Verlässliche Echtzeitsysteme

Abstrakte Interpretation

Peter Ulbrich

Friedrich-Alexander-Universität Erlangen-Nürnberg
Lehrstuhl Informatik 4 (Verteilte Systeme und Betriebssysteme)

`www4.informatik.uni-erlangen.de`

30. Juni 2014

Fragestellungen

- Warum ist es so schwierig Korrektheitsaussagen 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

2 Problemstellung

3 Sammelsemantiken

4 Präfixsemantiken

5 Mathematische Grundlagen

6 Zusammenfassung

Wiederholung: Was kann hier alles schief gehen?


```
1  unsigned int average(unsigned int *array,
2                       unsigned int size)
3  {
4    unsigned int temp = 0;
5
6    for(unsigned int i = 0;i < size;i++) {
7      temp += array[i];
8    }
9
10   return temp/size;
11 }
```

- 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.

Das Verhalten zur Laufzeit ist entscheidend!

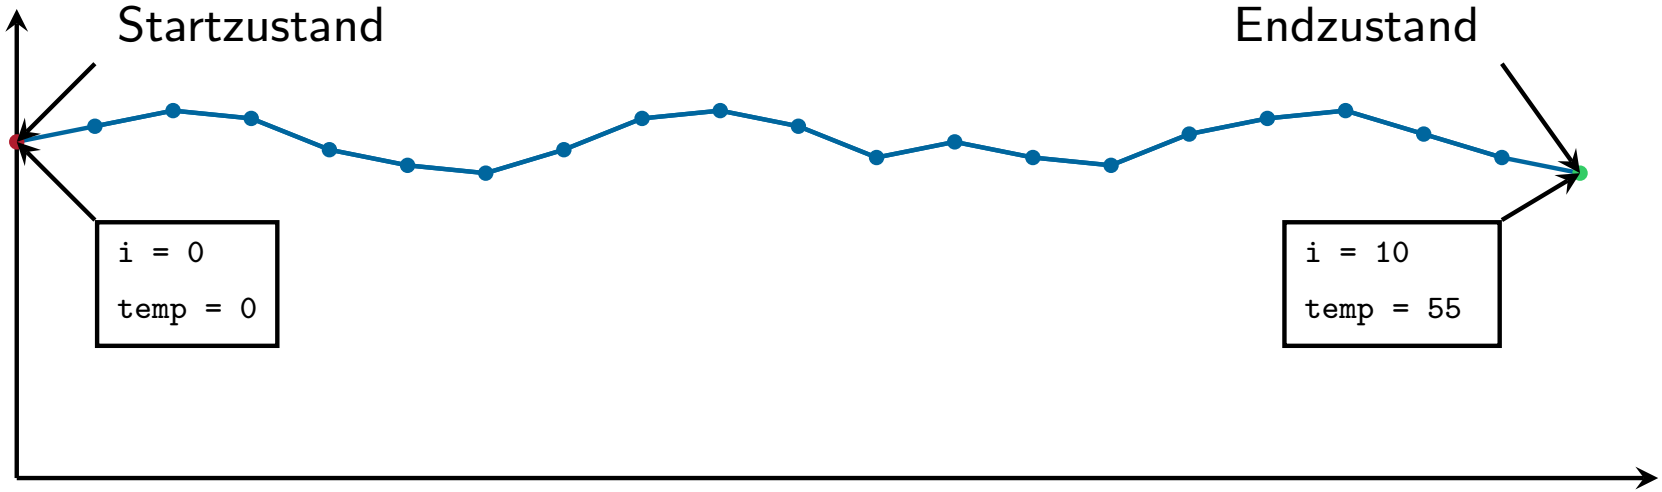

☞ `res = average([1,2,...,10],10);`

```
1  unsigned int average(uint *array,
2                       uint size)
3  {
4    uint temp = 0;
5
6    for(uint i = 0;i < size;i++) {
7      temp += array[i];
8    }
9
10   return temp/size;
11 }
```

i	temp
0	0
1	1
2	3
3	6
...	...
10	55

Konkrete Programmsemantik

Eine informelle Einführung in die Prinzipien abstrakter Interpretation [1]

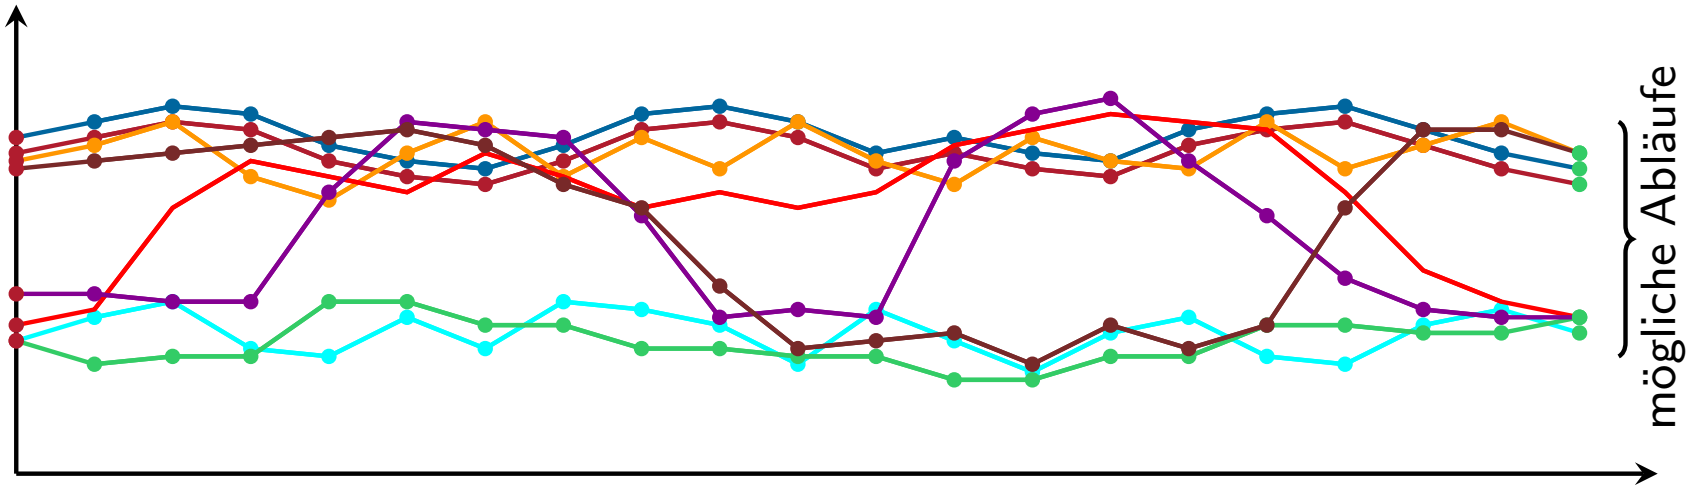

- die konkrete Semantik (engl. *concrete semantics*) beschreibt
  - alle möglichen Ausführungen eines Programms
  - unter allen möglichen Ausführungsbedingungen
  - Für unser Beispiel bedeutet dies:
    - 2^{32} verschieden große Felder, 2^{32} verschiedene Werte für jedes Element
- sie beschreibt ein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

Sicherheitseigenschaft

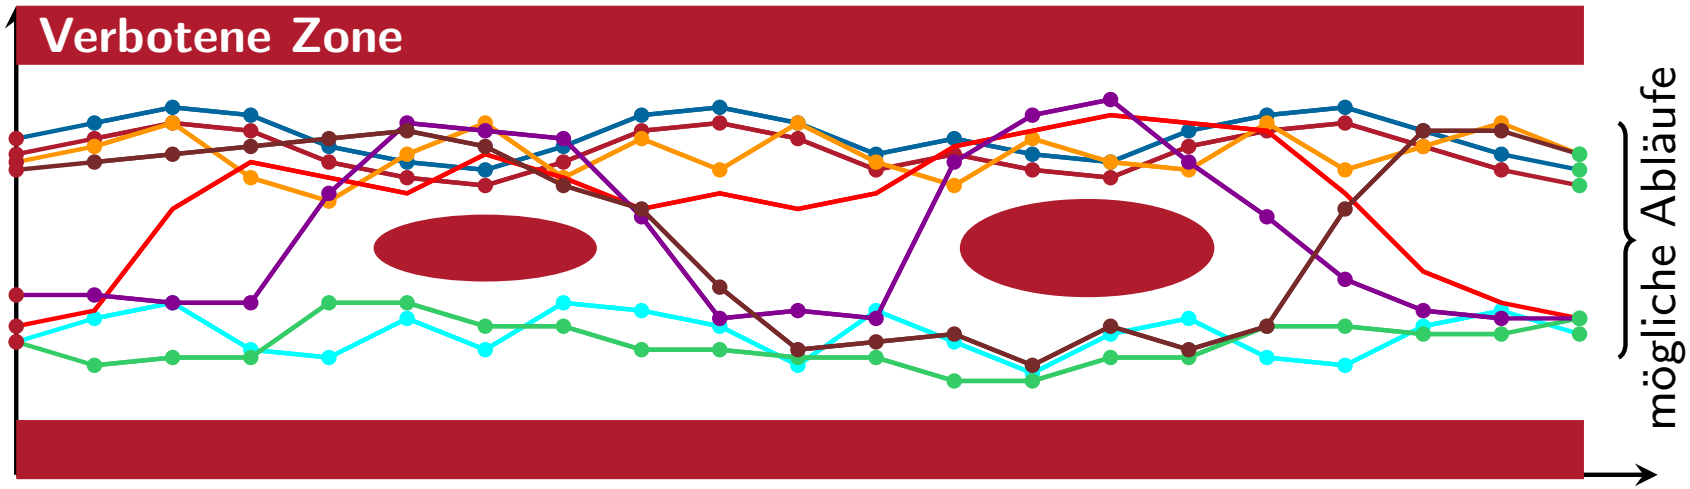

- Sicherheitseigenschaften (engl. *safety properties*) stellen sicher, dass keine fehlerhaften Zustände eingenommen werden
- ein Sicherheitsnachweis (engl. *safety proof*) garantiert, dass die konkrete Semantik nie eine verbotene Zone durchläuft

☞ das ist ein unentscheidbares Problem

  - die konkrete Programmsemantik ist nicht berechenbar

Testen: Das Problem der Möglichkeiten

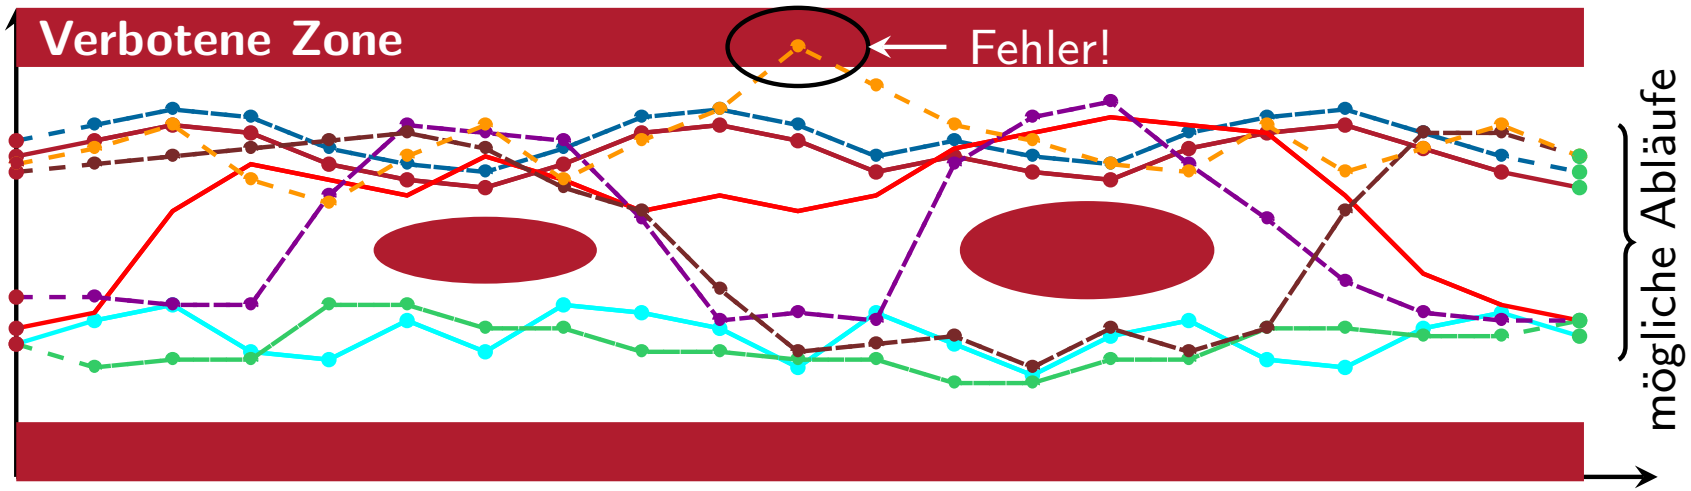

- Testen betrachtet nur eine Teilmenge aller möglichen Ausführungen
  - ⇝ gut geeignet, um die Existenz von Defekten zu zeigen
  - ⇝ ungeeignet, um ihre Abwesenheit zu zeigen
    - evtl. hat man die fehlerhafte Ausführung einfach nicht getestet
- Problem: unzureichende Abdeckung der konkreten Semantik

Abstrakte Interpretation

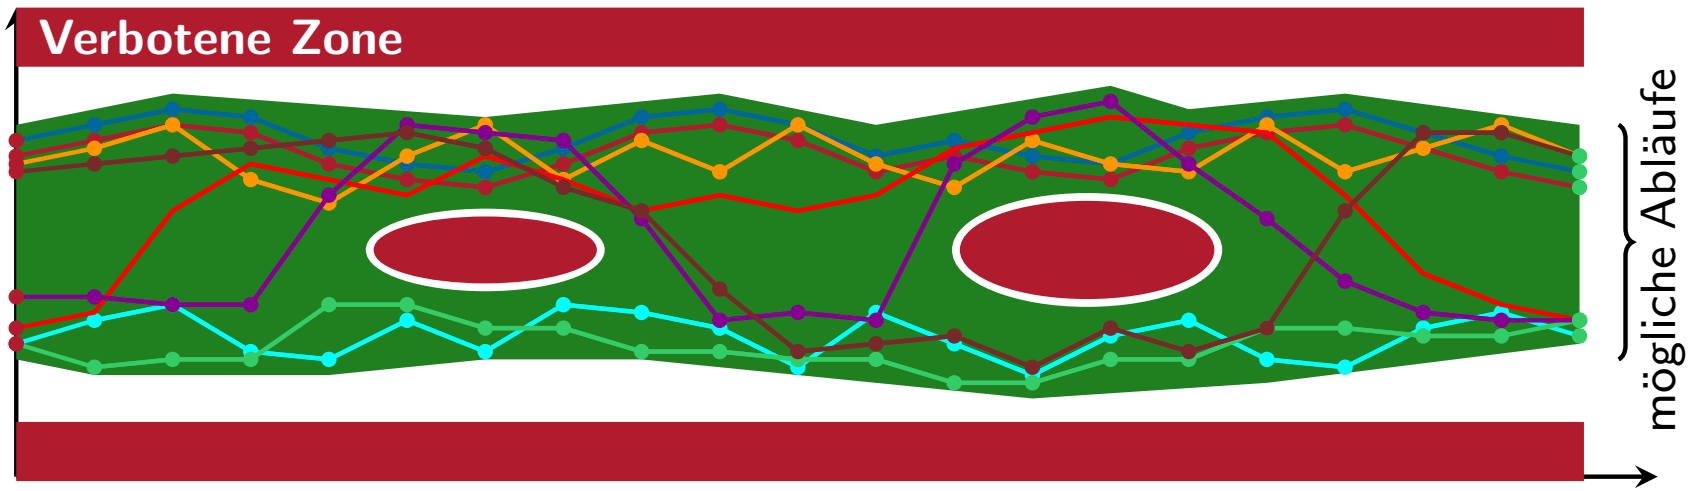

- Abstrakte Interpretation (engl. *abstract interpretation*)
  - betrachtet eine abstrakte Semantik (engl. *abstract semantics*)
    - sie umfasst alle Fälle der konkreten Programmsemantik
  - ist die abstrakte Semantik sicher $\Rightarrow$ konkrete Semantik ist sicher

Formale Methoden sind abstrakte Interpretationen

Die abstrakte Semantik wird aber auf unterschiedliche Weise bestimmt

Model Checking

- abstrakte Semantik wird explizit vom Nutzer angegeben

$\rightsquigarrow$ 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

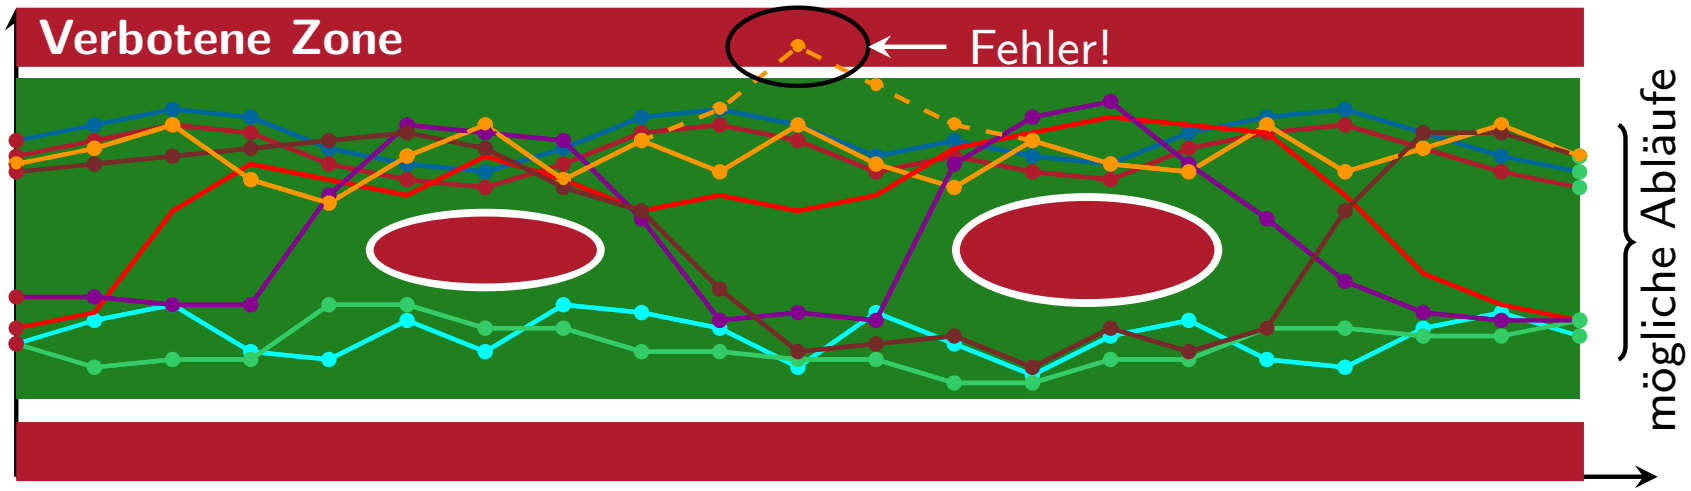

Vollständigkeit und Korrektheit

- keine potentieller Defekt darf übersehen werden

$\rightsquigarrow$ nur so kann die Abwesenheit von Defekten gezeigt werden

  - ansonsten wäre gegenüber reinem Testen nichts gewonnen

Eigenschaften abstrakter Semantiken

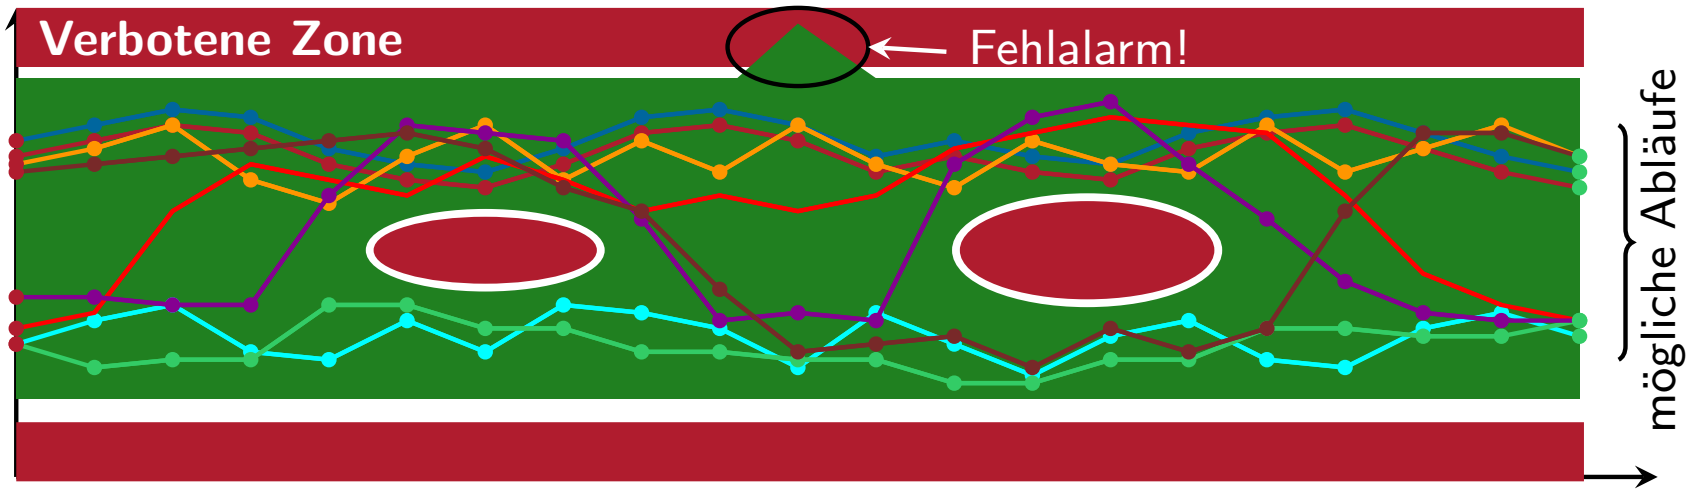

Präzision

- weitgehende Vermeidung von Fehlalarmen (engl. *false alarms*)
  - synonyme englische Bezeichnung: false positives
- ermöglicht erst eine vollkommen automatisierte Anwendung

Eigenschaften abstrakter Semantiken

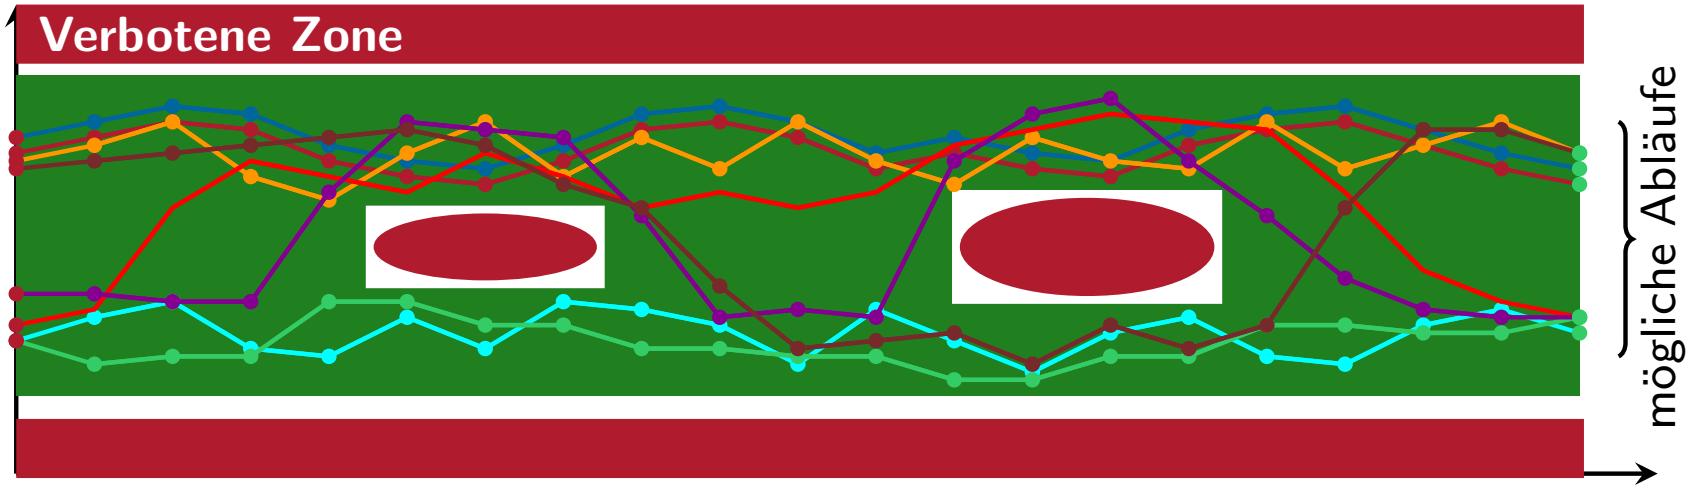

geringe Komplexität

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

Problemstellung

Reduktion des Zustandsraums ist unumgänglich!

- ☞ Fasse verschiedene Zustände geeignet zusammen
  - ⇝ Sammelsemantiken (s. Folie X/14 ff.)
- ☞ Betrachte nur den Anfang der Zustandshistorie
  - ⇝ Präfixsemantiken (s. Folie X/22 ff.)

Gliederung

1 Überblick

2 Problemstellung

3 Sammelsemantiken

4 Präfixsemantiken

5 Mathematische Grundlagen

6 Zusammenfassung

Sammelsemantik (engl. *collecting semantics*)

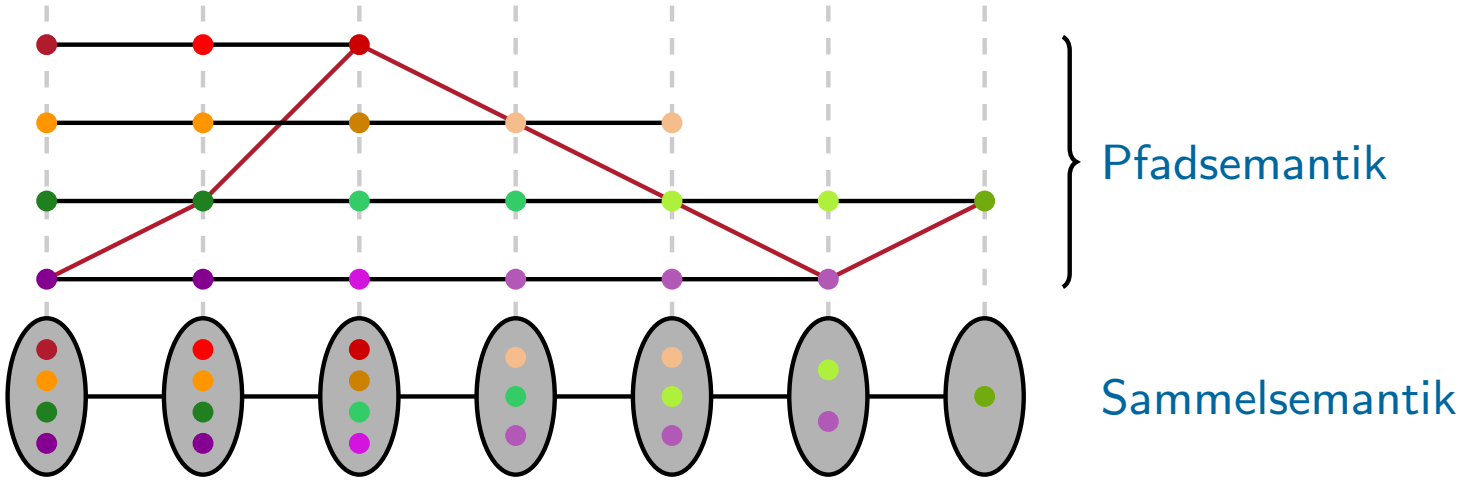

- sammelt die Zustände aller Pfade an einem bestimmten Punkt
  - d. h. an einer bestimmten Programmanweisung
  - aufgrund der Größe, wird sie i. d. R. approximiert
- das ist eine verlustbehaftete Abstraktion
  - Beispiel: Existiert der rote Pfad?
    - konkrete Semantik $\mapsto$ Nein, Sammelsemantik $\mapsto$???

☞ Der Laufzeitgewinn wird durch Unschärfe erkauft!

- das Ergebnis „Weiß nicht . . . “ ist typisch für solche Methoden
- und die Ursache vieler Vorbehalte . . .

Intervallabstraktion

Als Approximation der Sammelsemantik

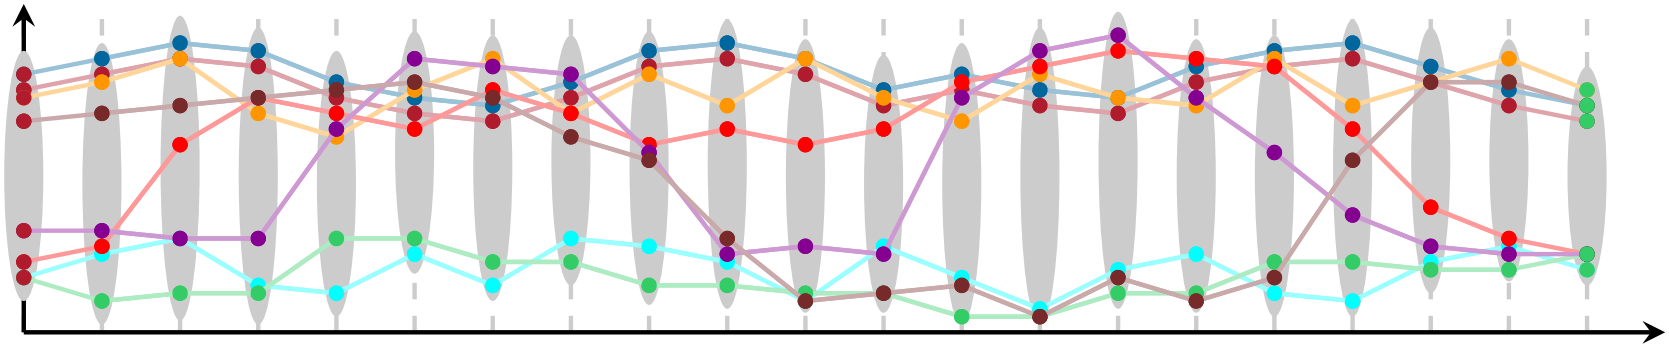

- die Sammelsemantik verwaltet Zustandsmengen
- ☞ die Intervallabstraktion nur ihre oberen und unteren Schranken
  - die zu verwaltenden Daten werden dadurch beträchtliche reduziert
  - allerdings wird auch die Präzision reduziert

    ⇝ bestimmte Zustände im appromixierten Zustandsraum werden nicht erreicht

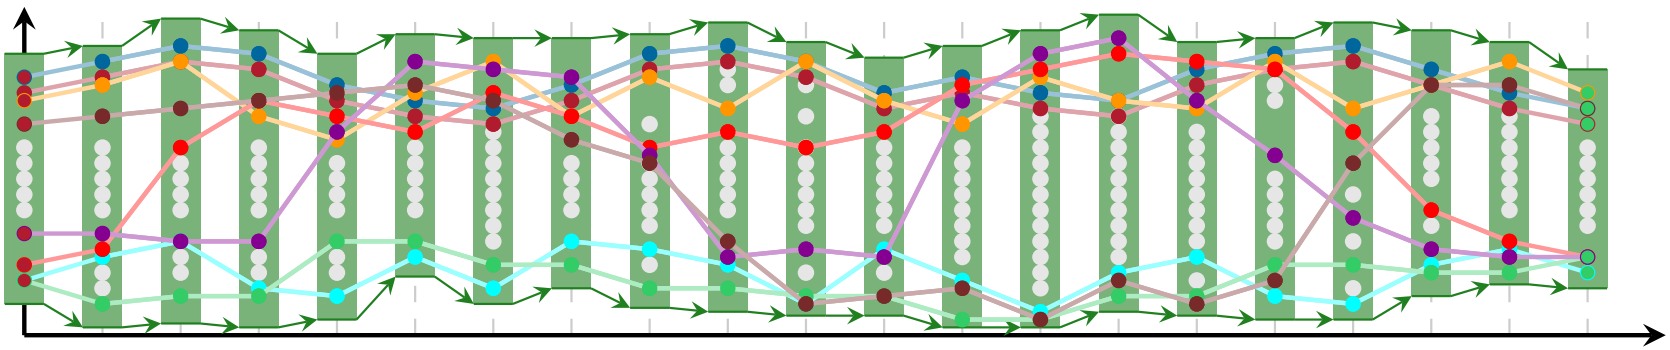

Theoretisches Fundament $\rightsquigarrow$ Galoisverbindungen

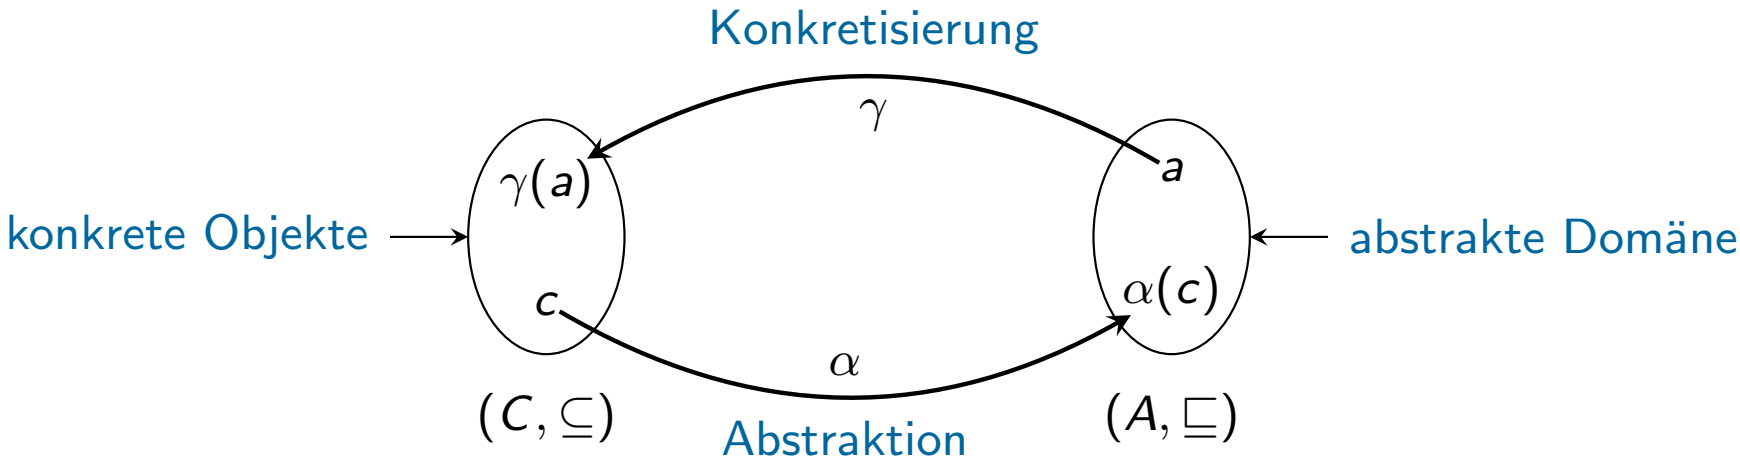

- wähle eine abstrakte Domäne (engl. *abstract domain*)
  - ersetzt die Menge konkreter Objekte S durch ihre Abstraktion $\alpha(S)$
  - verschiedene Domänen unterscheiden sich hinsichtlich ihrer Präzision
    - Vorzeichen, Intervalle, Oktagon, Polyhedra, ...
- Abstraktionsfunktion α (engl. *abstraction 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

Theoretisches Fundament $\rightsquigarrow$ Abstrakte Interpretation

☞ Approximation von f durch die abstrakte Funktion f'

- häufig verwendet man Galoiseinbettungen
  - diese sind Galoisverbindungen $(C, \subseteq) \underset{\alpha}{\overset{\gamma}{\leftrightarrows}} (A, \sqsubseteq)$
  - 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

Beispiel: Intervallabstraktion für ein C-Programm

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

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 $x_7 = (x_1 \cup x_5) \cap [10000, \infty]$

- die Intervallabstraktion ist eine manuell vorgegebene, abstrakte Interpretation der Semantik der Programmiersprache C
  - C-Programme werden dann automatisiert darauf abgebildet
    - z. B. durch einen Übersetzer oder ein statisches Analysewerkzeug
  - nur Elemente, die den Wertebereich von `x` betreffen, sind relevant
- dies ist bereits eine starke Vereinfachung
  - angenommen `x` wäre eingangs nicht bekannt

  $\rightsquigarrow$ es gäbe 10000 verschiedene Pfade durch den Zustandsraum
  - nehme eine Schleifenobergrenze `unsigned short y` statt 10000 an

  $\rightsquigarrow$ es gäbe $\leq (2^{16})^2$ verschiedene Pfade durch den Zustandsraum

Beispiel: Intervallabstraktion für ein C-Programm (Forts.)

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

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 1:

Zeile 1 $x_1 = [1, 1]$

Zeile 3 $x_4 = [1, 1]$

Zeile 4 $x_4 = [2, 2]$

Zeile 7 $x_7 = \emptyset$

Iteration 2:

Zeile 1 $x_1 = [1, 1]$

Zeile 3 $x_4 = [1, 2]$

Zeile 4 $x_4 = [2, 3]$

Zeile 7 $x_7 = \emptyset$

Beispiel: Intervallabstraktion (Forts.)

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

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 $x_7 = [10000, 10000]$

Gliederung

1 Überblick

2 Problemstellung

3 Sammelsemantiken

4 Präfixsemantiken

5 Mathematische Grundlagen

6 Zusammenfassung

Pfadsemantik

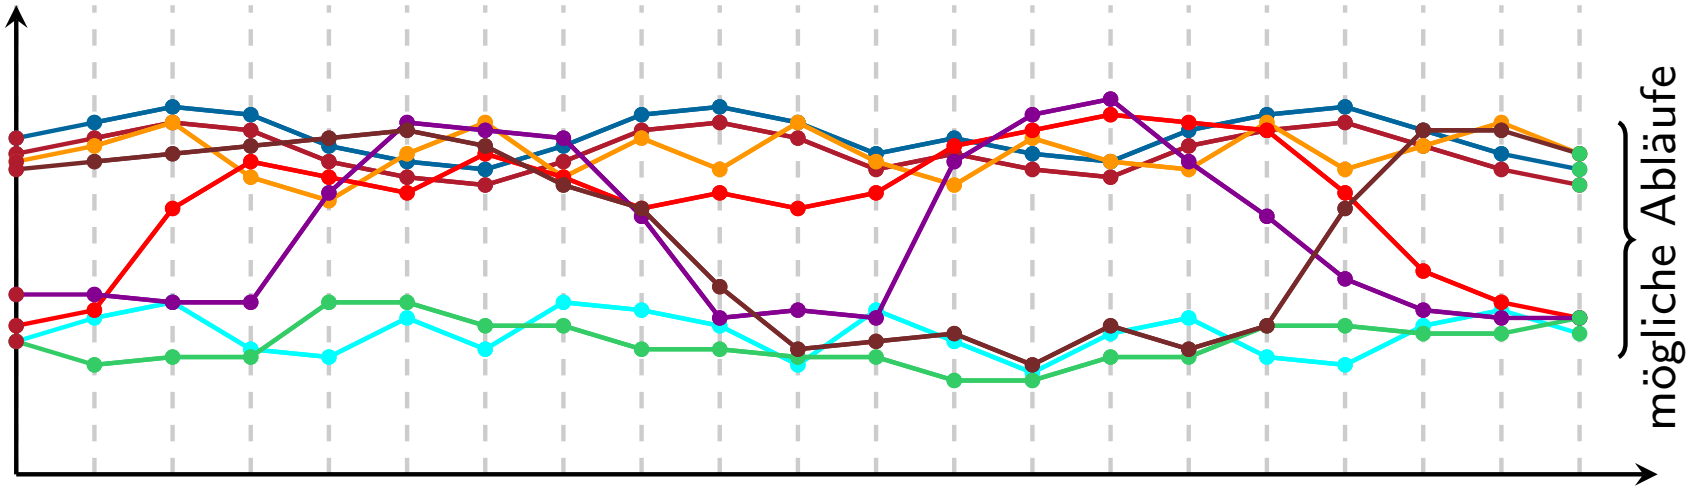

- betrachte durch ein Transitionssystem beschriebene Programmpfade
  - Ausgehend von ausgezeichneten Startzuständen,
  - beschreiben sie eine (unendliche) Abfolge von Programmzuständen,
  - deren Reihenfolge durch die Übergangsrelation bestimmt wird.

  ⇝ die Gesamtheit dieser Programmpfade heißt Pfadsemantik
  - Wie die konkrete Programmsemantik ist sie nicht berechenbar.

- Reduktion der Komplexität durch Abstraktion
  - unendliche Pfade ⇝ (endliche) Pfadpräfixe

Pfadpräfixe

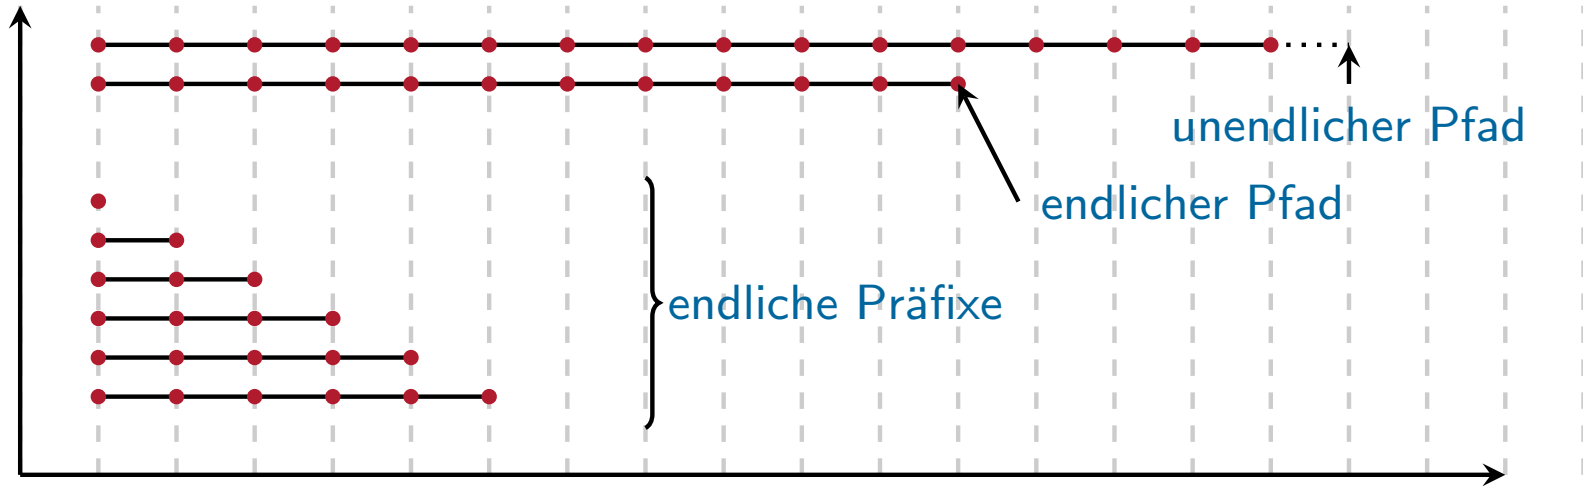

- Pfadsemantiken enthalten alle endlichen und unendlichen Pfade
  - Pfadpräfixe enthalten nur die Anfänge dieser Pfade

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

Pfadpräfixe und Fixpunkte

- Menge der Präfixe ist rekursiv:

$$\text{Präfixe} = \{x | x \text{ ist Startzustand}\} \cup \{x_1 \rightarrow^* x_2 \rightarrow x_3 | x_1 \rightarrow^* x_2 \in \text{Präfixe} \wedge x_2 \rightarrow x_3 \in \rightarrow\}$$

- zu lösen ist die Fixpunktiteration 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

Gliederung

1 Überblick

2 Problemstellung

3 Sammelsemantiken

4 Präfixsemantiken

5 Mathematische Grundlagen

6 Zusammenfassung

Warum funktioniert das eigentlich . . . ?

- Wann ist eine Abstraktion korrekt?

  ⇝ Wenn sie durch eine Galoisverbindung beschrieben wird! ⇝ **OK!**
- Fixpunkte . . . wer sagt, dass die Iteration überhaupt konvergiert?

  ⇝ Aufsteigende Kettenbedingung! ⇝ **???**
- Das waren ziemlich viele Iterationen . . . geht das auch schneller?

  ⇝ Widening-/Narrowing-Operatoren helfen! ⇝ **???**

- **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:

$$\begin{aligned} \text{reflexiv} \quad & \forall x \in S : x \sqsubseteq x \\ \text{antisymmetrisch} \quad & \forall x, y \in S : x \sqsubseteq y \wedge y \sqsubseteq x \Rightarrow x = y \\ \text{transitiv} \quad & \forall x, y, z \in S : x \sqsubseteq y \wedge y \sqsubseteq z \Rightarrow x \sqsubseteq z \end{aligned}$$

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

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*)

Verbände

Vollständiger Verband (engl. *complete lattice*)

Ein vollständiger Verband ist eine partiell geordnete Menge $(S, \sqsubseteq, \bot, \top, \sqcup, \sqcap)$ 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 $\sqcap P$
- $\bot = \sqcap S$ 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 $+\infty$

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 $\nabla : V \times V \mapsto V$ 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
3  while(x < 10000) {
4    x = x + 1;
5  }
6
7  return x;
```

Die Intervallabstraktion liefert:

Zeile 1 $x_1 = [1, 1]$

Zeile 3 $x_3 = (x_1 \triangledown x_4) \cap [-\infty, 9999]$

Zeile 4 $x_4 = x_3 \oplus [1, 1]$

Zeile 7 $x_7 = (x_1 \triangledown x_4) \cap [10000, \infty]$

- 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

Gliederung

1 Überblick

2 Problemstellung

3 Sammelsemantiken

4 Präfixsemantiken

5 Mathematische Grundlagen

6 Zusammenfassung

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

  $\rightsquigarrow$ abstrakte Interpretation approximiert die Sammelsemantik

Mathematische Grundlagen abstrakter Interpretation

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

Literaturverzeichnis

[1] Cousot, P. :
Abstract Interpretation.
http://web.mit.edu/16.399/www/, 2005