

Verlässliche Echtzeitsysteme

Grundlagen der statischen Programmanalyse

Peter Ulbrich

Friedrich-Alexander-Universität Erlangen-Nürnberg
Lehrstuhl Informatik 4 (Verteilte Systeme und Betriebssysteme)
www4.informatik.uni-erlangen.de

05. Mai 2015

Übersicht der heutigen Vorlesung

- Wie verifiziert man die Eigenschaften (funktional/nicht-funktional) von Software stichhaltig?

- Dynamische Codeanalyse (Testen) (s. Kapitel IV) meist unzureichend!
- Korrektheit im Allgemeinen nicht berechenbar/entscheidbar!

Analysen und Vereinfachung der Programmsemantik

- Statische Codeanalyse:
automatische Extraktion von Programmeigenschaften
- Abstrakte Interpretation:
Analysemethode unter Zuhilfenahme von Approximation



Fragestellungen

- Korrektheitsaussagen sind schwer zu formulieren!
 - Auch wenn nur eine bestimmten Programmeigenschaft relevant ist!
~ Wie hilft uns „Abstrakte Interpretation“ bei diesem Problem?
- Was sind die mathematischen Grundlagen abstrakter Interpretation?
 - Eine „informelle“ Sichtweise auf die Zusammenhänge
- Ziel: Grobes Verständnis abstrakter Interpretation entwickeln!

Gliederung

1 Überblick

- Problemstellung
 - Beispiel
 - Konkrete Programmsemantik

- Abstrakte Interpretation
 - Abstrakte Semantik
 - Sammelsemantiken
 - Präfixsemantiken

4 Mathematische Grundlagen (Selbststudium)

5 Zusammenfassung



Fehlersuche: Was kann hier alles schief gehen?

Die Gretchenfrage der Softwareentwicklung ...


```
1 unsigned int average(unsigned int *array,
                      unsigned int size)
{
    unsigned int temp = 0;
    for(unsigned int i = 0; i < size; i++) {
        temp += array[i];
    }
    return temp / size;
}
```

- Wo könnte es hier klemmen?
 - Ist der Zugriff auf Feld `array` in Zeile 7 korrekt?
 - Kann die Addition in Zeile 7 überlaufen?
 - Kann in Zeile 10 eine Division durch 0 auftreten?
- Wie findet man das heraus?
 - ☞ Schauen wir mal, wie sich das Programm verhält.



Konkrete Programmsemantik


Eine informelle Einführung in die Prinzipien abstrakter Interpretation [2]



- Die **konkrete Semantik** (engl. *concrete semantics*) beschreibt
 - Alle möglichen Ausführungen eines Programms
 - Unter allen möglichen Ausführungsbedingungen
 - Für unser Beispiel bedeutet dies:
 - 2^{32} verschiedene große Felder, 2^{32} verschiedene Werte für jedes Element
- Sie beschreibt ein „unendliches“ mathematisches Objekt
 - Im Allgemeinen **nicht berechenbar** durch einen Algorithmus
 - Alle nicht-trivialen Fragestellungen sind **nicht entscheidbar**



Das Verhalten zur Laufzeit ist entscheidend!




```
1 unsigned int average(uint *array,
                      uint size)
{
    uint temp = 0;
    for(uint i = 0; i < size; i++) {
        temp += array[i];
    }
    return temp / size;
}
```

	i	temp
1	0	0
2	1	1
3	2	3
4	3	6
5
10	10	55




Sicherheitseigenschaft



- Sicherheitseigenschaften (engl. *safety properties*) stellen sicher, dass keine **fehlerhaften/unerwünschten Zustände** eingenommen werden
- Ein **Sicherheitsnachweis** (engl. *safety proof*) garantiert, dass die konkrete Semantik nie eine **verbotene Zone** durchläuft
- ☞ Das ist ein **unentscheidbares Problem**
 - Die konkrete Programmsemantik ist nicht berechenbar



Testen: Das Problem der Möglichkeiten



- Testen betrachtet **nur eine Teilmenge** aller möglichen Ausführungen
 - ~ Gut geeignet, um die **Existenz** von Defekten zu zeigen
 - ~ Ungeeignet, um ihre **Abwesenheit** zu zeigen
 - Evtl. hat man die fehlerhafte Ausführung einfach nicht getestet
- Problem: **unzureichende Abdeckung** der konkreten Semantik



Gliederung

- 1 Überblick
- 2 Problemstellung
 - Beispiel
 - Konkrete Programmsemantik


- 3 Abstrakte Interpretation
 - Abstrakte Semantik
 - Sammelsemantiken
 - Präfixsemantiken

- 4 Mathematische Grundlagen (Selbststudium)

- 5 Zusammenfassung



Abstrakte Interpretation



- **Abstrakte Interpretation** (engl. *abstract interpretation*)
 - Betrachtet eine **abstrakte Semantik** (engl. *abstract semantics*)
 - Sie umfasst **alle Fälle** der konkreten Programmsemantik
 - Ist die abstrakte Semantik sicher \Rightarrow konkrete Semantik ist sicher



Formale Methoden sind abstrakte Interpretationen

Die abstrakte Semantik wird aber auf unterschiedliche Weise bestimmt

Model Checking

- Abstrakte Semantik wird explizit vom Nutzer angegeben
 - ~ endliche Beschreibung der konkreten Programmsemantik
 - Z.B. endliche Automaten, Aussagen- oder Prädikatenlogik
- Automatische Ableitung durch **statische Analyse**

Deduktive Methoden


- Abstrakte Semantik wird durch Nachbedingungen beschrieben
- Nutzer gibt sie durch induktive Argumente an
 - Z.B. Vorbedingungen und Invarianten
- Automatische Ableitung durch **statische Analyse**

Statische Analyse

- Abstrakte Semantik wird ausgehend vom Quelltext bestimmt
 - Abbildung auf **vorab bestimmte, wohldefinierte Abstraktionen**
- Anpassungen (automatisch/durch den Nutzer) sind möglich



Eigenschaften abstrakter Semantiken




Vollständigkeit und Korrektheit

- Keine potentieller Defekt darf übersehen werden
 - ~ nur so kann die Abwesenheit von Defekten gezeigt werden
 - Ansonsten wäre gegenüber reinem Testen nichts gewonnen



Eigenschaften abstrakter Semantiken




Geringe Komplexität

- Berechnung der abstrakten Semantik in akzeptabler Laufzeit
 - Vermeidung der **kombinatorischen Explosion** des Zustandsraums



Eigenschaften abstrakter Semantiken



Präzision

- Weitgehende Vermeidung von **Fehlalarmen** (engl. *false alarms*)
 - Synonyme englische Bezeichnung: *false positives*
- Ermöglicht erst eine vollkommen automatisierte Anwendung



Problemstellung

Reduktion des Zustandsraums ist unumgänglich!

☞ Fasse verschiedene Zustände geeignet zusammen
~ **Sammelsemantiken** (s. Folie 15 ff.)

☞ Betrachte nur den Anfang der Zustandshistorie
~ **Präfixsemantiken** (s. Folie 20 ff.)



Beispiel: Intervallabstraktion (Forts.)

```

1 unsigned short x = 1;
2 while(x < 10000) {
3     x = x + 1;
4 }
5 return x;
6
7

```

Die Intervallabstraktion liefert:

Zeile 1 $x_1 = [1, 1]$
 Zeile 3 $x_3 = (x_1 \cup x_4) \cap [-\infty, 9999]$
 Zeile 4 $x_4 = x_3 \oplus [1, 1]$
 Zeile 7 $x_7 = (x_1 \cup x_4) \cap [10000, \infty]$

- Approximation durch **chaotische Iteration** (engl. *chaotic iteration*)

Iteration 3:


Zeile 1 $x_1 = [1, 1]$
 Zeile 3 $x_3 = [1, 3]$
 Zeile 4 $x_4 = [2, 4]$
 Zeile 7 $x_7 = \emptyset$

viele, viele Iterationen später:

Zeile 1 $x_1 = [1, 1]$
 Zeile 3 $x_3 = [1, 9999]$
 Zeile 4 $x_4 = [2, 10000]$
 Zeile 7 $x_7 = [10000, 10000]$



Pfadpräfixe



- Pfadsemantiken enthalten alle endlichen und unendlichen Pfade


- Pfadpräfixe enthalten nur die Anfänge dieser Pfade

☞ das ist eine **verlustbehaftete Abstraktion**

- Beispiel: betrachte Worte der Sprache $a^n b$
 - Frage: Gibt es Worte mit unendlich vielen aufeinanderfolgenden 'a'?
 - Pfadsemantik: $\{a^n b | n \geq 0\} \mapsto \text{Nein}$
 - Pfadpräfixe: $\{a^n | n \geq 0\} \cup \{a^n b | n \geq 0\} \mapsto ???$



Pfadsemantik



- Betrachte durch ein **Transitionssystem** beschriebene **Programmpfade**
 - Ausgehend von ausgezeichneten Startzuständen,
 - Beschreiben sie eine (unendliche) Abfolge von **Programmzuständen**,
 - Deren Reihenfolge durch die Übergangsrelation bestimmt wird.
- ☞ die Gesamtheit dieser Programmpfade heißt **Pfadsemantik**
 - Wie die konkrete Programmsemantik ist sie **nicht berechenbar**.
- Reduktion der Komplexität durch **Abstraktion**
 - Unendliche Pfade ↠ (endliche) **Pfadpräfixe**



Pfadpräfixe und Fixpunkte

- Menge der Präfixe ist rekursiv:

$$\begin{aligned} \text{Präfixe} = & \{x \mid x \text{ ist Startzustand}\} \cup \\ & \{x_1 \rightarrow^* x_2 \rightarrow x_3 \mid x_1 \rightarrow^* x_2 \in \text{Präfixe} \wedge x_2 \rightarrow x_3 \in \rightarrow\} \end{aligned}$$

- Zu lösen ist die Fixpunktiteration $\text{Präfixe} = F(\text{Präfixe})$

- üblicherweise besitzt diese Gleichung mehrere Lösungen
 - ☞ ordne die Lösungen nach der **Teilmengenbeziehung \subseteq**
 - ☞ wähle die kleinste Teilmenge als Lösung
 - ☞ **least fixpoint prefix trace semantics**

- Vereinfachungen ermöglichen **effektive, iterative Analysealgorithmen**

- Vereinfachung im Sinne von Abstraktion bzw. Approximation
 - ☞ man muss nur noch die Präfixe betrachten
 - Nicht mehr die vollständigen (evtl. unendlichen) Pfade




- 1 Überblick
- 2 Problemstellung
 - Beispiel
 - Konkrete Programmsemantik
- 3 Abstrakte Interpretation
 - Abstrakte Semantik
 - Sammelsemantiken
 - Präfixsemantiken
- 4 Mathematische Grundlagen (Selbststudium)
- 5 Zusammenfassung



Theoretisches Fundament \leadsto Abstrakte Interpretation

- ☞ Approximation von f durch die abstrakte Funktion f'
- Häufig verwendet man Galoiseinbettungen
 - Diese sind Galoisverbindungen $(C, \subseteq) \xleftarrow[\alpha]{} (A, \sqsubseteq)$
 - Mit der Eigenschaft $\alpha(\gamma(a)) = a$
 - Konkretisierung gefolgt von Abstraktion impliziert keinen Präzisionsverlust
- Abstrakte Interpretation nutzt diese Eigenschaften
 - Statt die konkrete Funktion $f(c)$ zu berechnen
 - Kann man sie annähern, indem
 - Man die abstrakte Funktion f' auf die Abstraktion $\alpha(c)$ anwendet
 - Und das Ergebnis $f'(\alpha(c))$ wieder konkretisiert



- Wähle eine abstrakte Domäne (engl. *abstract domain*)
 - Ersetzt die Menge konkreter Objekte S durch ihre Abstraktion $\alpha(S)$
 - Verschiedene Domänen unterscheiden sich hinsichtlich ihrer Präzision
 - Vorzeichen, Intervalle, Oktagon, Polyhedra, ...
- Abstraktionsfunktion α (engl. *abstraction function*)
 - Bildet die Menge konkrete Objekte auf ihre abstrakte Interpretation ab
- Konkretisierungsfunktion γ (engl. *concretization function*)
 - Bildet die Menge abstrakter Objekte auf konkrete Objekte ab



Warum funktioniert das eigentlich . . . ?

- Wann ist eine Abstraktion korrekt?
 - ☞ Wenn sie durch eine Galoisverbindung beschrieben wird! \leadsto OK!
- Fixpunkte . . . wer sagt, dass die Iteration überhaupt konvergiert?
 - ☞ Aufsteigende Kettenbedingung! \leadsto ???
- Das waren ziemlich viele Iterationen . . . geht das auch schneller?
 - ☞ Widening-/Narrowing-Operatoren helfen! \leadsto ???
- Jetzt: Grundlegende mathematische Zusammenhänge erfassen!
 - Was ist das und was hat es mit abstrakter Interpretation zu tun?
 - Nicht: Warum ist das korrekt?
 - Keine Beweisführung ...



Partiell geordnete Mengen

- Konkrete und abstrakte Domänen sind partiell geordnete Mengen!

Partiell geordnete Mengen (engl. *partially ordered sets*)

Eine partiell geordnete Menge ist ein Tupel (S, \sqsubseteq) :

- S ist eine Menge,
- $\sqsubseteq \subseteq S \times S$ ist eine **Ordnungsrelation** mit folgenden Eigenschaften:
 - Reflexiv** $\forall x \in S : x \sqsubseteq x$
 - Antisymmetrisch** $\forall x, y \in S : x \sqsubseteq y \wedge y \sqsubseteq x \Rightarrow x = y$
 - Transitiv** $\forall x, y, z \in S : x \sqsubseteq y \wedge y \sqsubseteq z \Rightarrow x \sqsubseteq z$

- Beispiele:

- (\mathbb{N}, \leq) ist ein partiell geordnete Menge
- $(\mathcal{P}(S), \subseteq)$ ist ein partiell geordnete Menge



Verbände

Vollständiger Verband (engl. *complete lattice*)

Ein **vollständiger Verband** ist eine partiell geordnete Menge $(S, \sqsubseteq, \perp, \top, \sqcup, \sqcap)$ mit folgenden Eigenschaften:

- (S, \sqsubseteq) ist eine partiell geordnete Menge
 - Für jede Teilmenge $P \subseteq S$ existiert eine
 - Eine kleinste obere Schranke $\sqcup P$ und
 - Eine größte untere Schranke $\sqcap P$
 - $\perp = \sqcap S$ heißt **Infimum** von S
 - $\top = \sqcup S$ heißt **Supremum** von S
-
- Beispiele:
 - $(\mathcal{P}(S), \subseteq, \emptyset, S, \cup, \cap)$ ist ein vollständiger Verband
 - $(\mathbb{Z} \cup \{-\infty, +\infty\}, \leq, -\infty, +\infty, \max, \min)$ ist ein vollständiger Verband
 - Die Menge der ganzen Zahlen erweitert um $-\infty$ und $+\infty$



Obere und untere Schranken

- Sei (S, \sqsubseteq) eine partiell geordnete Menge

Obere Schranke (engl. *upper bound*)

$x \in S$ eine **obere Schranke** von $P \subseteq S \Leftrightarrow y \in P : y \sqsubseteq x$

☞ analog: **untere Schranke** (engl. *lower bound*)

Kleinste obere Schranke (engl. *least upper bound*)

$x \in S$ ist eine **kleinste obere Schranke** von $P \subseteq S \Leftrightarrow$

- x ist eine obere Schranke von P und
- x ist kleiner als alle oberen Schranken von P :

$$\forall y \in S : (\forall z \in P : z \sqsubseteq y) \Rightarrow x \sqsubseteq y$$

☞ analog: **größte untere Schranke** (engl. *greatest lower bound*)



Terminierung der Fixpunktiteration

- Möglichkeit 1:** aufsteigende Kettenbedingung ist erfüllt

- ☞ aufsteigende Ketten sind endlich
- ☞ Fixpunktiteration terminiert

- Möglichkeit 2:** aufsteigende Kettenbedingung ist nicht erfüllt

- ☞ Terminierung kann durch einen **Widening-Operator** erzwungen werden

Widening-Operator

Sei V ein Verband, ein **Widening-Operator** $\nabla : V \times V \rightarrow V$ ist eine Abbildung für die gilt:

$$\forall x, y \in V : x \sqsubseteq x \nabla y \wedge y \sqsubseteq x \nabla y$$

- Sicher Abschätzung der Elemente x und y nach oben durch $x \nabla y$
- Ermöglicht auch eine Beschleunigung der Fixpunktiteration
 - Widening-Operator $\nabla \approx$ Bestimmung der kleinsten oberen Schranke
 - In vollständigen Verbänden mit aufsteigender Kettenbedingung



Beispiel: Intervallabstraktion – nun mit Widening

```
1 unsigned short x = 1;
2 while(x < 10000) {
3     x = x + 1;
4 }
5
6 return x;
```

Die Intervallabstraktion liefert:

Zeile 1 $x_1 = [1, 1]$
Zeile 3 $x_3 = (x_1 \nabla x_4) \cap [-\infty, 9999]$
Zeile 4 $x_4 = x_3 \oplus [1, 1]$
Zeile 7 $x_7 = (x_1 \nabla x_4) \cap [10000, \infty]$

■ Approximation mit Hilfe des Widening-Operators

Iteration 1:

Zeile 1 $x_1 = [1, 1]$
Zeile 3 $x_3 = [1, 1]$
Zeile 4 $x_4 = [2, 2]$
Zeile 7 $x_7 = \emptyset$

Iteration 2:

Zeile 1 $x_1 = [1, 1]$
Zeile 3 $x_3 = [1, 9999]$
Zeile 4 $x_4 = [2, 10000]$
Zeile 7 $x_7 = [10000, 10000]$

■ Konvergenz in der 2. Iteration



Zusammenfassung

Konkrete Programmsemantik ist **nicht berechenbar**

- Approximation durch eine **abstrakte Semantik**
 - Korrektheit der Approximation ist entscheidend
 - Nur so kann man einen **Sicherheitsnachweis** führen
 - Die Approximation muss präzise sein
 - Nur so kann man **Fehlalarme** vermeiden
 - Die Approximation darf nicht zu komplex sein
 - Nur so kann sie **effizient berechnet** werden

Transitionssystem beschreiben Programme

- **Pfadsemantiken** beschreiben die konkrete Programmsemantik
- Approximation durch **Pfadpräfixe** und **Sammelsemantik**
 - ~~ abstrakte Interpretation approximiert die Sammelsemantik

Mathematische Grundlagen abstrakter Interpretation

- (vollständig) partiell geordnete Mengen, Verbände
- Galoiseinbettungen, lokale konsistente Funktionen, Widening
- Intervallabstraktion



Gliederung

1 Überblick

2 Problemstellung

- Beispiel
- Konkrete Programmsemantik

3 Abstrakte Interpretation

- Abstrakte Semantik
- Sammelsemantiken
- Präfixsemantiken

4 Mathematische Grundlagen (Selbststudium)

5 Zusammenfassung



Literaturverzeichnis

- [1] COUSOT, P. : Semantic foundations of program analysis. In: *Program flow analysis: theory and applications* 10 (1981), S. 303–342
- [2] COUSOT, P. : *Abstract Interpretation*. <http://web.mit.edu/16.399/www/>, 2005
- [3] COUSOT, P. ; COUSOT, R. : Abstract Interpretation: A Unified Lattice Model for Static Analysis of Programs by Construction or Approximation of Fixpoints. In: *Proceedings of the 4th ACM SIGACT-SIGPLAN Symposium on Principles of Programming Languages*. ACM (POPL '77), 238–252
- [4] COUSOT, P. ; COUSOT, R. : Abstract interpretation frameworks. In: *Journal of Logic and Computation* 2 (1992), Nr. 4, S. 511–547



- [5] COUSOT, P. ; COUSOT, R. :
Abstract Interpretation and Application to Logic Programs.
In: *Journal of Logic Programming* 13 (1992), Jul., Nr. 2-3, S. 103–179.
[http://dx.doi.org/10.1016/0743-1066\(92\)90030-7](http://dx.doi.org/10.1016/0743-1066(92)90030-7). –
DOI 10.1016/0743-1066(92)90030-7. –
ISSN 0743-1066
- [6] MIDTGAARD, J. :
Abstract Interpretation.
<http://www.cs.au.dk/~jmi/AbsInt/>, 2012

