

# SAT-Solving und Anwendungen

## Software Verifikation mit Bounded Model Checking

Prof. Dr. Wolfgang Küchlin  
Dipl. Inf. Christoph Zengler

Universität Tübingen

15. Mai 2012



# Fahrplan für heute

## ① Einführung Software-Verifikation

- Was ist Software Verifikation?
- Warum Software Verifikation?

## ② Ein formales Modell für Software

- Wie kann Software formalisiert werden?
- Wie kann man Verifikationsbedingungen und Gegenbeispiele formalisieren?

## ③ Bit-Vektoren

- Was sind Bit-Vektoren?
- Wie kann man Bit-Vektor Gleichungen entscheiden?

## ④ Bounded Model Checking (BMC)

- Wie funktioniert BMC?
- Beispiele für BMC?
- Und in der echten Welt?

# Softwareverifikation — 1

## Definition (Softwareverifikation)

Beweis der Korrektheit eines Programms mit mathematischen Methoden.

### Einschränkungen:

- Es kann nur verifiziert werden, was vorher spezifiziert wurde, d.h. es muss eine formale Beschreibung vorliegen, was eine bestimmte Methode / ein bestimmter Algorithmus tun soll
- Bei falscher Spezifikation bringt auch die Verifikation nichts
- Verifikation auf Sourcecode Ebene: Selbst ein korrektes Programm kann z.B. durch das Linken inkorrekt externer Libraries, einen fehlerhaften Compiler oder einen Fehler im Betriebssystem nicht korrekt ausgeführt werden

### Allerdings:

- Es gibt viele universelle Spezifikationen: keine Null-Pointer Dereferenzierung, kein Array-Index-Überlauf, nur positive Werte in *unsigned* Variablen ...
- Compiler-Fehler durch Verifikation des Zwischencodes finden.

## Softwareverifikation — 2

Unterschiede zu den Überprüfungen, die eine IDE oder ein Compiler vornimmt:

- **Syntaxchecks:** Kann ein Programm überhaupt compiliert werden (genügt es der Grammatik einer bestimmten Programmiersprache)
- **Typchecks:** Stimmen die Typen im Programm überein (erwartet eine Methode ein Objekt der Klasse “Student”, kann kein Objekt der Klasse “Stuhl” übergeben werden)
- Sind alle Felder, Methoden, etc. vorhanden und eindeutig
- Aber keine Überprüfung, ob ein Programm / eine Methode auch das tut, was sie soll (Semantik)

## Softwareverifikation — 3

### Beispiel (Compilerchecks vs. Verifikation)

```
// Soll das Maximum von drei Zahlen berechnen
int max3(int a, int b, int c) {
    if (a > b) {
        return a;
    } else {
        return c;
    }
}
```

- Compiliert problemlos (kein Syntax- oder Typfehler)
- Ist semantisch falsch bezüglich folgender Spezifikation

$$\text{max3}(a, b, c) \geq a \wedge \text{max3}(a, b, c) \geq b \wedge \text{max3}(a, b, c) \geq c$$

- Dann soll Verifikation einen Fehler melden (und einen Pfad zu einem Fehler ausgeben, z.B.  $a = 2, b = 5, c = 3$ )

# Softwareverifikation — 4

Viele verschiedene Verfahren zur Softwareverifikation (hier nur einige:)

- **Software Bounded Model Checking (SBMC)**
  - Übersetzt Code in aussagenlogische Formel
  - Verifiziert mit SAT-Solving
  - Dicht am Quellcode und an der hardwareseitigen Implementierung, weitgehend automatisiert
  - *bounded*: setzt (beliebige aber feste) Grenze für Schleifen / Rekursionen
- Theorembeweiser
  - Manuelle Spezifikation mit (höherer) Logik (1. Stufe, 2. Stufe)
  - Deduktion von Nachbedingungen
  - Ausdrucksstark, bedarf menschlicher Begleitung
- Hoare-Logik mit Theorembeweiser
- Konventionelle Statische Codeanalyse
- ...

# Motivation

## Warum Software-Verifikation?

Immer mehr Software...

- ... in sicherheitskritischen Bereichen, in denen ein Fehler Millionen (z.B. Kreditkartenfirmen, Banken,...) oder auch Menschenleben (Bremsysteme, Flugsteuerung,...) kosten kann
- ..., die nicht einfach mit Updates versehen werden kann (z.B. Motorensteuerung, Waschmaschine, Satellit,...)

Die Korrektheit von Software ist ein Thema seit es Programme gibt:

- *Checking a Large Routine*, A.M. Turing, 1949
- *Assigning Meanings to Programs*, R. W. Floyd, 1967
- *An Axiomatic Basis for Computer Programming*, C. A. R. Hoare, 1969

### Standpunkt:

- Programme sind eine Reihe von Instruktionen, die die Werte einer gegebenen Menge an Variablen verändern
- Diese Variablen werden z.B. als ganze oder reelle Zahlen modelliert

# Wie sieht es in der Realität aus?

## Realität

Die meisten hardware-nahen Programmiersprachen haben vordefinierte Datentypen mit Bit-Vektor Arithmetik, d.h.

- beschränkter Wertebereich, je nach Anzahl allozierter Bits
- Überläufe bei Überschreiten des Wertebereichs sind möglich

Auf Hardware-Ebene vor allem bitweise Operationen, z.B. Shift, Und, Oder,...

## Beispiel (Absolutbetrag)

### Mathematisch

$$\text{abs}(a) = \begin{cases} a & \text{falls } a \geq 0 \\ -a & \text{sonst} \end{cases}$$

### Programmatisch

```
short abs(short a) {  
    if (a >= 0)  
        return a;  
    else  
        return -a;  
}
```

Mathematisch korrekt, programmatisch gibt es jedoch bei -32768 ein Problem.

# Was wäre also besser?

## Besser...

Hardwarenahe Modellierung von Programmen mit Bit-Vektoren und dadurch genauere Übereinstimmung von Modell und Realität

- weniger *False Positives*: Es werden weniger Fehler gemeldet, die zwar mathematisch ein Problem sind, jedoch nicht programmatisch
- weniger *False Negatives*: Es werden weniger Fehler übersehen, die zwar mathematisch korrekt sind, jedoch programmatisch ein Problem sind

## Bit-Vektoren:

- Vektor (typischerweise der Länge 16, 32 oder 64) von Bits
- können mit Aussagenvariablen modelliert werden
- Bit-Vektor Operationen können mit Booleschen Funktionen modelliert werden
- Verifikations- bzw. Fehlerproblem kann als SAT Instanz kodiert werden

Ist das Fehlerproblem **unerfüllbar**, so gab es keinen Fehler im Programm, ist das Fehlerproblem **erfüllbar**, so gab es einen Fehler im Programm und die erfüllende Belegung der SAT Instanz gibt einen möglichen Pfad zu diesem Fehler an.

# Fahrplan für heute: Wo stehen wir?

## ① Einführung Software-Verifikation ✓

- SW-Verifikation: Korrektheit eines Programms mit mathematischen Methoden beweisen
- Motivation: Immer mehr sicherheitskritische Software

## ② Ein formales Modell für Software

- Wie kann Software formalisiert werden?
- Wie kann man Verifikationsbedingungen und Gegenbeispiele formalisieren?

## ③ Bit-Vektoren

- Was sind Bit-Vektoren?
- Wie kann man Bit-Vektor Gleichungen entscheiden?

## ④ Bounded Model Checking (BMC)

- Wie funktioniert BMC?
- Beispiele für BMC?
- Und in der echten Welt?

# Ein formales Softwaremodell — 1

Üblicherweise wird Software als Zustandsübergangssystem (*Transition System*) modelliert.

## Transition System

Ein Transition System ist ein Drei-Tupel  $M = (S, S_0, R)$ , mit

- $S$  einer Menge an Zuständen,
- $S_0 \subseteq S$  einer Menge an Startzuständen und
- $R \subseteq S \times S$  einer Übergangsrelation.

Ein Zustand  $s$  fasst folgende Informationen zusammen:

- den momentanen Stand der Programmausführung (*program location*)
- die aktuellen Werte der lokalen und globalen Variablen

## Program Locations

- $\mathcal{L}$ : endliche Menge aller Program Locations
- $s.\ell$ : Program Location im Zustand  $s \in S$
- $\ell_0$ : Program Location beim Programmeintritt (Main Methode)

# Ein formales Softwaremodell — 2

## Programmvariablen

- Menge  $V$  von Variablen über endlichem Wertebereich  $D$
- $V$  möglicherweise unbeschränkt wenn dynamische Allokation von Objekten erlaubt ist
- $s.v$ : Wert der Variable  $v \in V$  im Zustand  $s \in S$

## Funktionsaufrufe

- Modellierung mit Hilfe eines unbeschränkten Funktionsaufruf-Stacks  
 $\Gamma : \mathbb{N} \rightarrow D \dot{\cup} \mathcal{L}$
- Auf dem Stack werden Program Locations sowie lokale Variablen gespeichert
- $s.\Gamma$ : Stack im Zustand  $s \in S$

**Zusammenfassend:**  $S$  besteht aus drei Komponenten:

$$S = \mathcal{L} \times \underbrace{(V \rightarrow D)}_{\text{Variablen}} \times \underbrace{(\mathbb{N} \rightarrow D \dot{\cup} \mathcal{L})}_{\text{Stack}}$$

# Ein formales Softwaremodell — 3

## Bemerkungen

- Es gibt nur einen Programmzähler, d.h. nur einen Thread
- $S_0$  weist dem Programm den initialen Ausführungsstand  $\ell_0$  zu
- Initialisierung von globalen Variablen muss innerhalb des Programms geschehen

Programminstruktionen werden mit Übergangsrelation modelliert

## Übergangsrelation $R$

Für zwei Zustände  $\langle s, s' \rangle \in S \times S$  gilt  $R(s, s')$  genau dann, wenn es einen Übergang im Programm von  $s$  nach  $s'$  gibt.

- Sowohl Programmfluss als auch Veränderungen der Daten werden mit  $R$  beschrieben
- $R$  wird partitioniert in ein  $R_l$  für jede Program Location  $l \in \mathcal{L}$ :

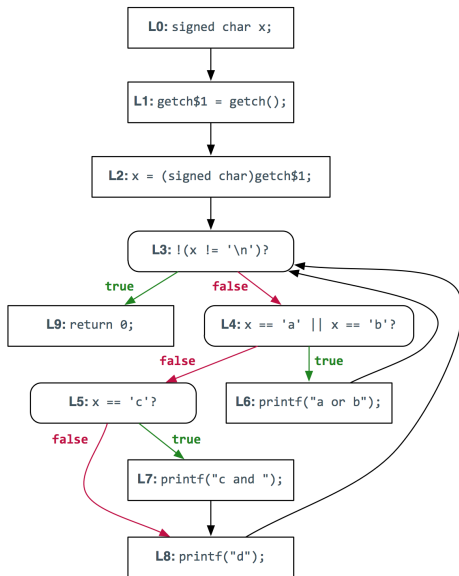
$$R(s, s') \Leftrightarrow \bigwedge_{l \in \mathcal{L}} (s.l = l \rightarrow R_l(s, s'))$$

# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
    char x;
    x = getch();
    while (x != '\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a_or_b");
                break ;
            case 'c':
                printf("c_and_");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```

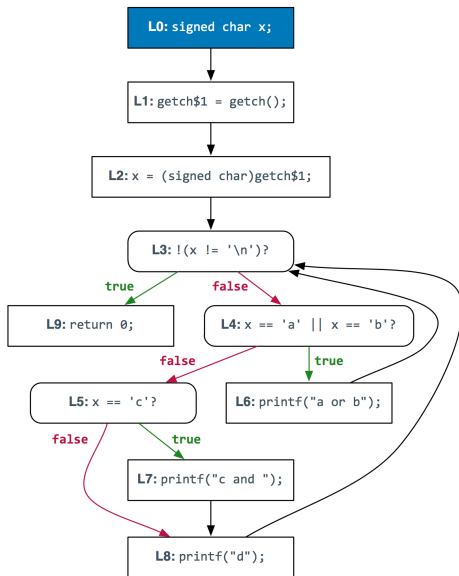


# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
  char x;
  x = getch();
  while (x != '\n') {
    switch(x) {
      case 'a':
      case 'b':
        printf("a_or_b");
        break ;
      case 'c':
        printf("c_and_");
        /* fall-through */
      default:
        printf("d");
        break;
    }
  }
  return 0;
}

```

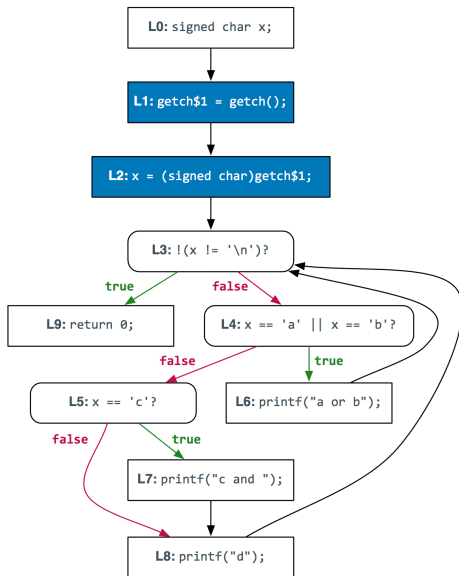


# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
    char x;
    x = getch();
    while (x != '\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a_or_b");
                break ;
            case 'c':
                printf("c_and_");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```

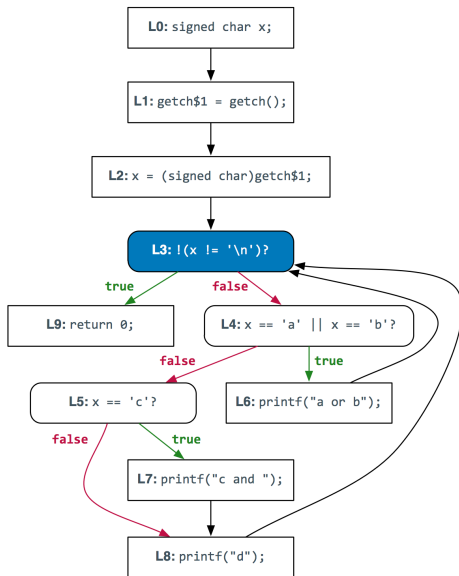


# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
    char x;
    x = getch();
    while (x!='\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a_or_b");
                break ;
            case 'c':
                printf("c_and_");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```

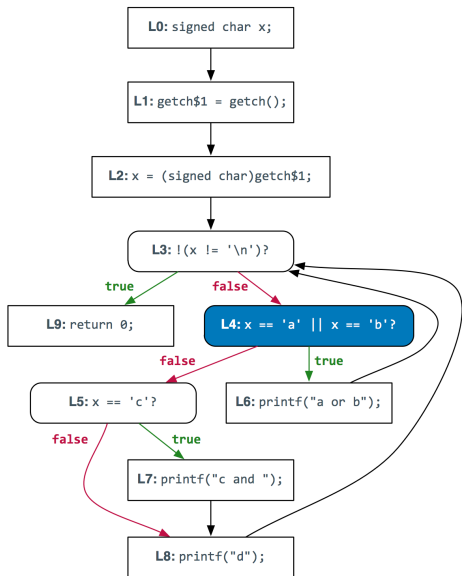


# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
    char x;
    x = getch();
    while (x != '\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a_or_b");
                break ;
            case 'c':
                printf("c_and_");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```

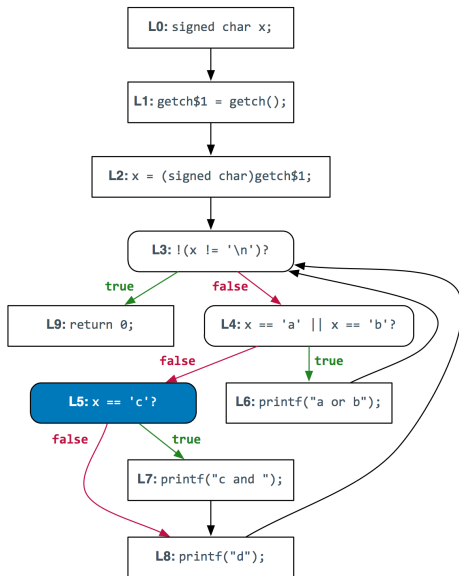


# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
    char x;
    x = getch();
    while (x != '\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a_or_b");
                break ;
            case 'c':
                printf("c_and_");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```

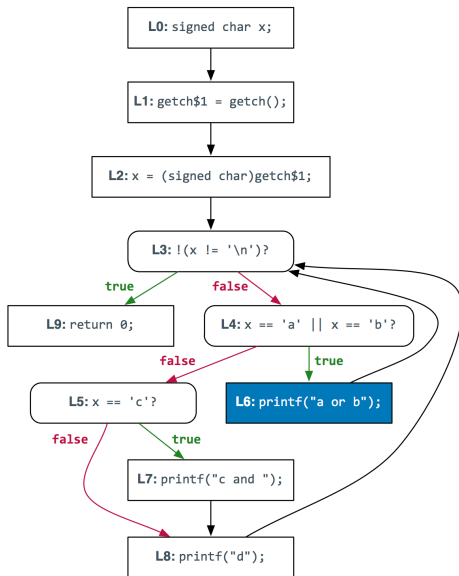


# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
    char x;
    x = getch();
    while (x != '\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a or b");
                break ;
            case 'c':
                printf("c and ");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```

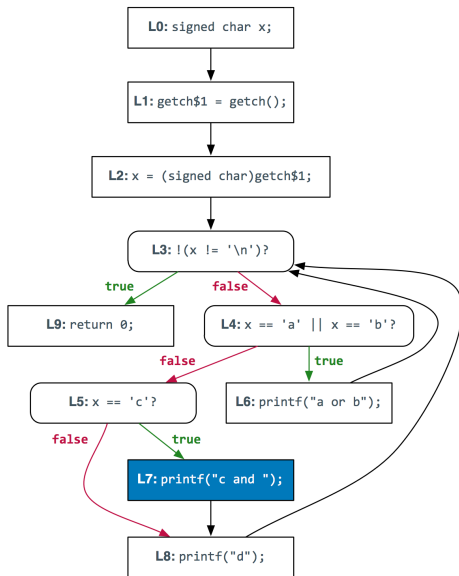


# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
    char x;
    x = getch();
    while (x != '\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a_or_b");
                break;
            case 'c':
                printf("c and ");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```

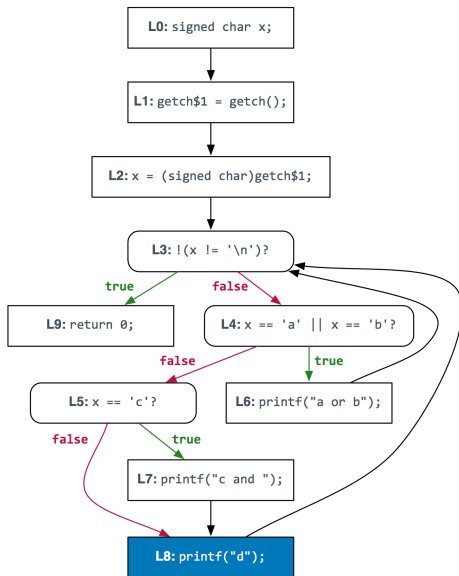


# Ein formales Softwaremodell — Beispiel

```

int main( void ) {
    char x;
    x = getch();
    while (x != '\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a_or_b");
                break ;
            case 'c':
                printf("c_and_");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```

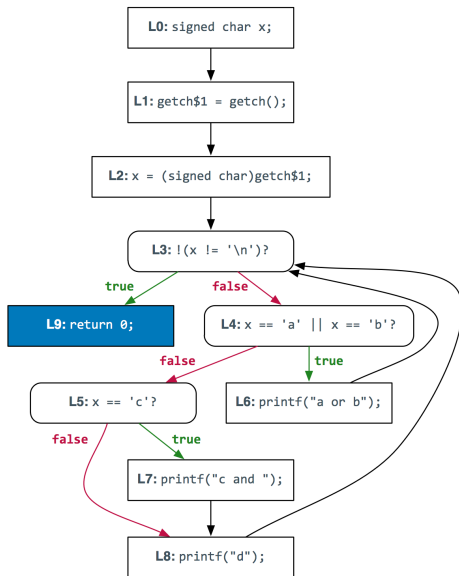


# Ein formales Softwaremodell — Beispiel

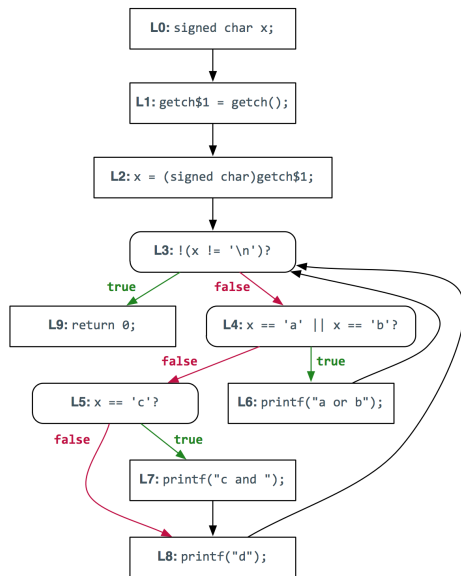
```

int main( void ) {
    char x;
    x = getch();
    while (x != '\n') {
        switch(x) {
            case 'a':
            case 'b':
                printf("a_or_b");
                break ;
            case 'c':
                printf("c_and_");
                /* fall-through */
            default:
                printf("d");
                break;
        }
    }
    return 0;
}

```



# Ein formales Softwaremodell — Kodierungen



## Übergangsrelation an $L_2$ :

$$\begin{aligned}
 R_{L_2}(s, s') &\iff s'.l = L_3 \\
 &\wedge \forall v \neq x : s'.v = s.v \\
 &\wedge s'.x = TC(s.getch\$1) \\
 &\wedge s'.\Gamma = s.\Gamma
 \end{aligned}$$

- TC bildet integer auf char ab (modulo 256 auf den meisten Architekturen)

## Übergangsrelation an $L_3$ :

$$\begin{aligned}
 R_{L_3}(s, s') &\iff \\
 s'.l &= \begin{cases} L_9 & \text{if } s.x = '\backslash n' \\ L_4 & \text{otherwise} \end{cases} \\
 &\wedge \forall v \in V : s'.v = s.v \\
 &\wedge s'.\Gamma = s.\Gamma
 \end{aligned}$$

# Gegenbeispiel

## Notationen

Wir schreiben

- $s \rightarrow t$  für  $R(s, t)$  und
- $s \rightsquigarrow t$  für  $R^*(s, t)$  (reflexiv-transitive Hülle).

**Was uns interessiert?** Können bestimmte „schlechte“ Programmezustände (*error locations*) erreicht werden? (*Reachability Problem*)

## Gegenbeispiel (*Counterexample*)

- $\mathcal{L}_E \subset \mathcal{L}$ : Menge der Error Locations
- $s \in S$  mit  $s.l \in \mathcal{L}_E$ : Fehlerhafter Zustand (error state)

Ein Gegenbeispiel erhält man durch Lösung eines Erreichbarkeitsproblems als Sequenz von Zuständen  $s_0, s_1, \dots, s_n$  mit  $s_i \in S$ ,  $s_0 \in S_0$ ,  $s_n.l \in \mathcal{L}_E$  und  $s_j \rightarrow s_{j+1}$  für  $0 \leq j < n$ .

# Fahrplan für heute: Wo stehen wir?

## ① Einführung Software-Verifikation ✓

- SW-Verifikation: Korrektheit eines Programms mit mathematischen Methoden beweisen
- Motivation: Immer mehr sicherheitskritische Software

## ② Ein formales Modell für Software ✓

- Formalisierung eines Programms als Transition System
- Zustand speichert: Stand des Program Counter, Variablenbelegungen, Ausführungsstack
- Gegenbeispiel: Pfad zu einem Fehler

## ③ Bit-Vektoren

- Was sind Bit-Vektoren?
- Wie kann man Bit-Vektor Gleichungen entscheiden?

## ④ Bounded Model Checking (BMC)

- Wie funktioniert BMC?
- Beispiele für BMC?
- Und in der echten Welt?

# Bit-Vektoren — 1

## Bit Vektoren

Ein Bit-Vektor der Länge  $n$  ist eine Sequenz von  $n$  Booleschen Variablen.  $b[i]$  notiert das  $i$ -te Bit von Vektor  $b$  (von links, beginnend mit 0).

## Beispiel

- $\langle 00001111 \rangle$ , Bit-Vektor der Länge 8,  $b[4] = 1$

## Grammatik für gültige BV Formeln

```

formula : formula  $\wedge$  formula |  $\neg$ formula | (formula) | atom
atom    : term rel term | Boolean-Identifizier
rel      : < | =
term     : term op term | identifizier |  $\sim$  term | constant |
          atom?term : term
op       : + | - |  $\cdot$  | / | << | >> | & | || |  $\oplus$  |  $\circ$ 
  
```

# Entscheidungsverfahren für Bit-Vektoren

Durch schnelle SAT-Solver begünstigt: **Bit Blasting**

## Bit Blasting

Eingabeformel  $\varphi$  in Bit-Vektor Arithmetik, Ausgabe: Erfüllbarkeitsäquivalente Formel in Aussagenlogik  $\varphi_f$

- $A(\varphi)$  die Menge aller Atome in  $\varphi$
- ①  $\varphi_{sk}$ : Originalformel, in der jedes Atom  $a \in A(\varphi)$  durch eine neue Boolesche Variable  $\mu(a)$  ersetzt ist (Aussagenlogisches Skelett),  $\varphi_f = \varphi_{sk}$
- ② Jeder Bit-Vektor Term  $t$  wird durch einen neuen Vektor  $\mu(t)$  von Booleschen Variablen ersetzt
- ③ Constraints für  $\mu(a)$  und  $\mu(t)$  werden je nach Art des Atoms oder des zu Grunde liegenden Operators generiert. Z.B. für  $t = a|b$  mit jeweils  $n$  Bits:

$$c_t = \bigwedge_{i=0}^{n-1} ((a[i] \vee b[i]) \Leftrightarrow \mu(t)[i])$$

- ④ Füge für jedes  $t$   $c_t$  zu  $\varphi_f$  hinzu

# Bit Blasting — Beispiel

## Beispiel

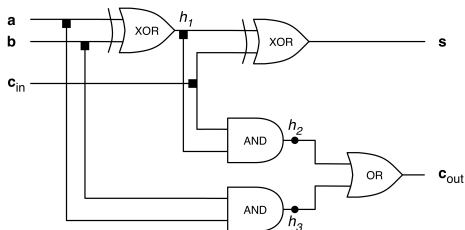
- 32 Bit
- Zeile im Programm:  $x = a \ \& \ b; \ y = x;$
- Bit-Vektor Formel:  $(x = a \ \& \ b) \wedge (y = x)$

### Bit-Blasting:

- ①  $\varphi_{sk} = \alpha \wedge \beta$
- ②  $c_1 = \bigwedge_{i=0}^{31} (a[i] \wedge b[i]) \Leftrightarrow \gamma[i]$  (Constraint für  $a \ \& \ b$ )
- ③  $c_2 = \bigwedge_{i=0}^{31} x[i] \Leftrightarrow \gamma[i]$  (Constraint für  $x = a \ \& \ b$ )
- ④  $c_3 = \bigwedge_{i=0}^{31} y[i] \Leftrightarrow x[i]$  (Constraint für  $y = x$ )
- ⑤  $\varphi_f = \varphi_{sk} \wedge c_1 \wedge c_2 \wedge c_3$

# Bit-Blasting — Arithmetische Operationen

Arithmetische Operationen werden mit Kodierungen von Schaltkreisen repräsentiert



## Beispiel

Addition von zwei Bit-Vektoren  $\langle a_0 a_1 a_2 a_3 \rangle$  und  $\langle b_0 b_1 b_2 b_3 \rangle$  ist ein neuer Bit-Vektor  $\langle s_0 s_1 s_2 s_3 \rangle$  mit

- $s_0 \Leftrightarrow (a_0 \oplus b_0) \oplus c_1$
- $s_1 \Leftrightarrow (a_1 \oplus b_1) \oplus c_2, c_1 \Leftrightarrow (a_1 \wedge b_1) \vee (c_2 \wedge (a_1 \oplus b_1))$
- $s_2 \Leftrightarrow (a_2 \oplus b_2) \oplus c_3, c_2 \Leftrightarrow (a_2 \wedge b_2) \vee (c_3 \wedge (a_2 \oplus b_2))$
- $s_3 \Leftrightarrow a_3 \oplus b_3, c_3 \Leftrightarrow a_3 \wedge b_3$

# Fahrplan für heute: Wo stehen wir?

## ① Einführung Software Verifikation ✓

- SW-Verifikation: Korrektheit eines Programms mit mathematischen Methoden beweisen
- Motivation: Immer mehr sicherheitskritische Software

## ② Ein formales Modell für Software ✓

- Formalisierung eines Programms als Transition System
- Zustand speichert: Stand des Program Counter, Variablenbelegungen, Ausführungsstack
- Gegenbeispiel: Pfad zu einem Fehler

## ③ Bit-Vektoren ✓

- Bit-Vektor: Sequenz von Booleschen Variablen
- Entscheiden von Bit-Vektor Gleichungen mit Bit-Blasting und SAT-Solvern

## ④ Bounded Model Checking (BMC)

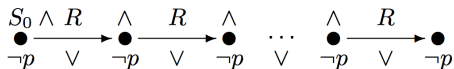
- Wie funktioniert BMC?
- Beispiele für BMC?
- Und in der echten Welt?

# Bounded Model Checking

- **Idee:** Wickle das zu verifizierende Design  $k$ -mal ab und teste die Verifikationseigenschaft dabei
- Wenn die Formel erfüllbar ist, gibt es ein Gegenbeispiel der Länge  $k$

## Bounded Model Checking (BMC)

- Übergangsrelation  $R$
  - Menge der Anfangszustände  $S_0$
  - zu verifizierende Eigenschaft  $p$
- 1 Kopiere die Übergangsrelation  $k$  mal
  - 2 Benenne die Variablen in jeder Kopie so um, dass der Folgezustand von Schritt  $n$  der aktuelle Zustand von Schritt  $n + 1$  ist
  - 3 Der aktuelle Zustand des ersten Schritts muss in  $S_0$  sein
  - 4 An einem der Zustände muss  $\neg p$  gelten



# Abwickeln des gesamten Programmes

- Betrachte gesamtes Programm als eine Übergangsrelation (keine Partitionen)
- Repräsentiere den Program Counter  $\ell$  als Bit-Vektor mit Länge  $\lceil \log_2 |\mathcal{L}| \rceil$
- *Optimierungsmöglichkeit: Führe Instruktionen, die einen Block bilden zu einer Program Location zusammen*

## Die resultierende Formel

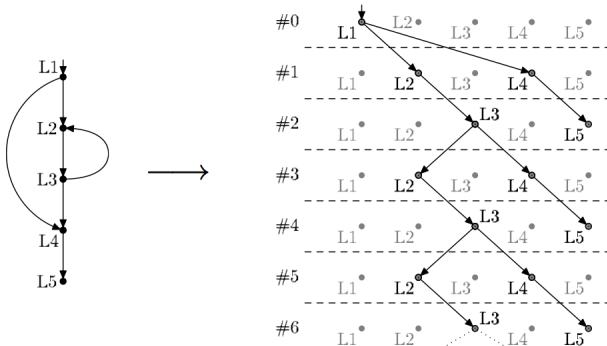
- $s_i$  Zustand im Schritt  $i$  der Abwicklung

$$\varphi = \underbrace{S_0(s_0)}_{s_0 \text{ ist Startzustand}} \wedge \underbrace{\bigwedge_{i=0}^{k-1} R(s_i, s_{i+1})}_{\text{Es gibt einen Übergang}} \wedge \underbrace{\bigvee_{i=0}^k \bigvee_{l \in \mathcal{L}_E} s_i.l = l}_{\text{Ein Fehlerzustand wird erreicht}}$$

- $\varphi$  **erfüllbar**: Gegenbeispiel kann konstruiert werden (aus  $s_0, \dots, s_k$ )
- $\varphi$  **unerfüllbar**: Es gibt kein Gegenbeispiel, das in  $k$  oder weniger Schritten erreichbar ist

# Optimierungsmöglichkeiten

- **Problem:**  $k$ -faches Abwickeln des gesamten Programms führt schnell zu sehr großen Formeln
- **Lösungsidee:** Kopiere nicht gesamt  $R$   $k$ -mal sondern führe eine Analyse des Kontrollflussgraphen durch

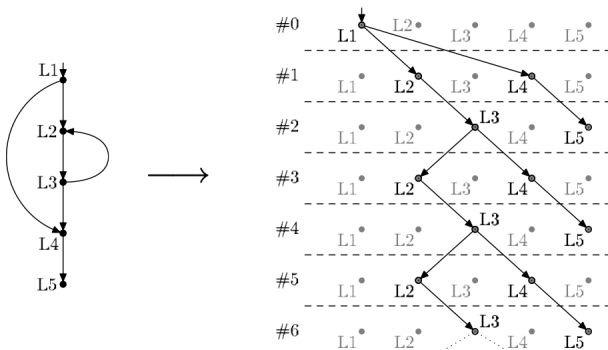


# Einzelnes Abwickeln von Schleifen — 1

**Aber:** Es wird immer noch zu viel kopiert:

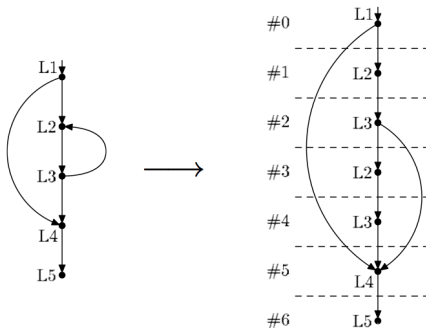
- Z.B. Kann  $L4$  in einem Programmablauf nur einmal erreicht werden, jedoch haben wir  $k/2$  Kopien davon

**Lösungsidee:** Kopiere nicht das gesamte Programm  $k$  mal, sondern wickle nur jede Schleife  $k$  mal ab



# Einzelnes Abwickeln von Schleifen — 2

Abwicklung der Schleife mit  $k = 2$



- Für jede Schleife kann eine eigene Grenze  $k_i$  verwaltet werden
- Auch geschachtelte Schleifen können verarbeitet werden

## Einzelnes Abwickeln von Schleifen — 3

- $R$  wird nun nicht mehr einfach kopiert
- Der originale Kontrollflussgraph des Programms wird verändert
- Das  $k$ -fache Abwickeln einer Schleife bedeutet  $k$ -faches Kopieren des Schleifenkörpers
- Jede Abwicklung wird mit einer `if` Abfrage umgeben falls die Schleife frühzeitig terminiert

```

while(x)
  BODY;
  →
  if(x) {
    BODY;
    while(x)
      BODY;
  }
  →
  if(x) {
    BODY;
    if(x)
      BODY;
    else
      assume( false );
  }
  
```

- `assume(false)` wird benutzt, um festzustellen, dass die Grenze  $k$  zu klein war (und nicht fälschlicherweise kein Gegenbeispiel ausgegeben wird)

# Vom Programm zur Formel — 1

Wie gehen wir mit anderen Programmkonstrukten um?

## Schritt 1

- Präprozessor auf dem Code ausführen (z.B. `#define` entpacken)
- `break` und `continue` durch passende `goto`-Statements ersetzen
- `for`- und `do-while`-Schleifen durch äquivalente `while` Schleifen ersetzen

## Beispiel (for-Schleife)

```
for (int i=0; i<3; i++) {  
    a[i] = i*i;  
}
```

wird konvertiert zu:

```
int i=0;  
while (i < 3) {  
    a[i] = i*i;  
    i++;  
}
```

# Vom Programm zur Formel — 2

## Schritt 2

Wie bereits gesehen:

- Ersetze `while` durch `if`
- Kopiere Schleife maximal  $k$  mal (Bound  $k$ ) hintereinander
- Prüfe Bound durch nachfolgende *unwinding assertion*

## Beispiel (Loop unwinding mit Bound $k = 2$ )

```
int i = 0;
while (i < 3) {
    a[i] = i*i;
    i++;
}
```

```
int i = 0;
if (i < 3) { // Kopie 1
    a[i] = i*i;
    i++;
}
if (i < 3) { // Kopie 2
    a[i] = i*i;
    i++;
}
assert !(i < 3) // unwinding assertion
```

# Vom Programm zur Formel — 3

## Schritt 3

Funktionsaufrufe werden ähnlich den `while`-Schleifen abgewickelt

- Funktionsaufrufe expandieren (Aufruf durch Funktionsinhalt ersetzen)
- Rekursive Funktionen  $k$  mal abwickeln + Assertion, dass Rekursionstiefe nicht tiefer als  $k$  sein kann
- `return` Statements ersetzen durch `goto` zum Ende der Funktion

## Beispiel (Function unwinding)

```
int max(int a, int b) {
    if (a > b)
        return a;
    else
        return b;
}
```

```
main() {
    int max12 = max(1,2);
}
```

```
main() {
    int temp_val;
    if (1 > 2)
        temp_val = 1;
    else
        temp_val = 2;
    int max12 = temp_val;
}
```

## Vom Programm zur Formel — 4

Programm besteht nun nur noch aus:

- (möglicherweise verschachtelten) `if-then-else` Blöcken
- Zuweisungen
- Assertions
- `goto`-Statements mit zugehörigen Labels

### Problem: Auflösung der zeitlichen Reihenfolge

- Anweisungssequenz `x=0; x=1;` kann nicht in die Formel  $(x = 0) \wedge (x = 1)$  übersetzt werden.
- Was im Programm nacheinander geschieht, das geschieht in der Formel gleichzeitig

### Schritt 4

Programm wird in Single Static Assignment Form gebracht

- $x_i$  bezeichnet den  $i$ -ten Wertezustand der Variable  $x$ .
- Sequenz `x=0; x=1;` wird zur Formel  $(x_i = 0) \wedge (x_{i+1} = 1)$

# Single Static Assignment Form — 1

## Single Static Assignment Form

Spezielle Darstellungsform von Programmen: Jede Variable wird genau einmal zugewiesen. Vorhandene Variablen werden in verschiedene Versionen aufgespalten.

- Kommt aus dem Compilerdesign, erlaubt dort Vereinfachungen

## Beispiel (Vereinfachungen - Fortsetzung)

```
int x = 1;  
x = 2;  
int y = x;
```

Konvertierung in SSA:

```
x1 = 1  
x2 = 2  
y1 = x2
```

Offensichtlich (auch für den Compiler):

- $x_1$  wird nie verwendet (kommt nie auf einer rechten Seite vor)
- Erste Zuweisung überflüssig

# Single Static Assignment Form — 2

## Übersetzen von if-then-else in SSA

```

if (x == 1) {
    y = 5;
} else {
    y = 42;
}

```

Übersetzung in SSA:

$$y_1 = (x == 1) ? 5 : 42$$

```

y = 3;
if (x == 1) {
    y = 5;
}

```

Übersetzung in SSA:

$$y_1 = 3$$

$$y_2 = (x == 1) ? 5 : y_1$$

# Single Static Assignment Form — 3

## Beispiel (Programm in SSA bringen)

<pre> x = x + y; <b>if</b> (x != 1)     x = 2; <b>else</b>     x++;  <b>assert</b> (x &lt;= 3);         </pre>	<pre> x_1 = x_0 + y_0;  x_2 = 2;  x_3 = x_1 + 1;  x_4 = (x_1 != 1) ? x_2 : x_3; <b>assert</b> (x_4 &lt;= 3);         </pre>
----------------------------------------------------------------------------------------------------------------	-----------------------------------------------------------------------------------------------------------------------------

## Beispiel (SSA zu Bitvektorgleichung)

```

C := x1 = x0 + y0 ∧
x2 = 2 ∧
x3 = x1 + 1 ∧
x4 = (x1 != 1) ? x2 : x3
P := x4 ≤ 3
    
```

letzter Schritt: Bit-Blasting und Formel  $C \wedge \neg P$  in CNF konvertieren

# Das komplette Beispiel — 1

## Beispiel (C Programm)

```
x = 3;
if (x < 4) {
    y = 2;
} else {
    y = 5;
}
assert (y < 4)
```

## Beispiel (Programm in SSA)

```
x_0 = 3;
y_0 = 2;
y_1 = 5;
y_2 = (x_0 < 4) ? y_0 : y_1;
assert (y_2 < 4)
```

# Das komplette Beispiel — 2

## Beispiel (SSA in Bitvektorgleichung)

$C := x_0 = 3 \wedge$   
 $y_0 = 2 \wedge$   
 $y_1 = 5 \wedge$   
 $y_2 = (x_0 < 4) ? y_0 : y_1$   
 $P := y_2 < 4$

Expandieren der Bitvektoren für eine 32-Bit Architektur

- Jede Variable  $x$  wird expandiert zu 32 Variablen  $x[31] \dots x[0]$
- $x_0 = 3$  wird zu  $x_0[0] \wedge x_0[1] \wedge \neg x_0[2] \wedge \dots \wedge \neg x_0[31]$
- $y_0 = 2$  wird zu  $\neg y_0[0] \wedge y_0[1] \wedge \neg y_0[2] \wedge \dots \wedge \neg y_0[31]$
- $y_1 = 5$  wird zu  $y_1[0] \wedge \neg y_1[1] \wedge y_1[2] \wedge \neg y_1[3] \wedge \dots \wedge \neg y_1[31]$
- $x_0 < 4$  wird zu  $x_0[31] \vee (\neg x_0[31] \wedge \dots \wedge \neg x_0[2])$
- $a = b ? c : d$  wird zu  $(b \wedge (a = c)) \vee (\neg b \wedge (a = d))$
- $y_2 = (x_0 < 4) ? y_0 : y_1$  wird zu  
 $((x_0[31] \vee (\neg x_0[31] \wedge \dots \wedge \neg x_0[2])) \wedge \neg y_2[0] \wedge y_2[1] \wedge \neg y_2[2] \wedge \dots \wedge \neg y_2[31]) \vee$   
 $(\neg(x_0[31] \vee (\neg x_0[31] \wedge \dots \wedge \neg x_0[2])) \wedge y_2[0] \wedge \neg y_2[1] \wedge y_2[2] \wedge \neg y_2[3] \wedge \dots \wedge \neg y_2[31])$
- $y_2 < 4$  wird zu  $y_2[31] \vee (\neg y_2[31] \wedge \dots \wedge \neg y_2[2])$

## Das komplette Beispiel — 3

- $x_0 = 3$  wird zu  $x_0[0] \wedge x_0[1] \wedge \neg x_0[2] \wedge \dots \wedge \neg x_0[31]$
- $y_2 = (x_0 < 4)?y_0 : y_1$  wird zu  
 $((x_0[31] \vee (\neg x_0[31] \wedge \dots \wedge \neg x_0[2])) \wedge \neg y_2[0] \wedge y_2[1] \wedge \neg y_2[2] \wedge \dots \wedge \neg y_2[31]) \vee$   
 $(\neg(x_0[31] \vee (\neg x_0[31] \wedge \dots \wedge \neg x_0[2])) \wedge y_2[0] \wedge \neg y_2[1] \wedge y_2[2] \wedge \neg y_2[3] \wedge \dots \wedge \neg y_2[31])$
- $y_2 < 4$  wird zu  $y_2[31] \vee (\neg y_2[31] \wedge \dots \wedge \neg y_2[2])$

Codiere  $C \wedge \neg P$

### Beispiel (Endformel)

$$\begin{aligned} \varphi := & (x_0[0] \wedge x_0[1] \wedge \neg x_0[2] \wedge \dots \wedge \neg x_0[31]) \wedge \\ & (((x_0[31] \vee (\neg x_0[31] \wedge \dots \wedge \neg x_0[2])) \wedge \neg y_2[0] \wedge y_2[1] \wedge \neg y_2[2] \wedge \dots \wedge \neg y_2[31]) \vee \\ & (\neg(x_0[31] \vee (\neg x_0[31] \wedge \dots \wedge \neg x_0[2])) \wedge y_2[0] \wedge \neg y_2[1] \wedge y_2[2] \wedge \neg y_2[3] \wedge \dots \wedge \neg y_2[31])) \wedge \\ & \neg(y_2[31] \vee (\neg y_2[31] \wedge \dots \wedge \neg y_2[2])) \end{aligned}$$

- Ist  $\varphi$  erfüllbar, so gibt es eine Belegung, die Assertion  $P$  im Programm  $C$  verletzt (wegen  $\neg P$ ), d.h. die Verifikation schlägt fehl
- Die Belegung stellt auch gleichzeitig einen Pfad zu einem Fehler dar (Gegenbeispiel)
- Ist  $\varphi$  unerfüllbar, so gibt es keinen Pfad zu einer Verletzung der Assertion, und daher ist die Verifikation erfolgreich

# Implementierungen von BMC

## CBMC

Bounded Model Checker für C Programme<sup>a</sup>

- emuliert eine große Anzahl an Architekturen
- Little-Endian und Big-Endian Speichermodelle
- Wickelt Schleifen wie hier beschrieben ab
- Benutzt Bit-Blasting und MiniSAT um die Formel zu entscheiden
- Kann Formeln im Dimacs Format ausgeben
- Unterstützt auch andere Ausgabeformate (z.B. SMT)
- Unterstützt (in Ansätzen) auch C++, SpecC und SystemC

---

<sup>a</sup><http://www.cprover.org/cbmc/>

## FYI:

- An unserem Arbeitsbereich wird viel mit CBMC gearbeitet
- Erfolgreiche Diplomarbeiten im Bereich Linux Treiberverifikation oder Verifikation von hardwarenahem C++ Code

# Fahrplan für heute: Das war's!

## ① Einführung Software Verifikation ✓

- SW-Verifikation: Korrektheit eines Programms mit mathematischen Methoden beweisen
- Motivation: Immer mehr sicherheitskritische Software

## ② Ein formales Modell für Software ✓

- Formalisierung eines Programms als Transition System
- Zustand speichert: Stand des Program Counter, Variablenbelegungen, Ausführungsstack
- Gegenbeispiel: Pfad zu einem Fehler

## ③ Bit-Vektoren ✓

- Bit-Vektor: Sequenz von Booleschen Variablen
- Entscheiden von Bit-Vektor Gleichungen mit Bit-Blasting und SAT-Solvern

## ④ Bounded Model Checking (BMC) ✓

- BMC:  $k$ -faches Abwickeln von Schleifen und Rekursion, SSA, Bit-Blasting, SAT-Solver
- CBMC für C Programme