$ jeder Zeile i .

- für eine in Zeile z stehende Sequenz von s top-level Statements S_1, \dots, S_s von denen S_i in Zeile s_i steht

$$\begin{array}{c|l} z & \{ \\ z_1 & S_1 \\ \vdots & \vdots \\ z_s & S_s \\ & \} \end{array}$$

Definieren wir als Nachfolger von Zeile z_i für $1 \leq i < s$

$$N(z_i) = z_{i+1}$$

und für z_s

$$N(z_s) = N(z)$$

- für ein Konditional in Zeile z mit Substatement in Zeile \hat{z}

$$\begin{array}{c|l} z & \mathbf{if} \ e \\ \hat{z} & S \end{array}$$

Definieren wir

$$N(\hat{z}) = N(z)$$

- für eine Schleife in Zeile z mit Substatement in Zeile \hat{z}

Hilfreiche Definitionen

$$\begin{array}{l|l} z & \text{while } e \\ \hat{z} & S \end{array}$$

Definieren wir

$$N(\hat{z}) = z$$

(also wird nach Ausführung des Schleifenkörpers nocheinmal die Schleife begonnen)

Sei nun c eine Konfiguration. Die nächste Konfiguration c' ist definiert durch Fallunterscheidung des Statements $P_{c.pc}$.

- Zuweisung

$$d = e$$

Dann gilt

$$\begin{aligned} c'.pc &= N(c.pc) \\ m(c', [d]_c) &= [e]_c \end{aligned}$$

Sonst alles unverändert

- Schleife oder Konditional mit Substatement S

$$\begin{array}{l|l} z & \text{while/if } e \\ z_s & S \end{array}$$

Es gilt

$$c'.pc = \begin{cases} z_s & [e]_c \neq 0 \\ N(z) & \text{sonst} \end{cases}$$

Sonst alles unverändert

- Funktionsaufrufe

$$e = f(e_1, \dots, e_s)$$

wobei f Parameter+Variablen n_i von Typ T_i hat. Wir setzen eine neue Schachtel auf, die zur Funktion f gehört, hinter das Aktuelle Statement zurückspringt, den Wert in die Variable e zurückschreibt, und Parametern+Variablen einen unten definierten Wert v gibt

$$c'.st(|c.st|) = (f, N(c.pc), [e]_c, v)$$

wobei v Parametern den Wert des Ausdrucks zuweist und Variablen den Default-wert. Sei also n_i Name und T_i Typ des/der i -ten Parameters/Variablen, dann gilt

$$v.n_i = \begin{cases} [e_i]_c & i \leq s \\ default(T_i) & \text{sonst} \end{cases}$$

Sei die Funktionsdeklaration mit Substatement S in Zeile z_s also wie folgt

Hilfreiche Definitionen

$$z_s \left| \begin{array}{l} T \ f(t_1 \ n_1, \dots, t_s \ n_s) \{ \\ \quad t_{s+1} \ n_{s+1} \\ \quad \vdots \\ \quad t_k \ n_k \\ S \end{array} \right.$$

dann Springt die Ausführung nun zu Zeile z_s

$$c'.pc = z_s$$

Ansonsten bleibt die Ausführung unverändert.

- Rücksprung

`return e`

Ist dies die letzte Schachtel auf dem Stapel, so wird die Programmausführung beendet und das Programm gibt den Wert e aus. Sonst wird der Rückgabewert der Wert von e zugewiesen

$$m(c', c.st(|c.st - 1|).rd) = [e]_c$$

die alte Schachtel wird verlassen

$$|c'.st| = |c.st| - 1$$

und es wird zur Rücksprungadresse zurückgesprungen

$$c'.pc = c.st(|c.st - 1|).ra$$

Sonst ändert sich nichts.

- Sequenz von $s \geq 1$ top-level Statements, von denen das erste in Zeile z_1 beginnt

$$z_1 \left| \begin{array}{l} \{ \\ \quad S_1 \\ \quad \vdots \\ \quad S_s \\ \} \end{array} \right.$$

Dann wird zu Zeile z_1 gesprungen

$$c'.pc = z_1$$

Achtung: in vielen Fällen ist obiges keine Definition; zB wenn es kein Statement $P_{c.pc}$ gibt. Dann ist die nächste Konfiguration undefiniert. Um zu Zeigen dass ihr Programm gewisse Eigenschaften hat, müssen Sie stets Zeigen, dass der nächste Zustand stets definiert ist, zumindest bis zum letzten `return` (wenn der Stapel leer ist).

Hilfreiche Definitionen

3.5 Bigstep Semantik

Angenommen Sie haben für eine Teilmenge F von Funktionen $f \in F$ in ihrem Programm eine Relation zwischen Stapeln

$$st \rightarrow_f st'$$

sowie eine Vorbedingung auf die Argumente

$$P_f(st, v_1, \dots, v_s)$$

und eine Funktion die den Rückgabewert angibt

$$f(st, v_1, \dots, v_s) = r$$

Dann können Sie die Semantik eines Funktionsaufrufs

$$e = f(e_1, \dots, e_s)$$

wie folgt ändern: Angenommen dass die Vorbedingung in der Konfiguration c mit dem Stack und den Werten der Argumente gilt

$$P_f(c.\mathbf{st}, [e_1]_c, \dots, [e_s]_c)$$

dann gibt es einen Stack st' der in Relation zu $c.\mathbf{st}$ steht

$$c.\mathbf{st} \rightarrow_f st'$$

und für die nächste Konfiguration c' gilt

$$\begin{aligned} c'.\mathbf{pc} &= N(c.\mathbf{pc}) \\ c'.\mathbf{st}(i).(\mathbf{rd}, \mathbf{ra}) &= st'(i).(\mathbf{rd}, \mathbf{ra}) \\ c'.\mathbf{st}(i).\mathbf{m}(x) &= \begin{cases} f(c.\mathbf{st}, [e_1]_c, \dots, [e_s]_c) & (\mathbf{st}, i, \mathbf{m}) \circ x = [e]_c' \\ st'(i).\mathbf{m}(x) & \text{sonst} \end{cases} \end{aligned}$$

vorrausgesetzt Sie können Zeigen, dass

- in der normalen (small-step) Semantik jede Funktion $f \in F$ Terminiert und
- in der Bigstep Semantik jede Funktion $f \in F$ vor dem Return-zustand einen Zustand erreicht, dessen Stack in relation zum Stack der Ursprünglichen funktion steht, und dessen Rückgabewert anhand der Vorschrift $f(\dots)$ berechnet wurde. Formal: Habe die Funktion f die Form

$$z_s \left| \begin{array}{l} T \ f(t_1 \ n_1, \dots, t_s \ n_s) \{ \\ \quad t_{s+1} \ n_{s+1} \\ \quad \vdots \\ \quad t_k \ n_k \\ S \end{array} \right.$$

Hilfreiche Definitionen

und sei $c = c^0$ eine beliebige Konfiguration mit Stapelhöhe $h = |c.st|$ die in Zeile z_s

$$c.pc = z_s$$

mit default initialiserten variablen beginnt

$$i > s \rightarrow [n_i]_c = default(t_i)$$

und ausserdem die Vorbedingung erfüllt

$$Q_f(c.st[0 : h - 2], [n_1]_c, \dots, [n_s]_c)$$

Sei nun c^t die Konfiguration nach t Schritten. Wenn gilt

$$P_{c^t.pc} = \text{return } e$$

und die Höhe des Stapels sich nicht verändert hat

$$|c^t.st| = |c.st|$$

und auch nie unter diese Höhe gesunken ist

$$\forall i < t. |c^i.st| \geq |c.st|$$

dann muss folgendes Gelten:

$$c.st[0 : h - 2] \rightarrow_f c^t.st[0 : h - 2]$$

und

$$[e]_{c^t} = f(c.st[0 : h - 2], [n_1]_c, \dots, [n_s]_c)$$

Das heisst, wenn Sie gezeigt haben dass die Funktionen $f \in F$ die Semantik haben die durch \rightarrow_f und $f(\dots)$ beschrieben wird, können Sie die Funktionsaufrufe von f ersetzen durch einen einzelnen Schritt, der diese Semantik anwendet.

Hilfreiche Definitionen

4 Listen

Für Mengen A ist A^n die Menge der Listen der Länge n , welche Funktionen

$$a[1 : n] : [1 : n] \rightarrow A$$

sind. Dabei wird die Länge auch denotiert durch

$$|a| = n$$

Konkatenation von Listen $a[1 : n]$ und $b[1 : m]$ gibt eine Liste

$$(a \circ b)[1 : n + m]$$

die definiert ist durch

$$(a \circ b)[x] = \begin{cases} a[x] & x \leq |a| \\ b[x - |a|] & \text{sonst} \end{cases}$$

Sublisten $a[i : j]$ sind entweder die leere Liste falls $j < i$

$$j < i \rightarrow a[i : j] = \epsilon$$

oder eine Liste der Länge $j - i + 1$

$$(a[i : j])[1 : j - i + 1]$$

die wie folgt definiert ist:

$$(a[i : j])[k] = a[k + i - 1]$$